


Федеральное государственное бюджетное образовательное учреждение
высшего профессионального образования
«Комсомольский-на-Амуре государственный технический университет»

На правах рукописи



Баена Светлана Геннадьевна

ВЫЧИСЛИТЕЛЬНЫЙ МЕТОД И СИНТЕТИЧЕСКИЕ АЛГОРИТМЫ
ОЦЕНИВАНИЯ СОСТОЯНИЯ ДИНАМИЧЕСКИХ СИСТЕМ С
ИСПОЛЬЗОВАНИЕМ ДЕКОМПОЗИЦИИ

05.13.18 Математическое моделирование, численные методы и
комплексы программ

Диссертация на соискание ученой степени кандидата технических наук

Научный руководитель
д.т.н., профессор О.С. Амосов

Комсомольск-на-Амуре – 2014

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	5
ГЛАВА 1. КРИТИЧЕСКИЙ АНАЛИЗ СУЩЕСТВУЮЩИХ МЕТОДОВ ОЦЕНИВАНИЯ СОСТОЯНИЯ ДИНАМИЧЕСКИХ СИСТЕМ.....	12
1.1. Задача оценивания.....	12
1.2. Традиционные методы оценивания.....	14
1.2.1. Байесовский подход.....	16
1.2.2. Небайесовский подход.....	19
1.2.3. Метод наименьших квадратов.....	20
1.2.4. Рекуррентные алгоритмы оценивания. Фильтр Калмана.....	21
1.3. Методы оценивания на основе искусственных нейронных сетей и нечетких систем.....	24
1.3.1. Метод оценивания на основе искусственных нейронных сетей.....	24
1.3.2. Метод оценивания на основе нечетких систем.....	31
1.4. Метод оценивания с использованием вейвлетов.....	35
Выводы по первой главе.....	40
ГЛАВА 2. ВЫЧИСЛИТЕЛЬНЫЙ МЕТОД ОЦЕНИВАНИЯ СОСТОЯНИЯ ДИНАМИЧЕСКИХ СИСТЕМ	43
2.1. Постановка нелинейной задачи оценивания состояния динамической системы.....	43
2.2. Традиционное решение нелинейной задачи оценивания.....	44
2.2.1. Байесовское решение задачи оценивания.....	45
2.2.2. Решение задачи оценивания с помощью метода наименьших квадратов	48
2.3. Вычислительный метод оценивания с использованием синтетических систем	49
2.3.1. Байесовский подход.....	52
2.3.2. Характеристика точности для вычислительного метода оценивания	56

2.3.3. Решение задачи рекуррентного оценивания с использованием синтетических систем.....	57
2.3.4. Вычислительный метод оценивания с использованием синтетических систем на базе метода наименьших квадратов.....	58
2.4. Математические модели иерархических синтетических систем нелинейного оценивания динамических процессов.....	62
Выводы по второй главе.....	68
ГЛАВА 3. ЧИСЛЕННЫЕ МЕТОДЫ И ПРОГРАММНАЯ РЕАЛИЗАЦИЯ НЕЛИНЕЙНОГО ОЦЕНИВАНИЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ, НЕЧЕТКИХ СИСТЕМ И ДЕКОМПОЗИЦИИ	70
3.1. Решение задачи нелинейного оценивания с помощью численного метода на основе нейронных сетей и декомпозиции.....	71
3.1.1. Нелинейная нейронная сеть прямого распространения.....	73
3.1.2. Нейронная сеть с радиальными базисными функциями	76
3.1.3. Численная и программная реализация решения задачи оптимального нелинейного оценивания с использованием различных типов нейронной сети.....	79
3.1.4. Иллюстрирующие примеры решения задач оценивания.....	83
3.2. Решение задачи нелинейного оценивания с использованием численного метода на основе нечеткой логики и декомпозиции.....	92
3.2.1. Решение задачи нелинейного оценивания с помощью численного метода на основе нейронечетких систем.....	93
3.2.2. Иллюстрирующий пример решения задач оценивания.....	96
Выводы по третьей главе.....	99
ГЛАВА 4. ЧИСЛЕННЫЙ МЕТОД И ПРОГРАММНАЯ РЕАЛИЗАЦИЯ НЕЛИНЕЙНОГО ОЦЕНИВАНИЯ С ИСПОЛЬЗОВАНИЕМ ВЕЙВЛЕТОВ И ДЕКОМПОЗИЦИИ.....	101
4.1. Решение задачи нелинейного оценивания с помощью численного метода на основе вейвлетов и декомпозиции.....	101
4.2. Пример оценивания экспоненциально-коррелированного процесса.....	109

4.2.1. Математическая модель экспоненциально-коррелированного процесса с локальными особенностями.....	109
4.2.2. Процесс без нарушений.....	110
4.2.3. Процесс с нарушениями	112
4.2.4. Численная и программная реализация решения задачи оптимального нелинейного оценивания и фильтрации с использованием вейвлет-анализа.....	114
4.3. Применение предложенных синтетических алгоритмов оценивания состояния динамических систем в других приложениях.....	119
Выводы по четвертой главе.....	124
ЗАКЛЮЧЕНИЕ.....	126
Список сокращений и условных обозначений.....	129
Словарь терминов.....	130
СПИСОК ЛИТЕРАТУРЫ.....	132
ПРИЛОЖЕНИЕ А. Иллюстрация к алгоритму Сугено.....	146
ПРИЛОЖЕНИЕ В. Структура нечеткой нейронной системы (архитектура ANFIS).....	147
ПРИЛОЖЕНИЕ С. Акт о внедрении научно-практических результатов диссертации.....	148
ПРИЛОЖЕНИЕ D. Акт о внедрении результатов диссертации в учебную деятельность.....	149
ПРИЛОЖЕНИЕ Е. Охранные документы на результаты интеллектуальной деятельности	150
ПРИЛОЖЕНИЕ F. Коды программ	155

ВВЕДЕНИЕ

Актуальность работы. Задача нелинейного оценивания случайных процессов является фундаментальной и до сих пор требует поиска эффективных алгоритмов. В настоящее время для решения задачи оценивания нелинейного процесса широко используются традиционные методы [20, 22, 34, 50, 60, 62, 64–66, 72, 73, 75, 81, 82, 89, 97, 98, 104], среди которых можно выделить подходы байесовский и небайесовский, а также метод наименьших квадратов [66, 72, 81]. В этих подходах для построения оптимальных алгоритмов требуется знание априорной информации об оцениваемых процессах и ошибках их измерений, хотя предположения о статистической природе динамических процессов различны. Численная реализация традиционных методов для нелинейных задач оказывает значительные вычислительные трудности, поэтому необходимо исследовать альтернативные методы. Для синтеза быстродействующих субоптимальных нелинейных алгоритмов оценивания разрабатываются эффективные численные процедуры. К этой группе методов относятся и методы вычисления с использованием искусственных нейронных сетей (НС) [3, 4, 91, 101, 107, 112–116], нечетких систем (НчС) [1, 3, 4, 15, 92] и вейвлетов [12, 14, 93, 95]. Lo J. T. H., Naykin S., Yee P., Alessandri A., Parisini T., Zoppoli R., Parlos A.G., Menon S.K., Atiya A.F., Степанов О.А., Амосов О.С. впервые использовали методы искусственного интеллекта для задач нелинейного оценивания и фильтрации. Девятисильный А.С., Дорожко В.М., Числов К.А., Гальченко В.Я., Гринь Н.Ю., Яковлев Е.К., Блатов И.А. [28, 31–33, 88] предлагают использовать вейвлеты для подавления и снижения уровня шумов, также очищения сигнала от шума для восстановления исходного сигнала. Использование же регрессии и вейвлетов для решения задачи оценивания впервые предложили в работах Амосов О.С., Амосова Л.Н., Магола Д.С.

Достоинства данных методов для решения задачи оценивания заключается в следующем: нейронные сети – обучаемы и подстраиваемы; нечеткие системы – работают в условиях неопределенности и имеют прозрачные правила вывода решений; вейвлеты – описывают сигналы в частотной и временной областях, предоставляя возможность обнаружить внутреннюю структуру существенно неоднородного объекта и изучить его локальные свойства. Нейронные сети, нечеткие системы и вейвлеты могут применяться как раздельно, так и совместно в виде гибридных систем, сочетающих в себе их преимущества. Под синтетическими системами в дальнейшем и будем понимать перечисленные выше конструкции [117–120].

Однако, до сих пор остаются непроработанными такие вопросы как, проектирование архитектур НС, НЧС и вейвлетов для задач оценивания; снижение значительных вычислительных затрат при настройке алгоритмов оценивания [3, 4, 94, 95, 114]. 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.

Целью диссертации является разработка эффективного по быстродействию и точности вычислительного метода оценивания состояния динамических систем на основе класса параметрически заданных функций с их численной реализацией на базе иерархических синтетических систем.

В качестве **объекта исследования** рассматривается динамический процесс, который представляет собой последовательность значений некоторых переменных, регистрируемых непрерывно или через некоторые промежутки времени. **Предметом исследования** является вычислительный метод и синтетические алгоритмы оценивания состояния динамических систем, основанные на использовании принципов декомпозиции и эвристик.

Задачи исследования:

- 1) провести критический анализ существующих методов оценивания;
- 2) разработать эффективный по быстродействию и точности вычислительный метод оценивания состояния динамических систем, охватывающий все процессы решения задачи оценивания;
- 3) разработать математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов;
- 4) развить численные методы стохастической аппроксимации на основе нейросетевого, нечеткого и вейвлет подходов;
- 5) синтезировать быстродействующие субоптимальные нейросетевые, нечеткие и вейвлет алгоритмы оценивания состояния динамических систем с использованием декомпозиции;
- 6) на основе метода вейвлет-оценивания разработать алгоритмы для оценивания процессов без нарушений и с нарушениями;
- 7) реализовать и проверить точность и быстродействие алгоритмов при решении задач оценивания.

Методы исследования. При решении поставленных задач были использованы: теория оптимального оценивания и фильтрации, методы математического моделирования динамических процессов; системный анализ, теория нечетких множеств, искусственных нейронных и гибридных сетей, теория вейвлет-преобразований. Для практических исследований и алгоритмической обработки использована математическая среда MatLab.

Научная новизна работы:

- предложен вычислительный метод оптимального оценивания состояния динамических систем с использованием класса параметрически заданных функций и принципа минимизации эмпирического риска для критерия оценивания, отличающийся его численной реализацией на базе иерархических синтетических систем;

- предложены математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов;
- развиты численные методы стохастической аппроксимации, отличающиеся тем, что для их реализации предложены быстродействующие нейросетевые, нечеткие, вейвлет методы и декомпозиционные алгоритмы субоптимального оценивания состояния динамических систем;
- предложена реализация нейросетевых и нечетких алгоритмов обучения в реальном режиме работы;
- разработаны комплексы программ оценивания состояния динамических систем на основе нейронных сетей и вейвлетов;
- получены закономерности увеличения быстродействия обучения декомпозиционных синтетических систем оценивания при сохранении их точности.

Практическая ценность результатов работы. Предложены алгоритмы и программные комплексы для решения нелинейных задач оценивания, которые могут быть использованы для разных предметных областей, таких как навигация и системы управления движением подвижных объектов, информационно-навигационные системы, радиотехника, электротехника, робототехника.

Результаты диссертационной работы внедрены в научно-исследовательской деятельности кафедры «Информационные и управляющие системы» Факультета математики и информатики ФГБОУ ВПО «Амурский государственный университет» г. Благовещенск и в учебном процессе Факультета компьютерных технологий и Электротехнического факультета ФГБОУ ВПО «Комсомольский-на-Амуре государственный технический университет».

По результатам работы получен патент на полезную модель № 138401 РФ и свидетельства о государственной регистрации программы для ЭВМ № 2014617763 и № 2014617998.

В части, касающейся использования вейвлетов для оценивания, работа поддержана РФФИ, грант № 15-08-08593 А «Исследование эффективности применения вейвлетов при решении задач обработки навигационной информации» (руководитель проекта Амосов О.С.).

На защиту выносятся следующие положения:

1. Вычислительный метод оценивания состояния динамических систем.
2. Математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов.
3. Численные методы и комплексы программ реализация нелинейного оценивания с использованием нейросетевого, нечеткого, вейвлет подходов и декомпозиции.
4. Выявленные закономерности увеличения быстродействия обучения декомпозиционных синтетических систем оценивания при сохранении их точностных характеристик.

Апробация результатов работы. Основные положения и результаты диссертационной работы докладывались и получили одобрение на:

- 21 Международной конференции по интегрированным навигационным системам, г. Санкт-Петербург, 2014 г. (21st Saint Petersburg international conference on integrated navigation systems);
- Всероссийской научной конференции XXXVIII Дальневосточная Математическая Школа-Семинар имени академика Е.В. Золотова на секциях «Вычислительная математика и компьютерные технологии» и «Управление и оптимизация», г. Владивосток, 2014 г.;
- Международной научно-практической конференции «Фундаментальные проблемы науки», г. Уфа, 2013 г.;
- Международной научно-практической конференции «Актуальные проблемы математики, физики, информатики в вузе и школе», г. Комсомольск-на-Амуре, 2012 г.;

- Международной заочной научно-практической конференции «Социальное и экономическое развитие АТР: проблемы, опыт, перспективы», г. Комсомольск-на-Амуре, 2012 г.;

- Ежегодных конференциях и семинарах ФГБОУ ВПО «КнАГТУ».

Публикации и личный вклад автора. Основные результаты диссертации отражены в 11 научных работах, в том числе 5 – в ведущих рецензируемых журналах, входящих в перечень ВАК, одна из которых включена в международную базу Web of Science; 6 работ в материалах и трудах конференции, одна из которых включена в международную базу Scopus. Теоретическая проработка методов оценивания состояния динамических систем; разработка вычислительного алгоритма для решения поставленной задачи; анализ и обобщение результатов, полученных в процессе вычислительных экспериментов с моделью, выполнены лично автором.

Структура и объём работы. Диссертация состоит из введения, четырёх глав, заключения, списка сокращений и условных обозначений, словаря терминов, списка литературы, приложения. Основные результаты диссертации изложены в работах [117–130].

В **первой главе** проведена систематизация известных исследований по оцениванию состояния динамических систем и критически освещены работы отечественных и зарубежных авторов в этой области. Поставлена цель и сформулированы задачи настоящего диссертационного исследования.

Во **второй главе** предложен эффективный с точки зрения быстродействия и точности вычислительный метод оценивания состояния динамических систем на основе субоптимальных систем оценивания – иерархических синтетических систем, которые строятся на основе принципа декомпозиции и эвристик. Разработаны математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов.

В **третьей главе** 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.

Для численного решения задачи нелинейного оценивания разработаны алгоритмы оценивания: - с использованием декомпозиционных искусственных нейронных сетей прямого распространения и сетей с радиальными базисными функциями; - нейронечетких систем, построенных на основе базовых принципов декомпозиции.

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 обучения при использовании декомпозиции.

В **четвертой** главе рассмотрены численные методы и программная реализация методов оценивания с использованием вейвлетов и декомпозиции. Дано решение задачи оценивания с использованием вейвлетов на основе стохастической схемы регрессии. Проиллюстрировано использование вейвлетов для оценивания нестационарного процесса с локальными особенностями. Разработан комплекс программ для задачи нелинейного оценивания с использованием вейвлетов. Рассмотрено применение предложенных синтетических алгоритмов оценивания состояния динамических систем в других разработках.

Работа содержит 172 страницы основного текста, 33 рисунка, 4 таблицы, список литературы из 130 наименований и 6 приложений.

Работа выполнена на кафедре «Промышленная электроника» Комсомольского-на-Амуре государственного технического университета. Автор выражает благодарность научному руководителю – доктору технических наук, профессору Амосову Олегу Семеновичу за непрерывное сопровождение и руководство при написании диссертации.

ГЛАВА 1. КРИТИЧЕСКИЙ АНАЛИЗ СУЩЕСТВУЮЩИХ МЕТОДОВ ОЦЕНИВАНИЯ СОСТОЯНИЯ ДИНАМИЧЕСКИХ СИСТЕМ

Проведена систематизация известных исследований по оцениванию состояния динамических систем и критически освещены работы отечественных и зарубежных авторов в этой области. Поставлена цель и сформулированы задачи настоящего диссертационного исследования.

1.1. Задача оценивания

Среди современных методов обработки информации важное место занимают методы оценивания состояния динамических систем. Под динамическими системами в дальнейшем будем понимать системы, которые под действием внешних и внутренних сил изменяют во времени свои состояния [52, 57, 65, 83]. Преимущественно будут рассматриваться нелинейные стохастические системы. Наряду с понятием «система» или «динамическая система» будем использовать понятие процесса, который характеризует состояние системы.

Задача оценки заключается в аппроксимации поведения процесса по данным зашумленных измерений. Обычно отыскивается аппроксимация, наилучшая в смысле некоторого критерия J , имеющего вид функции от ошибки оценки [6, 50].

Структурная схема системы оценивания представлена на рисунке 1.1, где S – динамическая система с n -мерным вектором состояния $\{\mathbf{x}_i, i \in I\}$, $I = \{i : i = 0, 1, \dots\}$; M – измерительная система с m -мерным вектором измерения $\{\mathbf{y}_\lambda, \lambda \in \Lambda\}$, $\Lambda = \{\lambda : \lambda = 1, 2, \dots, k\}$; E – система оценивания с вектором оценок

$\tilde{\mathbf{x}}_{i/k}$. Задача оценки представляет собой задачу определения функции $\mathbf{h}_i$ некоторым рациональным обоснованным способом [50]:

$$\tilde{\mathbf{x}}_{i/k} = \mathbf{h}_i[\mathbf{y}_\lambda, \lambda = 1, 2, \dots, k]. \quad (1.1)$$




Рисунок 1.1 – Структурная схема системы оценивания

В зависимости от расположения момента формирования оценки относительно отрезка наблюдения оценивание делится на фильтрацию, экстраполяцию и интерполяцию [89]. Если $i > k$, задача называется задачей предсказания, если $i = k$, это задача фильтрации, а если $i < k$ – задача сглаживания или интерполяции [50].

В настоящее время для задачи оценивания нелинейного процесса широко используются традиционные методы [21, 22, 29, 50, 65, 72–74, 81, 82, 89], среди которых можно выделить подходы байесовский и небайесовский, а также метод наименьших квадратов [66, 72, 73]. Однако численная реализация традиционных методов оказывает значительные вычислительные трудности, поэтому необходимо исследовать альтернативные методы. Для синтеза быстродействующих субоптимальных нелинейных алгоритмов оценивания разрабатываются эффективные численные процедуры. К этой группе методов относятся методы вычисления с использованием нейронных сетей [1, 3, 4, 91, 101, 107, 112–116], нечетких систем [1–4, 15, 72, 92] и вейвлетов [7, 12, 15, 28, 31–33, 87, 93, 94].

Нами в работах [117–120, 123–125] предложено понимать под синтетическими методы и алгоритмы вычисления с использованием нейронных сетей, нечетких систем, вейвлетов и их комбинаций.

Критически оценим достоинства и недостатки указанных методов и алгоритмов оценивания и выявим нерешенные задачи в этой области. Так как традиционные методы хорошо известны и широко используются на практике,

остановимся на них кратко, а большее внимание уделим альтернативным методам оценивания.

1.2. Традиционные методы оценивания

В настоящее время задача нелинейного оценивания состояния динамических систем решается с помощью множества алгоритмов.

Процедура оценивания состоит из методов и математических процедур (алгоритмов) нахождения оптимальных или субоптимальных решений при условии, что эти на эти решения оказывают влияние все имеющиеся в наличии сведения. Математическая теория оптимального оценивания берет начало с основополагающих работ А.Н. Колмагорова и Н. Винера, посвященных оптимальному линейному оцениванию стационарных случайных процессов. Подобные задачи сводятся к установлению и разрешению уравнений регрессии. Впервые систематическое применение методов математической статистики для решения радиотехнических задач описано В.А. Котельниковым. Оптимальные алгоритмы нестационарного линейного оценивания гауссовских процессов для дискретного и непрерывного времени получены в 1960-1961 гг. Р.Е. Калманом и Р.С. Бьюси [89].

Широкое применение в решении задачи линейного оценивания нашли алгоритмы калмановского типа, получение которых опирается на хорошо разработанную теорию линейной фильтрации марковских последовательностей и процессов. Этой теории и ее применению в прикладных задачах посвящена обширная литература таких авторов, как Аоки М., Браммер К., Зиффинг Г., Бьюси Р.С., Казаков И.Е., Гладков Д.И., Медич Дж., Сейдж Э., Мелс Дж., Фомин В.Н., Gelb А. Решение задачи сводится к следующему: линейная зависимость вычисляемых оценок вектора состояния от измерений, является

следствием гауссовского характера апостериорной (условной к измерениям) плотности для этого вектора [16, 21, 22, 39, 50, 62, 66, 81, 82, 97].

В задачах, когда апостериорная плотность не является гауссовской (когда имеет место наличие неточно известных параметров в этих уравнениях или в условиях, когда в составе вектора состояния или ошибок измерения имеются составляющие с негауссовской плотностью распределения), решение сводится к применению теории нелинейной фильтрации. Общие принципы решения задач нелинейной фильтрации и разработка алгоритмов оценивания отражены в работах таких авторов, как: Бьюси Р.С., Ибрагимов И.А., Хасьминский Р.З., Кайлатц Т., Стратонович Р.С., Тихонов В.И., Ярлыков М.С., Миронов М.А., Сосулин Ю.Г., Степанов О.А., Jazwinski A.H., Kushner H.J [22, 38, 40, 64, 66, 74, 78, 89, 104, 106].

В отечественных и зарубежных публикациях по традиционным методам оптимального оценивания и фильтрации имеется достаточно информации, среди которых можно выделить монографии Стратоновича Р.Л.; Тихонова В.И. и Кульмана Н.К.; Ярлыкова М.С. и Миронова М.А.; Фомина В.Н.; Дмитриева С.П.; Степанова О.А.; Медича Дж.; Брайсона А. и Хо Ю-Ши; Сейджа Э. и Мелса Дж; Jazwinski A.H. [20, 34, 50, 62, 75, 78, 81, 82, 89, 104]. Основными из традиционных являются методы, соответствующие байесовскому и классическому – небайесовскому подходам, метод наименьших квадратов (МНК) и алгоритмы, основанные на использовании приближений, – фильтр Калмана (ФК) и расширенный ФК.

Для решения задачи оценивания n -мерного вектора $\mathbf{x} = (x_1, \dots, x_n)^T$ по m -мерным измерениям $\mathbf{y} = (y_1, \dots, y_m)^T$, которые представлены в виде

$$\mathbf{y} = \mathbf{s}(\mathbf{x}, \mathbf{v}), \quad (1.2)$$

где $\mathbf{s}(\cdot, \cdot) = (s_1(\mathbf{x}, \mathbf{v}), \dots, s_m(\mathbf{x}, \mathbf{v}))^T$ – в общем случае нелинейная относительно $\mathbf{x}$ и $\mathbf{v}$ m -вектор-функция известного вида; $\mathbf{v}$ – m -мерный вектор, характеризующий ошибки измерения, в зависимости от объема имеющейся

априорной статистической информации о векторах $\mathbf{x}$ и $\mathbf{v}$ возможны различные подходы [66, 72, 73].

В тех случаях, когда для этих векторов задана совместная плотность распределения вероятностей $f(\mathbf{x}, \mathbf{v})$ задача может решаться в рамках байесовского подхода.

Если известна лишь плотность распределения вероятностей $f(\mathbf{v})$ и не вводится предположение о случайном характере неизвестного вектора $\mathbf{x}$, т.е. считается, что он неслучаен-детерминирован, задачу решают в рамках классического – небайесовского подхода.

И, наконец, в тех ситуациях, когда статистический характер $\mathbf{x}$ и $\mathbf{v}$ вообще не предполагается, либо ограничиваются заданием для этих векторов только двух моментов: математического ожидания $\bar{\mathbf{x}}$ и матрицы ковариаций $\mathbf{P}$, задачу оценивания решают на основе иных подходов, таких, например, как метод наименьших квадратов.

Так, при решении задач навигации теоретической основой для выработки навигационных параметров являются методы оптимальной калмановской фильтрации, предполагающие, что параметры стохастических марковских моделей погрешностей навигационной системы известны точно, вычисления при выработке оценки проведены без ошибок, а вычислительные возможности навигационной системы таковы, что позволяют обеспечить реализацию фильтра Калмана (ФК) [79].

Ниже опишем теоретические положения о представленных подходах [66, 72, 73].

1.2.1. Байесовский подход

В задачах оценивания, решаемых с использованием байесовского подхода для вектора $\mathbf{x}$ определяется плотность, условная к измерениям $\mathbf{y}$. Эта

плотность является основным объектом исследования и называется апостериорной плотностью [66, 72, 73]:

$$f(\mathbf{x}/\mathbf{y}) = f(\mathbf{x}, \mathbf{y}) / f(\mathbf{y}),$$

где

$$f(\mathbf{y}) = \int f(\mathbf{x}, \mathbf{y}) d\mathbf{x}.$$

В этих соотношениях $f(\mathbf{y})$ характеризует плотность распределения вектора измерений $\mathbf{y}$, а $f(\mathbf{x}, \mathbf{y})$ – совместную плотность распределения измерений и оцениваемого вектора. Обычно эта плотность вычисляется с помощью соотношения

$$f(\mathbf{x}, \mathbf{y}) = f(\mathbf{y}/\mathbf{x}) f(\mathbf{x}),$$

в котором $f(\mathbf{y}/\mathbf{x})$ представляет собой плотность измерений, условную к вектору $\mathbf{x}$. Эта плотность рассматривается как функция $\mathbf{x}$ и называется функцией правдоподобия. Она определяется с точностью до постоянного множителя с использованием выражения (1.2).

Для оценки вектора $\mathbf{x}$, отыскиваемой как функции измерений $\mathbf{y}$, будем использовать обозначение $\tilde{\mathbf{x}}(\mathbf{y})$. Чтобы определить потери, вызванные неточным оцениванием, вводится скалярная функция потерь $L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))$. В рамках байесовского подхода качество оценивания характеризуют условными по отношению к измерениям потерями [66, 72, 73]

$$r^{yc}(\mathbf{y}) = M_{\mathbf{x}/\mathbf{y}}\{L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))\} = \int L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) f(\mathbf{x}/\mathbf{y}) d\mathbf{x} \quad (1.3)$$

или безусловными (средними) потерями

$$r^{\bar{o}} = M_{\mathbf{x}, \mathbf{y}}\{L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))\} = \iint L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) f(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y}. \quad (1.4)$$

В выражениях (1.3), (1.4) $M_{\mathbf{x}/\mathbf{y}}$, $M_{\mathbf{x}, \mathbf{y}}$ определяют операции взятия математических ожиданий, соответствующих плотностям $f(\mathbf{x}/\mathbf{y})$ и $f(\mathbf{x}, \mathbf{y})$.

Средние потери могут быть также определены с помощью соотношений

$$r^{\bar{o}} = M_{\mathbf{y}}\{r^y(\mathbf{y})\};$$

$$r^{\bar{o}} = M_{\mathbf{x}}\{r^x(\mathbf{x})\},$$

где $r^{\mathbf{x}}(\mathbf{x}) = M_{\mathbf{y}/\mathbf{x}}\{L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))\} = \int L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) f(\mathbf{y}/\mathbf{x}) d\mathbf{y}$

– потери, условные по отношению к оцениваемому параметру $\mathbf{x}$. Верхний индекс $\mathbf{x}$ $r^{\mathbf{x}}(\mathbf{x})$ означает, что эти потери относятся к задаче оценивания вектора $\mathbf{x}$.

Оптимальная байесовская оценка отыскивается из условия минимизации условных $r^{\mathbf{x}}(\mathbf{y})$ или безусловных r^{δ} потерь. Различные функции потерь порождают различные алгоритмы оценивания. Так оценка, соответствующая квадратичной функции потерь

$$L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) = (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})), \quad (1.5)$$

представляет собой математическое ожидание, соответствующее апостериорной плотности $f(\mathbf{x}/\mathbf{y})$, т.е.

$$\tilde{\mathbf{x}}(\mathbf{y}) = \int \mathbf{x} f(\mathbf{x}/\mathbf{y}) d\mathbf{x}.$$

Для простой функции потерь

$$L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) = c - \delta(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})), \quad c > 0,$$

где $\delta(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) = \prod_{j=1}^n \delta(x_j - \tilde{x}_j(\mathbf{y}))$

– многомерная дельта-функция, в качестве оценки выступает значение, соответствующее максимуму апостериорной плотности, т.е. $\tilde{\mathbf{x}} = \arg \max_{\mathbf{x}} f(\mathbf{x}/\mathbf{y})$.

В случае модульной функции потерь

$$L(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) = \sum_{j=1}^n |x_j - \tilde{x}_j(\mathbf{y})|$$

оценками являются медианы апостериорных плотностей $f(x_j/\mathbf{y})$, т.е. $\tilde{x}_j(\mathbf{y})$ такие, что

$$\int_{-\infty}^{\tilde{x}_j} f(x_j/\mathbf{y}) dx_j = \int_{\tilde{x}_j}^{\infty} f(x_j/\mathbf{y}) dx_j,$$

где $f(x_j/y)$ – апостериорные плотности компонент x_j , определяемые из соотношения $f(x_j/y) = \int \dots \int f(\mathbf{x}/y) dx_1 \dots dx_{j-1} dx_{j+1} \dots dx_n$, вытекающего из условия согласованности.

Итак, в не зависимости от вида выбранной функции потерь в рамках байесовского подхода необходимо располагать апостериорной плотностью $f(\mathbf{x}/y)$. А алгоритм нахождения оценок, как и их свойства в значительной степени зависят от вида выбранной функции потерь [66, 72, 73].

Для **традиционной постановки** требуется, располагая значением вектора y , найти оценку $\tilde{\mathbf{x}}(y)$, минимизирующую критерий [72, 114, 116]

$$J = M[(\mathbf{x} - \tilde{\mathbf{x}}(y))^T (\mathbf{x} - \tilde{\mathbf{x}}(y))] = M\|\mathbf{x} - \tilde{\mathbf{x}}(y)\|^2 = \iint \|\mathbf{x} - \tilde{\mathbf{x}}(y)\|^2 f(\mathbf{x}, y) d\mathbf{x} dy, \quad (1.6)$$

где M – знак математического ожидания, соответствующий плотности $f(\mathbf{x}, y)$.

В этом подходе для построения оптимальных алгоритмов требуется знание априорной информации об оцениваемых процессах и ошибках их измерений, когда предположения о статистической природе динамических процессов различны.

1.2.2. Небайесовский подход

В задаче оценивания при небайесовском подходе вектор $\mathbf{x}$ неслучайный и детерминированный. В качестве минимизируемого критерия используется величина $r^{\mathbf{x}}(\mathbf{x})$, характеризующая условные потери при фиксированном значении оцениваемого вектора. При функции потерь $L(\mathbf{x} - \tilde{\mathbf{x}}(y))$, задаваемой в виде (1.5), $r^{\mathbf{x}}(\mathbf{x})$ определяется как [66, 72, 73]

$$r^{\mathbf{x}}(\mathbf{x}) = \int (\mathbf{x} - \tilde{\mathbf{x}}(y))^T (\mathbf{x} - \tilde{\mathbf{x}}(y)) f(y/\mathbf{x}) dy,$$

и оценка $\tilde{\mathbf{x}}(y)$ отыскивается исходя из минимизации условного по отношению к $\mathbf{x}$ риска.

При решении задач в рамках небайесовского подхода стремятся использовать такие процедуры, которые обеспечивали бы нахождение оценок, близких по своим свойствам к несмещенным оценкам с минимальной дисперсией. В наибольшей степени этим требованиям удовлетворяет получившая широкое распространение процедура, основанная на максимизации функции правдоподобия. При ее использовании оценка определяется как [66, 72, 73]

$$\tilde{\mathbf{x}}^M(\mathbf{y}) = \arg \max_{\mathbf{x}} f(\mathbf{y} / \mathbf{x}). \quad (1.7)$$

Эта оценка обладает следующими основными свойствами: состоятельна; в асимптотике при $m \rightarrow \infty$ она не смещена, нормальна (имеет гаусовское распределение) и эффективна.

При данном подходе необходимо располагать функцией плотности распределения вероятностей (ф.п.р.в.) $f(\mathbf{v})$, а вектор $\mathbf{x}$ должен быть неслучаен и детерминирован [66, 72, 73].

1.2.3. Метод наименьших квадратов

В тех ситуациях, когда статистический характер $\mathbf{x}$ и $\mathbf{v}$ не предполагается, либо ограничиваются заданием для этих векторов только двух моментов: математического ожидания $\bar{\mathbf{x}}$ и матрицы ковариаций $\mathbf{P}$, задачу оценивания решают на основе метода наименьших квадратов [66, 72, 73].

При таком подходе, в частности для измерений вида $\mathbf{y} = \mathbf{s}(\mathbf{x}) + \mathbf{v}$, оценки отыскивают исходя из условия минимизации некоторой функции $\Pi(\mathbf{x})$, характеризующей меру близости между измерениями и вычисленными значениями функции $\mathbf{s}(\mathbf{x})$, т.е.

$$\tilde{\mathbf{x}}(\mathbf{y}) = \arg \min_{\mathbf{x}} \Pi(\mathbf{x}).$$

Функция $\Pi(\mathbf{x})$ определяется как [66, 72]

$$J(\mathbf{x}) = (\mathbf{y} - \mathbf{s}(\mathbf{x}))^T (\mathbf{y} - \mathbf{s}(\mathbf{x})).$$

$$\hat{\mathbf{x}}^{\text{МНК}} = \arg \min_{\mathbf{x}} (\mathbf{y} - \mathbf{s}(\mathbf{x}))^T (\mathbf{y} - \mathbf{s}(\mathbf{x})).$$

1.2.4. Рекуррентные алгоритмы оценивания. Фильтр Калмана

Прежде чем перейти к методам решения задач нелинейной фильтрации случайных последовательностей с использованием фильтра Калмана, предварительно рассмотрим решение для линейной задачи оценивания вектора состояния, как это представлено в работах [66, 67, 69, 70].

Предположим, что в каждый дискретный момент времени $i = 1, 2, \dots$ требуется оценить значения n -мерной гауссовской случайной последовательности $\mathbf{x}_i = (\mathbf{x}_{1i}, \dots, \mathbf{x}_{ni})^T$, формируемой в виде

$$\mathbf{x}_i = \Phi_i \mathbf{x}_{i-1} + \mathbf{w}_i, \quad (1.8)$$

по m -мерным измерениям $\mathbf{y}_i = (\mathbf{y}_{1i}, \dots, \mathbf{y}_{mi})^T$, определяемым как

$$\mathbf{y}_i = \mathbf{H}_i \mathbf{x}_i + \mathbf{v}_i, \quad (1.9)$$

где $\Phi_i, \mathbf{H}_i$ – известные матрицы соответствующей размерности; $\mathbf{w}_i$ и $\mathbf{v}_i$ n - и m -мерные центрированные гауссовские бел шумные последовательности с матрицами ковариаций $\mathbf{Q}_i$ и $\mathbf{R}_i$. Считается, что значения последовательности $\mathbf{x}_0$ в начальный момент времени представляют собой гауссовский центрированный случайный n -мерный вектор с матрицей ковариаций $\mathbf{P}_0$ и при этом предполагается, что порождающие $\mathbf{w}_i$ и измерительные $\mathbf{v}_i$ шумы, а также начальное значение $\mathbf{x}_0$ между собой статистически независимы.

Важно подчеркнуть, что в данной постановке фактически считается известной совместная ф.п.р.в. $f(\mathbf{x}_0, \mathbf{w}_i, \mathbf{v}_i)$ векторов $\mathbf{x}_0, \mathbf{w}_i = [\mathbf{w}_1^T, \mathbf{w}_2^T, \dots, \mathbf{w}_i^T]^T$

и $\mathbf{v}_i = [\mathbf{v}_1^T, \mathbf{v}_2^T, \dots, \mathbf{v}_i^T]^T$. Это действительно так, поскольку в силу отмеченной независимости между собой векторов $\mathbf{x}_0$, $\mathbf{w}_i$ и $\mathbf{v}_i$

$$f(\mathbf{x}_0, \mathbf{w}_i, \mathbf{v}_i) = f(\mathbf{x}_0) f(\mathbf{w}_i) f(\mathbf{v}_i),$$

причем ф.п.р.в. $f(\mathbf{x}_0)$, $f(\mathbf{w}_i)$ и $f(\mathbf{v}_i)$ является гауссовскими, соответствующими центрированным векторам с заданными матрицами ковариаций. Так что $f(\mathbf{x}_0, \mathbf{w}_i, \mathbf{v}_i)$ также является известной гауссовской ф.п.р.в.

При нахождении оптимальной в среднеквадратическом смысле оценки (оценки с минимальной дисперсией ошибки), используется критерий вида

$$J_i = M[(\mathbf{x}_i - \tilde{\mathbf{x}}_i(\mathbf{y}_i))^T (\mathbf{x}_i - \tilde{\mathbf{x}}_i)] = M\|(\mathbf{x}_i - \tilde{\mathbf{x}}_i(\mathbf{y}_i))\|^2, \quad (1.10)$$

где $\tilde{\mathbf{x}}_i(\mathbf{y}_i)$ – оценка в текущий момент времени, полученная с использованием всего набора измерений $\mathbf{y}_i = [\mathbf{y}_1^T, \mathbf{y}_2^T, \dots, \mathbf{y}_i^T]^T$, M – знак математического ожидания.

Из теории оценивания известно, что оптимальная в среднеквадратическом смысле оценка, минимизирующая критерий (1.10), и соответствующая ей апостериорная матрица ковариаций ошибок оценивания при сделанных предположениях могут быть найдены с помощью приводимого ниже дискретного фильтра Калмана. В дискретном ФК, как правило, выделяется два блока: блок прогноза и блок обновления.

В блоке прогноза с использованием оптимальной оценки вектора состояния для предыдущего момента времени $\tilde{\mathbf{x}}_{i-1}$ и матрицы динамики Φ_i находится прогноз вектора $\tilde{\mathbf{x}}_{i/i-1}$ и матрица ковариаций $\mathbf{P}_{i/i-1}$ его ошибок

$$\tilde{\mathbf{x}}_{i/i-1} = \Phi_i \tilde{\mathbf{x}}_{i-1}, \quad (1.11)$$

$$\mathbf{P}_{i/i-1} = \Phi_i \mathbf{P}_{i-1} \Phi_i^T + \mathbf{Q}_i. \quad (1.12)$$

В блоке обновления с использованием значений прогноза $\tilde{\mathbf{x}}_{i/i-1}$ и текущего измерения $\mathbf{y}_i$ вычисляется оптимальная оценка вектора состояния для текущего момента времени $\tilde{\mathbf{x}}_i$ и матрица ковариаций $\mathbf{P}_i$ ее ошибок

$$\tilde{\mathbf{x}}_i = \tilde{\mathbf{x}}_{i/i-1} + \mathbf{K}_i(\mathbf{y}_i - \mathbf{H}_i\tilde{\mathbf{x}}_{i/i-1}), \quad (1.13)$$

$$\mathbf{P}_i = \mathbf{P}_{i/i-1} - \mathbf{P}_{i/i-1}\mathbf{H}_i^T(\mathbf{H}_i\mathbf{P}_{i/i-1}\mathbf{H}_i^T + \mathbf{R}_i)^{-1}\mathbf{H}_i\mathbf{P}_{i/i-1} = (\mathbf{E} - \mathbf{K}_i\mathbf{H}_i)\mathbf{P}_{i/i-1}, \quad (1.14)$$

где $\mathbf{K}_i$ - матрица коэффициентов усиления, определяемая как

$$\mathbf{K}_i = \mathbf{P}_{i/i-1}\mathbf{H}_i^T(\mathbf{H}_i\mathbf{P}_{i/i-1}\mathbf{H}_i^T + \mathbf{R}_i)^{-1}. \quad (1.15)$$

На первом шаге предполагается, что $\tilde{\mathbf{x}}_0 = M[\mathbf{x}_0] = 0$.

Для дальнейшего весьма важным представляется вопрос об объеме и характере априорной информации, привлекаемой при построении алгоритма.

Из приведенной постановки следует, что заданными являются уравнения (1.8), (1.9), описывающие динамику изменения оцениваемой последовательности $\mathbf{x}_i$ и связь измеряемой последовательности $\mathbf{y}_i$ с $\mathbf{x}_i$ и ошибками измерений $\mathbf{v}_i$. Кроме того, известной предполагается совместная функция плотности распределения вероятностей $f(\mathbf{x}_0, \mathbf{w}_i, \mathbf{v}_i)$. Заметим, что фактически заданной является совместная ф.п.р.в. $f(\mathbf{x}_0, \mathbf{x}_i, \mathbf{y}_i)$, которая может быть легко определена с использованием уравнений (1.8), (1.9), ф.п.р.в. $f(\mathbf{x}_0, \mathbf{w}_i, \mathbf{v}_i)$ и правил преобразований линейных векторов.

Приведенный алгоритм (1.10)-(1.15) может быть получен и при наличии менее подробной априорной информации. Так можно считать, что известны лишь уравнения (1.8), (1.9) и для векторов $\mathbf{x}_0$ и $\mathbf{w}_j$, $\mathbf{v}_j$ заданы матрицы ковариаций $\mathbf{P}_0$, $\mathbf{Q}_j$ и $\mathbf{R}_j$, $j = \overline{1, l}$, причем эти векторы считаются центрированными и независимыми между собой. Фактически это означает, что заданными являются лишь первые два момента $f(\mathbf{x}_0, \mathbf{x}_i, \mathbf{y}_i)$. Из теории оценивания известно, что в этом случае представленный алгоритм обеспечивает минимизацию выбранного критерия в классе линейных относительно измерений оценок [66, 67, 69].

В то же время заметим, что круг задач обработки информации, в которых теория линейной фильтрации может быть использована без их предварительного упрощения, достаточно ограничен. Обычно это задачи

первичной обработки, направленные на сглаживание информации, поступающей, например, от навигационных датчиков. Как правило, они сводятся к фильтрации стационарных процессов на фоне помехи в виде стационарного процесса при наличии или отсутствии белого шума. Во всех остальных случаях исходная постановка задач обработки сводится к задаче фильтрации случайных последовательностей по измерениям. Поэтому расширенный фильтр Калмана (РФК) получил широкое распространение на практике при решении задач обработки навигационной информации [66, 69].

Рассмотрев теоретические положения по традиционным методам оценивания, можно сделать следующий вывод:

- численная реализация традиционных нелинейных методов оценивания оказывает значительные вычислительные трудности;
- для построения оптимальных алгоритмов требуется знание априорной информации об оцениваемых процессах и ошибках их измерений, хотя предположения о статистической природе динамических процессов различны;
- при использовании ФК требуется знание математической модели и должна быть известна совместная ф.п.р.в.

Поэтому задача дальнейшего исследования заключается в предложении альтернативных методов решения нелинейных задач оценивания.

1.3. Методы оценивания на основе искусственных нейронных сетей и нечетких систем

1.3.1. Метод оценивания на основе искусственных нейронных сетей

По искусственным нейронным сетям много литературы как отечественной, так и зарубежной, они нашли обширное практическое применение в разных областях науки [3–4, 26, 27, 36, 41–43, 46, 47, 55, 58, 59,

61, 67, 69, 70, 76, 77, 83, 90, 91, 94, 101, 102, 108, 109, 112–116]. Одна из возможных классификаций искусственных нейронных сетей (НС) по характеру связей [5] приводится на рисунке 1.2.




Рисунок 1.2 – Классификация НС

Основные достоинства и недостатки при использовании НС для решения задач обработки информации можно выделить следующие [3–5, 46, 47, 117, 120, 121, 124].

Достоинства:

1. Способность к обучению.
2. Возможность успешного решения сложных в вычислительном отношении задач.
3. Распараллеливание обработки информации.
4. Применение сети с радиально базисными функциями (РБФ) с одним скрытым слоем снимает остроту вопроса проектирования структуры НС.

Недостатки:

1. Сетям с РБФ присущи недостатки, связанные с ее излишней громоздкостью.
2. Потребность значительного времени для обучения. Трудоемкость обучения при большой выборке.

3. Отсутствие теории выбора типа НС для решения задачи обработки информации.

4. Сложность извлечения приобретенных знаний из обученной НС.

Для нелинейной задачи оценивания НС нашли свое применение лишь в последние два десятилетия. В работах [3, 4, 36, 67–70, 94, 101, 102, 107, 112–116] для решения сложных в вычислительном отношении задач нелинейного оптимального оценивания исследуется возможность применения искусственных НС. Если процесс является нелинейным, НС является мощным средством решения задачи оценивания и прогнозирования, так как нелинейная обработка сигнала предполагается самой архитектурой НС [83].

Из всех архитектур НС наибольшее внимание было уделено применению хорошо изученных многослойных сетей **прямого распространения** [47, 69, 83, 94, 102, 114, 116]. НС с прямыми связями для задачи оценивания рассматривались в работах Ефименко В.С., Харисова В.Н., Стребкова Е.Г.; Перова А.И. и Соколова Г.Г.; Степанова О.А. и Амосова О.С.; Alessandri A., Parisini T., and Zoppoli R.; Parlos A.G., Menon S.K., and Atiya A.F. [36, 58, 67–70, 91, 94, 113–116].

НС представляет собой обладающую определенной топологией структуру соединенных между собой нейронов. Под нейроном понимается специального вида скалярная функция многих переменных, которая может быть записана в виде [27, 41, 47, 101, 102]

$$y(\mathbf{u}) = \varphi \left(\sum_{j=1}^N (\alpha_j u_j) + \alpha_0 \right),$$

где $\mathbf{u} = [u_1 \ \dots \ u_N]^T$ – входной вектор-столбец; $\alpha_0, \alpha_j, j = \overline{1.N}$ – смещения и веса нейрона; $\varphi(\cdot)$ – нелинейная функция скалярного аргумента, называемая активационной характеристикой нейрона. При синтезе НС существуют два основных этапа: определение структуры сети и ее обучение [69, 116].

Неизвестно какой из алгоритмов обучения является наиболее быстрым для данной задачи. Это будет зависеть от многих факторов, включая сложность

и размерность поставленной задачи, число параметров обучающей выборки, количество смещений и весовых коэффициентов, значение ошибки [99]. Алгоритмы отличаются друг от друга способом настройки синаптических весов нейронов. В целом, для сетей, которые содержат до нескольких сотен весовых коэффициентов, алгоритм Левенберга-Маркварда (Levenberg-Marquardt) имеет быструю сходимость. Метод Квази-Ньютона (Quasi-Newton) используется для сетей среднего размера и считается быстрым в выполнении. Этот алгоритм требует хранения матрицы Гессе, но он быстрее, чем алгоритм сопряженных градиентов (Scaled Conjugate Gradient). Алгоритм Пауэлла-Била (Powell-Beale) также требует хранения большого количества данных и имеет быструю сходимость. В алгоритмах наискорейшего спуска (Rprop) и сопряженных градиентов (Scaled Conjugate Gradient) требуется небольшая память для хранения данных, поэтому они выполняются достаточно быстро, и могут использоваться для задач с большим количеством значений. Алгоритм обучения с переменной скоростью обучения (Variable Learning Rate) гораздо медленнее, чем другие методы, и имеет примерно такие же характеристики хранения данных, как и алгоритм наискорейшего спуска (Rprop), но он может быть полезен для таких ситуаций, в которых необходимо медленное схождение. Например, при досрочном прекращении работы возможны противоречивые результаты при использовании алгоритмов, которые сходятся слишком быстро. Таким образом, правильный выбор алгоритма обучения для поставленной задачи при решении минимизирует значение ошибки [99].

В работе Haykin S., and Yee P. [102] предлагается использовать сети с **радиальными базисными функциями (РБФ)** — Radial Basis Function Network (RBFN). Нейронная сеть с РБФ представляет собой двухслойную сеть без обратных связей, которая содержит единственный скрытый слой радиально симметричных шаблонных нейронов – шаблонный слой [46, 47, 58, 83, 105]. Но при этом применение этих сетей для оценивания динамических систем осталось до конца не изучено, хотя они имеют ряд очевидных преимуществ перед вышеуказанными сетями [47, 83, 105]:

1) они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя, тем самым избавляя нас от необходимости решать вопрос о числе слоев;

2) параметры линейной комбинации в выходном слое можно полностью оптимизировать с помощью хорошо известных методов линейной оптимизации, которые работают быстро и не испытывают трудностей с локальными минимумами, так мешающими при обучении с использованием алгоритма обратного распространения ошибки. Поэтому сеть РБФ обучается очень быстро.

Недостатки сетей РБФ: данные сети обладают плохими экстраполирующими свойствами и получаются громоздкими при большой размерности вектора входов [46, 47].

Для того чтобы шаблонный слой был радиально-симметричным, необходимо выполнение следующих условий [46, 47]:

- наличие центра, представленного в виде вектора во входном пространстве; обычно этот вектор сохраняется в пространстве весов от входного слоя к слою шаблонов;
- наличие способа измерения расстояния входного вектора от центра; обычно это стандартное евклидово расстояние;
- наличие специальной функции прохождения от одного аргумента, которая определяет выходной сигнал нейрона путем отображения функции расстояния.

Нейросетевой рекуррентный алгоритм фильтрации. В работах Lo J. T.-H. и Parlos A.G., Menon S.K., and Atiya A.F. [107, 112] рассматриваются возможности нелинейных рекуррентных НС. Интерес представляет то, что в работе [69] доказано, что рекуррентный ФК можно трактовать как обученный «с учителем» (в соответствии с описанной процедурой) рекуррентный линейный нейросетевой алгоритм.

При построении этих алгоритмов, основанных на применении НС, можно выделить следующие основные этапы [69, 112, 113]:

1) Сначала выбирается структура алгоритма и определяется топология предполагаемых к использованию в нем НС (число слоев, число нейронов в каждом слое, связи между ними).

2) Затем конкретизируется процедура обучения, которую предлагается использовать при определении настраиваемых параметров НС – весов и смещений.

3) После этого проводится непосредственное обучение нейросетевого алгоритма и его тестирование. Только после этого алгоритм может быть использован для решения задачи в штатном режиме.

4) Выделяется шаг прогноза и обновления. При этом прогноз вычисляется согласно

$$\tilde{\mathbf{x}}_{i/i-1}^{HC} = \Phi_i \tilde{\mathbf{x}}_{i-1}^{HC}, \quad (1.16)$$

а оценка на шаге обновления определяется как

$$\tilde{\mathbf{x}}_i^{HC} = \mathbf{K}_i^{HC}(\tilde{\mathbf{x}}_{i/i-1}^{HC}, \varepsilon_i^{HC}, \tilde{\mathcal{G}}_i), \quad (1.17)$$

где $\mathbf{K}_i^{HC}(\tilde{\mathbf{x}}_{i/i-1}^{HC}, \varepsilon_i^{HC}, \tilde{\mathcal{G}}_i)$ – нейронная сеть с массивом смещений и весовых коэффициентов $\tilde{\mathcal{G}}_i$; ε_i^{HC} – невязка, определяемая как

$$\varepsilon_i^{HC} = \mathbf{y}_i - \mathbf{H}_i \tilde{\mathbf{x}}_{i/i-1}^{HC}. \quad (1.18)$$

На первом шаге, как и в традиционном алгоритме, полагаем, что $\tilde{\mathbf{x}}_0^{HC} = 0$. Таким образом, на очередном шаге на вход НС поступает прогноз (1.16), определенный с использованием оценок $\tilde{\mathbf{x}}_{i-1}^{HC}$, выработанных на предыдущем шаге и невязка измерений (1.18).

Определение НС, т.е. конкретизация вида функции $\mathbf{K}_i^{HC}(\tilde{\mathbf{x}}_{i/i-1}^{HC}, \varepsilon_i^{HC}, \tilde{\mathcal{G}}_i)$.

Для удобства дальнейшего изложения вводится $q = n + m$ -мерный входной вектор НС $\mathbf{z}_i$ в виде

$$\mathbf{z}_i = [\mathbf{z}_{1i} \quad \dots \quad \mathbf{z}_{qi}]^T \equiv \left[\left(\tilde{\mathbf{x}}_{i/i-1}^{HC} \right)^T, \left(\varepsilon_i^{HC} \right)^T \right]^T, \quad (1.19)$$

тогда вместо (1.17):

$$\tilde{\mathbf{x}}_i^{HC} = \mathbf{K}_i^{HC}(\mathbf{z}_i, \tilde{\mathcal{G}}_i). \quad (1.20)$$

Процедура обучения НС проводится «с учителем». Это означает, что имеется n_o независимых между реализаций случайных векторов

$$\{(\mathbf{x}_0^{(j)}), \mathbf{y}_i^{(j)}, \mathbf{x}_i^{(j)}\}, j = 1..n_o, \quad (1.21)$$

с ф.п.р.в. $f(\mathbf{x}_0, \mathbf{x}_i, \mathbf{y}_i)$.

Критерий обучения $J_i(\tilde{\mathcal{G}}_i)$ на шаге i :

$$J_i(\tilde{\mathcal{G}}_i) = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_i^{HC(j)}(\mathbf{z}_i^{(j)}, \tilde{\mathcal{G}}_i) \right\|^2, \quad (1.22)$$

где входной вектор $\mathbf{z}_i^{(j)}$ определяется как $\mathbf{z}_i^{(j)} = [(\tilde{\mathbf{x}}_{i/i-1}^{HC(j)})^T, (\varepsilon_i^{HC(j)})^T]^T$.

Существенно, что

$$\begin{aligned} \tilde{\mathbf{x}}_{i/i-1}^{HC(j)} &= \Phi_i \tilde{\mathbf{x}}_{i-1}^{HC(j)}(\mathbf{z}_{i-1}^{(j)}, \tilde{\mathcal{G}}_{i-1}); \\ \varepsilon_i^{HC(j)} &= \mathbf{y}_i^{(j)} - \tilde{\mathbf{y}}_{i/i-1}^{HC(j)} = \mathbf{y}_i^{(j)} - \mathbf{H}_i \tilde{\mathbf{x}}_{i/i-1}^{HC(j)}, \end{aligned}$$

где $\tilde{\mathbf{x}}_{i-1}^{HC(j)}(\mathbf{z}_{i-1}^{(j)}, \tilde{\mathcal{G}}_{i-1})$ – оценки, на предыдущем шаге $i-1$, рассчитанные с помощью обученной НС.

Определение структуры и процедуры обучения рекуррентного алгоритма фильтрации было описано в работе [69] для линейной НС.

Нейросетевой алгоритм возможно применять для решения как нестационарных так и стационарных задач фильтрации, имеющих установившийся режим. Для стационарных задач запоминание одинаковой для всех моментов времени матрицы весов и выборочной матрицы ковариаций не составит какой-либо проблемы. Если оцениваемые последовательности и ошибки их измерения отличны от гауссовских, то существенно, что линейный нейросетевой алгоритм обеспечит нахождение оптимальных в среднеквадратическом смысле оценок в классе линейных алгоритмов [69].

Представляется перспективным дальнейшее исследование эффективности применения НС как с РБФ, так и НС прямого распространения для многомерных задач оптимального нелинейного оценивания.

Нерешенные задачи при использовании НС для оценивания.

1. В работах [36, 68, 76, 91, 102, 107, 112] основное внимание уделяется исследованию эффективности использования НС различных типов для оценивания. Но нет сопоставительного анализа с традиционными методами оценивания и выявления достоинств и недостатков нейросетевых алгоритмов по сравнению с традиционными.

2. В работах авторов [3, 4, 67–70, 94, 113–116] дан сопоставительный анализ нейросетевых, традиционных байесовских алгоритмов и алгоритмов на основе МНК, показаны преимущества и недостатки этих алгоритмов.

3. В работах [46, 47, 83, 105] рассматривается применение сетей РБФ для оценивания состояния динамических систем, но не представлена их реализация.

Доказана эквивалентность ФК и НС в работах [3, 4, 69].

Подведем итоги представленного выше критического обзора по применению НС для оценивания. Отметим следующее:

- Задачи повышения быстродействия алгоритмов обучения и оценивания не рассматривались.
- Не исследовалось влияние существующих алгоритмов обучения на точность и время обучения нейронных сетей, выбранных для оценивания.
- Не решалась задача построения эффективных декомпозиционных структур алгоритмов оценивания и не выявлялись закономерности увеличения быстродействия декомпозиционных синтетических систем оценивания при сохранении их точности.

1.3.2. Метод оценивания на основе нечетких систем

Работ посвященных применению для оценивания и фильтрации нечетких систем по сравнению с нейронными сетями значительно меньше. Хотя теория нечетких множеств дает эффективный инструмент для подобного

моделирования [1–5, 15, 44, 47, 48, 53, 56, 59, 61, 71, 85, 86, 92, 110, 118, 119]. На данный момент нечеткая логика рассматривается как стандартный метод моделирования и проектирования.

Отметим **достоинства и недостатки** нечетких систем (НчС) при проектировании систем [3, 4, 46, 47, 85].

Достоинства:

1. Легкость объяснения получаемых выводов.
2. Способность функционировать в условиях неопределенности.

Недостатки:

1. Не могут автоматически приобретать знания для использования их в механизмах выводов.

2. Нечеткие правила формулируются экспертом-человеком, поэтому могут оказаться неполными или противоречивыми.

3. Определение параметров функций принадлежности не всегда отражают реальную действительность.

4. Трудности при генерации обучения при количестве входов больше 5-6.

Используемый в различного рода экспертных и управляющих системах механизм нечетких выводов в своей основе имеет базу знаний, формируемую специалистами предметной области в виде совокупности нечетких предикатных правил вида:

Π_1 : если x есть A_1 , то y есть B_1 ;

Π_2 : если x есть A_2 , то y есть B_2 ;

.....

Π_k : если x есть A_k , то y есть B_k ,

где x – входная переменная (имя для известных значений данных); y – переменная вывода (имя для значения данных, которое будет вычислено); A и B – функции принадлежности, определенные на x и y .

На практике используются алгоритмы вывода Mamdani, Tsukamoto, Sugeno, Larsen. Наибольшее применение для оценивания получил алгоритм Сугено (Sugeno) [1–5, 15, 46, 47, 58, 71, 92]. Рассмотрим его подробнее.

Алгоритм Sugeno. Sugeno и Takagi использовали набор правил в следующей форме (на примере двух правил) (рисунок П.1 в Приложении А):

$$П_1: \text{ если } x \text{ есть } A_1 \text{ и если } y \text{ есть } B_1, \text{ то } z = a_1x + b_1y;$$

$$П_2: \text{ если } x \text{ есть } A_2 \text{ и если } y \text{ есть } B_2, \text{ то } z = a_2x + b_2y.$$

1) *Введение нечеткости.* Находятся степени истинности для предпосылок каждого из правил $A_1(x_0)$, $A_2(x_0)$, $B_1(y_0)$, $B_2(y_0)$.

2) *Нечеткий вывод.* Находятся уровни «отсечения» $\alpha_1 = A_1(x_0) \wedge B_1(y_0)$, $\alpha_2 = A_2(x_0) \wedge B_2(y_0)$ и индивидуальные выходы правил:

$$z_1^* = a_1x_0 + b_1y_0; \quad z_2^* = a_2x_0 + b_2y_0.$$

3) *Определяется четкое значение выходной переменной:*

$$z_0 = \frac{\alpha_1 z_1^* + \alpha_2 z_2^*}{\alpha_1 + \alpha_2}. \quad (1.23)$$

При численной реализации НчС удобным оказывается использование адаптивной сети нечеткого вывода (Adaptive-Network-Based Fuzzy Inference System – ANFIS) [1, 5, 46, 47]. В основу функции ANFIS положен один из первых методов построения нейро-нечетких систем для аппроксимации функций, предложенный в 1991 году Янгом (Jang). Для идентификации параметров системы нечеткого логического вывода типа Сугено функция ANFIS использует метод обратного распространения ошибки, а также гибридный алгоритм, основанный на комбинации метода обратного распространения ошибки и метода наименьших квадратов. Функция ANFIS может использовать дополнительный аргумент для проверки модели – тестирующую выборку. ANFIS является одним из первых вариантов гибридных нейронечетких сетей. В нейронечетких сетях используются дифференцируемые реализации треугольных норм (умножение и вероятностное ИЛИ), а также гладкие функции принадлежности. Это позволяет применять для настройки

нейронечетких сетей быстрые алгоритмы обучения нейронных сетей, основанные на методе обратного распространения ошибки [85, 86].

Настройка систем нечеткого логического вывода представляет собой итерационную процедуру нахождения параметров функций принадлежности, которые минимизируют расхождения между результатами логического вывода и экспериментальными данными, т.е. между действительным и желаемым поведением системы. Экспериментальные данные, по которым настраиваются функции принадлежности, представляются в виде обучающей выборки [46, 47].

Нечеткая НС, реализующая приведенный механизм вывода, представлена на рисунке П.2 (Приложение В). Узлы данной нечеткой НС формируются с помощью нейронов в виде пятислойной нейронной сети прямого распространения. Назначение слоев: первый слой – термы входных переменных; второй слой – посылки нечетких правил; третий слой – нормализация степеней выполнения правил; четвертый слой – заключения правил; пятый слой – агрегирование результата, полученного по различным правилам. Входы сети в отдельный слой не выделяют [85, 86].

Нерешенные задачи при использовании НЧС для оценивания.

Представим итоги проведенного критического обзора по применению НЧС для оценивания:

Применению нечетких систем для решения задач оценивания посвящены работы [1–4, 15, 56, 71, 92], в которых отражается эффективность их использования, показаны преимущества и недостатки этих алгоритмов.

В работе [71] для решения задач нелинейного оценивания предлагается подход к построению алгоритмов, основанных на нечеткой логике. Проводится сопоставление, и обсуждаются особенности предлагаемого и байесовского подходов. Показано, что при определенных предположениях алгоритмы, получаемые в рамках двух подходов, между собой совпадают.

В работе [15] рассматривается повышение быстродействия алгоритмов обучения с использованием алгоритмов вычитающей кластеризации и кластеризации на основе нечетких центров. Доказано, что точность нечеткого

оценителя в этом случае близка к предельно достижимой и быстродействие этого алгоритма значительно выше, чем алгоритмов без кластеризации.

В указанных выше работах внимание уделяется исследованию эффективности использования НчС, проведен сопоставительный анализ с традиционными методами оценивания, выявлены достоинства и недостатки нечетких алгоритмов по сравнению с традиционными, предлагается повышение быстродействия с помощью кластеризации.

1. Но, не решалась задача построения эффективных нечетких алгоритмов оценивания с использованием базовых принципов декомпозиции.

2. При этом нет изучения закономерностей повышения быстродействия декомпозиционных нечетких систем.

Поэтому представляется перспективным использовать данные алгоритмы для решения задачи оценивания.

1.4. Метод оценивания с использованием вейвлетов

В последнее время возникло и оформилось целое научное направление, связанное с вейвлет-анализом [17, 25, 28, 35, 54, 63, 84, 87, 93, 95, 103, 111]. Вейвлеты широко применяются для фильтрации и предварительной обработки данных, анализа и прогнозирования временных рядов [7–14, 93, 95].




Рисунок 1.3 – Виды вейвлетов

На рисунке 1.3 представлены вейвлеты, которые имеют определенные свойства и подходят для решения разных задач [7–14, 28, 30–33, 87, 88].

Выделим **достоинства и недостатки** применения вейвлетов [25, 35, 63, 87, 119, 120, 123, 124].

Достоинства:

1. Локализация во времени и частоте.

Недостатки:

1. Вычисление с помощью вейвлетов требует значительного времени для обучения.

2. Слабая практическая реализация вейвлетов, т.е. отсутствие практических примеров и описания современного компьютерного «инструментария» для практического использования вейвлетов [87].

3. Для вейвлет-преобразования (ВП) нет программных средств, реализующих многомерную обработку информации.

Вейвлеты представляют собой особые функции в виде коротких волн (всплесков) с нулевым интегральным значением и с локализацией по оси независимой переменной t , способных к сдвигу по этой оси и масштабированию (растяжению/сжатию). Любой из наиболее часто используемых типов вейвлетов порождает полную ортогональную систему функций. В случае вейвлет-анализа процесса (сигнала) в связи с изменением масштаба вейвлеты способны выявить различие в характеристиках процесса на различных шкалах, а посредством сдвига можно проанализировать свойства процесса в различных точках на всем исследуемом интервале. Именно благодаря свойству полноты этой системы, можно осуществить восстановление (реконструкцию или синтез) процесса посредством обратного ВП [87].

Вейвлет-преобразование. ВП одномерного сигнала – это его представление в виде обобщенного ряда или интеграла Фурье по системе базисных функций [87]

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad (1.24)$$

сконструированных из материнского (исходного) вейвлета $\psi(t)$, обладающего определенными свойствами за счет операций сдвига во времени (b) и изменения временного масштаба (a). Множитель $1/a$ обеспечивает независимость нормы этих функций от масштабирующего числа a .

Непрерывное вейвлет-преобразование. Прямое и обратное непрерывное вейвлет-преобразование сигнала $s(t)$ имеют вид [87, 124]:

$$W_s(a, b) = (s(t), \psi_{ab}(t)) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} s(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (1.25)$$

$$s(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_s(a, b) \psi_{ab}(t) \frac{da db}{a^2},$$

где $\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right)$ – вейвлет, порождаемый материнским вейвлетом $\psi(t)$ за счет операций сдвига во времени (b) и изменения временного масштаба (a); C_ψ – нормирующий коэффициент, $(\cdot, \cdot)$ – скалярное произведение соответствующих сомножителей.

Из (1.25) следует, что вейвлет-спектр $W_s(a, b)$ (wavelet spectrum, или time-scale-spectrum – масштабно-временной спектр) в отличие от фурье-спектра является функцией двух аргументов: первый аргумент a (временной масштаб) аналогичен периоду осцилляций, т.е. обратен частоте, а второй b – аналогичен смещению сигнала по оси времени. Следует отметить, что $W_s(b, a_0)$ характеризует временную зависимость (при $a = a_0$), тогда как зависимости $W_s(a, b_0)$ можно поставить в соответствие частотную зависимость (при $b = b_0$).

Дискретное вейвлет-преобразование.

Эффективную технику обработки случайных последовательностей дает теория вейвлетов [35, 54, 63, 87, 93, 95, 111]. Одна из основополагающих идей вейвлет-представления сигнала $s(t)$ заключается в разбивке приближения $\tilde{s}_j(t)$ к сигналу на две составляющие – грубую (аппроксимирующую) $\tilde{s}_{j-1}(t)$ и

уточненную (детализирующую) $\tilde{s}_{j-1}^d(t)$, с последующим их уточнением итерационным методом [12]:

$$\tilde{s}_j(t_i) = \tilde{s}_{j-1}(t_i) + \tilde{s}_{j-1}^d(t_i) = \sum_{k \in \mathbf{Z}} a_{j-1,k} \varphi_{j-1,k}(t_i) + \sum_{k \in \mathbf{Z}} d_{j-1,k} \psi_{j-1,k}(t_i), \quad (1.26)$$

где число j характеризует уровень разрешения; $\varphi_{j-1,k}(t)$, $\psi_{j-1,k}(t)$ – масштабирующая (аппроксимирующая) и вейвлет-функция (детализирующая функция) соответственно; $\mathbf{a}_1 = \{a_{j-1,k}\}$, $\mathbf{d}_1 = \{d_{j-1,k}\}$ – наборы аппроксимирующих и детализирующих коэффициентов разложения $(j-1)$ уровня разрешения; $\mathbf{Z} = \{\dots, -1, 0, 1, \dots\}$ – множество целых чисел. Аппроксимирующие функции $\varphi(t)$ присущи далеко не всем вейвлетам, а только тем, которые относятся к ортогональным. Приближению (1.26) соответствует начальный набор коэффициентов $\mathbf{a}_0 = \{a_{j,k}\}$. Обычно в качестве $\mathbf{a}_0 = \{a_{j,k}\}$ выбирается массив значений сигнала $s(t)$, $a_{j,i} = s(t_i)$.

Повторение процедуры m раз, $m = \overline{1, M}$ с разложением каждый раз сглаженной функции $\tilde{s}_{j-m}(t_i)$ на еще более сглаженную часть $\tilde{s}_{j-m-1}(t_i)$ и детализирующую часть $\tilde{s}_{j-m-1}^d(t_i)$ дает вейвлет-разложение аппроксимации j -го уровня разрешения $\tilde{s}_j(t)$ для глубины разложения m :

$$\tilde{s}_j(t_i) = \tilde{s}_{j-m}(t_i) + \tilde{s}_{j-m}^d(t_i) + \dots + \tilde{s}_{j-1}^d(t_i), \quad (1.27)$$

$$\tilde{s}_j(t_i) = \sum_{k \in \mathbf{Z}} a_{j-m,k} \varphi_{j-m,k}(t_i) + \sum_{k \in \mathbf{Z}} d_{j-m,k} \psi_{j-m,k}(t_i) + \dots + \sum_{k \in \mathbf{Z}} d_{j-1,k} \psi_{j-1,k}(t_i) \quad (1.28)$$

Вейвлет-разложение (1.27), (1.28) можно представить в виде следующей схемы нахождения коэффициентов:

$$\tilde{s}_j(t_i) = \mathbf{a}_0 \rightarrow \{\mathbf{a}_1, \mathbf{d}_1\} \rightarrow \{\mathbf{a}_2, \mathbf{d}_2, \mathbf{d}_1\} \rightarrow \dots \rightarrow \{\mathbf{a}_M, \mathbf{d}_M, \mathbf{d}_{M-1}, \dots, \mathbf{d}_1\}. \quad (1.29)$$

Практическая работа по обработке и представлению реальных сигналов обычно базируется на трактовке ВП (1.24) в частотной области и позволяет плодотворно использовать аппарат частотной фильтрации и методы быстрого ВП [35, 63]. Они основаны на пирамидальном алгоритме Малла и прореживании спектра вейвлетов по частоте. Главным результатом является

вывод о соответствии вейвлет-коэффициентов коэффициентам передаточной характеристики низкочастотного и высокочастотного фильтров, что позволяет организовать эффективные, с точки зрения объема вычислений, процедуры вычислений коэффициентов вейвлетов.

Таким образом, при вейвлет-анализе сигнал раскладывается на аппроксимирующие коэффициенты, которые представляют сглаженный сигнал, и детализирующие коэффициенты, описывающие колебания [63]. Шумовая компонента отражается в детализирующих компонентах. Поэтому простейший способ удаления шума состоит в том, чтобы сделать нулевыми значения коэффициентов, меньшие некоторого порогового значения. Эта процедура называется пороговой обработкой (трешолдингом). Широкое распространение получили такие методы пороговой обработки, как жесткий и мягкий трешолдинг [63].

Для решения задач сглаживания, оценивания и прогноза случайных последовательностей, целесообразным оказывается использование ортогональных вейвлетов с компактным носителем, поскольку свойства данных вейвлетов обеспечивают необходимое приближение вейвлет-разложения [12–14, 87].

Нерешенные задачи при использовании вейвлетов для оценивания.

Подведем итоги представленного выше критического обзора.

Вейвлет-анализ является одним из новейших направлений в теории и практике обработки функций и сигналов [17, 25, 28, 35, 54, 63, 84, 87, 93, 95, 103, 111]. Вейвлеты перспективны в решении задач приближения (интерполяции, аппроксимации, регрессии) функций, сигналов и изображений [7–14, 93, 95, 103].

Использование вейвлетов для подавления и снижения уровня шумов, а также очищения сигнала от шума для восстановления исходного сигнала представлено в работах [28, 31–33, 88]. А для решения задачи оценивания использование вейвлетов впервые предложили в работах [12–14, 93, 95] как задачи нахождения функции регрессии. Новый способ оценивания случайных

дискретных последовательностей основан на использовании регрессионного анализа и вейвлет-преобразования. Поэтому вейвлеты выбраны для использования при решении задач оценивания.

В работах авторов [12–14, 93, 95] рассматривается применение вейвлетов для оценивания динамических систем, показаны преимущества и недостатки этих алгоритмов. Указаны проблемы применения вейвлетов для решения многомерных задач, но не было предложено способа синтеза алгоритмов оценивания. В частности, не рассматривалась возможность построения эффективных декомпозиционных структур алгоритмов оценивания с использованием вейвлетов для повышения быстродействия работы. Кроме того, проанализировав литературу, было выяснено, что до сих пор нет работ по оцениванию динамических систем с локальными особенностями с использованием вейвлетов.

Выводы по первой главе

В данной главе был проведен анализ основных положений, достоинств и недостатков традиционных методов стохастического оценивания и фильтрации. Выявлены причины, обосновывающие необходимость разработки альтернативных методов – нейросетевых, нечетких и вейвлетов. Рассмотрены основные положения данных методов применительно к решению задачи оценивания.

В итоге сравнительный анализ методов оценивания, отражающий их достоинства и недостатки, представлен в таблице 1.1.

Таблица 1.1

Методы	Недостатки	Достоинства
1	2	3
Байесовский подход	Численная реализация методов оказывает значительные вычислительные трудности. Для построения оптимальных алгоритмов требуется знание априорной информации об оцениваемых процессах и ошибках их измерений, хотя предположения о статистической природе динамических процессов различны.	Общие решения задачи. Оптимальные, точные решения
Небайесовский подход		
МНК		
ФК	Требуется знание математической модели и должна быть известна совместная функция плотности распределения вероятностей.	Реализация рекуррентных процедур, используемых при выработке оценки. Вырабатывается ковариационная матрица ошибки оценки.
Нейронные сети	Проблема в потребности значительного времени для обучения. Особенно остро такая проблема ощущается в условиях обучения в режиме on-line. Отсутствие строгой теории по выбору структурной схемы НС.	Способность к обучению. Возможность успешного решения сложных в вычислительном отношении задач. Распараллеливание обработки информации.
Нечеткие системы	Трудности при генерации обучения при количестве входов больше 5-6	Способность функционировать в условиях неопределенности
Вейвлет-анализ	Трудности при высокой размерности	Локализация во времени и частоте

В результате, перед диссертационным исследованием поставлены следующие задачи:

1. Разработать эффективный по быстродействию и точности вычислительный метод оценивания состояния динамических систем, охватывающий все процессы решения задачи оценивания.

2. Предложить математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов.

3. Разработать численные методы стохастической аппроксимации, использующих быстродействующие нейросетевые, нечеткие, вейвлет методы и декомпозиционные алгоритмы субоптимального оценивания состояния динамических систем.

4. Синтезировать быстродействующие субоптимальные нейросетевые, нечеткие и вейвлет алгоритмы оценивания состояния динамических систем с использованием декомпозиции.

5. Разработать алгоритмы на основе вейвлетов для оценивания процессов без нарушений и с нарушениями.

6. Проверить точность и быстродействие алгоритмов при решении задач оценивания.

Таким образом, целью диссертационного исследования является разработка эффективного по быстродействию и точности вычислительного метода оценивания состояния динамических систем на основе класса параметрически заданных функций с их численной реализацией на базе иерархических синтетических систем.

ГЛАВА 2. ВЫЧИСЛИТЕЛЬНЫЙ МЕТОД ОЦЕНИВАНИЯ СОСТОЯНИЯ ДИНАМИЧЕСКИХ СИСТЕМ

В настоящей главе предложен вычислительный метод оценивания состояния динамических систем с использованием класса параметрически заданных функций и декомпозиции систем оценивания на основе трех базовых представлений подсистем. Задача оценивания решается как на основе байесовского подхода, так и с помощью метода наименьших квадратов.

2.1. Постановка нелинейной задачи оценивания состояния динамической системы

Итак, пусть задан недоступный непосредственному наблюдению n -мерный динамический случайный процесс с дискретным временем $\mathbf{x}_i = [x_{1i}, \dots, x_{ni}]^T, i = 0, 1, \dots$

Требуется, располагая связанными с $\mathbf{x}_i$ значениями m -мерного случайного процесса измерений с дискретным временем $\mathbf{y}_j = [y_{1j}, \dots, y_{mj}]^T, j = \overline{1, k}$, найти оценку $\mathbf{x}_i$ для некоторого заданного i , вычисляемую с использованием набора измерений, задаваемого составным вектором $\mathbf{Y}_k = [\mathbf{y}_1^T, \dots, \mathbf{y}_{k-1}^T, \mathbf{y}_k^T]^T$ размерности $k \cdot m$. Обозначим оценку $\mathbf{x}_i$, полученную на основе измерений $\mathbf{Y}_k$, через $\tilde{\mathbf{x}}_{i/k}$ и определим ее как n -мерную вектор-функцию измерений:

$$\tilde{\mathbf{x}}_{i/k} = \mathbf{h}_i(\mathbf{Y}_k).$$

Таким образом, суть рассматриваемой задачи оценивания представляет собой задачу определения функции $\mathbf{h}_i$ некоторым рациональным и обоснованным способом [14, 119, 125].

Эта задача **нерекуррентного оценивания** легко сводится к более простой задаче оценивания одного вектора $\mathbf{x}$ по измеренным значениям другого вектора $\mathbf{y}$. Для этого достаточно предположить, что в качестве фигурирующих здесь векторов $\mathbf{x}$ и $\mathbf{y}$ выступают соответственно $\mathbf{x}_i$ и $\mathbf{Y}_i$: $\mathbf{x} \equiv \mathbf{x}_i$, $\mathbf{y} \equiv \mathbf{Y}_i = [\mathbf{y}_1^T, \dots, \mathbf{y}_{i-1}^T, \mathbf{y}_i^T]^T$.

Несмотря на кажущуюся простоту приведенной постановки задачи оценивания, к такой постановке могут быть сведены вполне конкретные прикладные задачи, например, задачи обработки навигационной информации [66, 67, 114, 115].

Итак, целью решения рассматриваемой задачи оценивания является нахождение оценки n -мерного неизвестного вектора состояния $\mathbf{x} = [x_1 \dots x_n]^T$ по m -мерному вектору измерений $\mathbf{y} = [y_1 \dots y_m]^T$.

Во многих практических задачах измерения могут быть записаны следующим образом [66]

$$\mathbf{y} = \mathbf{s}(\mathbf{x}) + \mathbf{v}, \quad (2.1)$$

где $\mathbf{s}(\mathbf{x}) = [s_1(\mathbf{x}) \dots s_m(\mathbf{x})]^T$ – m -мерная в общем случае нелинейная вектор функция векторного аргумента, которая обычно считается известной; а $\mathbf{v} = [v_1 \dots v_m]^T$ – случайный вектор, передающий наличие ошибок измерения.

2.2. Традиционное решение нелинейной задачи оценивания

Рассмотрим решение нелинейной задачи оценивания в рамках байесовского подхода и с помощью метода наименьших квадратов.

2.2.1. Байесовское решение задачи оценивания

Для **традиционной постановки** требуется, располагая значением вектора $\mathbf{y}$ (2.1), найти оценку $\tilde{\mathbf{x}}(\mathbf{y})$, минимизирующую критерий [66, 114, 116]

$$J = M[(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))] = M\|\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})\|^2 = \iint \|\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})\|^2 f(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y}, \quad (2.2)$$

где M – знак математического ожидания, соответствующий плотности $f(\mathbf{x}, \mathbf{y})$. Здесь и далее интегралы понимаются как многократные с бесконечными пределами. Известно, что оптимальная в среднеквадратическом смысле оценка, минимизирующая критерий (2.2), определяется как [66]

$$\tilde{\mathbf{x}}(\mathbf{y}) = \int \mathbf{x} f(\mathbf{x} / \mathbf{y}) d\mathbf{x}, \quad (2.3)$$

где $f(\mathbf{x} / \mathbf{y}) = f(\mathbf{x}, \mathbf{y}) / f(\mathbf{y})$ – условная (апостериорная) функция плотности распределения вероятности вектора $\mathbf{x}$, $f(\mathbf{y}) = \int f(\mathbf{x}, \mathbf{y}) d\mathbf{x}$.

Для традиционной байесовской постановки задачи оценивания оптимальная оценка $\tilde{\mathbf{x}}(\mathbf{y})$ минимизирует среднеквадратический критерий $J = M[(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))]$, где M – математическое ожидание, соответствующее ф.п.р.в. $f(\mathbf{x}, \mathbf{y})$. Оценка $\tilde{\mathbf{x}}(\mathbf{y})$, которая минимизирует критерий J определяется следующим образом [66, 70]:

$$\tilde{\mathbf{x}}^{opt}(\mathbf{y}) = \int \mathbf{x} f(\mathbf{x} / \mathbf{y}) d\mathbf{x}, \quad (2.4)$$

где $f(\mathbf{x} / \mathbf{y}) = f(\mathbf{x}, \mathbf{y}) / f(\mathbf{y})$ – апостериорная ф.п.р.в. для вектора $\mathbf{x}$; $f(\mathbf{y}) = \int f(\mathbf{x}, \mathbf{y}) d\mathbf{x}$ – ф.п.р.в. для $\mathbf{y}$. В случае (2.2) обычно, совместная ф.п.р.в. $f(\mathbf{x}, \mathbf{v})$ известна, и ф.п.р.в. $f(\mathbf{x}, \mathbf{y})$ определяется как $f(\mathbf{x}, \mathbf{y}) = f(\mathbf{x}) f_{\mathbf{v}}(\mathbf{y} - \mathbf{s}(\mathbf{x}))$, где $f_{\mathbf{v}}(\bullet)$ является ф.п.р.в. для вектора ошибок измерения $\mathbf{v}$. Обычно, $\mathbf{v}$ и $\mathbf{x}$ полагаются случайными векторами с нулевыми средними и независимыми друг от друга, т.е. $f(\mathbf{x}, \mathbf{v}) = f(\mathbf{x}) f(\mathbf{v})$.

Рекуррентное оценивание. Рассмотрим дискретные временные стохастические уравнения состояния [66, с.47]:

$$\mathbf{x}_i = \Phi_i(\mathbf{x}_{i-1}, \mathbf{w}_i), \quad (2.5)$$

где $\Phi_i(\mathbf{x}_{i-1}, \mathbf{w}_i) = (\Phi_{i1}(\mathbf{x}_{i-1}, \mathbf{w}_i), \dots, \Phi_{in}(\mathbf{x}_{i-1}, \mathbf{w}_i))^T$ – n -мерная в общем случае нелинейная относительно $\mathbf{x}_{i-1}$ и $\mathbf{w}_i$ вектор функция; $\mathbf{w}_i$ – не зависящая от x_0 n -мерная последовательность, $\mathbf{x}_i \in \mathbb{R}^n$ вектор состояния (начальное состояние неизвестно), и $\mathbf{w}_i \in \mathbb{R}^q$ – случайный шум.

Вектор состояния наблюдений через измерения шумов:

$$\mathbf{y}_i = \mathbf{s}_i(\mathbf{x}_i, \mathbf{v}_i) \quad (2.6)$$

где $\mathbf{y}_i \in \mathbb{R}^p$ это вектора наблюдений и $\mathbf{v}_i \in \mathbb{R}^r$ это случайное измерение шума. Случайные векторы x_0 , $\mathbf{w}_i$, и $\mathbf{v}_i$ определяются на подходящий вероятностный пространств.

Частный случай последовательности (2.6) задается уравнением

$$\mathbf{x}_i = \Phi_i(\mathbf{x}_{i-1}) + \Gamma_i(\mathbf{x}_{i-1})\mathbf{w}_i, \quad (2.7)$$

в котором $\Phi_i(\mathbf{x}_{i-1})$, $\Gamma_i(\mathbf{x}_{i-1})$ – известные функции, индекс снизу указывает на их зависимость от времени. Обычно в (2.7) полагают $M(\mathbf{w}_i \mathbf{w}_i^T) = \mathbf{E}$.

Наиболее широкое распространение получили гауссовские марковские последовательности [1, 66, 78], задаваемые с помощью уравнений

$$\mathbf{x}_i = \Phi_i \mathbf{x}_{i-1} + \Gamma_i \mathbf{w}_i, \quad (2.8)$$

в которых Φ_i – известные $n \times n$ матрицы, а $\mathbf{w}_i$ – гауссовский дискретный белый шум единичной интенсивности. Иногда вместо (2.8) используют уравнение

$$\mathbf{x}_i = \Phi_i \mathbf{x}_{i-1} + \mathbf{w}_i, \quad (2.9)$$

эквивалентное (2.8), если интенсивность белого шума определяется как $Q_i = \Gamma_i \Gamma_i^T$ [66, 82].

Решение задачи оценивания с помощью РФК. В случае расширенного фильтра Калмана решению подлежит задача нелинейной фильтрации

случайных последовательностей по измерениям $y_i = s_i(x_i) + v_i$ при гауссовском характере порождающих шумов w_i и v_i ошибок измерения [66]. Используется линеаризованное представление функций $\Phi_i(x_{i-1})$ и $s_i(x_i)$ в виде:

$$\Phi_i(x_{i-1}) \approx \Phi_i(x_{л1}) + \frac{\partial \Phi_i(x_{л1})}{\partial x_{i-1}^T} (x_{i-1} - x_{л1}), \quad (2.10)$$

$$s_i(x_i) \approx s_i(x_{л2}) + \frac{\partial s_i(x_{л2})}{\partial x_i^T} (x_i - x_{л2}), \quad (2.11)$$

где $x_{л1}$, $x_{л2}$ - точки линеаризации.

Для получения алгоритмов, основанных на приближениях (2.10) и (2.11), так же как и при выводе соотношений для ФК, сначала будем находить математические ожидания и матрицы ковариаций для плотностей $f(x_i / y_{i-1})$ и $f(x_i, y_i / y_{i-1})$, а затем, полагая $f(x_i, y_i / y_{i-1})$ гауссовской, вычисляем параметры апостериорной плотности $f(x_i / y_i)$. Наиболее точное линеаризованное описание функций $\Phi_i(x_{i-1})$, и $s_i(x_i)$ в окрестности истинных значений $x_{i-1}^{исT}$ и $x_i^{исT}$ будет иметь место в случае, если соответствующие производные в (2.10), (2.11) будут вычисляться непосредственно в этих точках. Поскольку их значения не известны, целесообразно в качестве точек линеаризации выбирать такие, которые меньше всего отличаются от $x_{i-1}^{исT}$ и $x_i^{исT}$. Разумно использовать $x_{л1} = \tilde{x}_{i-1}$ и $x_{л2} = \tilde{x}_{i/i-1}$.

Алгоритм фильтрации относительно измерений будет уже нелинейным, которому соответствуют следующие соотношения:

$$\tilde{x}_{i/i-1} = \Phi_i \tilde{x}_{i-1},$$

$$\tilde{x}_i = \tilde{x}_{i/i-1} + K_i(\tilde{x}_{i/i-1}, \tilde{x}_{i-1})[y_i - H_i(\tilde{x}_{i/i-1})].$$

Матрицы ковариаций $P_{i/i-1}(\tilde{x}_{i-1})$, $P_i(\tilde{x}_{i-1}, \tilde{x}_{i/i-1})$ и коэффициент усиления $K_i(\tilde{x}_{i-1}, \tilde{x}_{i/i-1})$ будут теперь зависеть от соответствующих оценок, поскольку

при использовании формул типа (1.12), (1.15), (1.14), вместо Φ_i и $\mathbf{H}_i$ следует подставлять соответственно $\frac{\partial \Phi_i(\tilde{\mathbf{x}}_{i-1})}{\partial \mathbf{x}_{i-1}^T}$ и $\frac{\partial \Phi_i(\tilde{\mathbf{x}}_{i-1})}{\partial \mathbf{x}_{i-1}^T}$.

Такой алгоритм нелинейной фильтрации называется обобщенный (расширенный) ФК [66].

2.2.2. Решение задачи оценивания с помощью метода наименьших квадратов

Если предположить, что статистика шумов неизвестна, то решение задачи оценивания может быть получена с использованием классического метода наименьших квадратов (МНК), как это сделано, например, в работе [66, 91].

В частности при использовании измерений вида [66]:

$$\mathbf{y} = \mathbf{s}(\mathbf{x}) + \mathbf{v} \quad (2.12)$$

При этом в качестве простейшего варианта может быть выбрана функция [66, 72]

$$\mathbf{I}^{MНК}(\mathbf{x}) = (\mathbf{y} - \mathbf{s}(\mathbf{x}))^T (\mathbf{y} - \mathbf{s}(\mathbf{x})) = \sum_{i=1}^m (y_i - s_i(\mathbf{x}))^2 \quad (2.13).$$

В наиболее общем случае, вводя симметричную неотрицательно определенную матрицу $\mathbf{D}$, в качестве минимизируемого наблюдаемого критерия можно использовать функцию

$$\mathbf{I}^{MMНК}(\mathbf{x}) = (\mathbf{y} - \mathbf{s}(\mathbf{x}))^T \mathbf{Q}(\mathbf{y} - \mathbf{s}(\mathbf{x})) + (\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{D}(\mathbf{x} - \bar{\mathbf{x}}), \quad (2.14)$$

которая при диагональном характере матриц $\mathbf{Q}$ и $\mathbf{D}$ примет вид

$$\mathbf{I}^{MMНК}(\mathbf{x}) = \sum_{i=1}^m q_i (y_i - s_i(\mathbf{x}))^2 + \sum_{j=1}^n d_j (x_j - \bar{x}_j)^2,$$

где $\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_n)^T$ – некоторый известный вектор.

Метод, основанный на минимизации критерия типа (2.14), называется модифицированным методом наименьших квадратов (ММНК). Смысл второго дополнительного слагаемого заключается в том, что при отличии получаемых оценок $\tilde{x}_j(\mathbf{y})$ от некоторых значений $\bar{x}_j$, устанавливается определенный штраф, уровень которого задается коэффициентами d_j , $j = \overline{1, n}$.

Из сказанного следует, что нахождение оценок, соответствующих МНК или одному из его обобщенных вариантов, сводится к отысканию минимума функций (2.13) или (2.14) [66].

2.3. Вычислительный метод оценивания с использованием синтетических систем

Несмотря на разные теоретические положения, лежащие в основе описания искусственных нейронных сетей, нечетких систем и вейвлетов, их объединяет возможность практического применения при реализации алгоритмов оценивания на основе класса нелинейных параметрически заданных функций [67, 70, 117–125]. В связи с этим появляется возможность к обобщению результатов оценивания с использованием этих подходов и возможность предложить единый вычислительный метод. Поэтому нам представляется целесообразным рассмотреть с единых позиций вычислительный метод с его реализацией на основе синтетических алгоритмов оценивания состояния динамических систем с использованием декомпозиции.

В настоящее время для решения указанной выше задачи используются искусственные нейронные сети [1–5, 36, 71, 82, 91, 101, 102, 106, 111, 112, 113, 114], нечеткие системы [1–4, 15, 56, 71, 92] и вейвлеты [12–14, 93, 95], которые могут применяться как отдельно, так и совместно в виде гибридных систем [8–11, 61]. Гибридные системы сочетают в себе гибкость и обучаемость

нейронных сетей, возможности компактного описания сигналов в частотной и временной областях, присущее вейвлетам, и возможность построения прозрачных правил вывода решений на основе аппарата нечеткой логики. Под синтетическими системами (СС) в дальнейшем и будем понимать перечисленные выше конструкции (Рисунок 2.1).




Рисунок 2.1 – Синтетические системы

Фильтры могут быть реализованы как фильтры с конечной и растущей памятью [60]. В дальнейшем будут рассматриваться синтетические системы оценивания как фильтры с растущей памятью. Фильтры, в которых оценка вырабатывается по всей предыстории входного процесса, называются *фильтрами с растущей памятью*, поскольку число измерений, участвующих в формировании оценки, с увеличением i неограниченно возрастает. Фильтры с растущей памятью могут быть как нерекуррентными так и рекуррентными. Схема фильтра с растущей памятью представлена на рисунке 2.2. Примером рекуррентного фильтра с растущей памятью является фильтр Калмана. При ограничении памяти фильтра в зависимости от способа различают фильтры с эффективной конечной памятью и экспоненциальный фильтр Калмана [60].




Рисунок 2.2 – Схема фильтра с растущей памятью

Если для вычисления оценок в фильтре используются только N последних измерений, такие фильтры называются фильтрами с конечной памятью (рисунок 2.3). Например, фильтры второго порядка называемые $\alpha\beta$ -фильтрами, и фильтры третьего порядка, известные в литературе как $\alpha\beta\gamma$ -фильтры [60].




Рисунок 2.3 – Схема фильтра с конечной памятью

Действия, выполняемые фильтром Калмана, иллюстрируются схемой на рисунке 2.4, в которой элемент задержки осуществляет запоминание предыдущей, $(i-1)$ -й, оценки до следующего, i -го, шага. Рисунок 2.4, как и поясняемый им рекуррентный (разностный) алгоритм, показывает, что фильтр Калмана является характерным примером линейной дискретной замкнутой астатической системы регулирования с переменными параметрами. Ее чувствительный элемент (дискриминатор) вырабатывает сигнал рассогласования (невязку) входных данных y_i и данных, поступающих по цепи обратной связи $\tilde{y}_{i/i-1}^{SS}$. После взвешивания, рассогласование суммируется с ранее накопленным результатом, что эквивалентно введению в замкнутый контур интегратора, исключаяющего статистическую ошибку.




Рисунок 2.4 – Схема фильтра Калмана

На рисунке 2.4 H_i - матрица измерений, Φ_i – матрица динамики и БЗ – база знаний. Сопоставление рисунка 2.4 фильтра Калмана с третьим принципом декомпозиции показывает, что структура фильтра Калмана вытекает из этого принципа.

2.3.1. Байесовский подход

Отличительная особенность байесовской постановки задачи оценивания заключается в том, что априорная информация об оцениваемом векторе $\mathbf{x}$ и используемых измерениях $\mathbf{y}$ задается либо в виде их совместной функции плотности распределения вероятностей (ф.п.р.в.) $f(\mathbf{x}, \mathbf{y})$, что характерно для традиционной постановки [66], либо в виде согласованного набора реализаций

$$\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}_{j=1}^N, \quad (2.15)$$

что характерно для постановки задачи оценивания с использованием настраиваемых, обучаемых систем, например, нейронных сетей и нечетких систем [1–4, 15, 67, 68, 70, 71]. Согласованность здесь понимается в том смысле, что они представляют независимые между собой реализации составного случайного вектора с одной и той же ф.п.р.в. $f(\mathbf{x}, \mathbf{y})$.

В случае обучающих множеств для решения задачи оценивания с использованием синтетических систем можно использовать подход, реализованный с помощью нейронных сетей, который более подробно рассмотрим в п. 2.3.3.

Нерекуррентное оценивание. Для решения задачи оценивания, описанной в п. 2.1. в рамках байесовского подхода, предлагается вычислительный метод оценивания с его реализацией на основе синтетических алгоритмов оценивания состояния динамических систем с использованием декомпозиции:

- 1) Вводится класс параметрически заданных функций $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$.
- 2) Используется имеющееся в наличии обучающее множество $\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}_{j=1}^N$.

- 3) Определяется среднеквадратический критерий оптимизации

$$\tilde{J}^*(\tilde{\mathbf{W}}) = \frac{1}{N} \sum_{j=1}^N \left(\mathbf{x}^{(j)} - \tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right)^T \left(\mathbf{x}^{(j)} - \tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right), \quad (2.16)$$

где $\tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}})$ – формируемая оценка.

- 4) Критерий (2.16) оптимизируется на основе минимизации эмпирического риска

$$P \left\{ \sup_{\tilde{\mathbf{W}}} |J(\tilde{\mathbf{W}}) - \tilde{J}^*(\tilde{\mathbf{W}})| > \varepsilon \right\} \rightarrow 0, \quad \text{при } N \rightarrow \infty, \quad (2.17)$$

где ε – заданная точность; $J(\tilde{\mathbf{W}}) = M \|\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})\|^2$.

- 5) Минимизация реализуется с помощью нейронных сетей, нечетких систем и вейвлетов

$$\tilde{\mathbf{x}}^\mu(\mathbf{y}) = \mathbf{K}^\mu(\mathbf{y}, \tilde{\mathbf{W}}), \quad \mu = NN, FS, W, \quad (2.18)$$

где $\tilde{\mathbf{W}}$ – матрица, отвечающая за параметры синтетических систем; $\mathbf{y}$ – вход синтетических систем; NN – нейронные сети; FS – нечеткие системы; W – вейвлеты.

Численная процедура для предложенного вычислительного метода представлена на рисунке 2.5.

При наличии обучающего множества (2.15) приближенное решение задачи оценивания находится путем ввода класса зависящих от параметров в общем случае нелинейных функций, используемых для вычисления оценки (2.18) [70, 92, 114, 117–125]. Эти неизвестные функции и отыскиваются с использованием синтетических систем. При этом проблема получения алгоритма оценивания на основе синтетической системы сводится вне зависимости от топологии системы к процедуре нахождения параметров этой

системы, отыскиваемых в результате минимизации критерия (2.16), формируемого с использованием данных обучающей выборки (2.15).




Рисунок 2.5 – Блок-схема вычислительного метода оценивания

В таблице 2.1 раскрыты понятия характеристик синтетических систем для приближенного решения задачи оценивания.

Таблица 2.1

Характеристика	Нейронные сети	Нечеткие системы	Вейвлет
$K^\mu(y, \tilde{W})$	специальная, в общем случае, нелинейная функция	нелинейное преобразование, осуществляемое, нечеткой системой	вейвлет-функция
$\tilde{W}$	массив смещений и весовых коэффициентов НС	матрица, определяющая набор свободных параметров (параметры функций принадлежности и весовые коэффициенты правил)	массив аппроксимирующих и детализирующих коэффициентов сигнала

Алгоритмы, основанные на минимизации критерия типа (2.16), широко используются в задачах распознавания образов. Обычно их называют методами **минимизации эмпирического риска** (2.17) [23, 24, 67, 83, 96].

Принцип минимизации эмпирического риска (principle of empirical risk minimization) состоит из трех взаимосвязанных частей [23, 24, 83].

1. Вместо функционала риска $J(\tilde{W})$

$$J(\tilde{W}) = \int L(x, \tilde{x}(y, \tilde{W})) d\tilde{x}_{y,x}(y, x),$$

где интеграл берется по всем возможным значениям $\{(y^{(j)}, x^{(j)})\}_{j=1}^N$, строится функционал эмпирического риска $\tilde{J}^*_{\text{emp}}(\tilde{W})$, определяемый следующей формулой:

$$\tilde{J}^*_{\text{emp}}(\tilde{W}) = \frac{1}{N} \sum_{i=1}^N L(x_i, \tilde{x}(y_i, \tilde{W})),$$

на базе множества примеров обучения $\{(y^{(j)}, x^{(j)})\}_{j=1}^N$.

2. Пусть $\tilde{W}_{\text{emp}}$ – вектор весовых коэффициентов, минимизирующий функционал эмпирического риска $\tilde{J}^*_{\text{emp}}(\tilde{W})$ в пространстве весов $\tilde{W}$. Тогда $\tilde{J}^*_{\text{emp}}(\tilde{W})$ сходится по вероятности к минимально возможным значениям фактического риска $J(\tilde{W})$. При этом при увеличении количества N примеров

обучения до бесконечности функционал эмпирического риска $\tilde{J}^*_{\text{emp}}(\tilde{\mathbf{W}})$ равномерно сходится к функционалу фактического риска $J(\tilde{\mathbf{W}})$.

3. Равномерная сходимоть, определяемая как

$$P(\sup_{\tilde{\mathbf{W}}} |J(\tilde{\mathbf{W}}) - \tilde{J}^*_{\text{emp}}(\tilde{\mathbf{W}})| > \varepsilon) \rightarrow 0 \text{ при } N \rightarrow \infty,$$

является необходимым и достаточным условием непротиворечивости принципа минимизации эмпирического риска [23, 24, 83].

Ясно, что эффективность предлагаемого решения с использованием синтетических систем будет в значительной степени зависеть от того, насколько удачным оказался выбор параметризованных функций, с точки зрения точности, т.е. близости минимального значений критерия $\tilde{J}^*$, достигаемого на заданном классе функций, по сравнению с минимальным значением критерия $\tilde{J}$, достигаемым без введения ограничений на класс функций. Кроме того, немаловажным представляется сложность как алгоритма обучения – нахождения параметров, обеспечивающих минимум критерия (2.16), так и последующего алгоритма вычисления самой оценки.

Однако для алгоритмов создания и обучения синтетических систем при решении задач нерекуррентного и рекуррентного нелинейного оценивания состояния динамических систем возникают вычислительные трудности при использовании больших массивов данных, когда количество входов системы превышает некоторое определенное значение. Поэтому для преодоления данной проблемы предлагается использовать декомпозицию синтетических систем.

2.3.2. Характеристика точности для вычислительного метода оценивания

Помимо самой оценки $\tilde{\mathbf{x}}(\mathbf{y})$ при решении прикладных задач, важным оказывается умение вычислять их характеристики точности.

Для традиционных методов для оптимальной в среднеквадратическом смысле оценки характеристика точности вычисляется с помощью следующих соотношений [67]

$$\mathbf{P}_e(\mathbf{y}) = \int (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T f(\mathbf{x}/\mathbf{y}) d\mathbf{x}, \quad (2.19)$$

$$\bar{\mathbf{P}}_e = \int \int (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T f(\mathbf{x}/\mathbf{y}) d\mathbf{x} f(\mathbf{y}) d\mathbf{y}, \quad (2.20)$$

используя условные и безусловные матрицы ковариаций ошибок оценивания $\mathbf{e} = \mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})$.

Для предлагаемого вычислительного метода оценивания характеристика точности оценивания, может быть рассчитана подобно тому, как это сделано в работах [4, 67, 92, 93, 113–125]:

$$\mathbf{P}_{e_{i/k}}^\mu = \frac{1}{N} \sum_{j=1}^N \left(\mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_{i/k}^\mu(\mathbf{y}_k^{(j)}, \tilde{\mathbf{W}}_i) \right) \left(\mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_{i/k}^\mu(\mathbf{y}_k^{(j)}, \tilde{\mathbf{W}}_i) \right)^T, \quad (2.21)$$

где $\mu = NN, FS, W$, $k = i$. Указанная характеристика точно может быть применена при использовании NN – нейронных сетей, FS – нечетких систем, W – вейвлетов.

2.3.3. Решение задачи рекуррентного оценивания с использованием синтетических систем

Широкий круг задач обработки информации может быть сведен к задаче оценивания n -мерной марковской последовательности $\mathbf{x}_i$, задаваемой с помощью разностных уравнений вида [66]

$$\mathbf{x}_i = \Phi_i(\mathbf{x}_{i-1}) + \mathbf{w}_i, \quad (2.22)$$

по проводимым в каждый i -й момент времени m -мерным измерениям, определяемым как

$$\mathbf{y}_i = \mathbf{s}_i(\mathbf{x}_i) + \mathbf{v}_i.$$

В этих отношениях, $\Phi_i(\mathbf{x}_{i-1})$ и $\mathbf{s}_i(\mathbf{x}_i)$ – n - и m -мерные векторные функции, в общем случае нелинейные относительно своих аргументов; $\mathbf{w}_i$ и $\mathbf{v}_i$ – n - и m -мерные независимые между собой и от $\mathbf{x}_0$ чисто случайные последовательности.

По аналогии с тем как это было сделано в работах [1, 4] и для вейвлетов [13, 93] обобщим результаты для синтетических систем.

Цель состоит в том, чтобы получить оценку состояния $\tilde{\mathbf{x}}_{i/i}$, используя алгоритм обновления и прогноза следующего вида.

$$\text{Шаг прогноза: } \tilde{\mathbf{x}}_{i/i-1} = \Phi_i(\tilde{\mathbf{x}}_{i-1/i-1}^\mu); \quad \tilde{\mathbf{y}}_{i/i-1} = \mathbf{s}_i(\tilde{\mathbf{x}}_{i/i-1}),$$

где $\tilde{\mathbf{x}}_{i/i-1}$, $\tilde{\mathbf{y}}_{i/i-1}$ – прогнозы состояния и измерения; $\tilde{\mathbf{x}}_{i-1/i-1}^\mu$ – оценка состояния на выходе алгоритма, синтезируемого с использованием синтетических систем $\mu = NN, FS, W$.

$$\text{Шаг обновления: } \tilde{\mathbf{x}}_{i/i}^\mu = \mathbf{K}_i^\mu(\tilde{\mathbf{x}}_{i/i-1}, \mathbf{Y}_i, \mathbf{E}_i, \tilde{\mathbf{W}}_i),$$

где $\mathbf{Y}_i = [\mathbf{y}_i^T, \mathbf{y}_{i-1}^T, \dots, \mathbf{y}_{i-n_y}^T]^T$ – вектор, содержащий текущее и прошлые измерения; $\mathbf{E}_i = [\boldsymbol{\varepsilon}_i^T, \boldsymbol{\varepsilon}_{i-1}^T, \dots, \boldsymbol{\varepsilon}_{i-n_\varepsilon}^T]^T$ – вектор, содержащий настоящую и прошлые невязки измерений $\boldsymbol{\varepsilon}_i = \mathbf{y}_i - \tilde{\mathbf{y}}_{i/i-1}$, n_y и n_ε – число предыдущих измерений и невязок измерений соответственно; $\mathbf{K}_i^\mu$ – нелинейная функция, построенная с использованием синтетических систем; $\tilde{\mathbf{W}}_i$ – массив коэффициентов синтетических систем.

2.3.4. Вычислительный метод оценивания с использованием синтетических систем на базе метода наименьших квадратов

Рассмотрим решение задачи оценивания, которое было описано в работе

[94], в случае отсутствия априорной информации, с использованием синтетических систем. Необходимо, имея измерение $\mathbf{y}$, найти оценку $\tilde{\mathbf{x}}(\mathbf{y})$, минимизирующую критерий вида:

$$\tilde{I}(\tilde{\mathbf{x}}) = \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y})]\}^T \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y})]\} = \sum_{i=1}^m \{y_i - s_i[\tilde{\mathbf{x}}(\mathbf{y})]\}^2. \quad (2.23)$$

Приближенное решение может быть найдено, вводя класс параметрически заданных функций, используемых для вычисления оценки [114]. Тогда критерий (2.23) может быть записан как:

$$\tilde{I}^*(\tilde{\mathbf{W}}) = \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\}^T \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\} = \sum_{i=1}^m \{y_i - s_i[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\}^2 \quad (2.24)$$

где $\tilde{\mathbf{W}}$ - вектор или матрица, определяющая ряд свободных параметров, которые определяют функцию $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$.

В частности, можно использовать для нейронных сетей и нечетких систем [4, 94, 113, 114]

$$\tilde{\mathbf{x}}^\mu(\mathbf{y}) = \mathbf{K}^\mu(\mathbf{y}, \tilde{\mathbf{W}}), \quad (2.25)$$

где $\mathbf{K}^\mu(\mathbf{y}, \tilde{\mathbf{W}})$ – специальная в общем случае нелинейная функция; $\tilde{\mathbf{W}}$ – матрица, которая определяет свободные параметры (смещения и весовые коэффициенты) и $\mathbf{y}$ – вход системы.

Используя алгоритм обучения на основе коррекции ошибки [83, 101, 102] изучаемый критерий может быть определен как:

$$\begin{aligned} \tilde{I}^*(\tilde{\mathbf{W}}) &= \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})]\}^T \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})]\} = \\ &= \sum_{i=1}^m \{y_i - s_i[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})]\}^2, \end{aligned} \quad (2.26)$$

где $\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})$ оценка, генерируемая нейронной сетью или нечеткими системами, с использованием измерений $\mathbf{y}$.

Таким образом, в качестве критерия используется точность значения суммы квадратов ошибок между измерениями $\mathbf{y}$ и предсказаниями системы

выхода $\mathbf{s}[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})]$.

Оптимизация критерия $\tilde{I}^*(\tilde{\mathbf{W}})$ происходит путем минимизации с подстройкой весовых коэффициентов $\tilde{\mathbf{W}}$.

Минимизация ведется методом градиентного спуска, что означает подстройку весовых коэффициентов следующим образом:

$$\begin{aligned} \frac{\partial \tilde{I}^*(\mathbf{w})}{\partial \mathbf{w}} = & -2\{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \mathbf{w})]\}^T \frac{\partial \mathbf{s}[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \mathbf{w})]}{\partial [\tilde{\mathbf{x}}^\mu(\mathbf{y}, \mathbf{w})]} \\ & \times \frac{\partial \tilde{\mathbf{x}}^\mu(\mathbf{y}, \mathbf{w})}{\partial \mathbf{w}}, \end{aligned} \quad (2.27)$$

где $\mathbf{w}$ это d -мерный вектор, содержащий веса и невязки системы. В соответствии с методом наискорейшего спуска [83, 101, 102], с учетом прежнего значения вектора на итерации $i-1$, обновленное значение этого вектора на следующей итерации i вычисляется как

$$\mathbf{w}_i = \mathbf{w}_{i-1} + \Delta \mathbf{w}_{i-1} = \mathbf{w}_{i-1} - \nu \frac{\partial \tilde{I}^*(\mathbf{w}_{i-1})}{\partial \mathbf{w}_{i-1}},$$

где ν коэффициент скорости обучения, $0 < \nu < 1$.

Для лучшего понимания специфики применения вычислительного метода оценивания с использованием синтетических систем на базе МНК рассмотрим нахождение линейной оптимальной оценки [3, 4, 94].

Линейная оптимальная оценка.

Для определения линейной оптимальной оценки логично использовать линейную систему оценивания. Принимая во внимание размеры вектора линейной системы для оценивания, $\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})$ можно записать следующим образом:

$$\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}}) = \mathbf{w}_0 + \mathbf{W}\mathbf{y}, \quad (2.28)$$

где $\tilde{\mathbf{W}} = [\mathbf{w}_0 \mid \mathbf{W}]$ является $n \times (m+1)$ -мерной матрицей, которая включает в себя n -мерный вектор смещения $\mathbf{w}_0 = [w_{10} \ \dots \ w_{n0}]^T$ и $n \times m$ -мерную матрицу весовых коэффициентов $\mathbf{W} = [\mathbf{w}_1 \mid \dots \mid \mathbf{w}_l \mid \dots \mid \mathbf{w}_n]^T$, в

которых $\mathbf{w}_l = [w_{l1} \dots w_{lm}]^T$ m -мерные векторы, $l = \overline{1, n}$. Система имеет один слой нейронов. Количество нейронов является таким же, как размеры оцененного вектора $\mathbf{x}$, и их функция активации, зависит от скалярного аргумента s , представляя собой тождественное преобразование (линейную функцию активации), то есть, $\psi(s) = s, -\infty < s < \infty$. Для on-line обучения линейной системы целесообразно использовать обычное правило Уидроу-Хоффа [83, 101, 102].

Чтобы минимизировать критерий (2.26) найдем $\mathbf{w}_0$ и $\mathbf{W}$, где $s[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})] = \mathbf{H}\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})$. Это отражается

$$\mathbf{w}_0 + \mathbf{W}\mathbf{y} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{y} = \mathbf{K}^\mu \mathbf{y}. \quad (2.29)$$

Из выражения (2.29) это следует, что линейная система (2.28), через какое-то адекватное обучение с помощью правила обучения коррекции ошибок, обеспечивает определение оценки близкое к оптимальной в линейном классе. Таким образом, оптимальный линейный алгоритм наименьших квадратов можно рассматривать, как линейную систему подготовленную в соответствии с (2.28), где

$$s[\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}})] = \mathbf{H}\tilde{\mathbf{x}}^\mu(\mathbf{y}, \tilde{\mathbf{W}}).$$

Однако следует отметить, что алгоритм, рассмотренный выше, не обеспечивает процедуры вычисления матрицы ковариаций, хотя ее наличие имеет важнейшее значение для решения различных прикладных задач, в частности, тех, которые связаны с обработкой навигационной информации [66].

Нелинейная оценка.

Для разработки «хорошего» алгоритма оценивания на основе нелинейной системы, необходимо выбрать «хороший» алгоритм обучения, то есть алгоритм, который обеспечивает такое $\tilde{\mathbf{W}}$, что минимизирует критерий обучения (2.26). Для этих целей может использоваться многослойная с прямой связью нейронная сеть [83, 101, 102]. Кроме того, в частности, двухслойная нейронная сеть (NN) с прямой связью может быть использована с m -входами,

q -нейронами в скрытом слое и n -нейронами в выходном слое.

В этом случае оценка $\tilde{x}_i^{NN}(\mathbf{y})$, $i = \overline{1, n}$, может быть записана в следующем виде

$$\tilde{x}_i^{NN}(\mathbf{y}) = \psi \left(\sum_{\mu=1}^q \left(w_{i\mu}^2 \varphi \left(\sum_{j=1}^m (w_{\mu j}^1 y_j) + w_{\mu 0}^1 \right) \right) + w_{i0}^2 \right), \quad (2.30)$$

где $\varphi(s) = \text{th } s$, $\psi(s) = s$ являются функциями активации для нейронов скрытого и выходного слоев; $(w_{\mu 0}^1, w_{\mu j}^1)$, $(w_{i0}^2, w_{i\mu}^2)$, $\mu = \overline{1, q}$, $j = \overline{1, m}$, $i = \overline{1, n}$ смещения и веса нейронов скрытого и выходного слоев. Для on-line обучения в NN может быть использован алгоритм обратного распространения [83, 101, 102].

Новизна или эффект от применения предложенных в данном разделе синтетических алгоритмов как раз и будет значительным и ощутимым, так как обучение происходит в режиме реального времени.

2.4. Математические модели иерархических синтетических систем нелинейного оценивания динамических процессов

Для повышения быстродействия настройки алгоритмов оценивания предлагается использование принципа декомпозиции сложных систем [118–125].

Синтетические системы могут быть декомпозированы с использованием трех **базовых представлений подсистем**. К ним относят: каскадное, параллельное соединение элементов, а также соединение замыканием обратной связи [51]. Для системы S справедливы следующие отношения [51].

Каскадное соединение: Каждая система $S \subset (X_1 \times X_2) \times (Y_1 \times Y_2)$ допускает декомпозицию в соединенные каскадно элементы, как показано на рисунке 2.6, б.

Параллельное соединение: Пусть система $S \subset (X_1 \times X_2) \times (Y_1 \times Y_2)$ и пусть $S(x) = \{y : (x, y) \in S\}$, где $X = X_1 \times X_2$, а $Y = Y_1 \times Y_2$. Система S допускает декомпозицию на системы S_1 и S_2 , (как это показано на рисунке 2.6, в) в том и только в том случае, когда для любых $x \in D(S)$ справедливо равенство $S(x) = \Pi_1(S(x)) \times \Pi_2(S(x))$ и операторы проектирования $\Pi_1 : (X_1 \times X_2) \times (Y_1 \times Y_2) \rightarrow (X_1 \times Y_1)$ и $\Pi_2 : (X_1 \times X_2) \times (Y_1 \times Y_2) \rightarrow (X_2 \times Y_2)$, такие, что $\Pi_1(x_1, x_2, y_1, y_2) = (x_1, y_1)$ и $\Pi_2(x_1, x_2, y_1, y_2) = (x_2, y_2)$.

Замыкание обратной связи: Любая система $S \subset (X_1 \times X_2) \times (Y_1 \times Y_2)$ допускает декомпозицию $S = F(S_1 \circ S_2)$ в соединенные каскадно и охваченные обратной связью элементы, где $S_1 \subset (X_1 \times Z_1) \times (Y_1 \times Z_2)$, $S_2 \subset (X_2 \times Z_2) \times (Y_2 \times Z_1)$, а Z_1 и Z_2 – вспомогательные множества (рисунок 2.6, г).




Рисунок 2.6 – Базовые представления подсистем: а) исходное соединение; б) каскадное соединение; в) параллельное соединение; г) соединение с замыканием обратной связью

С использованием приведенных базовых принципов могут быть построены на основе синтетических систем субоптимальные алгоритмы

оценивания состояния динамических процессов с различной степенью сложности [118–125].

Прежде всего, с использованием принципа параллельного соединения синтетическая система оценивания типа MIMO (many inputs – many outputs) может быть представлена совокупностью синтетических систем типа MISO (many inputs – single output) (рисунок 2.7). Поэтому вычислительные трудности обучения синтетических систем типа MIMO частично преодолеваются переходом от системы MIMO к совокупности систем типа MISO.




Рисунок 2.7 – Декомпозиция системы MIMO на системы MISO
 а) синтетическая система MIMO; б) совокупность синтетических систем MISO.

Для решения обозначенной в работе проблемы сокращения количества входов системы осуществляется другие базовые представления для декомпозиция систем.

С этой целью может быть построена иерархическая синтетическая система как для нерекуррентного, так и для рекуррентного оценивания применительно к нелинейным задачам обработки информации (Рисунок 2.8).

На рисунке 2.8 б) и в) применена рекуррентная декомпозиционная схема оценивания в виде каскадного соединения, в первом случае, с двумя входами и одним выходом, где на вход поступает текущее измерение и оценка, полученная на предыдущем шаге, а во втором случае на вход системы поступают p предыдущих измерений и оценка, полученная на предыдущем шаге.




Рисунок 2.8 – Схема нерекуррентного и рекуррентного оценивания:

а) нерекуррентное оценивание; б) рекуррентное оценивание с использованием декомпозиции с одним измерением; в) рекуррентное оценивание с использованием декомпозиции с несколькими измерениями

Математические модели иерархических синтетических систем нелинейного оценивания динамических процессов представленные на рисунке 2.8, определяются следующими выражениями.

Нерекуррентное оценивание:

$$\begin{aligned}\tilde{x}_1 &= K_1(y_1, \tilde{W}), \{y_1^{(j)}, x_1^{(j)}\}_{j=1}^N; \\ \tilde{x}_2 &= K_2(y_1, y_2, \tilde{W}), \{(y_1^{(j)}, y_2^{(j)}), x_2^{(j)}\}_{j=1}^N; \\ &\dots\end{aligned}\tag{2.31}$$

$$\tilde{\mathbf{x}}_k = \mathbf{K}_k(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_k, \tilde{\mathbf{W}}), \{(\mathbf{y}_1^{(j)}, \mathbf{y}_2^{(j)}, \dots, \mathbf{y}_k^{(j)}), \mathbf{x}_k^{(j)}\}_{j=1}^N.$$

Рекуррентное оценивание с использованием декомпозиции с одним измерением:

$$\begin{aligned} \tilde{\mathbf{x}}_1 &= \mathbf{K}_1^{d^{(\mu)}}(\mathbf{y}_1, \tilde{\mathbf{W}}), \{\mathbf{y}_1^{(j)}, \mathbf{x}_1^{(j)}\}_{j=1}^N; \\ \tilde{\mathbf{x}}_2 &= \mathbf{K}_2^{d^{(\mu)}}(\tilde{\mathbf{x}}_1, \mathbf{y}_2, \tilde{\mathbf{W}}), \{(\tilde{\mathbf{x}}_1^{(j)}, \mathbf{y}_2^{(j)}), \mathbf{x}_2^{(j)}\}_{j=1}^N; \\ &\dots \\ \tilde{\mathbf{x}}_k &= \mathbf{K}_k^{d^{(\mu)}}(\tilde{\mathbf{x}}_{k-1}, \mathbf{y}_k, \tilde{\mathbf{W}}), \{(\tilde{\mathbf{x}}_{k-1}^{(j)}, \mathbf{y}_k^{(j)}), \mathbf{x}_k^{(j)}\}_{j=1}^N. \end{aligned} \quad (2.32)$$

Рекуррентное оценивание с использованием декомпозиции с несколькими измерениями:

$$\begin{aligned} \tilde{\mathbf{x}}_1 &= \mathbf{K}_1^{d^{(\mu)}}(\mathbf{y}_1, \tilde{\mathbf{W}}), \{\mathbf{y}_1^{(j)}, \mathbf{x}_1^{(j)}\}_{j=1}^N; \\ \tilde{\mathbf{x}}_2 &= \mathbf{K}_2^{d^{(\mu)}}(\tilde{\mathbf{x}}_1, \mathbf{y}_1, \mathbf{y}_2, \tilde{\mathbf{W}}), \{(\tilde{\mathbf{x}}_1^{(j)}, \mathbf{y}_1^{(j)}, \mathbf{y}_2^{(j)}), \mathbf{x}_2^{(j)}\}_{j=1}^N; \\ &\dots \\ \tilde{\mathbf{x}}_k &= \mathbf{K}_k^{d^{(\mu)}}(\tilde{\mathbf{x}}_{k-1}, \mathbf{y}_{k-p}, \dots, \mathbf{y}_k, \tilde{\mathbf{W}}), \{(\tilde{\mathbf{x}}_{k-1}^{(j)}, \mathbf{y}_{k-p}^{(j)}, \dots, \mathbf{y}_k^{(j)}), \mathbf{x}_k^{(j)}\}_{j=1}^N. \end{aligned} \quad (2.33)$$

Критерий оптимизации вычисления оценок (2.32), (2.33) определяется формулой (2.16).

В случае отсутствия обучающего множества при вычислении оценок (2.32), (2.33) используется критерий (2.26).

На рисунке 2.9 представлен пример синтетической системы оценивания, которая построена на базовых принципах декомпозиции – каскадного и параллельного соединений, а также с использованием эвристик. Под эвристиками мы понимаем приемы проектирования, использующие опыт, знания и интуицию разработчиков.

В этой системе каждый из узлов (кроме первого), использует для оценивания, как соответствующий набор измерений, так и оценку, полученную на предыдущем шаге вычислений.




Рисунок 2.9 – Иерархическая синтетическая система для устройства оценивания с растущей памятью

Схема на рисунке 2.9 нами реализована в работах [118, 119, 122] для решения нелинейной задачи оценивания с использованием иерархических нечетких систем.

Подобно тому, как это было сделано в [4], также разработана общая схема рекуррентного оценивания с использованием синтетических систем, которая приведена на рисунке 2.10.

Математическая модель для рекуррентного оценивания с использованием моделей динамики и измерений (рисунок 2.10) будет выглядеть следующим образом:

$$\begin{aligned}
 \tilde{x}_{1/0} &= \Phi_1(\tilde{x}_0^\mu); \quad \tilde{y}_{1/0} = s_1(\tilde{x}_{1/0}); \quad \tilde{x}_{1/1}^\mu = K_1^\mu(\tilde{x}_{1/0}, Y_1, E_1, \tilde{W}_1); \\
 \tilde{x}_{2/1} &= \Phi_2(\tilde{x}_{1/1}^\mu); \quad \tilde{y}_{2/1} = s_2(\tilde{x}_{2/1}); \quad \tilde{x}_{2/2}^\mu = K_2^\mu(\tilde{x}_{2/1}, Y_2, E_2, \tilde{W}_2); \quad (2.34) \\
 &\dots \\
 \tilde{x}_{i/i-1} &= \Phi_i(\tilde{x}_{i-1/i-1}^\mu); \quad \tilde{y}_{i/i-1} = s_i(\tilde{x}_{i/i-1}); \quad \tilde{x}_{i/i}^\mu = K_i^\mu(\tilde{x}_{i/i-1}, Y_i, E_i, \tilde{W}_i).
 \end{aligned}$$




Рисунок 2.10 – Схема рекуррентного оценивания с использованием моделей динамической системы и системы измерений

В последующих главах рассмотрены реализации исходной (рисунок 2.8 а) и иерархической схемы (рисунок 2.8 б) для синтетических систем оценивания.

Выводы по второй главе

Таким образом, в данной главе получены следующие результаты:

1. Предложен эффективный с точки зрения быстродействия и точности вычислительный метод решения нелинейной задачи оценивания состояния динамических систем по нелинейным измерениям с использованием класса

параметрически заданных функций. Для оптимизации критерия оценивания используется принцип минимизации эмпирического риска. Показано, что его численная реализация может быть осуществлена на базе синтетических систем как по схеме нерекуррентного, так и рекуррентного оценивания.

2. Предложены математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов.

3. Реализацию вычислительно метода для стохастической аппроксимации предлагается осуществить на основе нейросетевого, нечеткого и вейвлет-подходов. Особенности численной реализации синтетических систем заключаются в следующем: для нейронных сетей различного типа определяется массив смещений и весовых коэффициентов с использованием разных алгоритмов обучения, для нечетких систем – массив параметров функций принадлежности и весовых коэффициентов правил с использованием адаптивной нейронечеткой системы, а для вейвлетов – массив аппроксимирующих и детализирующих коэффициентов сигнала.

4. Для реализации экономичных вычислений предложена декомпозиция синтетических систем оценивания с использованием базовых представлений подсистем: каскадное, параллельное и соединение с замыканием обратной связью.

5. Рассмотрены возможности обучения синтетических систем оценивания для режима off-line в случае байесовского подхода и реального режима работы on-line в случае метода наименьших квадратов.

6. Для вычислительного метода предложена характеристика оценки точности.

В последующих главах вычислительный метод с использованием минимизации эмпирического риска и синтетических систем и математические модели реализуются с помощью численных методов стохастической аппроксимации.

ГЛАВА 3. ЧИСЛЕННЫЕ МЕТОДЫ И ПРОГРАММНАЯ РЕАЛИЗАЦИЯ НЕЛИНЕЙНОГО ОЦЕНИВАНИЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ, НЕЧЕТКИХ СИСТЕМ И ДЕКОМПОЗИЦИИ

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 обучения при использовании декомпозиции.

Для решения задачи байесовского оптимального нелинейного оценивания состояния динамической системы помимо традиционных методов [62, 66, 81, 82], используются численные методы стохастической аппроксимации на основе искусственных нейронных сетей (НС) [3, 4, 36, 67, 83, 94, 101, 102, 107, 112–116], нечетких систем (НчС) [1–4, 15, 56, 71, 92].

Проведенный в главе 1 анализ литературы 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.

Численные методы решения задачи нелинейного оптимального оценивания на основе синтетических систем относятся к численным методам стохастической аппроксимации, т.к. алгоритм обратного распространения ошибки, использующий текущую оценку (instantaneous estimate) градиента поверхности ошибок в пространстве весов, лежащий в основе нейросетевого, нечеткого подходов рассматривается как реализация рекурсивной технологии, которая в статистическом оценивании называется стохастической аппроксимацией (stochastic approximation) [63, 83].

3.1. Решение задачи нелинейного оценивания с помощью численного метода на основе нейронных сетей и декомпозиции

Постановка задачи. Использование нейросетевой системы для решения задачи оценивания в рамках байесовской постановки предполагает наличие набора данных (обучающей выборки)

$$\{(\mathbf{Y}_i^{(j)}, \mathbf{x}_i^{(j)})\}, j = \overline{1, L}, \quad (3.1)$$

в котором пары $\mathbf{Y}_i^{(j)}, \mathbf{x}_i^{(j)}, j = \overline{1, L}$, согласованы, в том смысле, что они представляют независимые между собой реализации случайного составного вектора $\mathbf{z} = [\mathbf{x}_i^T \quad \mathbf{Y}_i^T]^T$ с функцией плотности распределения вероятностей $w(\mathbf{x}_i, \mathbf{Y}_i)$.

Для нейросетевого оценивания можно выделить **два основных режима работы** [67, 114, 117]. Первый из них – режим создания (построения) нейросетевой системы для решения задачи оценивания – можно назвать режимом синтеза, второй – это штатный режим оценивания в реальном времени.

Рассмотрим синтез модели нейросетевой системы. Если априорная информация задана в виде (3.1), то располагая таким набором данных и

измерением $\mathbf{Y}_i$, оценку можно найти с использованием нейронной сети как оценку $\tilde{\mathbf{x}}_i^{NN}(\mathbf{Y}_i)$, минимизирующую критерий вида

$$\tilde{J}_i = \frac{1}{L} \sum_{j=1}^L \left\| \mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_i^{NN}(\mathbf{Y}_i^{(j)}) \right\|^2, \quad (3.2)$$

где

$$\tilde{\mathbf{x}}_i^{NN}(\mathbf{Y}_i) = \mathbf{K}_i^{NN}(\mathbf{Y}_i, \tilde{\mathbf{W}}_i), \quad (3.3)$$

$\mathbf{K}_i^{NN}(\mathbf{Y}_i, \tilde{\mathbf{W}}_i)$ – нелинейное преобразование, выполняемое нейронной сетью, $\tilde{\mathbf{W}}_i$ – матрица, определяющая смещения и веса нейронной сети, $\mathbf{Y}_i$ – вход нейросетевой системы.

Таким образом, в **режиме синтеза**, с использованием обучающего множества (3.1), отыскивается зависимость вида $\tilde{\mathbf{x}}_i^{NN(j)}(\mathbf{Y}_i^{(j)}, \tilde{\mathbf{W}}_i)$, в соответствии с заданным критерием (3.2), то есть отыскиваются оптимальные параметры $\tilde{\mathbf{W}}_i$ нейронной сети. В **штатном режиме** с использованием найденных на предыдущем режиме параметров $\tilde{\mathbf{W}}_i$ отыскивается оценка по вектору измерений $\mathbf{Y}_i$.

Далее представлены эффективные субоптимальные алгоритмы, пригодные для работы в режиме реального времени. Спроектированы 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 использованы предложенные в [117, 119, 120, 125] и описанные в п. 2.4 математические модели декомпозиционных синтетических систем, которые реализуются как фильтры с растущей памятью на основе искусственных нейронных сетей, нечетких систем и их комбинаций.

В п. 3.1.4 представлены исходные и декомпозиционные синтетические системы в сравнении с оптимальным нелинейным оцениванием. Для улучшения быстродействия работы синтетической системы была применена

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 (рисунок 2.8 б п. 2.4).

3.1.1. Нелинейная нейронная сеть прямого распространения

Для решения задачи оценивания нами выбрана нелинейная нейронная сеть прямого распространения – Feed Forward Neural Network (FFNN), представленная как двухслойная НС с последовательными связями с i входами, с q нейронами в скрытом слое и одним нейроном в выходном слое (рисунок 3.1).




Рисунок 3.1 – Структура нейронной сети прямого распространения

В работе [114] приведено решение задачи оценивания с использованием не оптимизированной по быстродействию FFNN. При этом выход НС FFNN может быть определен как:

$$\tilde{x}^{FFNN}(\mathbf{y}) = \psi \left(\sum_{\mu=1}^q w_{\mu 1}^2 \left(\sum_{k=1}^i (w_{k\mu}^1 y_k) + w_{0\mu}^1 \right) + w_{01}^2 \right), \quad (3.4)$$

где $w_{0\mu}^1$, $w_{k\mu}^1$, $\mu = \overline{1.q}$, $k = \overline{1.i}$ – смещения и веса нейронов скрытого слоя; w_{01}^2 , $w_{\mu 1}^2$, $\mu = \overline{1.q}$ – смещение и веса нейрона выходного слоя FFNN; q – число нейронов скрытого слоя; $\varphi(s) = \tanh s = \frac{e^s - e^{-s}}{e^s + e^{-s}}$ – активационная функция для нейронов скрытого слоя; $\psi(s) = s$ – активационная характеристика нейрона выходного слоя.

Заметим, что эффективность решения задачи оценивания с использованием нейронной сети прямого распространения достигается при обучении сети в подборе таких весовых коэффициентов для всех слоев, чтобы при заданном входе получить на выходе значения, которые с требуемой точностью будут совпадать с ожидаемыми значениями. До сих пор особенности применения алгоритмов обучения и их влияние на работу нейронной сети не исследованы. Поэтому для анализа по быстродействию и точности работы нейронной сети помимо алгоритма обучения Левенберга-Маркварда используем алгоритм регуляризации Байеса [99, 100].

Алгоритм обучения Левенберга-Маркварда – Levenberg-Marquardt (LM) [99, 100]. модифицирует значения весов и смещений в соответствии с методом оптимизации. Может обучать любую сеть, если ее весовые, входные и активационные функции дифференцируемы. Но он мало эффективен для больших сетей, поскольку требует много памяти и времени для вычислений. Данный алгоритм работает лучше для аппроксимации функции (нелинейной регрессии), чем для решения задач распознавания образов [100].

Алгоритм LM был разработан как подход по скорости обучения второго порядка без необходимости вычисления матрицы Гессе. Когда функция представлена в виде суммы квадратов, матрица Гессе может быть аппроксимирована как:

$$\mathbf{H} = \mathbf{J}^T \mathbf{J},$$

а градиент вычисляется:

$$\mathbf{g} = \mathbf{J}^T \mathbf{e}$$

где $\mathbf{J}$ – матрица Якоби, которая содержит первые производные ошибки сети в отношении весов и смещений, а $\mathbf{e}$ – вектор ошибок. Матрица Якоби вычисляется через стандартный метод обратного распространения, что является гораздо менее сложным, чем вычисление матрицы Гессе.

Алгоритм LM использует аппроксимацию матрицы Гессе на основе метода Ньютона:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e}.$$

Когда $\mu = 0$, это метод Ньютона, при котором используется аппроксимированная матрица Гессе. При $\mu > 0$, становится метод градиентного спуска с небольшим размером шага. Метод Ньютона быстрее и точнее минимизирует ошибку, так что целью является переход к методу Ньютона так же быстро, насколько это возможно. Таким образом, μ уменьшается после каждого успешного шага, и увеличивается только тогда, когда этот шаг увеличивает производительность функции. Таким образом, минимизация критерия оптимизации будет достигаться пошагово на каждой итерации алгоритма [99].

Алгоритм обучения на основе обратного распространения ошибки с использованием регуляризации Байеса – Bayesian Regulation (BR) [99, 100]. Это функция обучения нейронной сети, которая модифицирует значения весов и смещений в соответствии с алгоритмом оптимизации LM. При этом минимизируется комбинация квадратов ошибок и весов, затем определяется скорректированная комбинация, которая обеспечивает улучшение обобщающей способности сети. Эта процедура называется регуляризация Байеса.

Данный алгоритм 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 [100].

3.1.2. Нейронная сеть с радиальными базисными функциями

Базовая архитектура сетей на основе радиально базисных функций (РБФ), предполагает наличие трех слоев, выполняющих совершенно различные функции. Входной слой состоит из сенсорных элементов, которые связывают сеть с внешней средой. Вторым слоем является единственным скрытым слоем сети. И третий выходной. Нейронная сеть с РБФ в скрытом слое состоит из радиально симметричных шаблонных нейронов, которые можно представить в виде модели искусственного нейрона (рисунок 3.2), где $\varphi(\circ)$ – шаблонный нейрон; $БП_k : \mathbf{c}^{(k)}$ – входные сигналы в виде весовых коэффициентов; Z_k – выходной сигнал шаблонного нейрона скрытого слоя [5, 47, 83, 117].




Рисунок 3.2 – Модель искусственного нейрона

Для построения сети РБФ необходимо выполнение следующих условий [5, 117]:

1. Наличие обучающего множества из набора примеров $\{p_1, \dots, p_k, \dots, p_N\}$ и пар примеров $\{(x^{(1)}, Y^{(1)}), \dots, (x^{(k)}, Y^{(k)}), \dots, (x^{(N)}, Y^{(N)})\}$ представленных в виде весовых векторов нейронов скрытого слоя.

2. Наличие способа измерения расстояния входного вектора от эталона – обычно это евклидово расстояние.

3. Выходной сигнал шаблонного нейрона – это функция только от расстояния между входным вектором $\mathbf{x}$ и сохраненным центром $\mathbf{c}^{(k)}$:

$$z_k = \varphi \left(\frac{\|\mathbf{x} - \mathbf{c}^{(k)}\|}{\sigma_k} \right), \quad (3.5)$$

где $\mathbf{x}$ – текущий входной вектор $\mathbf{x} = [x_1 \dots x_n]^T$; $\mathbf{c}^{(k)} = \mathbf{W}^{(k)}$ – сохраненные центры (эталонные), $w_{1k} = c_1^{(k)}, w_{2k} = c_2^{(k)}, \dots, w_{nk} = c_n^{(k)}$ – весовой вектор k -го эталонного нейрона скрытого слоя; σ_k – параметры активационной функции (отклонения радиальных элементов); φ – радиально базисная активационная функция; $k=1, \dots, k$ – число эталонов нейронов скрытого слоя.

Обычно вектор $\mathbf{c}^{(k)}$ сохраняется в пространстве весов от входного слоя к слою шаблонов,

Функция активации нейронов скрытого слоя задает способ измерения расстояния, обычно используется функция Гаусса $\varphi(s) = e^{-s^2}$, которая усиливает малую разницу между входными и эталонными векторами. При этом выходной сигнал эталонного нейрона скрытого слоя a_j – это функция (гауссиан) только от расстояния ρ_j между входным и эталонным векторами:

$$\rho_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij}^{(h)})^2}; \quad a_j = \exp \left[- \left(\frac{\rho_j - R}{\sigma_j} \right)^2 \right]; \quad j = 1, \dots, m_h,$$

где $\rho_j = \eta_j$ – активационный уровень нейрона j скрытого слоя; $\mathbf{x} = (x_1, \dots, x_n)^T$ – входной вектор; $\mathbf{w}_j^{(h)} = (w_{1j}^{(h)} \dots w_{nj}^{(h)})^T$ – весовой вектор j -го эталонного нейрона скрытого слоя; R, σ_j – параметры активационной функции; m_h – число эталонов – нейронов скрытого слоя.

В моделях РБФ могут быть использованы различные способы измерения расстояния между векторами, а также функции активации нейронов скрытого слоя.

4. Выходной слой сети является линейным:

$$z_j = \sum_{k=1}^{m_h} w_{kj} \varphi \left(\frac{\|\mathbf{x} - \mathbf{c}_k\|}{\sigma_k} \right), j = \overline{1, m}, \quad (3.6)$$

где $\mathbf{c}_k$ – центры, количество которых равно m_h , σ_k – отклонения радиальных элементов. Обучение слоя образцов-нейронов сети подразумевает предварительное проведение кластеризации для нахождения эталонных векторов и определенных эвристик для определения значений σ_k .

Решение задачи оценивания с использованием НС с РБФ, где при построении алгоритма в качестве априорной информации выступает набор пар (3.1) и в соответствие с (3.6) сводится к следующему (рисунок 3.3):

$$\tilde{x}^{RBFN}(\mathbf{y}) = \sum_{k=1}^{m_h} w_{k1} \varphi \left(\frac{\|\mathbf{y} - \mathbf{c}_k\|}{\sigma_k} \right), \quad (3.7)$$

где $\mathbf{y}$ – входной n -вектор, w_{k1} , – весовые вектора эталонного нейрона скрытого слоя, m_h – число эталонов (нейронов) скрытого слоя, φ – радиально базисная активационная функция; $\mathbf{c}_k$ – центры, количество которых равно m_h , σ_k – отклонения радиальных элементов.




Рисунок 3.3 – Сеть с радиальными базисными функциями

Обучение сети РБФ происходит следующим образом. Сначала определяются центры и отклонения для радиальных элементов; после этого оптимизируются параметры w_{kj} , $j = \overline{1, m}$ линейного выходного слоя.

3.1.3. Численная и программная реализация решения задачи оптимального нелинейного оценивания с использованием различных типов нейронной сети

Для реализации решения задачи оптимального нелинейного оценивания и фильтрации с использованием различных типов нейронной сети разработано программное обеспечение в MATLAB «Нейросетевая система оценивания NN Estimator» [Приложение E и F].

Программа предназначена для решения задачи байесовского оптимального нелинейного оценивания случайных векторов с использованием нейронной сети прямого распространения или нейронной сети с радиальными базисными функциями по выбору пользователя. Программа позволяет при соответствующем выборе критерия, используемого для обучения нейронной сети вырабатывать оценки, близкие по своим свойствам к оценкам, получаемым с помощью байесовского алгоритма. Реализован пример формирования векторов x и y для задачи оценки, равномерно распределенной на отрезке $[a_x; b_x]$ случайной величины x по ее измерениям $y_i = x + v_i$, $i = \overline{1, l}$, подверженным воздействию ошибок v_i , равномерно распределенных на отрезке $[a_v; b_v]$.

Общая структура разработанной нами программы [129] для ЭВМ «Нейросетевая система оценивания» по модулям представлена на рисунке 3.4.

При проектировании НС с РБФ были использованы функции `newtbe` и `newrb` пакета Neural Networks среды MatLab R2011b (win64), автоматизирующие синтез структуры нейронной сети и ее обучение.

Функция `newtbe` реализует НС с РБФ с нулевой ошибкой на обучающей выборке, когда число шаблонных нейронов в точности равно числу примеров из обучающей выборки. Использование данной функции не дало удовлетворительного результата по точности.





Рисунок 3.4 – Структура программы для ЭВМ «Нейросетевая система оценивания»

Функция `newrb` реализует обобщенную НС с РБФ, когда число шаблонных нейронов можно оптимизировать, при этом их количество будет значительно меньше числа примеров из обучающей выборки [47].

Для моделирования НС FFN была использована функция `newff` с использованием обучения по методу обратного распространения ошибки: алгоритмы Левенберга-Маркварда и регуляризации Байеса.

Алгоритм разработанной нейросетевой системы оценивания изображен на рисунке 3.5 в виде блок-схемы.






Рисунок 3.5 – Блок-схема программы нейросетевой системы оценивания

Дадим некоторые пояснения к блок-схеме отраженной на рисунке 3.5. В блок-схеме в модуле sParam_xy.m задаются параметры для моделирования векторов x и y . А в модуле sModel_xy.m производится моделирование векторов x (случайное значение оцениваемой величины) и y (случайных измерений).

Весам сети присваиваются небольшие начальные значения. Выбирается обучающая пара (X, Y) из обучающего множества. Вектор Y подается на вход сети. Вычисляется выход сети.

Алгоритм действует циклически, его циклы принято называть эпохами. На каждой эпохе на вход сети поочередно подаются все обучающие наблюдения, выходные значения сети сравниваются с целевыми значениями и вычисляется ошибка. Значение ошибки используется для корректировки весов, после чего все действия повторяются. Начальная конфигурация сети выбирается случайным образом, и процесс обучения прекращается, либо когда пройдено определенное количество эпох, либо когда ошибка достигнет некоторого определенного уровня малости, либо когда ошибка перестанет уменьшаться.

3.1.4. Иллюстрирующий пример решения задач оценивания

Данные результаты моделирования являются подтверждением теоретических положений изложенных в работах по теме диссертации [117–119, 125].

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 [114] 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

$$y_i = x + v_i, \quad i = \overline{1, l},$$

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 $x \equiv x$, $y \equiv [y_1 \dots y_l]^T$, $v = [v_1 \dots v_l]^T$. Необходимо отметить, что апостериорная функция плотности распределения вероятностей $f(x/y)$ здесь не является гауссовской, так как x и v_i , $i = \overline{1, l}$ – равномерно распределенные случайные переменные. При проведении моделирования принималось: $a = b = 1$, $i = \overline{1, l}$, $l = 10$.

Для сравнения результатов решений с помощью синтетических систем 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 (рисунок 3.6 а).

Для улучшения быстродействия работы синтетической системы (СС) была применена рекуррентная декомпозиционная схема оценивания (рисунок 2.8 б) в виде каскадного соединения с двумя входами и одним выходом, где на вход поступает текущее измерение и оценка, полученная на предыдущем шаге (рисунок 3.6 б). При этом все возможные декомпозиционные схемы будут находиться между указанными на рисунке 3.6 граничными фильтрами с растущей памятью.




Рисунок 3.6 – СС исходная (а) и с декомпозицией (б)

Ниже представлены реализации численных методов стохастической аппроксимации с использованием нелинейной нейронной сети прямого распространения – Feed Forward Neural Network (FFNN) и нейронной сети с радиальными базисными функциями – Radial Basis Function Network (RBFN).

Сравнение точности оценивания проводится с решением для оптимального нелинейного оценивания, рассмотренным в работе [114]. Были получены и исследованы среднеквадратичные отклонения (СКО) ошибок оценивания: выборочные СКО ошибок $\tilde{\sigma}_i$ для нелинейных оптимальных оценок и выборочные СКО ошибок для нейросетевых оценок $\tilde{\sigma}_i^\mu$, $\mu = FFNN, FFNN^d, RBFN, RBFN^d$, d означает декомпозиционную структуру. Выборочные СКО были рассчитаны следующим образом:

$$\tilde{\sigma}_i \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{(j)})^2}, \quad e_i^{(j)} = x^{(j)} - \tilde{x}^{(j)}(\mathbf{y}^{(j)}), \quad (3.8)$$

$$\tilde{\sigma}_i^\mu \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{\mu(j)})^2}, \quad e_i^{\mu(j)} = x^{(j)} - \tilde{x}^{\mu(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}). \quad (3.9)$$

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.

Аппроксимация отражает закономерность изменения времени обучения алгоритма от количества измерений. Для нахождения уравнения линейной регрессии (зависимости времени от количества измерений) вычислялись коэффициенты a и b [49]:

$$\begin{cases} M_{y^2} \cdot a + M_y \cdot b = M_{yt}, \\ M_y \cdot a + b = M_t; \end{cases} \quad \text{где} \quad \begin{cases} M_{y^2} = \frac{1}{n} \sum y_i^2, \\ M_y = \frac{1}{n} \sum y_i, \\ M_{yt} = \frac{1}{n} \sum y_i t_i, \\ M_t = \frac{1}{n} \sum t_i; \end{cases}$$

или формулами: $a = \frac{M_{yt} - M_y \cdot M_t}{M_{y^2} - M_t^2}, b = \frac{M_{y^2} M_t - M_y \cdot M_{yt}}{M_{y^2} - M_t^2}.$

При этом y это количество измерений, а t – время обучения.

Оптимальная нелинейная оценка $\tilde{x}(y) = \int x f(x/y) dx$ для данного примера может быть получена в явном виде [114]. Для того, чтобы объяснить это, введем область Ω , представляющую собой отрезок, формируемый в результате пересечения всех интервалов $[y_i - a/2, y_i + a/2], i = \overline{1, l}$, т.е.

$$\Omega \equiv [d_1, d_2] = \bigcap_{i=1}^l [y_i - a/2, y_i + a/2].$$

Можно показать, что апостериорная плотность в рассматриваемом примере является равномерной на отрезке $[c_1, c_2]$, представляющим собой пересечение априорной области $[0, b]$ и области Ω , так что $c_1 = \max\{0, d_1\}$, $c_2 = \min\{b, d_2\}$. Тогда из этого следует, что

$$\tilde{x}(y) = (c_2 + c_1) / 2.$$

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.

При реализации численного метода стохастической аппроксимации для настройки параметров FFNN по методу обратного распространения ошибки 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 рисунка 3.6 а), б), отображены на графиках:

- для алгоритма обучения LM (рисунок 3.7);
- для алгоритма обучения BR (рисунок 3.8).

В качестве исходной нелинейной сети FFNN соответствующей рисунку 3.6 а) выбрана двухслойная НС с последовательными связями с i входами, с $q=20$ нейронами в скрытом слое и одним нейроном в выходном слое.

На рисунке 3.7 и 3.8 а) представлены СКО ошибок оценивания, вычисление которых рассчитывается по формулам (3.8), (3.9).

На рисунке 3.7 б) и в) t_r – отражает время обучения системы (в секундах), а t_a – аппроксимация, уравнение для которой $t_a = e^{2,984x-10,688}$ при декомпозиции. Аппроксимация, полученная с помощью метода наименьших квадратов [49], отражает закономерность изменения времени обучения алгоритма от количества измерений.

Как видно из рисунка 3.7 б) для исходной сети FFNN без декомпозиции время обучения с увеличением количества входов возрастает (уравнение аппроксимации $t_a = e^{0,2921x+3,2017}$), рост начинается с 6-ти входов, максимальное значение при 10-ти 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 (рисунок 3.7 в).




Рисунок 3.7 – Нейронная сеть прямого распространения
алгоритм обучения Levenberg-Marquardt: а) СКО ошибок оценивания;
(слева исходная, справа с применением декомпозиции)

б) и в) – время обучения; г) и д) – время штатного режима оценивания в
реальном времени




Рисунок 3.8 – Нейронная сеть прямого распространения
 алгоритм обучения Bayesian Regulation: а) – СКО ошибок оценивания;
 (слева исходная, справа с применением декомпозиции)
 б) и в) – время обучения; г) и д) – время штатного режима оценивания в
 реальном времени

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

В сравнении с исходной системой (рисунок 3.8 б) для алгоритма обучения BR декомпозиция (рисунок 3.8 в) дает повышение быстродействия в среднем на 9 с. Однако алгоритм обучения BR уступает по быстродействию алгоритму LM при декомпозиции в среднем на 11 с.

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 Вычислительным центром ФГБОУ ВПО «КНАГТУ».

Решение задачи оценивания с использованием обобщенной НС RBFN приведено нами в работе [117]. 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 [47, 83]. Число нейронов в скрытом слое m_h подобрано опытным путем равным 500. Выходной слой содержит один нейрон (по числу оцениваемых переменных).

На рисунке 3.9 а) представлены СКО ошибок оценивания рассчитанные по формулам (3.8, 3.9). Видно, что при применении декомпозиции точность оценивания снижается. Но для решения задачи оценивания с использованием RBFN без декомпозиции было затрачено на процесс обучения 33 ч, а с декомпозицией – 0,85 ч (рисунок 3.9 б) и в). При этом для получения приемлемых результатов по точности для RBFN N было выбрано равным 20000, число нейронов m_h для реализации декомпозиционной НС RBFN выбрано равным 10.




Рисунок 3.9 – Нейронная сеть с радиальными базисными функциями:

а) СКО ошибок оценивания;

(слева исходная, справа с применением декомпозиции)

б) и в)– время обучения; г) и д)– время штатного режима оценивания в реальном времени

Для сети с применением декомпозиции (рисунок 3.9 в), время обучения в среднем на каждый вход занимает примерно 304 с, уравнение аппроксимации $t_a = e^{-0,0023x+5,1389}$.

В штатном режиме реальной работы время оценивания с использованием обученной декомпозиционной сети составляет 50 мкс, а время оценивания сети без декомпозиции составляет 210 мкс.

Таким образом, из рисунка 3.9 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 FFNN и RBFN совпадают между собой и близки к оптимальной нелинейной оценке.

3.2. Решение задачи нелинейного оценивания с использованием численного метода на основе нечеткой логики и декомпозиции

Сравнительный анализ алгоритмов оценивания на основе нечеткой логики с оптимальными в среднеквадратическом смысле традиционными алгоритмами показывает возможность их успешного применения при решении ряда сложных в вычислительном отношении задач оценивания, решаемых в рамках байесовской постановки [1–4, 15, 71, 92, 118, 121, 125]. Однако для алгоритмов создания и обучения нечетких систем при решении задачи нерекуррентного оценивания возникают вычислительные трудности при использовании больших массивов данных [15, 47, 92], когда количество входных параметров нечеткой системы больше 5–6. В качестве альтернативы для решения обозначенной вычислительной проблемы нерекуррентного

оценивания предлагается применение основных принципов системного подхода при построении нечетких оценивающих систем, в частности иерархичности их строения.

3.2.1. Решение задачи нелинейного оценивания с помощью численного метода на основе нейронечетких систем

Постановка задачи. Использование нечеткой системы для решения задачи оценивания в рамках байесовской постановки предполагает, как и в случае нейросетевого подхода, наличие набора данных (обучающей выборки) (3.1) в виде $\{(\mathbf{Y}_i^{(j)}, \mathbf{x}_i^{(j)})\}$, $j = \overline{1, L}$, в котором пары $\mathbf{Y}_i^{(j)}$, $\mathbf{x}_i^{(j)}$, $j = \overline{1, L}$, согласованы, в том смысле, что они представляют независимые между собой реализации случайного составного вектора $\mathbf{z} = [\mathbf{x}_i^T \ \mathbf{Y}_i^T]^T$ с функцией плотности распределения вероятностей $w(\mathbf{x}_i, \mathbf{Y}_i)$.

Для нечеткого оценивания аналогично нейросетевому подходу, описанному в работах [67, 114, 117], можно выделить **два основных режима работы**. Первый из них – режим создания (построения) нечеткой системы для решения задачи оценивания – можно назвать режимом синтеза, второй – это штатный режим оценивания в реальном времени.

Рассмотрим синтез нечеткой системы. Если априорная информация задана в указанном виде (3.1), то располагая таким набором данных и измерением $\mathbf{Y}_i$, оценку можно найти с использованием нечеткой системы как оценку $\tilde{\mathbf{x}}_i^{FS}(\mathbf{Y}_i)$, минимизирующую критерий вида

$$\tilde{J}_i = \frac{1}{L} \sum_{j=1}^L \left\| \mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_i^{FS}(\mathbf{Y}_i^{(j)}) \right\|^2, \quad (3.11)$$

где

$$\tilde{\mathbf{x}}_i^{FS}(\mathbf{Y}_i) = \mathbf{K}_i^{FS}(\mathbf{Y}_i, \tilde{\mathbf{W}}_i), \quad (3.12)$$

$\mathbf{K}_i^{FS}(\mathbf{Y}_i, \tilde{\mathbf{W}}_i)$ – нелинейное преобразование, выполняемое нечеткой системой, $\tilde{\mathbf{W}}_i$ – матрица, определяющая набор свободных параметров (параметры функций принадлежности и весовые коэффициенты правил), $\mathbf{Y}_i$ – вход нечеткой системы.

Таким образом, в **режиме синтеза**, с использованием обучающего множества (3.1), отыскивается зависимость вида $\tilde{\mathbf{x}}_i^{FS(j)}(\mathbf{Y}_i^{(j)}, \tilde{\mathbf{W}}_i)$, в соответствии с заданным критерием (3.11), то есть отыскиваются оптимальные параметры $\tilde{\mathbf{W}}_i$ нечеткой системы. В **штатном режиме** с использованием найденных на предыдущем режиме параметров $\tilde{\mathbf{W}}_i$ отыскивается оценка по вектору измерений $\mathbf{Y}_i$.

В работах [92, 118, 121] получены оценки измеряемой величины $\mathbf{x}_i$, близкой к оптимальной нелинейной оценке с использованием систем нечеткого логического вывода типа Сугено с p входами и 2^p правилами:

$$\tilde{\mathbf{x}}_i^{FS(j)} = \sum_{\lambda=1}^{2^p} \alpha_{\lambda i}^{(j)} \mathbf{K}_{\lambda i}^{FS}(\mathbf{Y}_i^{(j)}, \tilde{\mathbf{W}}_{\lambda i}) / \sum_{\lambda=1}^{2^p} \alpha_{\lambda i}^{(j)},$$

где $\mathbf{K}_{\lambda i}^{FS}(\mathbf{Y}_i^{(j)}, \tilde{\mathbf{W}}_{\lambda i})$ – нечеткая система;

$$\alpha_{\lambda i}^{(j)} = f_{\&}(\mu_{1i}(\mathbf{a}_{1i}, y_{1i}^{(j)}), \mu_{2i}(\mathbf{a}_{2i}, y_{2i}^{(j)}), \dots, \mu_{pi}(\mathbf{a}_{pi}, y_{pi}^{(j)})); f_{\&}(a, b) = \min(a, b) \text{ или}$$

$$f_{\&}(a, b) = a \cdot b; \mu_{ki}(\mathbf{a}_{ki}, y_{ki}^{(j)}) – \text{функция принадлежности } k\text{-го входа; } k = \overline{1, p};$$

$\mathbf{a}_{ki}$ – вектор параметров для $\mu_{ki}(\mathbf{a}_{ki}, y_{ki}^{(j)})$.

База знаний нечеткой системы это набор правил следующего типа:

$$R_{\lambda i} : \text{ЕСЛИ } \mathbf{Y}_i \text{ есть } \mathbf{Y}_i^{(j)}, \text{ ТО } \tilde{\mathbf{x}}_i^{FS} = \mathbf{w}_{0i} + \mathbf{W}_i \mathbf{Y}_i, \lambda = \overline{1, 2^p}. \quad (3.13)$$

В (3.13) $\tilde{\mathbf{W}}_i = [\mathbf{w}_{0i} | \mathbf{W}_i]$ – матрица параметров нечеткой системы размерности $n \times (p+1)$: $\mathbf{w}_{0i}$ – n -мерный вектор смещений и $\mathbf{W}_i$ – матрица весовых коэффициентов размерности $n \times p$.

Таким образом, для получения нечеткой оценки, близкой к оптимальной нелинейной оценке, необходимо для заданного количества измерений создать и обучить нечеткую систему $\mathbf{K}_i^{FS}(\mathbf{Y}_i, \tilde{\mathbf{W}}_i)$ в соответствии с критерием (3.11), определив тем самым оптимальные параметры $\tilde{\mathbf{W}}_i$.

Вычислительные трудности обучения нечетких систем типа MIMO (many inputs – many outputs) частично преодолеваются переходом от нечеткой системы MIMO к совокупности нечетких систем типа MISO (many inputs – single output), как это представлено на рисунке 2.7. При этом все нечеткие системы совокупности имеют одинаковые входы (как у исходной нечеткой системы), но каждая из нечетких систем совокупности в соответствии с (3.12) оценивает только одну компоненту искомого вектора параметров

$$\tilde{x}_{si}^{FS}(\mathbf{Y}_i) = \mathbf{K}_{si}^{FS}(\mathbf{Y}_i, \tilde{\mathbf{W}}_{si}),$$

где $\mathbf{K}_{si}^{FS}(\mathbf{Y}_i, \tilde{\mathbf{W}}_{si})$ – нечеткая система, оценивающая s компонент вектора $\mathbf{x}_i$, $\tilde{\mathbf{W}}_{si}$ – матрица, определяющая набор свободных параметров нечеткой системы $\mathbf{K}_{si}^{FS}$, $\mathbf{Y}_i$ – вход нечеткой системы, $s = 1, 2, \dots, n$. Для упрощения схем индекс времени i на рисунках данного раздела опустим.

Декомпозиция, как процесс расчленения, позволяет рассматривать любую исследуемую систему как сложную, состоящую из отдельных взаимосвязанных более простых подсистем, обучение или настройка которых не вызывает сложности. Применим сказанное к нечетким системам, так как для алгоритмов их обучения возникают вычислительные трудности при использовании обучающих выборок большого объема [15, 47, 92]. Например, при настройке нечеткой системы типа Сугено с p входами и 1 линейным выходом с двумя термами для оценки каждой входной переменной с гауссовыми функциями принадлежности необходимо настроить $4p$ параметров функций принадлежности (по 2 параметра для каждого из термов входных переменных), $(p+1)2^p$ параметра в заключениях правил. При $p=2$ это составит 20 параметров, при $p=3$ – 44, при $p=4$ – 96, при $p=5$ – 212, а при $p=10$ – 11304.

Ниже представим сравнение исходных и декомпозиционных нечетких систем при решении задачи оценивания.

3.2.2. Иллюстрирующий пример решения задач оценивания

Среда моделирования. 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.

Рассмотрим решение задачи оценивания с использованием нечетких систем на том же примере, что и для искусственных нейронных сетей в п. 3.1.4.

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 $\{(\mathbf{y}^{(j)}, x^{(j)})\}, j = \overline{1, N}$, где $N = 20000$, количество измерений $i = \overline{1, 7}$ для исходной нечеткой системы и $i = \overline{1, 10}$ с применением декомпозиции (рисунок 3.10 а). Как и в случае с нейронными сетями для нечетких систем применяется схема декомпозиции, имеющая два входа и один выход (рисунок 3.6 б).

На рисунке 3.10 а) представлены СКО ошибок нечеткого оценивания, вычисленные по формулам (3.8, 3.9), только $\mu = FS, FS^d$.




Рисунок 3.10 – Нечеткая система:

а) СКО ошибок оценивания; (слева исходная, справа с применением декомпозиции) б) и в) – время обучения; г) и д) – время штатного режима оценивания в реальном времени

Быстродействие представленных алгоритмов оценивания с использованием нечетких систем может характеризоваться временем, затраченным на обучение нечеткой системы, которое для рассматриваемого примера представлено на рисунке 3.10 б) и в) для исходной и декомпозиционной системы соответственно.

На рисунке 3.10 б) и в) отражается время обучения исходной нечеткой системы оценивания лишь для 7-ми входов, потому что, начиная с 5-ти измерений, происходит значительное увеличение времени на обучение. Так для 7-ми входов время обучения составляет 8,2 ч. Уравнение регрессии $t_a = e^{2,1946x-5,175}$ (рисунок 3.10 б).

Главное достоинство системы ANFIS состоит в том, что процедура проектирования частично формализована и число параметров генерируется автоматически. В таблице 3.1 отражаются параметры, сгенерированные для нечеткой системы без использования декомпозиции.

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

Таблица 3.1

Количество входов	Число нейронов	Число линейных параметров	Число нелинейных параметров	Количество 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	$2,6 \times 10^4$

Выводы по третьей главе

В таблице 3.2 сведены результаты обучения систем оценивания, построенных на основе нейронной сети прямого распространения, сети с радиальными базисными функциями и нечеткой системы, как без декомпозиции, так и с таковой.

Таблица 3.2

Кол-во входов	Время обучения алгоритма оценивания, с.							
	Искусственные нейронные сети						Нечеткая система	
	Сеть прямого распространения				Сеть с радиальными базисными функциями			
	LM		BR		RBF			
	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

Таким образом, в данной главе отражены следующие результаты:

1. Показано, что с помощью декомпозиционных синтетических систем может быть достигнута высокая точность оценивания, которая близка 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.

2. Предложены численные методы стохастической аппроксимации, для реализации которых используются быстродействующие нейросетевые и

нечеткие методы и декомпозиционные алгоритмы субоптимального оценивания состояния динамических систем.

3. Получена закономерность увеличения быстродействия обучения при использовании декомпозиции.

4. Реализация нейросетевых и нечетких алгоритмов обучения при использовании декомпозиции становится возможной в реальном режиме времени.

5. Получены новые результаты для решения задачи оценивания с помощью НС прямого распространения и с РБФ с декомпозицией и без таковой. Для НС прямого распространения проиллюстрировано применение разных алгоритмов обучения, выявлены их особенности работы. Продемонстрировано, что использование НС с РБФ затруднительно, в связи с ее излишней громоздкостью.

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

7. Разработаны комплексы программ для решения задачи нелинейного оценивания с использованием нейронных сетей и нечетких систем.

ГЛАВА 4. ЧИСЛЕННЫЙ МЕТОД И ПРОГРАММНАЯ РЕАЛИЗАЦИЯ НЕЛИНЕЙНОГО ОЦЕНИВАНИЯ С ИСПОЛЬЗОВАНИЕМ ВЕЙВЛЕТОВ И ДЕКОМПОЗИЦИИ

Для решения задачи оценивания состояния динамических систем рассмотрен численный метод стохастической аппроксимации на основе регрессии и вейвлетов с использованием декомпозиции. Показано, что синтетические системы могут быть использованы для обнаружения и оценивания неоднородных процессов с локальными особенностями (нарушениями). Вейвлет-преобразование в случае нарушений состояния динамической системы позволяет обнаружить и дать точную оценку системы. Описан комплекс программ для решения задачи оценивания системы по нелинейным измерениям с использованием вейвлет-преобразования и фильтра Калмана. При компьютерном моделировании получены спектрограммы, которые позволяют выявить и наглядно показать структуру процесса.

4.1. Решение задачи нелинейного оценивания с помощью численного метода на основе вейвлетов и декомпозиции

Численный метод решения задачи нелинейного оптимального оценивания на основе стохастической схемы регрессии и вейвлетов, относится к численным методам стохастической аппроксимации, т.к. регрессия для вейвлетов рассматривается как реализация рекурсивной технологии, которая в статистическом оценивании называется стохастической аппроксимацией (stochastic approximation) [63, 83].

Ниже приведем решение исходной и декомпозиционной системы на основе вейвлетов в сравнении с оптимальным нелинейным оцениванием.

Решение задачи оценивания с использованием регрессии и вейвлетов. В работах [12–14, 93, 95] предложено использовать вейвлеты для решения задачи оценивания как задачи нахождения функции регрессии. Доказано, что решение задачи оценивания как задачи регрессии может быть получено из выражения $\tilde{\mathbf{x}}_{i/k} = M[\mathbf{x}_i / \mathbf{Y}_k] = \mathbf{h}_i(\mathbf{Y}_k)$, где нелинейная функция $\mathbf{h}_i(\cdot)$ определена как условное математическое ожидание, из чего следует, что задача нахождения функции $\mathbf{h}_i(\cdot)$ может быть сведена к решению задачи регрессии. Выбор модели регрессии определяется предположением о форме нелинейной зависимости между векторами $\mathbf{x}_i$ и $\mathbf{Y}_k$. Находится зависимость $\tilde{\mathbf{x}}_{i/i} = \mathbf{h}_i(\mathbf{Y}_i)$ с заданным заранее типом функции $\mathbf{h}_i$. Решение задачи оценивания с использованием вейвлетов сводится к использованию стохастической схемы регрессии в следующем виде

$$\mathbf{x}_i = \mathbf{h}_i(\mathbf{Y}_k) + \mathbf{e}_i, \quad (4.1)$$

где $\tilde{\mathbf{x}}_{i/k} = \mathbf{h}_i(\mathbf{Y}_k)$, а $\mathbf{e}_i$ считается шумом.

Уравнение (4.1) называется регрессионным уравнением. Основная задача заключается в нахождении уравнения регрессии по выборочным данным векторов $\mathbf{x}_i = (x_{1i}, \dots, x_{ni})^T$ и $\mathbf{Y}_k = [\mathbf{y}_k^T, \mathbf{y}_{k-1}^T, \dots, \mathbf{y}_1^T]^T$, $\mathbf{y}_k = (y_{1k}, \dots, y_{mk})^T$, $i = 0, 1, \dots$, которые записываются в виде

$$\{(\mathbf{x}_i^{(j)}, \mathbf{Y}_k^{(j)})\}_{j=1}^N. \quad (4.2)$$

Таким образом, речь идет об удалении шума $\mathbf{e}_i$ в модели (4.1). В таких задачах вейвлеты применяются достаточно эффективно [63, 103].

В зависимости от статуса объясняющей переменной $\mathbf{Y}$ различают две схемы регрессии: классическую схему и стохастическую [63].

Классическая схема регрессии (Fixed-Design Regression). Это случай, когда значения $\mathbf{Y}$ детерминированы, предопределены, как, например, дни

недели, возраст и т.п. Обычно в этом случае значения переменной $\mathbf{Y}$ расположены равномерно.

Стохастическая схема регрессии (Stochastic Design Regression). Это случай, когда значения $\mathbf{Y}$ являются результатами измерения, обработки или случайно выбраны. Обычно значения $\mathbf{Y}$ располагаются нерегулярно [63].

В работе [13] для поиска функции регрессии $\mathbf{h}_i(\mathbf{Y}_k)$ на основе вейвлетов общую проблему регрессии предлагается свести к классической модели.

При этом модель регрессии (4.1) для оценки имеет вид:

$$x = \tilde{x}(y) + e, \quad \tilde{x}(y) = h(y),$$

где x , $\tilde{x}$, y , e – скалярные переменные, h – неизвестная скалярная функция. Скалярные значения переменных выбраны для упрощения вывода без потери общности.

В соответствие с последним выражением и (4.2)

$$x^{(j)} = h(y^{(j)}) + e^{(j)}, \quad j = \overline{1, N},$$

где $e^{(j)}$ – случайные переменные. Важно отметить, что значения $y^{(j)}$ не находятся на регулярной сетке на отрезке $[y_{\min}, y_{\max}]$.

Основные шаги для вычислений $\tilde{x} = h(y)$ следующие [12–14, 63, 93, 95, 103].

1. Преобразование выборочных данных $\{(x^{(j)}, y^{(j)})\}_{j=1}^N$ в данные $\{(\tilde{x}_l, z_l)\}$, $l = \overline{1, L}$ с использованием процедуры разбиения области значений переменной y на малые промежутки с центрами $z_1, \dots, z_L$ и шириной Δ . Значения z_l , $l = \overline{1, L}$ равномерно распределены. Для каждого l -го промежутка, $l = \overline{1, L}$ определяется

$$\tilde{x}_l = \sum_{j=1}^N x^{(j)} I\{|y^{(j)} - z_l| \leq \Delta/2\} / \sum_{j=1}^N I\{|y^{(j)} - z_l| \leq \Delta/2\}, \quad l = \overline{1, L}$$

с соглашением $0/0=0$. При этом $\tilde{x}_1, \dots, \tilde{x}_L$ – значения гистограммы в точках $z_1, \dots, z_L$.

2. Выполняется вейвлет-разложение сигнала $\tilde{x}_l$, $l = \overline{1.L}$ с использованием быстрых алгоритмов для нахождения вейвлет-коэффициентов.

3. Производится пороговая обработка (жесткий и мягкий трешолдинг) вейвлет-коэффициентов одним из методов для удаления шума e .

4. Восстановление оценки $\tilde{x}_l = h_l(z_l)$, $l = \overline{1.L}$ функции регрессии h из обработанных вейвлет-коэффициентов в точках $z_1, \dots, z_l$ с использованием быстрых алгоритмов.

5. Перемасштабирование результирующей функции $\tilde{x}_l = h_l(\tilde{y}_l)$ с преобразованием каждого значения индекса l в данные $\tilde{y}_l$, $l = \overline{1.L}$ и интерполяция $h_l(\tilde{y}_l)$ в каждом промежутке l для нахождения оценки $\tilde{x}$.

Численная реализация нерекуррентного вейвлет-оценивания. Задачу оценивания можно рассматривать как задачу нахождения неизвестного отображения $\mathbf{h}_i^W(\mathbf{Y}_k, \tilde{\mathbf{C}}_i)$, с помощью которого определяется оценка $\tilde{\mathbf{x}}_{i/k}$ аналогично выражению (4.1), т.е.:

$$\tilde{\mathbf{x}}_{i/k}^W = \mathbf{h}_i^W(\mathbf{Y}_k, \tilde{\mathbf{C}}_i) \quad (4.3)$$

где матрица $\tilde{\mathbf{C}}_i = \{\mathbf{a}_M, \mathbf{d}_M, \mathbf{d}_{M-1}, \dots, \mathbf{d}_1\}$ определяет массив аппроксимирующих коэффициентов, которые описывают сглаженный сигнал, и детализирующих коэффициентов, которые описывают колебания. В качестве входа для преобразования выступает вектор $\mathbf{Y}_k$, а выходом является вырабатываемая вейвлетом оценка $\tilde{\mathbf{x}}_{i/k}^W$. Определение матрицы $\tilde{\mathbf{C}}_i = \{\mathbf{a}_M, \mathbf{d}_M, \mathbf{d}_{M-1}, \dots, \mathbf{d}_1\}$ осуществляется с использованием выборочных данных (4.2) в соответствии с описанной выше процедурой.

Для вейвлет-оценивания, выделяются два режима работы: первый – режим синтеза алгоритма, в котором находится функция регрессии с использованием вейвлетов при наличии выборочных данных (4.2), второй – штатный режим.

В первом режиме, с использованием обучающего множества отыскивается функциональная зависимость вида $\tilde{\mathbf{x}}_{i/k}^W = \mathbf{h}_i^W(\mathbf{Y}_k, \tilde{\mathbf{C}}_i)$ в соответствии с заданным критерием. Другими словами, на этом этапе находятся коэффициенты вейвлет-разложения $\tilde{\mathbf{C}}_i$. Значения коэффициентов $\tilde{\mathbf{C}}_i$ зависят от типа вейвлета, уровня разложения, алгоритма пороговой обработки и размера выборки.

В качестве критерия работы вейвлет-алгоритма $J_{i/k}(\tilde{\mathbf{C}}_i)$, вне зависимости от типа вейвлета, выбирается функция вида:

$$J_{i/k}(\tilde{\mathbf{C}}_i) = \frac{1}{N} \sum_{j=1}^N \left\| \mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_{i/k}^{W(j)}(\mathbf{Y}_k^{(j)}, \tilde{\mathbf{C}}_i) \right\|^2, \quad (4.4)$$

где $\|\mathbf{a}\|^2 = \mathbf{a}^T \mathbf{a}$; $\tilde{\mathbf{x}}_{i/k}^{W(j)}(\mathbf{Y}_k^{(j)}, \tilde{\mathbf{C}}_i)$ – оценка, вырабатываемая вейвлетом по измерениям $\mathbf{Y}_k^{(j)}$, соответствующим эталонной реализации $\mathbf{x}_i^{(j)}$; $\tilde{\mathbf{C}}_i$ – массив аппроксимирующих и детализирующих коэффициентов сигнала для момента времени t_i .

Очевидно, что оценка, определяемая с помощью вейвлета вида (4.3), с использованием критерия (4.4) при увеличении N будет стремиться к оптимальной в среднеквадратическом смысле оценке, задаваемой соотношением (4.1) [12–14, 93, 95].

В штатном режиме с использованием полученных на предыдущем режиме коэффициентов вейвлет-разложения $\tilde{\mathbf{C}}_i$ в соответствии с выражением (4.3) оценка определяется по составному вектору измерений $\mathbf{Y}_k$.

В качестве расчетной характеристики точности для оптимальной в среднеквадратическом смысле оценки может быть выбрана апостериорная матрица ковариаций ошибок, вычисляемая с помощью следующего соотношения [67]:

$$\mathbf{P}_{e_{i/k}} = M[(\mathbf{x}_i - \tilde{\mathbf{x}}_{i/k})(\mathbf{x}_i - \tilde{\mathbf{x}}_{i/k})^T]. \quad (4.5)$$

Известно, что для линейного случая, эта расчетная характеристика точности имеет вид [4, 67, 92, 93, 113–125]:

$$\mathbf{P}_{e_i} = \mathbf{P}_{x_i x_i} - \mathbf{P}_{x_i y_i} (\mathbf{P}_{y_i y_i})^{-1} \mathbf{P}_{y_i x_i}.$$

Для исследуемого алгоритма после его синтеза характеристика точности оценивания, аналогичная матрице ковариаций (4.5), может быть рассчитана как

$$\mathbf{P}_{e_{i/k}}^W = \frac{1}{N} \sum_{j=1}^N (\mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_{i/k}^W(\mathbf{Y}_k^{(j)}, \tilde{\mathbf{C}}_i)) (\mathbf{x}_i^{(j)} - \tilde{\mathbf{x}}_{i/k}^W(\mathbf{Y}_k^{(j)}, \tilde{\mathbf{C}}_i))^T. \quad (4.6)$$

В дальнейшем рассматриваем задачу оценивания при $i = k$.

При решении поставленной проблемы нами было разработано программное обеспечение «Вейвлет-оценивание временного ряда». Описание программы и результаты компьютерного моделирования представлены ниже.

Решение задачи оценивания с использованием метода вейвлетов и декомпозиции. При решении задачи оценивания с помощью регрессии и вейвлет обработки имеет значение размерность входных данных. На данный момент для вейвлет-преобразования нет программных средств, реализующих многомерную обработку информации. В среде MatLab реализована возможность только для одномерного и двумерного вейвлет-преобразования. Поэтому нами предлагается по аналогии с нейросетевым и нечетким подходами использовать двумерное вейвлет-преобразование по схеме декомпозиции представленной на рисунке 4.1.

Для неррекуррентного оценивания (рисунок 4.1 а) применяется 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 (рисунок 4.1 в). Тогда оценка, полученная с использованием вейвлетов, определяется выражением

$$\tilde{\mathbf{x}}_\lambda = \mathbf{K}_\lambda^{W^d}(\tilde{\mathbf{x}}_{\lambda-1}, \mathbf{y}_\lambda) \quad \text{при} \quad \text{следующем} \quad \text{обучающем} \quad \text{множестве} \\ \{(\tilde{\mathbf{x}}_{\lambda-1}^{(j)}, \mathbf{y}_\lambda^{(j)}), \mathbf{x}_\lambda^{(j)}\}_{j=1}^N, \quad \lambda = \overline{1, k}.$$




Рисунок 4.1 – Схема оценивания с использованием вейвлетов:

а) нерекуррентное оценивание; б) обучающее множество для схемы с декомпозицией; в) рекуррентное оценивание с использованием декомпозиции

Ниже приведены полученные путем моделирования результаты, соответствующие оптимальному нелинейному, нейросетевому и вейвлет алгоритмам. Сравнительные результаты решения задачи оценивания с помощью нейронной сети (NN) и вейвлет (W), построенных по схемам рисунка 4.1 а), б), отображены на рисунке 4.2. В качестве нейронной сети выбрана сеть прямого распространения FFNN – двухслойная НС с последовательными связями с i входами, $i = \overline{1, l}$, $l = 10$, с $q = 20$ нейронами в скрытом слое и одним нейроном в выходном слое. Вейвлеты реализованы в виде двумерного вейвлет-преобразования по схеме, представленной на рисунке 4.1 в) как рекуррентное оценивание с использованием декомпозиции. Для достижения заданной точности (4.6) при оптимизации критерия (4.4) были подобраны следующие параметры: число выборок $L = 20000$; количество областей значения переменной равно 500; пороговая обработка проводилась с помощью мягкого

трешолдинга; вейвлет - Добеши 6, с уровнем разложения 8. При перемасштабировании использовалась интерполяция с помощью сплайнов.

Были получены и исследованы среднеквадратичные отклонения (СКО) ошибок оценивания: выборочные СКО ошибок $\tilde{\sigma}_i$ для нелинейных оптимальных оценок и выборочные СКО ошибок для нейросетевых и вейвлет оценок $\tilde{\sigma}_i^\mu$, $\mu = NN, W^d$, d означает декомпозиционную структуру. Выборочные СКО были рассчитаны следующим образом:

$$\tilde{\sigma}_i \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{(j)})^2}, \quad e_i^{(j)} = x^{(j)} - \tilde{x}^{(j)}(\mathbf{y}^{(j)}), \quad (4.7)$$

$$\tilde{\sigma}_i^\mu \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{\mu(j)})^2}, \quad e_i^{\mu(j)} = x^{(j)} - \tilde{x}^{\mu(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}). \quad (4.8)$$

Для получения приемлемых результатов по точности оценивания число реализаций N для обучения синтетических систем было выбрано равным 20000.




Рисунок 4.2 – СКО ошибок оценивания

Как видно из рисунка 4.2, полученная СКО оценивания $\tilde{\sigma}_i^{W^d}$ с использованием регрессии и вейвлета на основе декомпозиции близка к нейросетевому алгоритму $\tilde{\sigma}_i^{NN}$ и нелинейной оптимальной оценке σ_i .

На рисунке 4.2 представлено решение одного рационального варианта вейвлет-оценивания. Исходя из опыта разработчиков и накопленных знаний,

был выбран эмпирическим путем набор параметров, который позволил получить близкое приближение к субоптимальным нейронным сетям.

4.2. Пример оценивания экспоненциально-коррелированного процесса

4.2.1. Математическая модель экспоненциально-коррелированного процесса с локальными особенностями

В этом примере используются вейвлет-системы для оценивания неоднородного процесса (процесса с локальными особенностями).

Такие нарушения процесса могут быть вызваны, например, уходами гироскопов и смещениями нуля акселерометров инерциальных навигационных систем [34, 40, 45, 62, 64, 72, 73, 79].

Пусть необходимо оценить значения экспоненциально-коррелированного процесса [119, 121]

$$\dot{x}(t) = -\alpha x(t) + \sqrt{2\sigma_x^2 \alpha} n(t), \quad (4.9)$$

используя измерения

$$y_i = x_i + v_i, \quad i = 1, 2, \dots, k, \quad (4.10)$$

проведенные в дискретные моменты времени $t_i = (i-1)\Delta t$ с интервалом Δt .

В уравнении (4.9): σ_x^2 – дисперсия процесса; $\alpha = 1/\tau_k$ – интервал корреляции; $n(t)$ – центрированный гауссовский белый шум единичной интенсивности. Предполагается, что значение процесса x_0 в начальный момент времени представляет собой независимую от $n(t)$ центрированную гауссовскую случайную величину с нулевым математическим ожиданием и дисперсией σ_x^2 . Ошибки измерения v_i в (4.10) считаются независимыми между собой и от $x(t)$ гауссовскими случайными величинами с дисперсией $R_i = r_i^2$.

В разностном виде уравнение (4.9) записывается как [119, 121]

$$x_i = e^{-\alpha\Delta t} x_{i-1} + \frac{\sqrt{2\sigma_x^2\alpha}}{\alpha} (1 - e^{-\alpha\Delta t}) n_i + \theta_i, \quad (4.11)$$

где n_i независимые между собой и от v_i и x_0 центрированные гаусовские случайные величины с дисперсией $Q_i = q_i^2 = q^2 \approx 1/\Delta t$. В правой части уравнения (4.11) добавлена составляющая θ_i для учета нарушений. Параметр θ_i моделирует локальную особенность в поведении процесса, например, скачкообразное или линейное изменение в уходе гироскопа. В примере $\mathbf{x} \equiv x_i$, $\mathbf{y} \equiv [y_1 \dots y_i]^T$, $\mathbf{v} \equiv [v_1 \dots v_i]^T$.

Заметим, что оптимальным решением для оценивания экспоненциально-коррелированного процесса (4.9) в отсутствие нарушений, когда $\theta_i = 0$, является линейный фильтр Калмана (ФК). Поэтому рассмотренная задача решалась путем моделирования как с использованием фильтра Калмана, для которого необходимо располагать значениями σ_x^2 , α , r^2 , $q^2 = 1/\Delta t$, так и с использованием вейвлета.

Ниже приведены результаты моделирования, соответствующие следующим значениям указанных параметров: $\sigma_x^2 = 10$; $\Delta t = 1$ с; $r_i^2 = 27$; $\alpha = 1/30$, $r^2 = 1$ для дискретных моментов времени $t_i = (i-1)\Delta t$, $i = \overline{1, k}$, $k = 200$. Общее число реализаций $j = \overline{1, L}$, $L = 1000$. Для реализации вейвлет-алгоритма оценивания выбран вейвлет Добеши 4 с уровнем разложения 4.

4.2.2. Процесс без нарушений

Прежде всего, на рисунке 4.3 представлены результаты оценивания экспоненциально-коррелированного процесса (4.11) при отсутствии нарушений, когда $\theta_i = 0$:

– расчетные среднеквадратичные отклонения (СКО) ошибок оценивания σ_i , соответствующее дисперсии ошибки оптимального оценивания, которая является единственным элементом расчетной матрицы ковариаций ошибок фильтра Калмана;

– выборочные действительные СКО ошибок оценивания ФК (FK) $\tilde{\sigma}_i^{FK}$ для и алгоритма на основе вейвлета $\tilde{\sigma}_i^W$, вычисляемые как:

$$\tilde{\sigma}_i^{\mu} \approx \sqrt{\frac{1}{L} \sum_{j=1}^L (e_i^{\mu(j)})^2}, \quad e_i^{\mu(j)} = \tilde{x}_i^{\mu(j)}(\mathbf{y}_i^{(j)}, \mathbf{W}_i) - x_i^{(j)}, \quad \mu = FK, W \quad (4.12)$$




Рисунок 4.3 – СКО ошибок оценивания процесса без нарушений

Как видно из рисунка 4.3, полученная с использованием вейвлета оценка $\tilde{\sigma}_i^W$ практически совпадает с оптимальной оценкой σ_i .

Таким образом, применительно к задачам линейного оценивания случайных последовательностей показано, что оптимальный в среднеквадратическом смысле линейный алгоритм и алгоритм, основанный на использовании вейвлета, обеспечивают нахождение оценок с близкими свойствами. Полученный результат позволяет трактовать традиционный алгоритм – линейный фильтр Калмана как вейвлет простейшего вида [119, 121].

4.2.3. Процесс с нарушением

На рисунке 4.4 представлены: случайная последовательность x_i , с нарушением в момент $t_i = 100$ с; измерение y_i , оценка $\tilde{x}_i^{FK}$, полученная с использованием ФК и оценка $\tilde{x}_i^W$, полученная с использованием вейвлета. В этом случае выбрано нарушение в виде

$$\theta_i = \begin{cases} 0, & \text{при } t < t_\lambda; \\ 30, & \text{при } t \geq t_\lambda; \end{cases} \quad \lambda = 100. \quad (4.13)$$




Рисунок 4.4 – Последовательности x_i , y_i и оценки $\tilde{x}_i^{FK}$, $\tilde{x}_i^W$

Из рисунка 4.4 видно, что линейный фильтр Калмана дает значительные ошибки в отличие от фильтра на основе вейвлета.

На рисунке 4.5 представлены спектрограммы непрерывного вейвлет-преобразования (4.9) для измерений y_i для процесса без нарушения и с нарушениями в виде скачкообразного (4.13) и линейного изменения

$$\theta_i = \begin{cases} 0, & \text{при } t < t_\lambda; \\ 30/20, & \text{при } t_\lambda \leq t \leq t_\eta; \end{cases} \quad \lambda = 100, \eta = 120.$$

В нижней части спектрограмм рисунка 4.5 видна весьма сложная структура спектра шума, верхняя часть спектрограмм для процессов с нарушениями ($a > 20$) отчетливо показывает наличие разрыва. Этот пример

является наглядным свидетельством высокой разрешающей способности вейвлетов при выявлении локальной (тонкой) структуры сигналов [87, 88].




Рисунок 4.5 – Спектрограммы непрерывного вейвлет-преобразования

измерений y_i для процессов: а) без нарушений;

б) со скачкообразным изменением; в) с линейным изменением

На рисунке 4.6 представлены результаты оценивания экспоненциально-коррелированного процесса (4.11) при наличии скачкообразного нарушения (4.13):

– расчетное СКО ошибок оценивания σ_i , соответствующее дисперсии ошибки оптимального линейного оценивания;

– выборочные действительные СКО ошибок оценивания фильтра Калмана $\tilde{\sigma}_i^{FK}$ для алгоритма на основе вейвлета $\tilde{\sigma}_i^W$, вычисляемые в соответствии с (4.12).




Рисунок 4.6 – СКО ошибок оценивания процесса при наличии нарушения

Из рисунка 4.6 видно, что при наличии скачкообразного нарушения (4.13) экспоненциально-коррелированного процесса работа ФК нарушается и для повышения точности фильтрации необходимо использование, например, банка фильтров Калмана. Для алгоритма на основе вейвлета ошибка, вызванная нарушением, уменьшается и сходится к расчетной.

Все полученные в разделе 4.2 результаты получены с использованием разработанного нами математического и программного обеспечения зарегистрированного в виде комплекса программ «Вейвлет-оценивание временного ряда» [130]. Рассмотрим более подробно его содержание в следующем параграфе.

4.2.4. Численная и программная реализация решения задачи оптимального нелинейного оценивания и фильтрации с использованием вейвлет-анализа

Для вейвлет-оценивания случайного процесса создан программный комплекс «Вейвлет-оценивание временного ряда» [Приложение Е и F], разработанный в MATLAB (рисунок 4.7).

Программа предназначена для решения задачи оценивания временных рядов по нелинейным измерениям с использованием вейвлет-преобразования и

фильтра Калмана. Рассчитывается среднеквадратичное отклонение ошибок оценивания на примере экспоненциально-коррелированного процесса при отсутствии и наличии нарушений. Применительно к линейной задаче фильтрации случайных последовательностей реализован алгоритм, основанный на использовании вейвлет-преобразования, который обеспечивает нахождение оценок, близких по своим свойствам к оценкам, отыскиваемым с использованием фильтра Калмана. Приводится программная реализация алгоритмов оценивания с использованием фильтра Калмана и вейвлета для процесса с нарушением. Вейвлет-преобразование в случае нарушений временного ряда в отличие от фильтра Калмана позволяет обнаружить и дать точную оценку временного ряда. Реализуется построение спектрограмм непрерывного вейвлет-преобразования для измерений процесса.

Основные модули программы:

sFKalmWvEkr.m – Оценивание экспоненциально-коррелированного процесса без нарушений при гауссовских ошибках измерений с использованием фильтра Калмана и вейвлета.

sInputEkr.m – Параметры экспоненциально-коррелированного процесса без нарушений при гауссовских ошибках измерений.

sModelEkr.m – Модель экспоненциально-коррелированного процесса без нарушений при гауссовских ошибках измерений.

sNKorrelKalmEkr.m – Расчет начальных условий для определения корреляционной матрицы.

sKorrelKalmEkr.m – Корреляционная матрица ошибки фильтрации.

sOcenkaKalmEkr.m – Экстраполяция координаты x .

sFKalmNewWvEkrStep.m – Оценивание экспоненциально-коррелированного процесса при наличии нарушения при гауссовских ошибках измерений с использованием фильтра Калмана и вейвлета.

sInputEkrStep.m – Параметры экспоненциально-коррелированного процесса с нарушениями при гауссовских ошибках измерений.

sModelEkpStep.m – Модель экспоненциально-коррелированного процесса с нарушениями в виде скачкообразного и линейного изменения при гауссовских ошибках измерений.





Рисунок 4.7 – Структура программы «Вейвлет-оценивание временного ряда»

sEkp_FKalmNewWpdencmp.m – Формирование последовательности x_i , y_i и оценки $\tilde{x}_i^{FK}$, $\tilde{x}_i^W$ для экспоненциально-коррелированного процесса без нарушения.

sEkp_FKalmNewWpdencmpStep.m – Формирование последовательности x_i , y_i и оценки $\tilde{x}_i^{FK}$, $\tilde{x}_i^W$ для экспоненциально-коррелированного процесса с нарушениями.

sWaveLetSpektrEkpStep.m – Построение спектрограммы непрерывного вейвлет-преобразования измерений экспоненциально-коррелированного процесса.

Блок-схема оценивания экспоненциально-коррелированного процесса при наличии нарушения при гауссовских ошибках измерений с использованием фильтра Калмана и вейвлета отображена на рисунке 4.8.






Рисунок 4.8 – Блок-схема оценивания экспоненциально-коррелированного процесса при наличии нарушения с использованием ФК и вейвлета

4.3. Применение предложенных синтетических алгоритмов оценивания состояния динамических систем в других приложениях

Синтетические алгоритмы оценивания, предложенные в диссертационной работе, могут быть использованы для разных предметных областей, таких как навигация и системы управления движением подвижных объектов, информационно-навигационные системы, радиотехника, электротехника, робототехника и даже в образовании.

Оценка качества знаний обучаемых. Предлагается использовать синтетические алгоритмы оценивания при оценке качества образования, важным инструментом которой является компьютерное тестирование [126, 127]. Компьютерное тестирование позволяет дать достаточно объективную оценку учебных достижений обучающихся.

Для этого в построенной нами модели компьютерного тестирования для мониторинга качества обучения студентов предлагается в «модуле обработки результатов» применить синтетические алгоритмы оценивания (рисунок 4.9).




Рисунок 4.9 – Модель компьютерного тестирования в процессе мониторинга качества обучения

Параметром системы внутривузовского мониторинга выбрана оценка успеваемости студентов, как отображение результата достижения конечной цели и показателей качества обучения. Оценивание каждого студента в отдельности может дать характеристику только ему лично, но оценивание группы студентов, как некоторой системы, где каждому элементу предоставлялись одни и те же процедуры обучения и контроля способствует оценке самого процесса обучения, классификации преподавателя, отлаженности технологии обучения и контроля знаний в целом. При этом в роли индикативных показателей качества предложен комплекс дескриптивных статистических параметров (средний балл для группы, дисперсия, среднеквадратическое отклонение, коэффициенты асимметрии и эксцесса) отражающие тенденцию статистического распределения в результатах образовательной деятельности.

Представленная модель описывает процесс (алгоритм) формирования и диагностики знаний обучаемых не только при компьютерном тестировании, но и при любой форме контроля. Если необходимо использовать подсистему текущего контроля, то запускается данный процесс и далее по модели.

В «модуле целополагания» устанавливается конкретная цель, которую необходимо достичь.

В блоке «система управления» происходит сравнение требований государственного стандарта и полученных данных (вырабатывается список рекомендаций).

В «модуле управления знаниями» производится расчет критерия уровня сформированности структуры знаний, уровня незнания обучаемых, оценка средней скорости «забывания» знаний, а также при контроле знаний обучаемых - компьютерное тестирование - надежность тестовых результатов.

Блок «интерфейсная система» состоит из рабочих программ дисциплин, методов формирования структуры знаний обучаемых (словесные, комбинированные), виды диагностируемых знаний, дидактические единицы учебных дисциплин, компетенции.

Модуль «объект управления (обучаемые)» - это личные усилия и способности обучаемого, психофизиологические особенности личности.

«Система контроля знаний обучаемых» включает подсистемы компьютерного тестирования (ПКТ), текущего контроля (ПТК) и итоговой аттестации (ПИА).

В «модуле обработки результатов» обрабатываются данные полученные от контроля знаний обучаемых. Здесь и возможно применение синтетических алгоритмов оценивания.

Модуль «преподаватель» состоит из умения преподавателя правильно построить программу подготовки и эффективно ее изложить, ответственности в работе преподавателя по выявлению и устранению пробелов в знаниях студентов, умения преподавателя внести моменты индивидуализации в массовый процесс.

Основными объектами в модели при использовании подсистемы компьютерного тестирования являются: тестируемые – лично ориентированные обучаемые (студенты); преподаватели (тестологи) – разработчики тестовых материалов; нормативная система – предписания, правила, стандарты, нормы, знания, права; банки тестовых заданий (БТЗ) – совокупность тестовых заданий, из которых возможно формировать множество тестов; тестирующая система – компьютерная программная оболочка (инструментальная среда). Преподаватель как объект взаимодействия в дидактической коммуникации непосредственно проявляет себя в каждом модуле компьютерного тестирования.

В представленной модели контроля качества обучения учтена обратная связь. Также в модели цельно объединены все объекты состояния обученности тестируемого, характер тестирующих воздействий и ответных действий испытуемого, механизм оценки результатов тестирования.

Очистка сигнала от шумов. Возможно применить синтетические алгоритмы оценивания в разработанной нами полезной модели «Интеллектуальная изоляционная система» №138401 [128]. Данная модель

является грозозащитным устройством для объекта (изолятора) соединенного с высоковольтным проводом линии электропередачи.

Недостатком изоляторов является низкая (помехоустойчивость) надежность работы из-за возможности снижения сопротивления при внешних воздействиях биологических объектов, таких, например, как птицы.

В модели, предлагается для поддержания надежности работы использовать для изолятора-разрядника интеллектуальную систему по устранению (очищения) помех возмущающих систему в блоке адаптации фона (БАФ) и оценивание движения в блоке детекции движения (БДД) устройства анализа сцены по поступающей информации с камеры наблюдения.

Для фильтрации полезного сигнала от аддитивных помех, то есть очистка сигнала от шумов предлагается использовать вейвлеты. Так как вейвлет-преобразование позволяет выполнять фильтрацию сигнала (изображения) без потерь информации в горизонтальном и вертикальном направлениях при помощи биортогональных вейвлет-фильтров.

Процедура удаления шума и сжатия с помощью вейвлетов включает в себя три шага [63, 87]:

- 1) Разложение. Выполняется с помощью вейвлетов, при этом выбираются тип вейвлета и уровень декомпозиции.

- 2) Детализация. Выбирается определенный порог для детализирующих коэффициентов.

- 3) Вейвлет-восстановление.

Для оценивания движения предлагается использовать синтетические алгоритмы оценивания состояния динамических систем с использованием искусственных нейронных сетей, нечетких систем и вейвлетов.

Технический результат достигается интеграцией изолятора в интеллектуальную систему в качестве объекта управления (ОУ). Основное назначение всех элементов интеллектуальной изоляционной системы за исключением ОУ – фиксация появления посторонних биологических объектов в зоне действия изолятора и активизация исполнительного элемента. В качестве

системы измерений используются камеры наблюдения (КН), данные с которой отправляются на устройство анализа сцены (УАС), состоящее из блоков: нормализации (БН), анализа освещенности (БАО), адаптации фона (БАФ) и детекции движения (БДД). Где и происходит процедура оценивания с применением синтетических алгоритмов.

При обнаружении движения в зоне действия ОУ данные отправляются на подсистему адаптации и распознавания образов, в противном случае происходит обновление фона в БАФ, благодаря чему исключаются ложные срабатывания при изменении условий освещенности или изменении погодных условий. Блок проверки рейтинга (БПР) анализирует степень адаптированности системы распознавания образов к данной КН. При низком рейтинге адаптированного блока распознавания образов (АБРО), проверка корректности работы проверяется базовым блоком распознавания (ББР), который извлекает признаки для классификации из блока памяти признаков объекта (БППО). В БППО могут храниться признаки для любых объектов, распознавание которых необходимо в данной системе. В блоке коррекции рейтинга (БКР) происходит проверка работы системы, и, в случае ошибки происходит ее дообучение (адаптация) к условиям сцены в блоке обучения (БО), с перерасчетом рейтинга доверия. Результат работы подсистемы адаптации и распознавания образов (ПАИРО) передается в устройство управления (УУ) интеллектуальному блоку принятия решений (ИБПР), который оказывает управляющее воздействие на исполнительный элемент (ИЭ), обеспечивающий защиту ОУ. ИБПР, получая цель управления (ЦУ), оказывает влияние на БО и БППО, для выбора объектов распознавания.

Общий вид интеллектуальной изоляционной системы приведен на рисунке 4.10.




Рисунок 4.10 – Интеллектуальная изоляционная система

Таким образом, использование изолятора совместно с интеллектуальной системой управления на базе синтетических алгоритмов оценивания приводит к повышению надежности работы изолятора.

В итоге, применение предложенных синтетических алгоритмов оценивания в других разработках доказывает их эффективность и практическую значимость.

Выводы по четвертой главе

Таким образом, в данной главе получены следующие результаты:

1. Для вейвлет-оценивания предлагается переход от многомерной обработки к двумерной с использованием декомпозиции.
2. Предложен численный метод стохастической аппроксимации на основе регрессии, вейвлетов и декомпозиции.
3. Для проведения компьютерного моделирования разработана модель экспоненциально-коррелированного процесса с нарушениями.
4. На основе метода вейвлет-оценивания разработан новый алгоритм для оценивания неоднородного процесса (экспоненциально-коррелированного

процесса с локальными особенностями) без нарушений и с нарушениями. При компьютерном моделировании получены спектрограммы, которые позволяют выявить и наглядно показать структуру процесса, отражают разрывы непрерывности, скачки и другие особенности, возникающие из-за вариации измеряемой характеристики и сбоев или шума инструментов измерения.

5. Применительно к линейной задаче фильтрации случайных последовательностей показано, что алгоритм, основанный на использовании вейвлет-преобразования обеспечивает нахождение оценок, близких по своим свойствам к оценкам, отыскиваемым с использованием фильтра Калмана. Этот результат позволяет трактовать линейный фильтр Калмана как вейвлет-преобразование простейшего вида.

6. Показано, что при наличии нарушений состояния динамической системы работа фильтра Калмана нарушается и для повышения точности фильтрации необходимо принятие дополнительных мер. Вейвлет-преобразование в случае нарушений состояния динамической системы позволяет обнаружить и дать точную оценку.

7. Разработан комплекс программ оценивания состояния динамических систем на основе вейвлетов.

ЗАКЛЮЧЕНИЕ

В ходе выполнения диссертационной работы были получены следующие результаты:

1) Предложен эффективный с точки зрения быстродействия и точности вычислительный метод оценивания состояния динамических систем, охватывающий все процессы решения задачи оценивания. Основу метода составляет более рациональная по сравнению с существующими аналогами структурная организация используемых синтетических систем оценивания.

2) Предложены математические модели быстродействующих иерархических синтетических систем нерекуррентного и рекуррентного нелинейного оценивания динамических процессов.

3) Развита численные методы стохастической аппроксимации, отличающиеся тем, что для их реализации предложены быстродействующие нейросетевые, нечеткие, вейвлет методы и декомпозиционные алгоритмы субоптимального оценивания состояния динамических систем.

4) Синтезированы быстродействующие субоптимальные нейросетевые, нечеткие и вейвлет алгоритмы оценивания состояния динамических систем с использованием декомпозиции. Разработанные алгоритмы оценивания дают общее решение задачи оценивания для нелинейного, негауссовского случая. При этом скорость обучения иерархических систем значительно выше скорости обучения исходных систем. С помощью иерархических синтетических систем может быть достигнута высокая точность оценивания, которая близка к предельно достижимой точности оптимального нелинейного алгоритма.

5) Получены новые результаты для решения задачи оценивания с помощью НС прямого распространения и с РБФ с декомпозицией и без таковой. Для НС прямого распространения проиллюстрировано применение разных алгоритмов обучения, выявлены их особенности работы.

Продemonстрировано, что использование НС с РБФ затруднительно, в связи с ее излишней громоздкостью. Показано, что иерархические нейронные сети при соответствующем выборе критерия, используемого для их обучения, обеспечивают получение оценок, близких по своим свойствам к оценкам, получаемым с помощью байесовского алгоритма.

6) На основе нечетких методов нелинейного оценивания случайных последовательностей разработаны алгоритмы оценивания – иерархические нечеткие системы, построенные на основе принципа декомпозиции и эвристик. Показано, что с помощью иерархических нечетких систем может быть достигнута высокая точность оценивания, которая близка к предельно достижимой точности оптимального нелинейного алгоритма. При этом скорость обучения иерархических нечетких систем значительно выше скорости обучения исходных нечетких систем.

7) Получены и проанализированы закономерности увеличения быстродействия обучения при использовании декомпозиции при построении синтетических систем.

8) Показано, что системы оценивания на основе вейвлетов могут быть использованы для обнаружения и оценивания неоднородных процессов с локальными особенностями (нарушениями), когда факт появления нарушения в измерительной системе установлен и требуется определить его источник и уровень. Вейвлет-преобразование в случае нарушений состояния динамической системы позволяет обнаружить и дать точную оценку. В отличие от классического метода фильтра Калмана, где при наличии нарушений состояния динамической системы работа фильтра нарушается и для повышения точности фильтрации необходимо принятие дополнительных мер.

9) Применительно к линейной задаче фильтрации случайных последовательностей показано, что алгоритм, основанный на использовании вейвлет-преобразования, обеспечивает нахождение оценок близких по своим свойствам к оценкам, отыскиваемым с использованием фильтра Калмана. Этот

результат позволяет трактовать линейный фильтр Калмана как вейвлет-преобразование простейшего вида.

10) Для проведения компьютерного моделирования разработана модель экспоненциально-коррелированного процесса с локальными особенностями. При компьютерном моделировании получены спектрограммы, которые позволяют выявить и наглядно показать структуру процесса, отражают разрывы непрерывности, скачки и другие особенности, возникающие из-за вариации измеряемой характеристики и сбоев или шума инструментов измерения.

11) Реализованы комплексы программ для моделирования разрабатываемых алгоритмов. Проверена работоспособность, эффективность и точность алгоритмов при решении задач.

Таким образом, в диссертации предложены научно-обоснованные вычислительный метод и численные нейросетевые, нечеткие и вейвлет методы и декомпозиционные алгоритмы нелинейного оценивания недоступного непосредственному наблюдению динамического процесса, отражающего состояние динамической системы, по доступным измерениям другого процесса, связанного с первым посредством некоторой измерительной системы.

Копии охранных документов на интеллектуальную собственность, результаты внедрения, листинги программ для ЭВМ представлены в приложении.

Список сокращений и условных обозначений

МНК – метод наименьших квадратов.

ФК – фильтра Калмана.

РФК – расширенный фильтра Калмана.

НС (NN) – искусственная нейронная сеть.

НчС – нечеткая система.

ВП – мвейвлет-преобразование.

ф.п.р.в. – функция плотности распределения вероятностей.

ММНК – модифицированный метод наименьших квадратов.

СС (SS) – синтетическая система.

FS – нечетка система.

W – вейалет.

РБФ (RBFN) – нейронная сеть с радиальными базисными функциями.

РБЕ – радиальная базисная сеть с нулевой ошибкой.

FFN – Feed Forward Neural Network.

СКО – среднеквадратичное отклонение ошибок оценивания.

ANFIS – Adaptive-Network-based Fuzzy Inference System – адаптивная нейронечеткая сеть.

Список терминов

Динамическая система: система, которая под действием внешних и внутренних сил изменяет во времени свои состояния. В работе рассматриваются нелинейные стохастические системы.

Стохастические процессы: статическое явление, развивающееся во времени согласно законам теории вероятности.

Стохастичность (др.-греч. $\sigma\tau\acute{o}\chi\omicron\varsigma$ – цель, предположение): случайность.

Стохастическая аппроксимация (от греч. *stochastikos* – умеющий угадывать, проницательный и лат. *approximo* – приближаюсь) (С.а.): метод решения широкого класса задач статистического оценивания, при котором каждое следующее значение оценки получается в виде основанной лишь на новом наблюдении поправки к уже построенной оценке. Основными чертами, обусловившими популярность С. а. в теоретических и прикладных работах, явились её непараметричность (применимость при весьма скудной информации об объекте наблюдения) и рекуррентность (простота пересчёта оценки при поступлении нового результата наблюдений).

Аппроксимация: научный метод, состоящий в замене одних объектов другими, в каком-то смысле близкими к исходным, но более простыми. **Приближенная замена функции.**

Стационарные случайные процессы: процессы, протекающие во времени приблизительно однородно и имеющие вид непрерывных случайных колебаний вокруг некоторого среднего значения, причем ни средняя амплитуда, ни характер этих колебаний не обнаруживают существенных изменений с течением времени.

Нестационарный (неоднородный) процесс: процесс характерен тем, что он имеет определенную тенденцию развития во времени; характеристики такого процесса зависят от времени от начала отсчета до конца.

Регрессия: зависимость среднего значения какой-либо величины от некоторой другой величины или от нескольких величин.

Задача регрессии: задача описания одного случайного вектора при фиксированном значении другого статистически связанного с ним вектора.

Апостериорная (условная) плотность распределения: плотность соответствует апостериорной ситуации, когда один из векторов, связанный с оцениваемым вектором, фиксируется ($f(\mathbf{x}/\mathbf{y})$ и $f(\mathbf{y}/\mathbf{x})$).

Функция распределения вероятностей: представляет собой скалярную функцию $F_x(x)$ действительного аргумента x и определяющая вероятность того, что случайная величина x принадлежит открытому интервалу $(-\infty, x)$, т.е. вероятность того, что $x < x$.

Вейвлеты: представляют собой особые функции в виде коротких волн (всплесков) с нулевым интегральным значением и с локализацией по оси независимой переменной (t или x), способных к сдвигу по этой оси и масштабированию (растяжению/сжатию).

Вейвлет-функция: создается на основе той или иной базисной (материнской) функции, которая определяет тип вейвлета.

Вейвлет-преобразование сигналов: разложение сигнала на две составляющие - грубую (аппроксимирующую) и уточняющую (детализирующую) - с последующим их дроблением с целью изменения уровня декомпозиции сигнала. Это возможно как во временной, так и в частотной областях представления сигналов вейвлетами.

Байесовский подход - заключается в переходе от априорных знаний (или точнее незнаний) к апостериорным с учетом наблюдаемых явлений.

Измерительная система - это совокупность средств измерений и вспомогательных устройств, соединенных между собой каналами связи, размещенных в разных точках контролируемого пространства с целью измерения одной или нескольких физических величин, свойственных этому пространству (контролирующие, управляющие системы с ЭВМ).

СПИСОК ЛИТЕРАТУРЫ

1. Амосов, О.С. Фильтрация марковских последовательностей на основе байесовского, нейросетевого подходов и систем нечеткой логики при обработке навигационной информации / О. С. Амосов // Известия РАН. Теория и системы управления. – 2004. – Т. 43. – № 4. – С. 61–69.
2. Амосов, О.С. Системы нечеткой логики для фильтрации марковских последовательностей / О. С. Амосов // Информационные технологии. – 2004. – № 11. – С. 16–24.
3. Амосов, О.С. Нейросетевые и нечеткие методы оценивания стохастических систем: автореф. дис. ... д-ра техн. наук: 05.13.18 / Амосов Олег Семенович. – Владивосток, 2004. – 37 с.
4. Амосов, О.С. Нейросетевые и нечеткие методы оценивания стохастических систем: дис. ... д-ра техн. наук: 05.13.18 / Амосов Олег Семенович. – Комсомольск-на-Амуре, 2004. – 352 с.
5. Амосов, О.С. Интеллектуальные информационные системы. Нейронные сети и нечеткие системы: учебное пособие для студентов специальностей 010502 «Прикладная информатика (по областям)», 230201 «Информационные системы и технологии» вузов региона / О.С. Амосов. – Комсомольск-на-Амуре, КнАГТУ – 2006. – 136 с.
6. Амосов, О.С. Искусственные нейронные сети, нечеткие и экспертные системы: Лабораторный практикум / О.С. Амосов, Д.С. Магола. – Комсомольск-на-Амуре: ГОУ ВПО «КнАГТУ», 2005. – 100 с.
7. Амосов, О.С. Математическое моделирование и программная реализация вейвлет-преобразования сигналов / О.С. Амосов, Д.С. Магола // Информационно-коммуникационные технологии в образовании: Сб. науч. трудов. – Хабаровск, 2008. – С. 3–12.
8. Амосов, О.С. Модели и алгоритмы идентификации пользователя корпоративной информационной системы на основе нейронных сетей и

вейвлетов / О.С. Амосов, Д.С. Магола // Информатика и системы управления. – 2008. – № 3(17). – С. 91–101.

9. Амосов, О.С. Определение вида вейвлета с использованием нечеткого логического вывода / О.С. Амосов, Д.С. Магола // Труды IX Всероссийской научно-технической конференции «Теоретические и прикладные вопросы современных информационных технологий»: Ч.1 – Улан-Удэ, 24–29 марта 2008. – С. 108–112.

10. Амосов, О.С. Применение нечеткого логического вывода при вейвлет-анализе сигналов / О.С. Амосов, Д.С. Магола // Тр. межрегион. науч.-практ. конф. «Информационные и коммуникационные технологии в образовании и научной деятельности». – Хабаровск, 2008. – С. 238–246.

11. Амосов, О.С. Модели и алгоритмы обучения вейвлет-нейронных сетей и нечетких вейвлет-нейронных сетей / О.С. Амосов, Д.С. Магола // Труды X Международной научно-технической конференции «Теоретические и прикладные вопросы современных информационных технологий»: Ч.2 – Улан-Удэ, 20–26 июля 2009. – С. 388–392.

12. Амосов, О.С., Амосова, Л.Н., Магола, Д.С. Оценивание случайных последовательностей с использованием регрессии и вейвлетов / О.С. Амосов, Л.Н. Амосова, Д.С. Магола // Информатика и системы управления. – 2009. – №3(21). – С. 101-109.

13. Амосов, О.С., Амосова, Л.Н. Метод оценивания случайных последовательностей с помощью регрессии и вейвлетов / О.С. Амосов, Л.Н. Амосова // Амурский научный вестник. – 2009. – № 2. – С. 370-377.

14. Амосов, О.С. Оптимальное оценивание с использованием регрессии и вейвлетов // 17 Санкт-Петербургская Международная конференция по интегрированным навигационным системам. – Санкт-Петербург, 2010. – С. 314–317.

15. Амосов, О.С., Магола, Д.С., Малашевская, Е.А. Оценивание случайных последовательностей с использованием нечетких систем и кластеризации / О.С.

- Амосов, Д.С. Магола, Е.А. Малашевская // Информатика и системы управления. – 2012. – № 1 (31). – С. 146–155.
16. Аоки, М. Оптимизация стохастических систем / М. Аоки. – М.: Наука, 1971. – 424 с.
17. Астафьева, Н.И. Вейвлет-анализ: основы теории и примеры применения / Н.И. Астафьева. // Успехи физических наук. – 1996. – Том 166, № 11. – С. 1145–1170.
18. Бахвалов, Н.С. Численные методы (анализ, алгебра, обыкновенные дифференциальные уравнения) / Н.С. Бахвалов. – М.: Главная редакция физико-математической литературы издательства «Наука», 1975. – 628 с.
19. Березин, И.С., Жидков, Н.П. Методы вычислений / И.С. Березин, Н.П. Жидков. – Т.1 2-е изд. – М., 1962. – 464 с.
20. Брайсон А.Е., Хо Ю Ши Прикладная теория оптимального управления / А.Е. Брайсон, Ю Ши Хо. – М.: Мир, 1972. – 544 с.
21. Браммер, К., Зиффинг, Г. Фильтр Калмана-Бьюси / К. Браммер, Г. Зиффинг. – М.: Наука, 1982. – 198 с.
22. Бьюси, Р.С. Линейная и нелинейная фильтрация / Р.С. Бьюси // ТИИЭР. – 1970. – Т.58, № 5
23. Вапник, В.Н., Червоненкис, А.Я. Теория распознавания образов / В.Н. Вапник, А.Я. Червоненкис. – М.: Наука, 1974.
24. Вапник, В.Н. Восстановление зависимостей по эмпирическим данным / В.Н. Вапник. – М.: Наука, 1979. – 447с.
25. Витязев, В.В. Вейвлет-анализ временных рядов: учебное пособие / В.В. Витязев. – СПб.: Изд-во С.-Петербур. Ун-та, 2001. – 58 с.
26. Вороновский, Г.К., и др. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности / Г.К. Вороновский, К.В. Махотило, С.Н. Петрашов, С.А. Сергеев. – Х.: Основа, 1997. – 112 с.
27. Галушкин, А.И. Теория нейронных сетей. Кн. 1: Учебное пособие для вузов / Общ. Ред. А.И. Галушкина. – М.: ИПРЖР, 2000. – 416 с.

28. Гальченко, В.Я., Гринь, Н.Ю. Подавление шумов в изображениях с помощью комбинированного вейвлет-фильтра и фильтра Калмана / В.Я. Гальченко, Н.Ю. Гринь // Информационные технологии. – 2005. – №6. – С. 59–63.
29. Граничин, О.Н., Поляк, Б.Т. Рандомизированные алгоритмы оценивания и оптимизации при почти произвольных помехах / О.Н. Граничин, Б.Т. Поляк. – М.: Наука, 2003. – 293 с.
30. Грибунин, В. Введение в анализ данных с применением непрерывного вейвлет-преобразования / В. Грибунин. – СПб.: АВТЭКС, 1998. – 29 с.
31. Девятисильный, А.С., Дорожко, В.М., Числов, К.А. Разработка и исследование моделей и технологий гравиметрии на подвижном основании / А.С. Девятисильный, В.М. Дорожко, К.А. Числов // Информатика и системы управления. – 2009. – № 2 (20). – С. 106–111.
32. Девятисильный, А.С., Числов, К.А. Способ построения двухкомпонентной гравиинерциальной системы на основе принципа Д’Аламбера / А.С. Девятисильный, К.А. Числов // Информатика и системы управления. – 2011. – №1 (27). – С. 26–31.
33. Девятисильный, А.С., Числов, К.А. Модель интегрированной векторной двухкомпонентной гравиинерциальной системы / А.С. Девятисильный, К.А. Числов // Информатика и системы управления. – 2012. – № 2 (32). – С. 48–54.
34. Дмитриев, С.П., Степанов О.А. Нелинейная фильтрация в задачах обработки навигационной информации. В сб. «Нелинейная теория управления и ее приложения» / С.П. Дмитриев, О.А. Степанов. – М.: Физматлит, 2003. – С. 127–146.
35. Дьяконов, В.П. Вейвлеты. От теории к практике / В.П. Дьяконов. – М.: СОЛОН-Пресс, 2004. – 400 с.
36. Ефименко, В.С., Харисов, В.Н., Стребков, Е.Г. Применение нейронных сетей в задачах оптимальной фильтрации / В.С. Ефименко, В.Н. Харисов, Е.Г. Стребков // Радиотехника. – 2000. – № 7. – С. 56–61.

37. Зарицкий, В.С., Светник, В.Б., Шимелевич, Л.И. Метод Монте-Карло в задачах оптимальной обработки информации / В.С. Зарицкий, В.Б. Светник, Л.И. Шимелевич // Автоматика и телемеханика. – 1975 – №12 – С. 95–103.
38. Ибрагимов, И.А., Хасьминский, Р.З. Асимптотическая теория оценивания / И.А. Ибрагимов, Р.З. Хасьминский. – М.: Наука, 1979.
39. Казаков, И.Е., Гладков Д.И. Методы оптимизации стохастических систем / И.Е. Казаков, Д.И. Гладков. – М.: Наука, 1987. – 304 с.
40. Кайлатц, Т. Метод порождающего процесса в применении к теории обнаружения и оценки / Т. Кайлатц // ТИИЭР. – 1970. – Т.58, № 5
41. Каллан, Р. Основные концепции нейронных сетей: Пер. с англ. / Р. Каллан. – М.: Издательский дом «Вильямс», 2001. – 287 с.
42. Каточ, Р., Махапатра, П.Р. Оценка пространственного положения самолета при помощи GPS приемника с использованием нейронной сети и фильтра Калмана / Р. Каточ, П.Р. Махапатра // Гироскопия и навигация. – 2006. – №3. – С. 3–11.
43. Комашинский, В.И., Смирнов, Д.А. Нейронные сети и их применение в системах управления и связи / В.И. Комашинский, Д.А. Смирнов. – М.: Горячая линия – Телеком, 2003. – 94 с.
44. Кофман, А. Введение в теорию нечетких множеств / Пер. с франц. В.Б. Кузьмина. Под ред. С.И. Травкина. – М.: «Радио и связь», 1982. – 432 с.
45. Кошаев, Д.А. Методы оценивания сигналов навигационных систем на основе многоальтернативного и неполного стохастического описания: дис. ... д-ра. техн. наук: 05.13.01 / Кошаев Дмитрий Анатольевич. – СПб., 2010. – 242 с.
46. Круглов, В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. – М.: Горячая линия–Телеком, 2002.– 382 с.
47. Круглов, В.В., Дли, М.И., Голунов, Р.Ю. Нечеткая логика и искусственные нейронные сети / В. В. Круглов, М.И. Дли, Р.Ю. Голунов.– М.: Издательство Физико-математической литературы, 2001. – 224 с.

48. Леоненков, А.В. Нечеткое моделирование в среде MATLAB и fuzzy TECH / А.В. Леоненков. – СПб.: БХВ – Петербург, 2005. – 736 с.
49. Максимова, А.П., Малова, Н.А. Лабораторный практикум по вычислительной математике. Методические указания по выполнению лабораторных работ / А.П. Максимова, Н.А. Малова. – Чебоксары: Волжский филиал МАДИ (ГТУ), 2008. – 91 с.
50. Медич, Дж. Статистические оптимальные линейные оценки и управление / Дж. Медич. – М.: Энергия, 1973. – 440 с.
51. Месарович, М. Общая теория систем: Математические основы / М. Месарович, Я. Такахара. Пер. с англ. – М.: Мир, 1978. – 312 с.
52. Морозов, А.Д., Драгунов, Т.Н. Визуализация и анализ инвариантных множеств динамических систем / А.Д. Морозов, Т.Н. Драгунов. – М.: Ижевск: Институт компьютерных исследований, 2003. – 304 с.
53. Нечеткие множества в моделях управления и искусственного интеллекта / Под ред. Д.А. Поспелова. – М.: Наука. Главная редакция физико-математической литературы, 1986. – 312 с.
54. Новиков, Л.В. Основы вейвлет-анализа сигналов. Учебное пособие / Л.В. Новиков. – СПб.: Изд-во ИАНП РАН ООО «МОДУС+», 1999. – 152 с.
55. Осовский, С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.
56. Пащенко, Ф.Ф., Амосов, О.С., Иванов, С.Н. Синтез систем управления электромеханическими преобразователями / Ф.Ф. Пащенко, О.С. Амосов, С.Н. Иванов // Датчики и системы. – 2006. – № 8. – С. 18–22.
57. Пащенко, Ф.Ф., Пикина, Г.Ф. Основы моделирования энергетических объектов / Ф.Ф. Пащенко, Г.Ф. Пикина. – М.: Физматлит, 2011. – 556 с.
58. Перов, А.И., Соколов, Г.Г. Сравнительный анализ нейросетевых и статистических алгоритмов в задачах обнаружения сигналов / А.И. Перов, Г.Г. Соколов // Цифровая обработка сигналов и ее применение: Тр. 3 Междун. конф. “DSPA-2000”. – М., 2000. – С. 28–31.

59. Поляхов Н.Д., Приходько И.А., Кузнецов В.Е., Якупов О.Э. Интеллектуальные системы управления / Учеб. пособие. Изд-во СПбГЭТУ «ЛЭТИ», 2010.
60. Радиотехнические системы: Учеб. для вузов по спец. «Радиотехника» / Ю.П. Гришин, В.П. Ипатов, Ю.М. Казаринов и др.; Под ред. Ю.М. Казаринова. – М.: Высш. шк., 1990. – 496 с.: ил.
61. Рутковская, Д., Пилиньский, М., Рутковский, Л. Нейронные сети, генетические алгоритмы и нечеткие системы: Пер. с польск. И.Д. Рудинского / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2006. – 452 с.
62. Сейдж, Э., Мелс, Дж. Теория оценивания и ее применение в связи и управлении / Э. Сейдж, Дж. Мелс. – М.: Связь, 1976.
63. Смоленцев, Н.К. Основы теории вейвлетов. Вейвлеты в MATLAB / Н.К. Смоленцев. – М.: ДМК, 2005. – 304 с.
64. Сосулин, Ю.Г. Теория обнаружения и оценивания стохастических сигналов / Ю.Г. Сосулин. – М.: Сов. Радио, 1978.
65. Справочник по теории автоматического управления / Под ред. А.А. Красовского. – М.: Наука. Гл. ред. физ.-мат. лит., 1987. – 712 с.
66. Степанов, О.А. Применение теории нелинейной фильтрации в задачах обработки навигационной информации / О.А. Степанов. – СПб.: ГНЦ РФ–ЦНИИ «Электроприбор», 1998. – 370 с.
67. Степанов, О.А., Амосов, О.С. Байесовское оценивание с использованием нейронной сети / О.А. Степанов, О.С. Амосов // Авиакосмическое приборостроение. – 2004. – № 6. – С. 46–55.
68. Степанов, О.А., Амосов, О.С. Нерекуррентное линейное оценивание с использованием нейронной сети / О.А. Степанов, О.С. Амосов // Математика, информатика, управление: Материалы III Всероссийской конференции, 29 июня – 1 июля 2004. – Иркутск, 2004. – С. 1–12.

69. Степанов, О.А. Амосов, О.С. Оптимальная линейная фильтрация с использованием нейронной сети / О.А. Степанов, О.С. Амосов // Гирроскопия и навигация. – 2004. – № 3 (46). – С. 14–29.
70. Степанов, О.А., Амосов, О.С. Применение нейронных сетей в нелинейных задачах обработки навигационной информации / О.А. Степанов, О.С. Амосов // Матер. XIII Санкт-Петербургской междун. конф. по интегрированным навигационным системам: Сб. науч. тр. – СПб.: ГНЦ РФ ЦНИИ «Электроприбор», 2006. – С. 178–182.
71. Степанов, О.А., Осипов, А.В., Васильев, В.А. Нечеткие и байесовские алгоритмы в задаче нелинейного оценивания / О.А. Степанов, А.В. Осипов, В.А. Васильев // Гирроскопия и навигация. – 2009. – № 1 (64). – С. 22–35.
72. Степанов, О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. Ч.1. Введение в теорию оценивания / О.А. Степанов. – Изд. 2-е, исправлен и дополнен. – СПб.: ГНЦ РФ ОАО «Концерн «ЦНИИ «Электроприбор», 2010. – 509 с.
73. Степанов, О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. Ч.2. Введение в теорию фильтрации / О.А. Степанов. – СПб.: ГНЦ РФ ОАО «Концерн «ЦНИИ «Электроприбор», 2012. – 417 с.
74. Степанов, О.А. Сравнение методов идентификации моделей ошибок датчиков, основанных на вариациях Аллана и алгоритмах нелинейной фильтрации / О.А. Степанов, А.В. Моторин // Матер. XXI Санкт-Петербургской междун. конф. по интегрированным навигационным системам: Сб. науч. тр. – СПб.: ОАО «Концерн «ЦНИИ «Электроприбор», 2014. – С. 98–104.
75. Стратонович, Р.С. К теории оптимальной нелинейной фильтрации случайных функций/ Р.С. Стратонович // Теория вероятностей и ее применение. – 1958. – Т.4.
76. Строганов, А. Использование нейронных сетей для прогнозирования деградации выходных параметров ТТЛ ИС в системе MATLAB / Simulink / А. Строганов // Компоненты и технологии. – 2006. – № 1.

77. Терехов, В.А., Ефимов, Д.В., Тюкин, И.Ю., Антонов, В.Н. Нейросетевые системы управления. Кн.8 Сер. «Нейрокомпьютеры и их применение / Под. ред. Галушкина А.И. – М.: ИПРЖР, 2002. – 480с.
78. Тихонов, В.И., Кульман, Н.К. Нелинейная фильтрация и квазикогерентный прием сигналов / В.И. Тихонов, Н.К. Кульман. – М.: Советское радио. 1957. – 704 с.
79. Тупысев, А.В. Методы синтеза алгоритмов фильтрации с гарантированным качеством оценивания параметров в задачах обработки навигационной информации: автореф. дис. ... д-ра техн. наук: 05.11.03, 05.13.01 / Тупысев Виктор Авенирович. – СПб., 2011. – 35 с.
80. Турчак, Л.И. Основы численных методов: Учеб. Пособие / Л.И. Турчак. – М.: Наука. Гл. ред. физ.-мат. лит., 1987. – 320 с.
81. Фомин, В.Н. Рекуррентное оценивание и адаптивная фильтрация / В.Н. Фомин. – М.: Наука. Гл. ред. физ.-мат. лит., 1984. – 288 с.
82. Фомин, В.Н. Операторные методы теории линейной фильтрации случайных процессов / В.Н. Фомин. – СПб.: Изд-во СПбГУ, 1996.
83. Хайкин, С. Нейронные сети: полный курс, 2-е изд.: Пер. с англ. / С. Хайкин. – М.: Издательский дом «Вильямс», 2006. – 1104 с.
84. Чуи, Ч. Введение в вейвлеты: Пер. с англ. / Ч. Чуи.– М.:Мир, 2001. –412 с.
85. Штовба, С.Д. Введение в теорию нечетких множеств и нечеткую логику [Электронный ресурс] / С.Д. Штовба. – Режим доступа: <http://matlab.exponenta.ru/fuzzylogic/book1/index.php>.
86. Штовба С.Д. Проектирование нечетких систем средствами MATLAB / С.Д. Штовба. – М.: Горячая линия – Телеком, 2007. – 288 с.
87. Яковлев, А.Н. Введение в вейвлет- преобразование: Учебное пособие / А.Н. Яковлев. – Новосибирск: Изд-во НГТУ, 2003. – 104 с.
88. Яковлев, Е.К., Блатов, И.А. Определение параметров движения центра масс космического аппарата с помощью комбинированного вейвлет фильтра и фильтра Калмана / Е.К. Яковлев, И.А. Блатов // Известия Самарского научного центра Российской академии наук. – 2012. – Т. 14, №6. – С. 212 –215.

89. Ярлыков, М.С., Миронов, М.А. Марковская теория оценивания случайных процессов / М.С. Ярлыков, М.А. Миронов. – М.: Радио и связь, 1993. – 464 с.
90. Ярушкина, Н.Г. Интеллектуальный анализ временных рядов: Учеб. пособие / Н.Г. Ярушкина, Т.В. Афанасьева, И.Г. Перфильева. – Ульяновск: УлГТУ, 2010. – 320 с.
91. Alessandri, A., Parisini, T., Zoppoli, R. Sliding-window neural state estimation in a power plant heater line / A. Alessandri, T. Parisini, R. Zoppoli. // Proceedings of the American Control Conference San Diego. – California, June 1999. – P. 880–884.
92. Amosov, O.S., Amosova, L.N. Optimal Estimation by Using Fuzzy Systems / O.S. Amosov, L.N. Amosova // Proc. of the 17th IFAC World Congress. – Seoul, Korea, July 6-11, 2008. – P. 6094-6099.
93. Amosov, O.S. Random Sequences Optimal Estimation by Using Regression and Wavelets / O.S. Amosov, L.N. Amosova // 7th IEEE International Conference on Control and Automation. – Christchurch, New Zealand, December 9–11, 2009. – P. 2293–2298.
94. Amosov, O.S. Optimal and Adaptive Estimation Using On-Line Training Neural Networks / O.S. Amosov // Proc. of the 2nd International Conference on Intelligent Control and Information Processing ICICIP. – Harbin, China, 2011. – P. 208–213.
95. Amosov, Oleg S. Regression and Wavelet Model Based Nonlinear Optimal Estimation / O.S. Amosov // Proc. of the 2012 Third International Conference on Theoretical and Mathematical Foundations of Computer Science (ICTMF 2012). – Indonesia, in: Lecture Notes in Information Technology, Information Engineering Research Institute, USA. – December 1-2, 2012. – Vol. 38, pp. 710–716.
96. Berardi, V.I., Zhang, P.G. An Empirical Investigation of Bias and Variance in Time Series Forecasting: Modeling Considerations and Error Evaluation / V.I. Berardi, P.G. Zhang // IEEE Trans. Neural Networks. – 2003. – Vol. 14, No 3. – P. 668–679.

97. Gelb, A. Applied Optimal Estimation. M.I.T. / A. Gelb // Press, Cambridge, MA, 1974.
98. Grewal, M.S. Andrews, A.P. Kalman Filtering: Theory and Practice Prentice / M.S. Grewal, A.P. Andrews. – Upper Saddle River, New Jersey, 1993.
99. Hagan, M. T., and Menhaj, M. Training feedforward networks with the Marquardt algorithm / M.T. Hagan, M. Menhaj // IEEE Transactions on Neural Networks. – 1994. – Vol. 5, No 6. – P. 989–993.
100. Hagan, M.T., Demuth, H.B. and Beale, M.H. Neural Network Design / M.T. Hagan, H.B. Demuth, M.H. Beale. – Boston, MA: PWS Publishing, 1996. – 736 p.
101. Haykin, S. Neural networks: A comprehensive foundation / S. Haykin. – New York: Macmillan College Publishing Company, 1994. – 694p.
102. Haykin, S., Yee, P. Optimum nonlinear filtering / S. Haykin, P. Yee // IEEE Trans. On Signal Processing. – 1997. Vol. 45, No 11. – P.2774–2786.
103. Hardle, W. Wavelets, Approximation and Statistical Applications / W. Hardle, G. Kerkycharian, D. Picard, A. Tsubakov. – Berlin-Paris, 1997.
104. Jazwinski, A.H. Stochastic processes and filtering theory / A.H. Jazwinski. – New York. Academic Press, 1970.
105. Klemen, Rupnik, Primor Potocnik Identification of the measurement characteristic of the critical flow Venturi nozzle mass flow meter using radial basis function neural network models / Klemen, Rupnik, Primor Potocnik. – University of LJUBLJANA, 2011. – 29 p.
106. Kushner, H.J. Dynamic equations for optimal nonlinear filtering / H.J. Kushner // J. Differential Equations. – 1967. N 3. – P. 179–190.
107. Lo, J. T. H. Synthetic approach to optimal filtering / J. T. H. Lo // IEEE Trans. Neural Networks. – 1994. – Vol. 5, N 5. – P. 803–811.
108. Madan, M. Gupta, Liang Jin, and Noriyasu Homma Static and dynamic neural networks: From Fundamentals to Advanced Theory. Foreword by Lotfi A. Zadeh / M. Gupta Madan, Jin Liang, H. Noriyasu // IEEE PRESS Wiley-Interscience. – New Jersey. – 2003. – 722 p.

109. Merry Cherian, S. Paul Sathiyar Neural Network based ACC for optimized safety and comfort / Cherian Merry, S. Paul Sathiyar // International Journal of Computer Applications (0975-887). – 2012. – Vol. 42, No 14. – P. 1–6.
110. McNeill, F. Martin Fuzzy logic: a practical approach / F. Martin McNeill, Ellen Thro. – London. Ap Professional. – 1994. – 279 p.
111. Olivier, Rioul and Vetterli Wavelets and Signal Processing / Olivier, Rioul, Vetterli // IEEE SP Magazine. - 1991. – P. 14-38
112. Parlos, A.G., Menon, S.K., and Atiya, A.F. An algorithmic approach to adaptive state filtering using recurrent neural networks / A.G. Parlos, S.K. Menon, A.F. Atiya // IEEE Trans. Neural Networks. 2001. – Vol.12, No 6. – P. 1411–1432.
113. Stepanov, O.A., Amosov, O.S. Nonrecurrent linear estimation and neural networks / O.A. Stepanov, O.S. Amosov // Proc. of Workshop on Adaptation and Learning in Control and Signal Processing (ALCOSP) IFAC and Workshop on Periodic Control Systems (PSYCO) IFAC. – Yokohama, Japan, 2004. – P. 213–218.
114. Stepanov, O.A., Amosov, O.S. Optimal Estimation by Using Neural Networks. / O.A. Stepanov, O.S. Amosov // Proceeding of the 16-th IFAC World Congress. – Prague, Czech Republic July 3–8, 2005. – 6 p.
115. Stepanov, O.A., Amosov, O.S. Optimal Estimation Algorithms Based on the Monte Carlo Method and Neural Networks for Nonlinear Navigational Problems / O.A. Stepanov, O.S. Amosov // Proc. of the IEEE CAC/CACD/ICC. – Munich, Germany, October 4–6, 2006. – P. 1432–1437.
116. Stepanov, O.A., Amosov, O.S. The Comparison of the Monte-Carlo Method and Neural Networks Algorithms in Nonlinear Estimation Problems / O.A. Stepanov, O.S. Amosov // Proc. of the 9th IFAC WORKSHOPS «Adaptation and Learning in Control and Signal Processing». – Saint Peterburg, Russia, 2007. – 6 p.

ПУБЛИКАЦИИ АВТОРА ПО ТЕМЕ ДИССЕРТАЦИОННОЙ РАБОТЫ

117. Амосов, О.С., Баена, С.Г. Байесовское оценивание с использованием нейронной сети с радиальными базисными функциями / О.С. Амосов, С.Г.

- Баена // Информатика и системы управления. – 2013. – № 2 (36). – С. 127–133. (ВАК)
118. Амосов, О.С., Малашевская, Е.А., Баена, С.Г. Субоптимальное оценивание случайных последовательностей с использованием иерархических нечетких систем / О.С. Амосов, Е.А. Малашевская, С.Г. Баена // Информатика и системы управления. – 2013. – № 3 (37). – С. 123–133. (ВАК)
119. Амосов, О.С., Баена, С.Г. Субоптимальное нелинейное оценивание на основе иерархических синтетических систем / О.С. Амосов, С.Г. Баена // Системы управления и информационные технологии. – 2014. – №2(56). – С. 4–8. (Web of Science, ВАК)
120. Амосов, О.С., Баена, С.Г., Амосова, Л.Н. Нелинейное оценивание временных рядов с использованием синтетических систем / О.С. Амосов, С.Г. Баена, Л.Н. Амосова // Информатика и системы управления. – 2014. – № 2 (40). – С. 84–93. (ВАК)
121. Амосов, О.С., Баена, С.Г. Быстродействующие численные нейросетевые и нечеткие методы стохастического оценивания состояния динамических систем // Информатика и системы управления. – 2014. – № 4 (42). – С. 118–129. (ВАК)
122. Амосов, О.С., Баена, С.Г. Нелинейная фильтрация с использованием синтетических систем / О.С. Амосов, С.Г. Баена // Фундаментальные проблемы науки: сборник статей Международной научно-практической конференции. – Уфа: РИЦ БашГУ, 2013. – С. 3–9.
123. Amosov, O.S., Baena, S.G. Optimal nonlinear estimation by using hierarchical synthetic systems / O.S. Amosov, S.G. Baena // 21st Saint Petersburg international conference on integrated navigation systems / CSRI Elektropribor. – Saint Petersburg, 26-28 may 2014. – P. 161–166. (ISBN 978-5-91995-032-5) (Scopus)
124. Амосов, О.С., Баена, С.Г. Оптимальное нелинейное оценивание с использованием иерархических синтетических систем / О.С. Амосов, С.Г. Баена // 21 Санкт-Петербургская Международная конференция по интегрированным навигационным системам / Концерн «ЦНИИ «Электроприбор». – СПб, 26–28 мая 2014. – С. 126–131. (ISBN 978-5-91995-030-1) (РИНЦ)

125. Амосов, О.С., Баена, С.Г. Вычислительный метод и синтетические алгоритмы оценивания состояния динамических систем на основе декомпозиции / О.С. Амосов, С.Г. Баена // Всероссийская научная конференция XXXVIII Дальневосточная Математическая Школа-Семинар имени академика Е.В. Золотова 1–5 сентября 2014, Владивосток (ISBN 978-5-7442-1576-7)
126. Баена, С.Г. Модель компьютерного тестирования в процессе мониторинга качества обучения на основе кибернетического подхода / С.Г. Баена // Актуальные проблемы математики, физики, информатики в вузе и школе: материалы Международной научно-практической конференции. – г. Комсомольск-на-Амуре: АмГПГУ, 2012. – С. 45–52
127. Баена, С.Г. Оценивание результатов обучения и компетенций студентов с использованием информационных технологий / С.Г. Баена // Социальное и экономическое развитие АТР: проблемы, опыт, перспективы: материалы V Международной заочной научно-практической конференции. – г. Комсомольск-на-Амуре: АмГПГУ, 2012. – С. 141–147.
128. Пат. 138401 РФ. Интеллектуальная изоляционная система / Амосов О.С., Иванов Ю.С., Иванов С.Н., Баена С.Г. // Официальный бюл. «Изобретения. Полезные модели». –2014. – №7.
129. Амосов, О.С., Баена, С.Г. Нейросетевая система оценивания NN Estimator. Свидетельство о государственной регистрации программы для ЭВМ № 2014617763 от 01.08.2014 г.
130. Амосов, О.С., Баена, С.Г. Вейвлет-оценивание временного ряда. Свидетельство о государственной регистрации программы для ЭВМ № 2014617998 от 07.08.2014 г.




Рисунок П.1 – Иллюстрация к алгоритму Сугено




Рисунок П.2 – Структура нечеткой нейронной системы (архитектура ANFIS)

АКТ О ВНЕДРЕНИИ НАУЧНО-ПРАКТИЧЕСКИХ РЕЗУЛЬТАТОВ ДИССЕРТАЦИИ

«УТВЕРЖДАЮ»



Ректор ФГБОУ ВПО «Амурский
государственный университет»
д.т.н., профессор

А.Д. Плутенко

« 27 » октября 2014 г.

АКТ

**о внедрении научно-практических результатов диссертации
«Вычислительный метод и синтетические алгоритмы оценивания
состояния динамических систем с использованием декомпозиции»**

Комиссия в составе: председателя – Александра Анатольевича Остапенко (канд. техн. наук по спец. 05.13.18); членов – Светланы Геннадьевны Самохваловой (канд. техн. наук по спец. 05.13.18) и Александра Вениаминовича Бушманова (канд. техн. наук по спец. 05.02.13), составила настоящий акт о том, что основные результаты диссертации **Баена Светланы Геннадьевны**, подготовленной на соискание ученой степени кандидата технических наук по специальности 05.13.18 – Математическое моделирование, численные методы и комплексы программ, практически используются в научно-исследовательской деятельности Кафедры информационных и управляющих систем Факультета математики и информатики Амурского государственного университета.

Предмет внедрения: предлагаемые соискателем быстродействующие алгоритмы субоптимального оценивания состояния динамических систем, проводимого на основе нейронных сетей прямого распространения или с радиальными базисными функциями, выбираемыми пользователем; предлагаемая автором диссертации модель экспоненциально-коррелированного процесса с нарушениями в виде линейных изменений.

Объект внедрения: «Нейросетевая система оценивания NN Estimator» / Свидетельство о государственной регистрации программы для ЭВМ (РФ) № 2014617763; «Вейвлет-оценивание временного ряда» / Свидетельство о государственной регистрации программы для ЭВМ (РФ) № 2014617998.

Область внедрения: выполнение НИР № 01201053818 по теме «Компьютерное моделирование характеристик природных и технических систем».

Председатель комиссии:

проректор по ИиНОТ
к.т.н. Остапенко А.А.

Члены комиссии:

декан ФМиИ,
к.т.н. Самохвалова С.Г.

зав. кафедрой ИиУС
к.т.н. Бушманов А.В.

27.09.2014

АКТ О ВНЕДРЕНИИ РЕЗУЛЬТАТОВ ДИССЕРТАЦИИ В УЧЕБНУЮ ДЕЯТЕЛЬНОСТЬ



УТВЕРЖДАЮ
Ректор ФГБОУ ВПО «Комсомольский-на-Амуре
государственный технический университет»,
доктор технических наук, профессор
Эдуард Анатольевич Дмитриев
«18» 09 2014 г.

АКТ
о внедрении результатов кандидатской диссертационной работы
Баена Светланы Геннадьевны «Вычислительный метод и синтетические алгоритмы
оценивания состояния динамических систем с использованием декомпозиции»

Комиссия в составе:

председатель: Макурин Игорь Валерьевич, к.э.н., доцент, первый проректор
ФГБОУ ВПО «КСТАТУ»,

члены комиссии: Степанов Анатолий Николаевич, к.т.н., доцент, декан
электротехнического факультета; Котляров Валерий Петрович, к.т.н., профессор, декан
факультета компьютерных технологий; Еськова Анна Владимировна, к.т.н., доцент,
заведующая кафедрой «Информационные системы»; Любушкина Надежда Николаевна,
к.т.н., доцент кафедры «Промышленная электроника» составили настоящий акт о том, что
результаты диссертационной работы «Вычислительный метод и синтетические алгоритмы
оценивания состояния динамических систем с использованием декомпозиции»,
представленной на соискание ученой степени кандидата технических наук, внедрены и
использованы в учебной деятельности

Электротехнического факультета при изучении дисциплин:

- «Основы кибернетики и управление в радиоэлектронных системах» по теме
«Интеллектуальные системы управления и оценивания» направления подготовки
бакалавров 210100.62 «Электроника и нанoeлектроника»;

- «Основы цифровой обработки сигналов» по теме «Вейвлет-анализ»
специальности 210106.65 «Промышленная электроника»;

- «Методы математического моделирования» по темам «Математическое
моделирование с использованием искусственных нейронных сетей», «Математическое
моделирование с использованием нечетких систем»; «Компьютерные технологии в
научных исследованиях» по теме «Применение системы MATLAB для обработки данных
и сигналов» направления подготовки магистров 11.04.04 «Электроника и
нанoeлектроника»;

Факультета компьютерных технологий при изучении дисциплины
«Интеллектуальные информационные системы» по темам «Искусственные нейронные
сети», «Нечеткие системы» направления подготовки бакалавров 230700.62 «Прикладная
информатика».

Использование результатов диссертационной работы С.Г. Баена в учебном
процессе позволяет улучшить качество подготовки специалистов, бакалавров и магистров,
повысить уровень знаний по указанным направлениям.

Председатель комиссии:

Игорь Валерьевич Макурин

Члены комиссии:

Анатолий Николаевич Степанов
Валерий Петрович Котляров
Анна Владимировна Еськова
Надежда Николаевна Любушкина

ОХРАННЫЕ ДОКУМЕНТЫ НА РЕЗУЛЬТАТЫ ИНТЕЛЛЕКТУАЛЬНОЙ ДЕЯТЕЛЬНОСТИ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



ПАТЕНТ

НА ПОЛЕЗНУЮ МОДЕЛЬ

№ 138401

ИНТЕЛЛЕКТУАЛЬНАЯ ИЗОЛЯЦИОННАЯ СИСТЕМА

Патентообладатель(ли): *Общество с ограниченной
ответственностью "Позитрон-ДВ" (ООО "Позитрон-ДВ")
(RU)*

Автор(ы): *см. на обороте*

Заявка № 2013133649

Приоритет полезной модели 18 июля 2013 г.

Зарегистрировано в Государственном реестре полезных
моделей Российской Федерации 17 февраля 2014 г.

Срок действия патента истекает 18 июля 2023 г.



Руководитель Федеральной службы
по интеллектуальной собственности

Б.П. Симонов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



(19) RU (11)

138 401 (13) U1

(51) МПК

H01B 17/00 (2006.01)

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ

(12) ТИТУЛЬНЫЙ ЛИСТ ОПИСАНИЯ ПОЛЕЗНОЙ МОДЕЛИ К ПАТЕНТУ

(21)(22) Заявка: 2013133649/07, 18.07.2013

(24) Дата начала отсчета срока действия патента:
18.07.2013

Приоритет(ы):

(22) Дата подачи заявки: 18.07.2013

(45) Опубликовано: 10.03.2014 Бюл. № 7

Адрес для переписки:

681013, г. Комсомольск-на-Амуре, пр. Ленина,
27, ФГБОУ ВПО "КнАГТУ", отдел защиты
интеллектуальной собственности

(72) Автор(ы):

Амосов Олег Семенович (RU),
Иванов Юрий Сергеевич (RU),
Иванов Сергей Николаевич (RU),
Баена Светлана Геннадьевна (RU)


(73) Патентообладатель(и):

Общество с ограниченной ответственностью
"Позитрон-ДВ" (ООО "Позитрон-ДВ") (RU)

(54) ИНТЕЛЛЕКТУАЛЬНАЯ ИЗОЛЯЦИОННАЯ СИСТЕМА

(57) Формула полезной модели

Интеллектуальная изоляционная система, содержащая изоляционное тело, жестко закрепленные по центру изоляционного тела, по обе его стороны, первый и второй элементы арматуры, один из которых служит для соединения с высоковольтным проводом, а второй - с опорой линии электропередачи, на ребре изоляционного тела жестко закреплен профиль из силиконовой резины, внутри профиля расположена периодическая система электродов, между которыми выполнены отверстия, выходящие наружу профиля и образующие миниатюрные газоразрядные камеры, а к первому и второму элементам арматуры гальванически или через воздушный промежуток присоединены своими первыми концами первый и второй подводящие электроды соответственно, каждый из которых отделен воздушным промежутком от изоляционного тела и вторым своим концом связан через воздушный промежуток с первым или вторым концом периодической системы электродов, при этом по окружности изоляционного тела, с внутренней стороны периодической системы электродов, жестко закреплено кольцо из электропроводящего материала, отличающаяся тем, что изоляционное тело включено в качестве объекта управления в систему, включающую камеру наблюдения, блок нормализации, блок анализа освещенности, блок адаптации фона, блок детекции движения, устройство анализа сцены, блок проверки рейтинга, базовый блок распознавания, блок памяти признаков объектов, адаптированный блок распознавания образов, блок обучения, блок коррекции рейтинга, подсистему адаптации и распознавания образов, интеллектуальный блок принятия решений, устройство управления, цель управления и исполнительный элемент.



RU 138401 U 1

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2014617763

Нейросетевая система оценивания NN Estimator

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Комсомольский-на-Амуре государственный технический университет» (ФГБОУ ВПО «КнАГТУ»)* (RU)

Авторы: *Амосов Олег Семенович (RU),
Баена Светлана Геннадьевна (RU)*



Заявка № 2014615359

Дата поступления 04 июня 2014 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 01 августа 2014 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Б.П. Симонов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2014617998

Вейвлет-оценивание временного ряда

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Комсомольский-на-Амуре государственный технический университет» (ФГБОУ ВПО «КНАГТУ») (RU)*

Авторы: *Амосов Олег Семенович (RU),
Баена Светлана Геннадьевна (RU)*



Заявка № 2014615863

Дата поступления 18 июня 2014 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 07 августа 2014 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Б.П. Симонов

КОДЫ ПРОГРАММ

**Программа для ЭВМ «Нейросетевая система оценивания
NN Estimator»**

sSampleLearnTestNN.m

```
%sSampleLearnTestNN - программа формирования обучающей и тестовой выборки
%для нейронной сети
%24 April 2014
close all;
clear all;
disp('***Параметры обучающей выборки***');
% Ввод параметров
n=input('Число временных отсчетов = ');
ks=input('Число примеров обучающей выборки = ');
sParam_xy;
for s=1:ks
sModel_xy; % Программа формирования векторов состояния x и измерения y
X(s,:)=x;
Y(s,:)=y;
end % s
```

```
save SampleLearnNN X Y n ks %Сохранение результатов расчета
```

```
disp('***Параметры тестовой выборки***');
% Ввод параметров
ntest=input('Число временных отсчетов = ');
kstest=input('Число примеров тестовой выборки = ');
for s=1:kstest
sModel_xy; % Программа формирования векторов состояния x и измерения y
Xtest(s,:)=x;
Ytest(s,:)=y;
end % s
```

```
save SampleTestNN Xtest Ytest ntest kstest %Сохранение результатов расчета
```

sParam_xy.m

```
%sParam_xy.m - задание параметров для моделирования векторов x и y для задачи оценки
%равномерно распределенной на отрезке [ax;bx] случайной величины x по ее
%измерениям  $y=x+v$ , подверженным воздействию ошибок v,
%равномерно распределенных на отрезке [av;bv]
```

```
% Параметры случайных величин
ax=-1/2;
bx=1/2;
av=-1/2;
```

bv=1/2;

sModel_xy.m

```
%sModel_xy.m - пример формирования векторов x и y для задачи оценки
%равномерно распределенной на отрезке [ax;bx] случайной величины x по ее
%измерениям y=x+v, подверженным воздействию ошибок v,
%равномерно распределенных на отрезке [av;bv]
% Reference
% Stepanov O. A., Amosov O. S. Optimal estimation by using neural networks
%//Proc.of the 16-th World Congress IFAC.–Prague, Czech Republic, 2005.–6 p.

x0=ax+(bx-ax)*rand; %моделируемое случайное значение оцениваемой величины x

for k=1:n
    x(k)=x0;
    v(k)=av+(bv-av)*rand; % моделирование случайных ошибок измерений
    y(k)=x(k)+v(k);      % моделирование случайных измерений
end
```

sLearnUUNonLinNonRec.m

```
%sLearnUUNonLinNonRec - программа обучения нейронной сети
%25April2014
close all;
clear all;

load SampleLearnNN X Y n ks;
disp('***Выбор типа нейронной сети***');
% Ввод типа нейронной сети: d=1-нейронная сеть прямого распространения FFN;
% d=2-нейронная сеть с радиально-базисными элементами RBFN;
d=input('Тип нейронной сети = ');

switch d
case 1
    disp('***Выбор параметров нейронной сети FFN***');
    nh=input('*Количество нейронов в скрытом слое = ');

case 2
    disp('***Выбор параметров и обучение нейронной сети RBFN***');
    goal=input('Среднеквадратическая ошибка = ');
    spread=input('Отклонения радиальных элементов = ');
    mn=input('Максимальное количество нейронов сети = ');
    nf=input('Количество добавляемых на каждом шаге нейронов = ');
end %d

df=n; %Длина окна

yNRec=zeros(df,ks);
yNRecV=zeros(n,1);
```

```

Start=cputime;
for i=1:n
    i
    for s=1:ks
        if i<=df
            yNRecV(1:i)=Y(s,1:i);
            yNRec(1:i,s)=yNRecV(1:i);
        else
            yNRecV(i-df:i)=Y(s,i-df:i);
            yNRec(1:df+1,s)=yNRecV(i-df:i);
        end %if

        xNRec(1,s)=X(s,i);

    end %s
    yNRec;
    xNRec;

    switch d
        case 1
            netNRec= newff(yNRec,xNRec,nh,{ 'tansig', 'purelin'}, 'trainbr');
            netNRec=train(netNRec,yNRec,xNRec);
            Mnet{i}=netNRec;
            XNRec=sim(netNRec,yNRec);

        case 2
            netNRecRB= newrb(yNRec,xNRec,goal,spread,mn,nf);
            Mnet{i}=netNRecRB;
            XNRec=netNRecRB(yNRec);
        end %d
    end %i
    Elapsed=cputime-Start % Время выполнения программы
    save NRecTrOffFFNorRBFN.mat Mnet Elapsed

```

sSimNonLinOffFFNorRBFN.m

```

% sSimNonLinOffFFNorRBFN.m - программа моделирования обученной нейронной
% сети FFN или RBFN
%18 April 2014
clear all;
close all;

load NRecTrOffFFNorRBFN.mat Mnet Elapsed
load SampleTestNN Xtest Ytest ntest kstest
sParam_xy;
% Расчетные статистические параметры случайной величины x
mx=(bx+ax)/2;
Dx=(bx-ax)^2*(1/12);
Sx=sqrt(Dx);

```

```

df=ntest;
yNRectest=zeros(df,kstest);
yNRecVtest=zeros(ntest,1);

for i=1:ntest
for s=1:kstest

if i<=df
yNRecVtest(1:i)=Ytest(s,1:i);
yNRectest(1:i,s)=yNRecVtest(1:i);

else
yNRecVtest(i-df:i)=Ytest(s,i-df:i);
yNRectest(1:df+1,s)=yNRecVtest(i-df:i);
end %if

end %s
yNRectest;
netNRec=Mnet{i};
XNRectest=sim(netNRec,yNRectest);

xsNNRectest(:,i)=XNRectest(:);
end %i

xsNNRectest;
AxNRectest=xsNNRectest';
BxNRectest=AxNRectest(:);
xsNRectest=BxNRectest';

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Расчет СКО ошибок оценивания с использованием метода Монте-Карло

XxsNRectest=xsNNRectest;
%
for i=1:ntest

Gxztest(i)=0;
GxNRectest(i)=0;

for j=1:kstest

Gxztest(i)=Gxztest(i)+(Ytest(j,i)-Xtest(j,i))^2;
GxNRectest(i)=GxNRectest(i)+(XxsNRectest(j,i)-Xtest(j,i))^2;

end

Gxztest(i)=Gxztest(i)/kstest;
GxNRectest(i)=GxNRectest(i)/kstest;

SKOXZtest=sqrt(Gxztest);
SKOXNRectest=sqrt(GxNRectest);

```

end

%

%Вывод графика СКО ошибки оценки

figure (1);

hold on;

plot(0:n,[Sx SKOXNRectest(1:ntest)],'k'),grid;

save NRecOffFFNorRBFN SKOXNRectest ntest; %Сохранение результатов расчета

Программа для ЭВМ «Вейвлет-оценивание временного ряда»

sFKalmWvEkr.m

```
% Оценивание экспоненциально-коррелированного процесса без нарушений при
% гауссовских ошибках измерений с использованием фильтра Калмана и вейвлета

close all;
clear all;

ntest=200; % Количество значений временного ряда
kstest=1000; % Количество реализаций ;

% Линейный фильтр Калмана ++++++
for s=1:kstest
s
sInputEkr; % Параметры экспоненциально-коррелированного процесса без нарушений

sigmax0RAS=sigmax0;
Dwx_dRAS=Dwx_d;
Dvx_dRAS=Dvx_d;

sModelEkr; % Модель экспоненциально-коррелированного процесса без нарушений

xc=x;
yc=x;

xn=zx;
yn=zx;

rn=xn;
bn=xn;

sInputEkr;

xsfk(1,1)=0; % Нулевое математическое ожидание
sNKorrelKalmEkr;
for k=1:n-1

sKorrelKalmEkr;
sOcenkaKalmEkr
end

X1stest(s,1:ntest)=xsfk(1:ntest);
X2stest(s,1:ntest)=xsfk(1:ntest);

Xxsfk=X1stest;

T1Xtest(s,1:ntest)=x(1:ntest);
P1ZXtest(s,1:ntest)=zx(1:ntest);

SKO1XTtest(s,1:ntest)=sqrt(p11(1:ntest));
```

```

SKO1XTtestRAS(s,1:ntest)=sqrt(p11RAS(1:ntest)); % Расчетное значение СКО

T1Xtest(s,1:ntest)=xc(1:ntest); T1Ytest(s,1:ntest)=yc(1:ntest);
T1Xntest(s,1:ntest)=xn(1:ntest); T1Yntest(s,1:ntest)=yn(1:ntest);

P1Rtest(s,1:ntest)=rn(1:ntest); P1Btest(s,1:ntest)=bn(1:ntest);
P1Xtest(s,1:ntest)=xn(1:ntest); P1Ytest(s,1:ntest)=yn(1:ntest);

% Линейный фильтр Калмана ++++++

% Вейвлет-преобразование *****

y=zx;
t = 1:1:n;

wname = 'db4'; lev = 4; tree = wpdec(y,lev,wname);

det1 = wpcoef(tree,2); sigma = median(abs(det1))/0.6745;
alpha = 2; thr = wpbmpen(tree,sigma,alpha);
keepapp = 1; xd = wpdencmp(tree,'s','nobest',thr,keepapp);
xsWv=xd;

X2stest(s,1:ntest)=xsWv(1:ntest);
XxsWv=X2stest;

% Вейвлет-преобразование *****

end % s;

% Метод Монте-Карло #####
% Расчет СКО ошибок оценивания
for i=1:ntest

Gxztest(i)=0;
Gxfktest(i)=0;
GxWvtest(i)=0;

GxBtest(i)=0;

for j=1:kstest

Gxztest(i)=Gxztest(i)+(P1Xtest(j,i)-T1Xtest(j,i))^2;
Gxfktest(i)=Gxfktest(i)+(Xxsfk(j,i)-T1Xtest(j,i))^2;
GxWvtest(i)=GxWvtest(i)+(XxsWv(j,i)-T1Xtest(j,i))^2;

end % kstest

Gxztest(i)=Gxztest(i)/kstest;
Gxfktest(i)=Gxfktest(i)/kstest;
GxWvtest(i)=GxWvtest(i)/kstest;

```

```
SKOXZtest=sqrt(Gxztest);
SKOXFKtest=sqrt(Gxfktest);
SKOXWvtest=sqrt(GxWvtest);
```

```
end % ntest
```

```
SKOW(1:ntest)=Swx_d;
SKOV(1:ntest)=Svx_d;
```

```
SKOXAccuracy(1:ntest)=SkoAccuracy;
```

```
figure (1);
hold on;
plot(SKOXZtest(1:ntest),'r'),grid;
plot(SKOXFKtest(1:ntest),'g');
plot(SKOXWvtest(1:ntest),'k');
```

```
plot(SKO1XTtest(1,1:ntest));
plot(SKOV(1:ntest));
```

```
save FK_Wv_230514-1000-15-01 SKOXZtest SKOXFKtest SKOXWvtest % Сохранение
% результатов расчета
```

sInputEkp.m

```
% Параметры экспоненциально-коррелированного процесса без нарушений при
% гауссовских ошибках измерений
```

```
kmax=199;
n=kmax+1;
T=1;
dt=1;
```

```
mx=0; % Математическое ожидание процесса x
my=0; % Математическое ожидание процесса y
```

```
Dx=10; % Дисперсия процесса x
Sx=sqrt(Dx);
sigmax0=Sx;
Dx0=sigmax0^2;
```

```
tauk=30;
alfa=1/tauk; % Интервал корреляции
```

```
Dwx=2*Dx*alfa;
Swx=sqrt(Dwx); %Ekp;
```

```
Dvx=27; % Дисперсия шума измерения v
Svx=sqrt(Dvx);
Dvx_d=Dvx/dt;
Svx_d=sqrt(Dvx_d);
gamma_2=Dx/(Dvx/tauk);
```

```

f=exp(-alfa*dt);
f_1=1-f;
g=(sqrt(2*Dx*alfa)/alfa)*(1-f);
Swx_d=g/sqrt(dt);
Dwx_d=Swx_d^2;
STix=sqrt(2*Dx*alfa)/sqrt(2*alfa)*sqrt((1-exp(-2*alfa*dt)));
STix2=sqrt(2*Dx*alfa)*sqrt(dt);

Dx=Swx_d^2*dt*alfa/(2*(1-f)^2);

Ppp=Swx*Svx;
Sk0Ppp=sqrt(Ppp);
PppAccuracy=(Dvx/tauk)*(-1+sqrt(1+2*Dx*tauk/Dvx));
SkoAccuracy=sqrt(PppAccuracy);

vkurs=0;

Vx=0;
Vy=0;

```

sModelEkp.m

```

% Модель экспоненциально-коррелированного процесса без нарушений при
% гауссовских ошибках измерений

```

```

vx(1)=Vx; vy(1)=Vy;
vx(2)=vx(1);

x(1)=randn*sigmax0;
rx(1)=randn;
zxc(1)=x(1);
zx(1)=zxc(1)+rx(1)*Svx_d;
rx(1)=randn;

x(2)=f*x(1)+rx(1)*Swx_d;
rx(2)=randn;% 11.01.03
zxc(2)=x(2);
zx(2)=zxc(2)+rx(2)*Svx_d;

for k=3:n
    rx(k)=randn;

    rx(k)=randn;

vx(k)=vx(k-1);
x(k)=f*x(k-1)+vx(k-1)*T+rx(k-1)*Swx_d;

rx(k)=randn;
rzy(k)=randn;

```

```
zxc(k)=1*x(k);
zx(k)=zxc(k)+rzx(k)*Svx;
```

```
end % n
```

sNKorrelKalmEkp.m

```
% Расчет начальных условий для определения корреляционной матрицы
```

```
p11(1,1)=(sigmax0)^2;
```

```
p11RAS(1,1)=(sigmax0RAS)^2;
```

```
p11k(1,1)=(f)^2*p11(1,1)+Dwx_d./1; %27.01.03
```

```
p11kRAS(1,1)=(f)^2*p11RAS(1,1)+Dwx_dRAS./1; %10.11.03
```

```
K(1,1)=(p11(1,1)+Dwx_d./1)./(p11(1,1)+Dwx_d./1+Dvx_d./1);
```

```
KRAS(1,1)=(p11RAS(1,1)+Dwx_dRAS./1)./(p11RAS(1,1)+Dwx_dRAS./1+Dvx_dRAS./1);
```

sKorrelKalmEkp.m

```
% Корреляционная матрица ошибки фильтрации
```

```
p11k(1,k+1)=(f)^2*p11(1,k)+Dwx_d./1;
```

```
K(1,k+1)=p11k(1,k+1)./(p11k(1,k+1)+Dvx_d./1);
```

```
p11(1,k+1)=(1-K(1,k+1)).*p11k(1,k+1);
```

```
p11kRAS(1,k+1)=(f)^2*p11RAS(1,k)+Dwx_dRAS./1;
```

```
KRAS(1,k+1)=p11kRAS(1,k+1)./(p11kRAS(1,k+1)+Dvx_dRAS./1);
```

```
p11RAS(1,k+1)=(1-KRAS(1,k+1)).*p11kRAS(1,k+1);
```

sOcenkaKalmEkp.m

```
% Экстраполяция координаты x
```

```
xsek(1,k+1)=(f)*xsfk(1,k); %27.01.03
```

```
% Оценка координаты x
```

```
xsfk(1,k+1)=xsek(1,k+1)+K(1,k+1).*(zx(1,k+1)-xsek(1,k+1));
```

sFKalmNewWvEkpStep.m

```
% Оценивание экспоненциально-коррелированного процесса при наличии нарушения при
% гауссовских ошибках измерений с использованием фильтра Калмана и вейвлета
```

```
close all;
```

```
clear all;
```

```
ntest=200; % Количество значений временного ряда
```

```
kstest=1000; % Количество реализаций ;
```

```
% Линейный фильтр Калмана ++++++
```

```

for s=1:kstest
s

sInputEkpStep;

sigmax0RAS=sigmax0;
Dwx_dRAS=Dwx_d;
Dvx_dRAS=Dvx_d;

    sModelEkpStep;
    sInputEkpStep;

    xsfk(1,1)=0; % Нулевое математическое ожидание
    sNkorrelKalmEkp;
    zx=y1;
    for k=1:n-1

        sKorrelKalmEkp;
        sOcenkaKalmEkp
    end

    X1stest(s,1:nstest)=xsfk(1:nstest);
    X2stest(s,1:nstest)=xsfk(1:nstest);

    Xxsfk=X1stest;

    T1Xtest(s,1:nstest)=x1(1:nstest);
    P1Xtest(s,1:nstest)=y1(1:nstest);

    SKO1XTtest(s,1:nstest)=sqrt(p11(1:nstest)); % Теория

    SKO1XTtestRAS(s,1:nstest)=sqrt(p11RAS(1:nstest)); % Теория

    % Линейный фильтр Калмана ++++++

    % Вейвлет-преобразование *****

    t = 1:1:n;
    df=10; % Длина окна
    yWv=zeros(1,df);
    xsWv=zeros(1,df);

    for i=1:n
        y1=zx;

        if i<=df
            yWv(1:i)=y1(1:i);

        else
            yWv(i-df:i)=y1(i-df:i);

        end %if

```

```

t = 1:1:n;

wname = 'db4'; lev = 4; tree = wpdec(yWv,lev,wname);

det1 = wpccoef(tree,2); sigma = median(abs(det1))/0.6745;
alpha = 2; thr = wpbmpen(tree,sigma,alpha);
keepapp = 1; xd = wpdncmp(tree,'s','nobest',thr,keepapp);

xsWv(i)=xd(i);
end %i

X2stest(s,1:ntest)=xsWv(1:ntest);
XxsWv=X2stest;
% Вейвлет-преобразование *****
end % s;

% Метод Монте-Карло #####
% Расчет СКО ошибок оценивания процесса

for i=1:ntest

Gxztest(i)=0;
Gxfktest(i)=0;
GxWvtest(i)=0;

GxBtest(i)=0;

for j=1:kstest

Gxztest(i)=Gxztest(i)+(P1Xtest(j,i)-T1Xtest(j,i))^2;
Gxfktest(i)=Gxfktest(i)+(Xxsfk(j,i)-T1Xtest(j,i))^2;
GxWvtest(i)=GxWvtest(i)+(XxsWv(j,i)-T1Xtest(j,i))^2;

end % kstest

Gxztest(i)=Gxztest(i)/kstest;
Gxfktest(i)=Gxfktest(i)/kstest;
GxWvtest(i)=GxWvtest(i)/kstest;

SKOXZtest=sqrt(Gxztest);
SKOXFKtest=sqrt(Gxfktest);
SKOXWvtest=sqrt(GxWvtest);

end % ntest

SKOW(1:ntest)=Swx_d;
SKOV(1:ntest)=Svx_d;

SKOXAccuracy(1:ntest)=SkoAccuracy;

figure (2);

```

```

hold on;
plot(SKOXZtest(1:ntest),'r'),grid;
plot(SKOXFKtest(1:ntest),'g');
plot(SKOWvtest(1:ntest),'k');

plot(SKO1XTtest(1,1:ntest));
plot(SKOV(1:ntest));

% Сохранение результатов расчета
save FK_WvDb4_4_200514-1000-100Step SKOXZtest SKOXFKtest SKOWvtest

```

sInputEkpStep.m

```

% Параметры экспоненциально-коррелированного процесса с нарушениями при
% гауссовских ошибках измерений

```

```

kmax=199;
n=kmax+1;

```

```

k1=100; % Момент возникновения нарушения
k2=120; % Момент окончания нарушения с линейным изменением

```

```

T=1;
dt=1;

```

```

ck=30; % Постоянная составляющая
nc=20; % Количество отсчетов при нарушении
cstep=30; % Скачкообразное нарушение процесса
ch=cstep/nc; % Нарушение линейно нарастает в течение nc отсчетов

```

```

mx=0; % Математическое ожидание процесса x
my=0; % Математическое ожидание процесса y

```

```

Dx=10; % Дисперсия процесса x
Sx=sqrt(Dx);
sigmax0=Sx;
Dx0=sigmax0^2;

```

```

tauk=30;
alfa=1/tauk; % Интервал корреляции

```

```

Dwx=2*Dx*alfa;
Swx=sqrt(Dwx); %Ekp;
Dvx=27; % Дисперсия шума измерения v
Svx=sqrt(Dvx);
Dvx_d=Dvx/dt;
Svx_d=sqrt(Dvx_d);
gamma_2=Dx/(Dvx/tauk);

```

```

f=exp(-alfa*dt);
f_1=1-f;

```

```

g=(sqrt(2*Dx*alfa)/alfa)*(1-f);
Swx_d=g/sqrt(dt);
Dwx_d=Swx_d^2;
STix=sqrt(2*Dx*alfa)/sqrt(2*alfa)*sqrt((1-exp(-2*alfa*dt)));
STix2=sqrt(2*Dx*alfa)*sqrt(dt);

Dx=Swx_d^2*dt*alfa/(2*(1-f)^2);

Ppp=Swx*Svx;
Sk0Ppp=sqrt(Ppp);
PppAccuracy=(Dvx/tauk)*(-1+sqrt(1+2*Dx*tauk/Dvx));
SkoAccuracy=sqrt(PppAccuracy);

vkurs=0;

Vx=0;
Vy=0;

```

sModelEkpStep.m

% Модель экспоненциально-коррелированного процесса с нарушениями в виде
% скачкообразного и линейного изменения при гауссовских ошибках измерений

```

vx(1)=Vx; vy(1)=Vy;
vx(2)=vx(1);

k=1;
t(1)=t0+dt;
x(1)=randn*sigmax0;
x1(k)=x(k);
x2(k)=x(k);

rx(1)=randn;
zxc(1)=x(1);
zx(1)=zxc(1)+rx(1)*Svx_d;
y(k)=x(1)+rx(1)*Svx_d;

rx(1)=randn;
k=2;
x(2)=f*x(1)+rx(1)*Swx_d;
x1(k)=x(k);
x2(k)=x(k);

rx(2)=randn;

zxc(2)=x(2);
zx(2)=zxc(2)+rx(2)*Svx_d;
y(k)=x(k)+rx(2)*Svx_d;
for k=3:n
    rx(k)=randn;
    rzx(k)=randn;

```

```

vx(k)=vx(k-1);
x(k)=f*x(k-1)+vx(k-1)*T+rx(k-1)*Swx_d;

if k>k1

    x1(k)=x(k)+cstep;
else
    x1(k)=x(k);
    x2(k)=x(k);

end

if k>=(k1+1) & k<=(k2)
    cLin=ch*(k-k1);
    x2(k)=x(k)+cLin;

end

if k>k2

x2(k)=x(k)+cLin;
end

rx(k)=randn;
ry(k)=randn;

zxc(k)=1*x(k);
zx(k)=zxc(k)+rx(k)*Svx_d;
y(k)=x(k)+rx(k)*Svx_d;

end

v=rx*Svx_d;
y1=x1+v;
y2=x2+v;

```

sEkp_FKalmNewWpdencmp.m

```

% Формирование последовательности  $x_i$ ,  $y_i$  и оценки  $\tilde{x}_i^{FK}$ ,  $\tilde{x}_i^W$ 
% для экспоненциально-коррелированного процесса без нарушения

% sEkp_wpdencmp

close all;
clear all;

sInputEkp;
sModelEkp;

% Вейвлет-преобразование *****

```

```

t = 1:1:n;
df=10; % Длина окна
yWv=zeros(1,df);
xsWv=zeros(1,df);
for i=1:n
    i
    if i<=df
        yWv(1:i)=y1(1:i)

    else
        yWv(i-df:i)=y1(i-df:i);

    end % if

    wname = 'db4'; lev = 5; tree = wpdec(yWv,lev,wname);

    det1 = wpcoef(tree,2); sigma = median(abs(det1))/0.6745;
    alpha = 2; thr = wpbmpen(tree,sigma,alpha);
    keepapp = 1; xd = wpdencmp(tree,'s','nobest',thr,keepapp);
    xsWv(i)=xd(i);

end %i

figure (3);
hold on;
plot(x1), ,grid;
plot(y1,'r');
plot(xsWv,'k');

% Вейвлет-преобразование *****

% Линейный фильтр Калмана ++++++
zx=y1;
sigmax0RAS=sigmax0;
Dwx_dRAS=Dwx_d;
Dvx_dRAS=Dvx_d;
xsfk(1,1)=0; % Нулевое математическое ожидание
sNKorrelKalmEkr;
for k=1:n-1

sKorrelKalmEkr;
sOcenkaKalmEkr
end
plot(xsfk,'g');
% Линейный фильтр Калмана ++++++

```

sEkr_FKalmNewWpdencmpStep.m

```

% Формирование последовательности  $x_i$ ,  $y_i$  и оценки  $\tilde{x}_i^{FK}$ ,  $\tilde{x}_i^W$ .
% для экспоненциально-коррелированного процесса с нарушениями

```

```

% sEkp_wpdencmp

close all;
clear all;

sInputEkpStep;
sModelEkpStep;

% Вейвлет-преобразование *****

t = 1:1:n;
df=10; % Длина окна
yWv=zeros(1,df);
xsWv=zeros(1,df);
for i=1:n
    i
    if i<=df
        yWv(1:i)=y1(1:i)

    else
        yWv(i-df:i)=y1(i-df:i);
    end % if

    wname = 'db4'; lev = 5; tree = wpdec(yWv,lev,wname);

    det1 = wpccoef(tree,2); sigma = median(abs(det1))/0.6745;
    alpha = 2; thr = wpbmpen(tree,sigma,alpha);
    keepapp = 1; xd = wpdencmp(tree,'s','nobest',thr,keepapp);
    xsWv(i)=xd(i);

end % i

figure (4);
hold on;
plot(x1),grid;
plot(y1,'r');
plot(xsWv,'k');

% Вейвлет-преобразование *****

% Линейный фильтр Калмана ++++++
zx=y1;
sigmax0RAS=sigmax0;
Dwx_dRAS=Dwx_d;
Dvx_dRAS=Dvx_d;
xsfk(1,1)=0; % Нулевое математическое ожидание
sNKorrelKalmEkp;
for k=1:n-1

sKorrelKalmEkp;

```

```

sOcenkaKalmEkp
end
plot(xsfk,'g');
% Линейный фильтр Калмана ++++++

```

sWaveLetSpektrEkpStep.m

% Построение спектрограммы непрерывного вейвлет-преобразования измерений
экспоненциально-коррелированного процесса

```

s=y(1:n); % Измерения
t = 1:1:n;
figure (103); plot(t,y); axis([0 0.0004 -3 3]); grid on;
subplot(211), plot(t,y); title('Measurements y(t)')
subplot(212), c = cwt(y, 1:2:32, 'mexh', 'abs1vl', [0 10]);
title('Wavelet-spectr '); xlabel('Times shift, b');
ylabel('Times mashtab, a');

```