



УДК 519

© 2014 г. **О.С. Амосов**, д-р техн. наук
(Комсомольский-на-Амуре государственный технический университет),
С.Г. Баена
(Санкт-Петербургский национальный исследовательский университет
информационных технологий, механики и оптики)

БЫСТРОДЕЙСТВУЮЩИЕ ЧИСЛЕННЫЕ НЕЙРОСЕТЕВЫЕ И НЕЧЕТКИЕ МЕТОДЫ СТОХАСТИЧЕСКОГО ОЦЕНИВАНИЯ СОСТОЯНИЯ ДИНАМИЧЕСКИХ СИСТЕМ*

Рассмотрены быстродействующие численные методы стохастической аппроксимации для решения задачи оценивания состояния динамических систем с использованием декомпозиции. Декомпозиционные структуры реализуются как фильтры с растущей памятью на основе искусственных нейронных сетей, нечетких систем и их комбинаций. На примере решения нелинейной задачи оценивания показано, что с помощью декомпозиционных синтетических систем достигается высокая точность оценивания и при этом скорость обучения этих систем значительно выше скорости обучения исходных систем без декомпозиции. Получены закономерности увеличения быстродействия при использовании декомпозиции.

Ключевые слова: оценивание, синтетическая система, декомпозиция, искусственная нейронная сеть, нелинейная нейронная сеть прямого распространения, нейронная сеть с радиальными базисными функциями, нечеткая система, ANFIS.

Введение

Задача нелинейного оценивания случайных процессов является фундаментальной и до сих пор требует поиска эффективных алгоритмов. Для решения задачи байесовского оптимального нелинейного оценивания состояния динамической системы, помимо традиционных методов [1], используются численные методы стохастической аппроксимации на основе искусственных нейронных сетей (НС) [2 – 4], систем нечеткой логики (НчС) [5]. Проведенный анализ литературы [2 – 7] показал, что до сих пор остаются непроработанными такие вопросы как проектирование архитектур нейронных сетей и нечетких систем для задач оценивания; значительное снижение вычислительных затрат при настройке алгоритмов оценивания; эффективность применения различных алгоритмов обучения и их влияние на процедуру оценивания.

* Работа проводилась при поддержке гранта РФФИ 15-08-08593а.

Поэтому существует необходимость поиска эффективных субоптимальных алгоритмов, пригодных для работы в режиме реального времени. При этом необходимо спроектировать такие субоптимальные алгоритмы, которые, с одной стороны, представляют собой экономичные в вычислительном отношении процедуры, а с другой, – обеспечивают значение критерия оптимизации, близкого к значению, достигаемому при использовании оптимальных оценок. Для этого нами были предложены в [8 – 11] декомпозиционные синтетические структуры, реализующиеся как фильтры с растущей памятью на основе искусственных нейронных сетей, нечетких систем, вейвлетов и их комбинаций.

Целью данной работы является анализ быстродействия субоптимальных нейросетевых и нечетких систем оценивания, основанных на использовании принципов декомпозиции. В ходе исследования были получены закономерности увеличения быстродействия при использовании декомпозиции.

Постановка нелинейной задачи оценивания состояния динамической системы

Структурная схема системы оценивания представлена на рис. 1, где S – динамическая система с n -мерным вектором состояния $\{x_i, i \in I\}$, $I = \{i : i = 0, 1, \dots\}$; M – измерительная система с m -мерным вектором измерения $\{y_\lambda, \lambda \in \Lambda\}$, $\Lambda = \{\lambda : \lambda = 1, 2, \dots, k\}$; E – система оценивания с вектором оценок $\tilde{x}_{i/k}$. Задача оценки представляет собой задачу определения функции φ_i некоторым рациональным, обоснованным способом [12]: $\tilde{x}_{i/k} = \varphi_i[y_\lambda, \lambda = 1, 2, \dots, k]$.




Рис. 1. Структурная схема системы оценивания.

В зависимости от расположения момента формирования оценки относительно отрезка наблюдения оценивание делится на фильтрацию ($i = k$), экстраполяцию ($i > k$) и интерполяцию ($i < k$) [12]. В дальнейшем изложении нами рассматривается фильтрация, когда $i = k$.

Постановка задачи оценивания в развернутом виде дана в работах [1 – 4, 8 – 11, 13], поэтому ограничимся ее кратким изложением.

Необходимо оценить n -мерный вектор $x = [x_1 \dots x_n]^T$ по m -мерным измерениям $y = [y_1 \dots y_m]^T$. Заметим, что в некоторых случаях измерения могут быть записаны следующим образом: $y = s(x) + v$, где $s(x) = [s_1(x) \dots s_m(x)]^T$ – m -мерная в общем случае нелинейная вектор-функция векторного аргумента, которая обычно считается известной; $v = [v_1 \dots v_m]^T$ – случайный вектор, передающий наличие ошибок измерения [2, 4, 5].

Следует отметить, что к решению указанной задачи может быть сведен широкий круг задач обработки навигационной информации [1]. Кроме того, эта постановка задачи уместна для динамических объектов управления с запаздыванием по состоянию, когда параметры объекта являются неизвестными постоянными или медленно меняющимися во времени параметрами [14].

Решение нелинейной задачи оценивания

Несмотря на разные теоретические положения, лежащие в основе описания искусственных нейронных сетей, нечетких систем и вейвлетов, которые могут применяться как отдельно, так и совместно, их объединяет возможность практического применения при реализации алгоритмов оценивания на основе класса нелинейных параметрически заданных функций [2, 5, 9]. Нами в работах [9 – 11] было введено понятие "синтетические системы" (СС), под которыми понимаются перечисленные выше конструкции, и был предложен единый вычислительный метод для решения байесовской задачи оценивания состояния динамических процессов с его реализацией на основе синтетических систем. Численная процедура для предложенного вычислительного метода представлена на рис. 2.

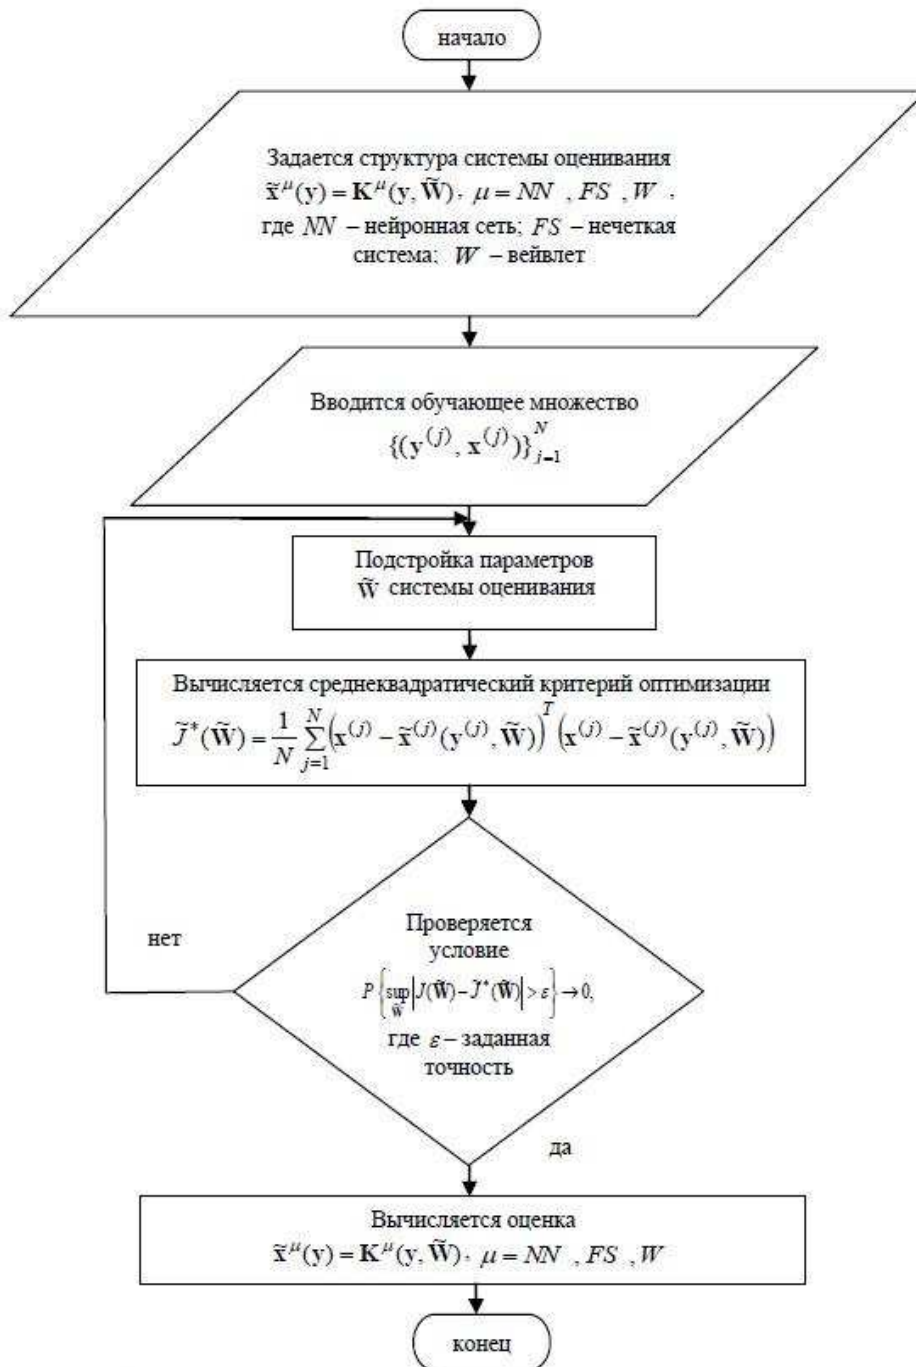


Рис. 2. Блок-схема алгоритма вычислительного метода оценивания.

Пример, иллюстрирующий решение задач оценивания

Данные результаты моделирования являются подтверждением теоретических положений, изложенных в работах [8 – 11, 13].

В качестве примера, иллюстрирующего решение задач оценивания с использованием численных нейросетевых и нечетких методов стохастического оценивания состояния динамических систем, возьмем задачу, которая была решена в работе [2] для искусственных линейных и нелинейных нейронных сетей прямого распространения в сравнении с оптимальным нелинейным оцениванием.

Пример. Необходимо оценить равномерно распределенную на интервале $[0, b]$ случайную величину x по зашумленным измерениям вида $y_i = x + v_i$, $i = \overline{1, l}$, в которых ошибки измерений v_i , $i = \overline{1, l}$ представляют собой независимые друг от друга и от x центрированные случайные величины, равномерно распределенные в интервале $[-a/2, a/2]$. В этом примере $\mathbf{x} \equiv x$, $\mathbf{y} \equiv [y_1 \dots y_l]^T$, $\mathbf{v} = [v_1 \dots v_l]^T$. Необходимо отметить, что апостериорная функция плотности распределения вероятностей $f(\mathbf{x}/\mathbf{y})$ здесь не является гауссовской, так как x и v_i , $i = \overline{1, l}$ – равномерно распределенные случайные переменные. При моделировании принималось: $a = b = 1$, $i = \overline{1, l}$, $l = 10$.

Для сравнения результатов решений с помощью СС и их декомпозиции были выделены такие характеристики: точность оценивания; время, затраченное на обучение системы (быстродействие); время работы системы в режиме реального времени (штатный режим).

Декомпозиционные структуры реализуются как фильтры с растущей памятью на основе искусственных нейронных сетей, нечетких систем и их комбинаций. Под фильтрами с растущей памятью принято понимать фильтры, в которых оценка вырабатывается по всей предыстории входного процесса, а число измерений, участвующих в формировании оценки, с увеличением i неограниченно возрастает (рис. 3а).

Для улучшения быстродействия работы СС была применена самая простая рекуррентная декомпозиционная схема оценивания в виде каскадного соединения с двумя входами и одним выходом, где на вход поступает текущее измерение и оценка, полученная на предыдущем шаге (рис. 3б). При этом все возможные декомпозиционные схемы будут находиться между указанными на рис. 3 граничными фильтрами с растущей памятью.

Ниже представлены реализации численных методов стохастической аппроксимации с использованием нелинейной нейронной сети прямого распространения – Feed Forward Neural Network (FFNN), нейронной сети с радиальными базисными функциями – Radial Basis Function Network (RBFN) и нечеткой системы – Fuzzy System (FS). Сравнение точности оценивания проводится с решением для оптимального нелинейного оценивания, рассмотренным в работе [2]. Были получены и исследованы среднеквадратичные отклонения (СКО) ошибок оценивания: выборочные СКО ошибок $\tilde{\sigma}_i$ для нелинейных оптимальных оценок и выбороч-

ные СКО ошибок для нейросетевых и нечетких оценок $\tilde{\sigma}_i^\eta$, $\eta = FFNN, FFNN^d, RBFN, RBFN^d, FS, FS^d$; d означает декомпозиционную структуру. Выборочные СКО были рассчитаны следующим образом:

$$\tilde{\sigma}_i \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{(j)})^2}, e_i^{(j)} = x^{(j)} - \tilde{x}^{(j)}(\mathbf{y}^{(j)}), \quad (1)$$

$$\tilde{\sigma}_i^\eta \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{\eta(j)})^2}, e_i^{\eta(j)} = x^{(j)} - \tilde{x}^{\eta(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}). \quad (2)$$

Для получения приемлемых результатов по точности оценивания число реализаций N для обучения синтетических систем было выбрано равным 20000. После обучения осуществлялась проверка. С этой целью дополнительно моделировалось еще $L = 3000$ пар реализаций $\mathbf{y}^{(j)}, x^{(j)}$ для разных $i = \overline{1, l}$, $l = 10$.

Моделирование систем проводилось в среде MatLab.




Рис. 3. СС: а – исходная; б – с декомпозицией.

Моделирование нейронной сети прямого распространения выполнялось на компьютере Intel (R) Core (TM) i5-4670 CPU@3.40GHz, 3.40GHz, 8.0 ГБ ОЗУ, 64-разрядная операционная система, процессор x64.

Для настройки параметров **FFNN** применялись алгоритмы обучения Левенберга – Маркварда, Levenberg – Marquardt (LM) и регуляризация Байеса – Bayesian Regulation (BR). Ниже приведены полученные путем моделирования результаты, соответствующие оптимальному нелинейному и нейросетевым алгоритмам. Сравнительные результаты решения задачи оценивания с помощью FFNN, построенных по схемам на рис. 3а и б, отображены на графиках. На рис. 4 для алгоритма обучения LM, на рис. 5 – для алгоритма обучения BR.

В качестве исходной нелинейной сети FFN, соответствующей рис. 3а, выбрана двухслойная НС с последовательными связями с i входами, с $q = 20$ нейронами в скрытом слое и одним нейроном в выходном слое.

На рис. 4а и б, 5а и б представлены СКО ошибок оценивания, вычисление которых рассчитывается по формулам (1), (2).

Алгоритм обучения LM может обучать любую сеть, если ее весовые, входные и активационные функции дифференцируемы. Но он малоэффективен для больших сетей, поскольку требует много памяти и времени для вычислений [15].

На рис. 4в и г: t_r – отражает время обучения системы (в секундах); t_a – аппроксимация, описываемая уравнением $t_a = e^{2,984x-10,688}$. Аппроксимация, полученная с помощью метода наименьших квадратов [16], отражает закономерность изменения времени обучения алгоритма от количества входов.

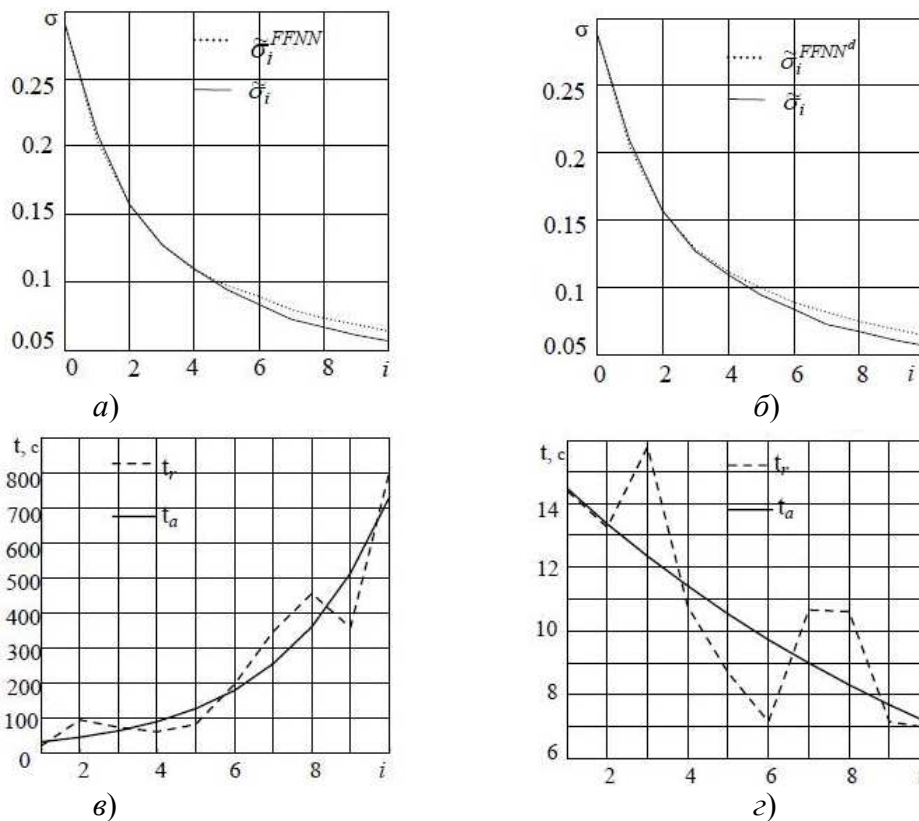


Рис. 4. Нейронная сеть прямого распространения алгоритма обучения Levenberg – Marquardt (слева исходная, справа с применением декомпозиции): а и б – СКО ошибок оценивания; в и г – время обучения.

Как видно из рис. 4в, для исходной сети FFNN без декомпозиции время обучения с увеличением количества входов возрастает, рост начинается с 6 входов, максимальное значение при 10 входах достигает 800 с, в среднем на каждый вход – 256 с. Для сети с применением декомпозиции в виде каскадного соединения с двумя входами и одним выходом время обучения в среднем на каждый вход занимает примерно 11 с (рис. 4г).

В штатном режиме online с использованием найденных в режиме обучения параметров \tilde{W}^* отыскивается оценка вектора x по вектору измерений y . Время оценивания в этом режиме с декомпозицией и без декомпозиции составляет десятки микросекунд.

Алгоритм обучения с использованием регуляризация Байеса BR может обучать любую сеть, если ее весовые, входные и активационные функции имеют производные. BR минимизирует линейную комбинацию квадратичных ошибок и весов. Модификация осуществляется таким образом, что в результате получается сеть с высокими обобщающими свойствами [15].

FFNN с алгоритмом обучения BR без декомпозиции по времени обучения сети показывает лучший результат в сравнении с алгоритмом обучения LM. С применением декомпозиции для алгоритма BR быстродействие улучшается в среднем на 9 с, но в сравнении с алгоритмом LM при декомпозиции результат хуже в среднем на 11 с (рис. 5).

Моделирование нейронной сети с радиальными базисными функциями в связи с высокими вычислительными потребностями выполнялось на компьютере

Intel (R) Xeon (R) CPU X5680 3.33GHz (4 процессора), 20.0 ГБ ОЗУ, 64-разрядная операционная система, предоставленном вычислительном центре «КНАГТУ».

Решение задачи оценивания с использованием обобщенной НС RBFN приведено в работе [13]. В качестве исходной была реализована обобщенная НС RBFN, которая представляет собой двухслойную сеть без обратных связей и содержит единственный скрытый слой радиально симметричных шаблонных нейронов – шаблонный слой [6, 7]. Число нейронов в скрытом слое m_h подобрано опытным путем, равным 500. Выходной слой содержит один нейрон (по числу оцениваемых переменных). На рис. 6а и б представлены СКО ошибок оценивания, рассчитанные по формуле (2). Видно, что при применении декомпозиции точность оценивания снижается. Но для решения задачи оценивания с использованием RBFN без декомпозиции на процесс обучения было затрачено 33 ч., а с декомпозицией – 0,85 ч. (рис. 6в и г). При этом для получения приемлемых результатов по точности для RBFN N было выбрано равным 20000, число нейронов m_h для реализации декомпозиционной НС RBFN – равным 10.

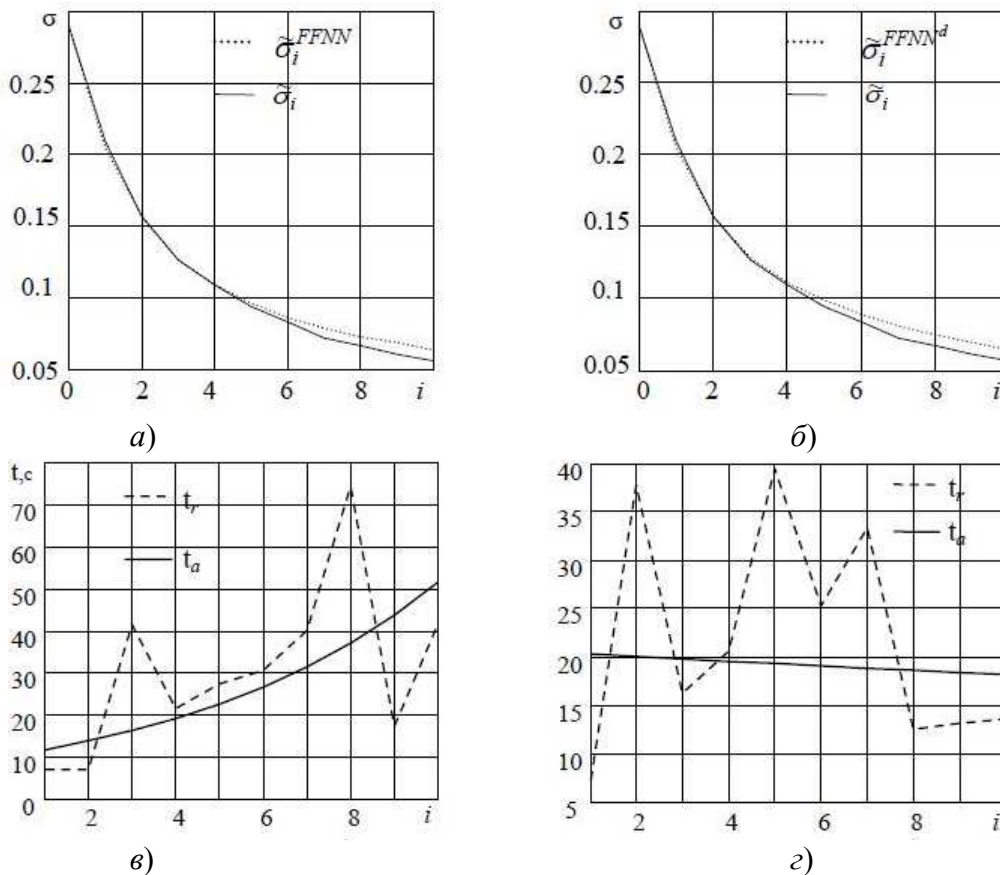


Рис. 5. Нейронная сеть прямого распространения алгоритм обучения Bayesian Regulation (слева исходная, справа с применением декомпозиции): а и б – СКО ошибок оценивания; в и г – время обучения.

Для сети с применением декомпозиции (рис. 6 г) время обучение в среднем на каждый вход занимает ≈ 304 с, уравнение аппроксимации $t_a = e^{-0,0023x+5,1389}$. В штатном режиме реального времени время оценивания с использованием обученной декомпозиционной сети составляет 50 мкс, а время оценивания сети без декомпозиции – 210 мкс.

Таким образом, из рис. 6 видно, что точность оценивания с применением декомпозиции немного снижается, но зато время обучения сети значительно сокращается, что улучшает быстродействие процесса оценивания в несколько раз. Однако эта сеть значительно проигрывает по быстродействию сети FFNN как в режиме обучения, так и в штатном режиме.

Оценки обученных нелинейных FFNN и RBFN совпадают между собой и близки к оптимальной нелинейной оценке.




Рис. 6. Нейронная сеть с радиальными базисными функциями (слева исходная, справа с применением декомпозиции): *a* и *б* – СКО ошибок оценивания; *в* и *г* – время обучения.

Моделирование нечеткой системы. При создании нечеткой системы были использованы функции пакета Fuzzy Logic Toolbox среды MatLab, автоматизирующие синтез структуры нечеткой системы и настройку ее параметров. Для синтеза нечеткой системы применяется функция `genfis1`. Для настройки параметров нечеткой системы была применена адаптивная нейронечеткая система вывода ANFIS – Adaptive Network Based Fuzzy Inference System.

Моделирование нечеткой системы в связи с высокими вычислительными требованиями выполнялось на том же компьютере, что и для сети RBFN.

Исходная нечеткая система представляет собой систему MISO (many inputs – single output) типа Сугено с i входами, двумя термами-гауссианами на каждую входную переменную и одним линейным выходом.

Для моделирования в среде MatLab генерировался обучающий массив данных $\{(y^{(j)}, x^{(j)})\}, j = \overline{1, N}$, где $N = 20000$, количество измерений $i = \overline{1, 7}$ для исход-

ной нечеткой системы и $i = \overline{1,10}$ – с применением декомпозиции (рис. 7а и б).

Как и в случае с нейронными сетями для нечетких систем, применяется самая простая схема декомпозиции, имеющая два входа и один выход (рис. 3б).

На рис. 7а и б представлены СКО ошибок нечеткого оценивания, вычисленные по формуле (2).

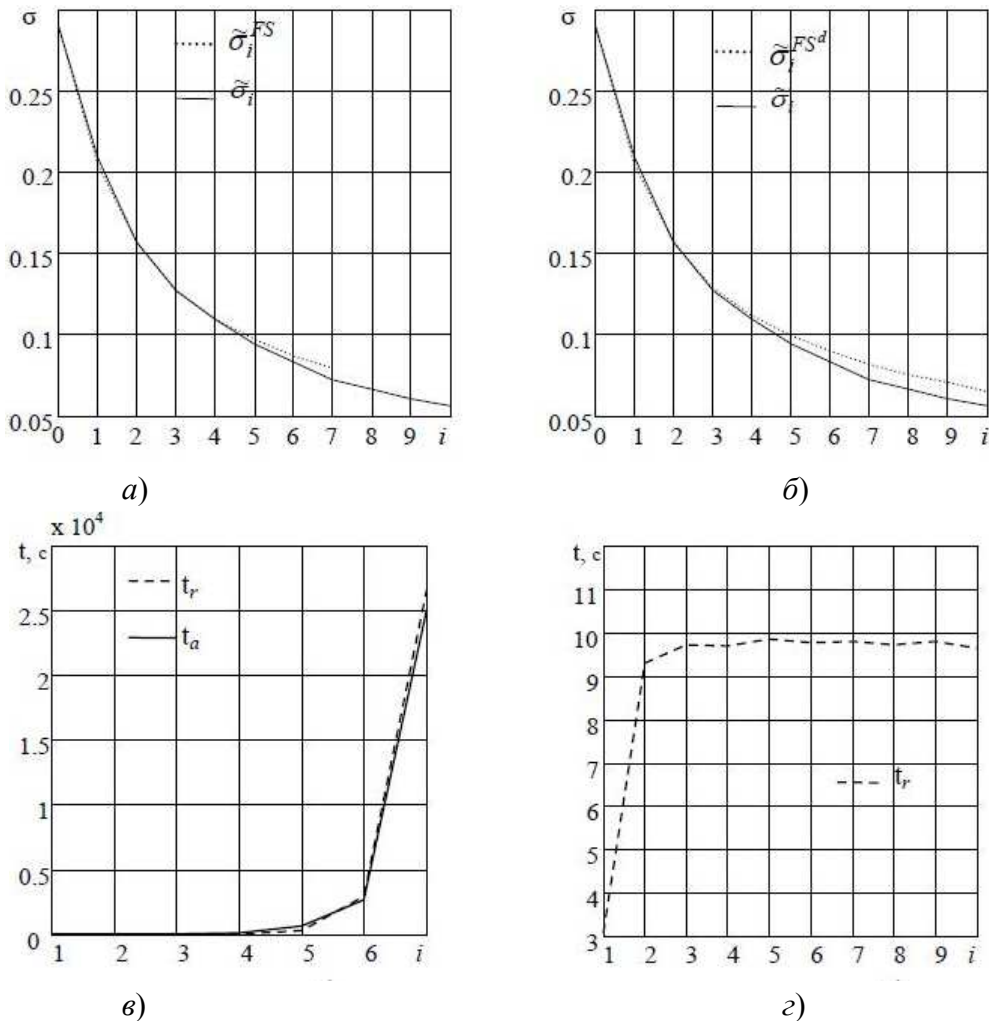


Рис. 7. Нечеткая система (слева исходная, справа с применением декомпозиции): а и б – СКО ошибок оценивания; в и г – время обучения.

Быстродействие представленных алгоритмов оценивания с использованием нечетких систем может характеризоваться временем, затраченным на обучение нечеткой системы, которое для рассматриваемого примера представлено на рис. 7в и г, для исходной и декомпозиционной системы соответственно.

На рис. 7в и г отражается время обучения исходной нечеткой системы оценивания лишь для 7 входов, потому что начиная с 5 измерений происходит значительное увеличение времени на обучение. Так, для 7 входов время обучения составляет 8,2 ч. Уравнение регрессии $t_a = e^{2,1946x-5,175}$ (рис. 7в).

Главное достоинство системы ANFIS состоит в том, что процедура проектирования частично формализована и число параметров генерируется автоматически. В табл. 1 отражены параметры, сгенерированные для нечеткой системы без использования декомпозиции.

Таблица 1

Кол-во входов	Число нейронов	Число линейных параметров	Число нелинейных параметров	Кол-во нечетких правил	Общее количество параметров	Время обучения, с
1	12	4	4	2	8	2,98
2	21	12	8	4	20	10,19
3	34	32	12	8	44	19,77
4	55	80	16	16	96	67,61
5	92	192	20	32	212	330,6
6	161	448	24	64	472	2959
7	294	1024	28	128	1052	2,6x10 ⁴

Рассмотрим эффект применения каскадного соединения с двумя входами и одним выходом, где на вход поступает текущее измерение и оценка, полученная на предыдущем шаге. Применение декомпозиционной системы дает значительное увеличение быстродействия. Время настройки нечеткой системы ANFIS не превышает 9 с.

В табл. 2 сведены результаты обучения систем оценивания, построенных на основе нейронной сети прямого распространения, сети с радиальными базисными функциями и нечеткой системы как без декомпозицией, так и с таковой.

Таблица 2

Кол-во входов	Время обучения алгоритма оценивания, с							
	Искусственные нейронные сети						Нечеткая система	
	Сеть прямого распространения				Сеть с радиальными базисными функциями			
	LM		BR		RBF		ANFIS	
	исходная	с декомпозицией	исходная	с декомпозицией	исходная	с декомпозицией	исходная	с декомпозицией
1	50	7,22	7,063	7,25	1,17x10 ⁴	347,9	2,98	3,07
2	100	13,96	7,031	37,7	1,2x10 ⁴	280,4	10,19	9,31
3	90	15,07	41,55	16,27	1,2x10 ⁴	295,1	19,77	9,73
4	80	6,95	21,44	20,64	1,19x10 ⁴	309,9	67,61	9,7
5	90	15,98	27,28	39,47	1,18x10 ⁴	307,9	330,6	9,85
6	200	10,35	30,55	25,28	1,17x10 ⁴	285,9	2959	9,76
7	350	7,25	40,03	33,31	1,19x10 ⁴	308,4	2,6x10 ⁴	9,79
8	450	11,03	74,52	12,52	1,2x10 ⁴	313,5	-	9,72
9	350	7,21	17,25	13,14	1,2x10 ⁴	300	-	9,79
10	800	10,25	41,81	13,63	1,2x10 ⁴	300,4	-	9,64
Ср.	256	10,5	30,85	21,92	11940	304,9	4229	9

Полученные результаты показывают, что самая простая декомпозиция является исчерпывающей для выбранного примера и для увеличения быстродейст-

вия работы синтетических систем нет необходимости применять более сложную структуру декомпозиции.

Заключение

Таким образом, в данной статье показано, что с помощью декомпозиционных синтетических систем может быть достигнута высокая точность оценивания, близкая к предельно достижимой точности оптимального нелинейного алгоритма. При этом скорость обучения декомпозиционных синтетических систем значительно, на несколько порядков, выше скорости обучения исходных синтетических систем без декомпозиции.

Определена закономерность увеличения быстродействия при использовании декомпозиции.

Получены новые результаты для решения задачи оценивания с помощью нейронных сетей прямого распространения и с радиальными базисными элементами, с декомпозицией и без таковой.

Для нейронной сети прямого распространения проиллюстрировано применение разных алгоритмов обучения, выявлены особенности их работы.

Продемонстрировано, что использование нейронной сети с РБФ затруднительно в связи с ее излишней громоздкостью.

Предложены декомпозиционные нечеткие системы, которые преодолевают значительные вычислительные трудности обучения нечеткой системы при количестве входов большем чем 5, сохраняя точность оценивания.

ЛИТЕРАТУРА

1. Степанов О.А. Применение теории нелинейной фильтрации в задачах обработки навигационной информации. – СПб.: ГНЦ РФ–ЦНИИ «Электроприбор», 1998.
2. Stepanov O.A., Amosov O.S. Optimal Estimation by Using Neural Networks. – // Proceeding of the 16-th IFAC World Congress, Prague, Czech Republic July 3–8, 2005.
3. Степанов О.А., Амосов О.С. Байесовское оценивание с использованием нейронной сети // Авиакосмическое приборостроение. – 2004. – № 6. – С. 46-55.
4. Степанов О.А., Амосов О.С. Применение нейронных сетей в нелинейных задачах обработки навигационной информации // Материалы XIII Санкт-Петербургской Международной конф. по интегрированным навигационным системам: Сб. науч. тр. – СПб.: ГНЦ РФ ЦНИИ «Электроприбор», 2006. – С. 178-182.
5. Amosov O.S., Amosova L.N. Optimal Estimation by Using Fuzzy Systems // Proc. of the 17th IFAC World Congress, Seoul, Korea, July 6-11, 2008. – P. 6094-6099.
6. Хайкин С. Нейронные сети: полный курс / пер. с англ. – Изд. 2-е. – М.: Изд. дом «Вильямс», 2006.
7. Круглов В.В., Дли М. И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети.– М.: Изд-во Физико-математической литературы, 2001.
8. Амосов О.С., Малашевская Е.А., Баена С.Г. Субоптимальное оценивание случайных последовательностей с использованием иерархических нечетких систем // Информатика и системы управления. – 2013. – № 3(37). – С. 123-133.
9. Амосов О.С., Баена С.Г. Субоптимальное нелинейное оценивание на основе иерархических синтетических систем // Системы управления и информационные технологии. – 2014. – №2(56). – С.4-8.



10. Амосов О.С., Баена С.Г. Оптимальное нелинейное оценивание с использованием иерархических синтетических систем // XXI Санкт-Петербургская Международная конф. по интегрированным навигационным системам. – Концерн "ЦНИИ "Электроприбор". – 2014. – С.126-131.
11. Амосов О.С., Баена С.Г., Амосова Л.Н. Нелинейное оценивание временных рядов с использованием синтетических систем // Информатика и системы управления. – 2014. – № 2(40). – С.84-93.
12. Медич Дж. Статистически оптимальные линейные оценки и управление / пер с англ. под ред. А.С. Шаталова. – М.: Энергия, 1973.
13. Амосов О.С., Баена С.Г. Байесовское оценивание с использованием нейронной сети с радиальными базисными функциями // Информатика и системы управления. – 2013. – № 2(36). – С.127-133.
14. Еремин Е.Л., Остапенко А.А., Плутенко А.Д., Акилова С.Г. Адаптивная система управления для объектов с запаздыванием. Патент на изобретение RUS 2130636 07.07.1998 г.
15. Hagan M.T., Demuth H.B., Beale M.H. Neural Network Design. – Boston, MA: PWS Publishing, 1996.
16. Максимова А.П., Малова Н.А. Лабораторный практикум по вычислительной математике. Методические указания по выполнению лабораторных работ. – Чебоксары: Волжский филиал МАДИ (ГТУ), 2008.

E-mail:

Амосов Олег Семенович. – osa18@yandex.ru;

Баена Светлана Геннадьевна – svetlana.baena@yandex.ru.

УДК 004.896

© 2014 г. **И.А. Голубкин,**
И.А. Щербатов, канд. техн. наук
(Астраханский государственный технический университет)

СИСТЕМА УПРАВЛЕНИЯ МОБИЛЬНЫМ КОЛЕСНЫМ РОБОТОМ ДЛЯ ВНУТРИТРУБНОЙ ИНСПЕКЦИИ ГАЗОПРОВОДОВ

В статье рассмотрена разработанная система управления мобильным колесным диагностическим роботом для проведения дефектоскопии газопроводов. Работа системы основана на методике нечеткого ситуационного управления роботом, которая предназначена для решения задач управления роботами разных размеров в условиях изменения физических параметров газопровода.

Ключевые слова: мобильные роботы, обследование газопроводов, сенсорная подсистема, система управления роботом.

Введение

Внутритрубная инспекция газопроводов – важный технологический процесс обслуживания, от качества и частоты выполнения которого зависит безопасная и надежная эксплуатация трубопроводных систем. Мероприятия по ос-