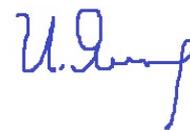


На правах рукописи



ЯСИНСКИЙ ИГОРЬ ФЕДОРОВИЧ

**СОВЕРШЕНСТВОВАНИЕ МЕТОДОВ
МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ
СРЕДСТВАМИ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ**

Специальность 05.13.18 – математическое моделирование,
численные методы и комплексы
компьютерных программ

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
доктора технических наук

Иваново 2018

Работа выполнена в государственном образовательном учреждении высшего профессионального образования "Ивановский государственный энергетический университет имени В.И.Ленина" (ИГЭУ)

Научный консультант

Официальные оппоненты

Ведущая организация

Защита диссертации состоится "___" _____ 20__ г. в ___ часов на заседании диссертационного совета _____ при Ивановском государственном энергетическом университете по адресу:

153003, г. Иваново, ул.Рабфаковская, д.34

С диссертацией можно ознакомиться в библиотеке Ивановского государственного энергетического университета

Автореферат разослан "___" _____ 20__ г.

Ученый секретарь
Диссертационного совета

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы.

В науке существует ряд нерешенных проблем.

При численном моделировании динамики сплошной среды с включением турбулентных процессов часто возникают сложные картины течений. Они могут включать в себя различные тонкие структуры: ударные волны, пограничные слои и области их взаимодействия. Известно, что решение таких задач с помощью чисто сеточных методов затруднительно. Вблизи твердых стенок турбулентную вязкость удобно вычислять с помощью формул Прандтля и Сполдинга, в областях перемешивания струй приходится прибегать либо к К-Е модели, либо применяется модель Г.Н.Абрамовича и А.Н.Секундова. Наибольшие трудности вызывают области взаимодействия ударных волн с турбулентными пограничными слоями.

Наблюдаются трудности медицинской диагностики ряда заболеваний, связанные с тем, что для их выявления требуется учет большого количества сочетаний различных факторов. К таким заболеваниям относятся пост-гипоксические нарушения сердца у новорожденных, наступление преэклампсии у беременных женщин на фоне хронической артериальной гипертензии. Также, эффективность диагностики заболеваний связана с обработкой результатов анализов и опросом пациента. При этом предоставленная информация бывает недостоверна, недостаточна, избыточна. Для решения указанной проблемы требуется совершенствование методов обработки и подготовки анализируемой информации.

Принятая в настоящее время в России методика расчета лесной пожарной опасности опирается, главным образом, на погодный критерий Нестерова. При этом, согласно статистике, ведущие роли в возникновении лесных пожаров играют нарушение правил пожарной безопасности и грозовая активность. Таким образом, имеется необходимость совершенствования методик оценивания лесной пожарной опасности. Предлагается это сделать, опираясь на возросшие возможности современной вычислительной техники и используя адаптивность нейросетевой технологии.

В современных условиях можно выделить два больших направления развития информационной науки и техники – ускорение вычислений и интеллектуализация информационных, автоматических систем. Первое направление, главным образом, связано с распараллеливанием программного обеспечения на многопроцессорных или многоядерных вычислительных машинах, а также с разработкой параллельных алгоритмов и архитектур для расчета вычислительно сложных задач математического моделирования. Вторая область подразумевает

расширение спектра задач, которые могут решаться автоматически, без участия человека. На рынке программного обеспечения наблюдается стремительный рост количества приложений, созданных на основе идей нейросетевых технологий. Нейронные сети активно используются в системах технического зрения, прогнозирования и распознавания образов, при выработке стратегий в банковской и финансовой сферах, обеспечении кибербезопасности.

Вместе с этим, проектирование нейросетевой интеллектуальной системы предполагает решение ряда неформализованных проблем.

Отсутствуют правила построения эффективной архитектуры сети применительно к новой задаче. Синтез архитектуры сети включает определение количества слоев и числа нейронных клеток в них, выбор моделей функционирования нейронов и топологии связей между ними. Правильность этого выбора зависит от опыта специалиста. При излишне большом количестве нейронов теряется свойство нейросети обобщать информацию, а задание несоразмерно малого размера ИНС, в свою очередь, отрицательно скажется на точности моделирования объекта. Для решения этой проблемы требуется математическая формализация процессов, происходящих в нейронной сети.

Необходимо совершенствование методов обучения нейросетевых структур. Известно, что настройка нейронной сети является реализацией методов оптимизации применительно к целевой функции невязки нейросетевого и наблюдаемого решения. Аргументами такой функции выступают весовые коэффициенты нейронных связей. Эффективная настройка нейросети зачастую не может быть выполнена вследствие проблемы многоэкстремального поиска. Такой класс проблем вызван существованием целевых функций с большим количеством локальных экстремумов. Каждый из них может оказаться ложным неоптимальным решением, если поисковая точка в процессе оптимизации будет не способна выбраться из окрестности данного локального экстремума. Эти обстоятельства порождают сложности при поиске нейросетевого решения. Среди возможных способов решения проблемы глобальной оптимизации можно выделить алгоритмы стохастического, генетического, инерционного поиска. Первые два алгоритма предлагают решение проблемы оптимизации, в том числе за счет использования механизмов вероятностного перехода между найденными оптимумами. Однако, перечисленные методы не могут гарантировать нахождение глобального решения и их эффективность варьируется в зависимости от поставленной задачи и вида целевой функции.

Автор работы утверждает и показывает, что преодоление подобных препятствий при построении нейронных сетей позволяет решить проблемы математического моделирования механики сплошной среды, медицинской диагностики заболеваний, оценки лесной пожарной опасности.

Цель диссертации. Разработать теоретические принципы синтеза структуры нейронных сетей, новые численные алгоритмы их обучения и комплексы программ, реализующие созданные методы для математического моделирования гидродинамических задач, диагностики состояния здоровья и прогнозирования исходов заболеваний, оценки лесной пожарной опасности.

Для достижения указанной цели в диссертации были решены следующие **проблемы:**

1. Изучены методы математического моделирования и автоматизации процессов при помощи нейросетевых технологий, определены перспективные направления в различных прикладных областях. Исследованы процессы, происходящие в нейронных сетях, предложены пути оптимизации и расширения возможностей математического моделирования процессов с использованием нейронных сетей.
2. На основе идей термодинамического формализма создана теория и предложены новые способы построения архитектуры нейронных сетей, которые позволяют решать актуальные, ранее недоступные задачи.
3. Предложен стохастический метод увеличения обучающей выборки с помощью потенциальных функций, решающий проблему нехватки обучающих данных для нейронной сети.
4. Развита нейросетевая способ выделения главной информации и понижения размерности задачи, ослабляющий проблему вычислительной сложности обучения больших нейронных сетей.
5. Создан гибридный алгоритм глобальной оптимизации, обладающий высокой эффективностью при обучении нейронных сетей с многоэкстремальной функцией ошибки. Алгоритм позволил настроить такие нейронные сети, с обучением которых не справлялись традиционные методы.
6. Проведены экспериментальные исследования теоретических и прикладных разработок в актуальных практических задачах. Для этого созданы комплексы программ, включая параллельные реализации, для нейросетевого математического моделирования в гидродинамике, техническом зрении, неонатологии и акушерстве, оценке лесной пожарной опасности.

Методы исследований. При решении поставленных задач использовались теория искусственных нейронных сетей, теория автоматического управления, теория параллельных вычислений, методы экспериментального исследования, а также методы математической статистики и вычислительной математики с применением ЭВМ.

В основе представленного исследования лежат принципы математического моделирования. Для обучения искусственных нейронных сетей использовались алгоритм обратного распространения ошибки, разработанный гибридный алгоритм глобальной оптимизации и входящие

в его состав оригинальные методы усовершенствованного случайного поиска, случайного поиска с памятью, инерционной минимизации функции, генетического поиска с применением каст и одномерной оптимизацией. Применялся метод сжатия информации с помощью нейронной сети.

Научная новизна. В представленной работе получены следующие оригинальные результаты:

1. На базе идей термодинамического формализма и понятия о вычислительной энтропии построена теория процессов, происходящих в нейронных сетях, и путях их оптимизации. Введение кроме энтропии других термодинамических функций, а также определение трех термодинамических начал применительно к вычислениям позволяет исследовать устойчивость, упорядочивать параметры по их информационному весу, выполнять декомпозицию сложной системы, строить быстрые алгоритмы.
2. Построена нейронная сеть, включающая заранее обученные фрагменты. Предложенный метод использует априорную информацию в виде предварительно обученных сетей, полученных при решении сопряженных задач, что повышает скорость обучения и точность настройки нейронной сети.
3. Создана гибридная технология математического моделирования, включающая динамическую и нейросетевую подсистемы, которая дополняет существующую модель, ускоряет исследование объекта, позволяет устанавливать неизвестные начальные условия процесса.
4. Разработан усовершенствованный метод генетического поиска с кастами и одномерной оптимизацией для поиска глобального экстремума функции. По сравнению с традиционным генетическим поиском, данный алгоритм обладает преимуществом в скорости и точности поиска оптимума. Созданный алгоритм успешно применялся для минимизации многоэкстремальных целевых функций ошибок при обучении нейросетевых систем, решающих задачи в гидродинамике, медицине и при оценке лесной пожарной опасности.
5. Разработаны алгоритмы, расширяющие возможности применения нейросетевых технологий на практике. Предложены метод потенциальных функций, позволяющий решить проблему недостатка обучающих образов, и алгоритм самоорганизации для настройки размера ассоциативного слоя нейронной сети.
6. Предложен нейросетевой метод сжатия информации. Исследованы различные способы понижения размерности пространства поиска оптимальных весовых коэффициентов сети. При понижении размерности задачи нейросетевая воронка успешно заменяет метод главных компонент, содержащий такие затратные операции как отыскание собственных чисел и собственных векторов матриц

7. Полученные новые нейросетевые технологии реализованы как в последовательном, так и в параллельном виде на многопроцессорных вычислительных системах.

Практическая ценность. Разработаны и реализованы:

- нейросетевой программный комплекс диагностики и прогноза состояния новорожденных в неонатальный период по варибельности ритма сердца и другим медицинским показателям. Комплекс классифицирует пациентов по группам возможных заболеваний, прогнозирует течение болезни и ее исход.
- нейросетевая программная система прогнозирования присоединения преэклампсии у беременных с хронической артериальной гипертензией.

Системы внедрены и используются в отделах Неонатологии и клинической неврологии и Акушерства и гинекологии научно-исследовательского института Материнства и детства им. В.Н. Городкова г.Иваново.

Создана программно-аппаратная система, совершенствующая оценку лесной пожарной опасности учетом человеческого фактора и грозовой активности на основе нейронной сети. Система повышает эффективность работы центра по предотвращению лесных пожаров и позволяет уполномоченным службам оперативно отреагировать на угрозу.

Разработан комплекс компьютерных программ HydroEcology. Система создана по заказу АО «Водоканал» г. Иваново и использовалась для моделирования задачи о паводковой ситуации.

Разработана программно-аппаратная система непрерывного микробиологического контроля за состоянием водной среды. В неё входят программы реставрации и повышения четкости изображений, выделения и подсчета числа объектов на изображении, распознавания образов.

На защиту выносятся:

1. Технология синтеза архитектуры нейронной сети на основе априорной информации. В этом случае система строится из заранее обученных нейросетевых фрагментов.
2. Метод настройки структуры ассоциативных слоев нейронной сети в процессе работы.
3. Гибридная технология математического моделирования процессов, включающая динамическую и нейросетевую подсистемы.
4. Методы подготовки и обработки входной информации, включая метод увеличения обучающей выборки с помощью потенциальных функций, оптимизированный нейросетевой способ сжатия информации.
5. Гибридный алгоритм глобальной оптимизации для обучения нейронных сетей с многоэкстремальной функцией ошибки.

6. Метод нейросетевой интерполяции параметров для внутренней задачи о смешивании потоков в сплошной среде.
7. Нейросетевые программные комплексы диагностики состояния новорожденных и прогнозирования лесной пожарной опасности.

Апробация работы.

Основные положения и результаты работы доложены и обсуждены на следующих научно-технических форумах: Межвузовская научно-практическая конференция «Экологические проблемы Ивановской области» (Иваново, ИГТА, 2005 г.); «4th Central European Conference 2005» fibre-grade polymers, chemical fibres and special textiles (Czech Republic, Liberec, Technical University, 2005); 16-я Всероссийская конференция «Теоретические основы и конструирование численных алгоритмов и решение задач математической физики с приложением к многопроцессорным системам» (Дюрсо, Институт прикладной математики им. М.В.Келдыша РАН и МГУ им. М.В.Ломоносова, 2006 г.); V Международная конференция «Идентификация систем и задачи управления (SICPRO'06)» (Москва: Институт Проблем Управления РАН, 2006г.); III Международная конференция «Параллельные вычисления и задачи управления (PACO'06)» (Москва: Институт Проблем Управления РАН, 2006г.); Республ. конференция «Кардиологические проблемы в акушерстве, гинекологии и перинатологии» (г. Иваново, 27-29 сент. 2006г.); Региональная научно-техническая конференция «Применение многопроцессорных суперкомпьютеров в исследованиях, наукоемких технологиях и учебной работе» (Иваново:ИГТА, 2007г., 2008г.); «Молодые ученые - развитию текстильной и легкой промышленности» (Поиск-2009, Поиск-2011) (Иваново, ИГТА, 2009 г., 2011г.); Международная конференция «Высокопроизводительные параллельные вычисления на кластерных системах» (Владимир: ВГУ, 2009г.); Международная научно-техническая конференция «Состояние и перспективы развития электротехнологии», (Иваново:ИГЭУ, 2009г.); Международная научно-практическая конференция «Пожары и аварийная безопасность», (Иваново:МЧС, ИИ ГПС, 2011г.); Third International Conference on Modelling, Monitoring and Management of Forest Fires 2012 – New Forest: Wessex Institute of Technology, 2012; Международная научно-техническая конференция «Состояние и перспективы развития электротехнологии» (XVII Бенардосовские чтения, Иваново, ИГЭУ, 2013г.); VII Международная молодёжная научно-техническая конференция «Электроэнергетика глазами молодёжи – 2016», Казань, КГЭУ, 2016 г.; II International Scientific Congress «Innovations in Engineering», Bulgaria, Varna, 2016.

Публикации

По теме диссертации опубликованы 70 научных работ: из них 27 статей в рецензируемых журналах из перечня ВАК при Минобрнауки

России, в том числе в журналах, входящих в системы цитирования SCOPUS – 4 статьи, Web of science - 1 статья. По результатам исследования изданы 2 монографии (в соавторстве), 2 учебных пособия (в соавторстве и единолично), получен патент на изобретение и 3 свидетельства о регистрации программ ЭВМ.

Структура и объем работы

Диссертация состоит из введения, пяти глав, заключения и приложений, изложенных на 303 страницах машинописного текста, содержит 58 рисунков, 31 таблицу, 312 формул, список литературы из 179 наименований.

Соответствие работы паспорту специальности

Диссертационное исследование направлено на разработку методов математического моделирования, численных методов и комплекса программ, и вносит вклад в следующие области исследований, перечисленные в паспорте специальности 05.13.18:

1. Разработка новых математических методов моделирования объектов и явлений (3-е положение, выносимое на защиту).

2. Развитие качественных и приближенных аналитических методов исследования математических моделей. (1-ое положение)

3. Разработка, обоснование и тестирование эффективных вычислительных методов с применением современных компьютерных технологий. (2-ое, 4-ое и 5-ое положения)

4. Реализация эффективных численных методов и алгоритмов в виде комплексов проблемно-ориентированных программ для проведения вычислительного эксперимента. (6-ое и 7-ое положения)

5. Комплексные исследования научных и технических проблем с применением современной технологии математического моделирования и вычислительного эксперимента (7-ое положение).

В первой главе рассматривается совершенствование процесса обучения нейронной сети как задача многоэкстремальной оптимизации функции. Одним из распространенных методов настройки является метод обратного распространения ошибки, полученный в результате применения метода градиента для минимизации целевой функции ошибки распознавания. При использовании этого метода, часто возникают ситуации, когда процесс обучения, достигнув некоторого уровня, останавливается. Происходит это из-за того, что поисковая точка попадает в один из локальных минимумов целевой функции, из которого выйти уже не может. Ранее автором были предложены методы оптимизации, способные отыскать глобальный экстремум, и эффективно зарекомендовавшие себя при обучении нейронных сетей. В разработанном гибридном алгоритме объединяется действие методов усовершенствованного стохастического поиска, инерционной минимизации, градиентного поиска с памятью, генетического поиска.

В целях дальнейшего совершенствования процесса обучения нейронной сети в рамках данной работы создан **генетический алгоритм с использованием каст** при образовании пар родителей. Его особенность заключается в следующей последовательности действий.

1. Выбор случайных точек-особей и вычисление в них целевых функций.
2. Определение интервала отклонения целевых функций в популяции.

$$\Delta Q = Q_{\max} - Q_{\min} \quad (1.1)$$

3. Для каждой из поисковых точек исходного поколения вводится функция предпочтения, на основе которой формируются касты:

$$F_j = \frac{(Q_{\max} - Q_j)}{\Delta Q}, \quad F|_{Q_{\max}} = 0; \quad F|_{Q_{\min}} = 1; \quad F \in [0, +1], \quad (1.2)$$

4. Формирование каст, как средства повышения эффективности отбора родительских пар. Касты представляют собой изолированные группы поисковых точек. Самые оптимальные поисковые точки попадают в одну касту, менее успешные группируются в другой и далее аналогично. Для улучшения селекции шансы каст с точками, имеющими более высокую функцию предпочтения, должны быть выше. В связи с этим размер касты выбирается в зависимости от величины функции предпочтения.
5. Случайный выбор касты, с учетом функции предпочтения.
6. Отбор родительской пары в выбранной касте. Установлено, что для получения наилучших потомков родители должны иметь близкие целевые функции, но находиться на максимальном расстоянии друг от друга.
7. По прямой между выбранными родительскими точками выполняется одномерный поиск минимума целевой функции. Получаем новые точки-потомки, которые расположены между родительскими точками (рис.1.1):

$$xx[i] = x[rod1, i] + \eta^k \cdot (x[rod2, i] - x[rod1, i]), \quad (1.3)$$

$$\eta^{k+1} = \eta^k + h.$$

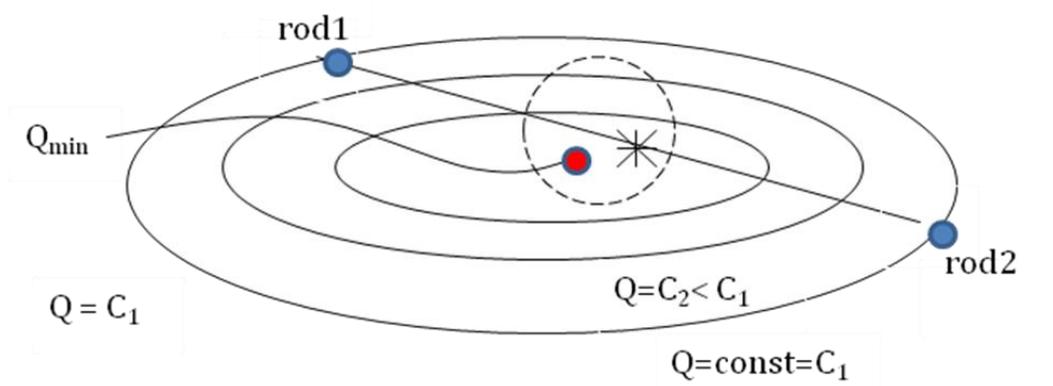


Рис.1.1. Генетический поиск. Алгоритм с кастами:

Среди полученных целевых функций определяем оптимальную целевую функцию Q_{opt} , имеющую минимальное значение. Точка, целевая функция которой оказалась оптимальной попадает в новое поколение.

8. Смена поколений с учетом найденных оптимальных значений.

Одним из достоинств предложенного алгоритма генетической минимизации является возможность сокращения размерности пространства поиска. Особи-родители соединяются прямой, по которой осуществляется глобальный одномерный поиск согласно (1.3). Таким образом, производится сведение многомерного движения поисковых точек к перемещению в одном направлении.

Алгоритм апробирован при создании системы прогнозирования присоединения преэклампсии беременных женщин на фоне хронической артериальной гипертензии (п.5.2.4 диссертации), при регуляризации параметров гидродинамической задачи о скрытых течениях (п.3.2.2), при решении проблемы реставрации изображений, искаженных диффузией (п.5.3), на тестовых многоэкстремальных функциях (п.1.7).

Для минимизации брались тестовые целевые функции с множеством локальных экстремумов вида:

$$Q = - \sum_{s=1}^K \frac{B_s}{a_s^{2n} + \left[\sum_j^N (x_j - X_{js})^2 \right]^n},$$

здесь N - размерность пространства поиска, K - число минимумов, X_{js} - координаты минимумов, B_s , a_s^2 - постоянные, n - степень,

$$Q = \left(\varepsilon + \prod_{k=1}^M \left(1 - e^{-\sum_{i=1}^n \left(\frac{x_i - x_i^k}{r} \right)^2} \right) \right) \cdot \sum_{i=1}^n x_i^2,$$

где x_i^k - координаты, определяющие локальные минимумы, r - радиус притяжения локального минимума.

Численные эксперименты показали, что традиционный генетический алгоритм заканчивает поиск при значениях целевой функции, удаленных от оптимума. Требуется значительное число итераций для достижения окрестности оптимума. Имеет место увеличение точности нахождения глобального экстремума генетическим алгоритмом с кастами по сравнению с традиционным на два порядка в случае популяции из 20 особей, на три порядка и более при возрастании численности набора поисковых точек свыше 100 особей. Происходит сокращение числа итераций поиска генетического алгоритма с кастами от 12 до 67 раз в зависимости от размера популяции поисковых точек

Генетический алгоритм оптимизации с кастами был реализован в последовательном и параллельном виде в интерфейсах MPI и OpenMP. В параллельной реализации алгоритма на MPI была использована топология

"звезда". Каждый рабочий процессор выполняет однопроцессорный вариант алгоритма, но со своим исходным поколением точек. В процессе поиска центральный процессор получает лучшие решения и рассылает их рабочим процессорам. Далее, рабочие процессоры повторяют генетический поиск, но уже из новых лучших условий. Остановка вычислений производится при достижении заданной точности. При реализации параллельного варианта алгоритма на суперЭВМ МВС-100 (НИИ ММ ИГТА) и многопроцессорной кластерной системе "Энергет" (ИГЭУ) попаданий в локальные минимумы не наблюдалось.

Вторая глава посвящена разработке методов построения оптимальной архитектуры нейронной сети. Для этого была модифицирована теория термодинамического формализма, которая рассматривает свойства вычислительного процесса в целом.

Пусть имеет место итерационный вычислительный процесс:

$$x^{k+1} = F(x^k, \xi^k), \quad (2.1)$$

где $x^k \equiv (x_1^k, x_2^k, \dots, x_n^k)$ - точка в n -мерном фазовом пространстве X , F - некий алгоритм, k - номер итерации, ξ^k - параметр учета шума.

Если процесс сходится, то

$$x_i^k \rightarrow x_i^*, k \rightarrow \infty, i = 1, 2, \dots, n, \quad (2.2)$$

где x^* - финальная точка, $x^* \in X$.

Возьмем в X множество фазовых точек с плотностью $\rho(x_1, \dots, x_n)$. Это множество рассматриваются как «фазовый газ», который в процессе вычислений сжимается к точке x^* . Рассмотрим этот процесс с точки зрения термодинамики.

Первое начало:

$$dN = T \cdot dI + p \cdot dn + \mu \cdot d\pi, \quad (2.3)$$

$$T = \left. \frac{\partial N}{\partial I} \right|_{n, \pi}, \quad p = \left. \frac{\partial N}{\partial n} \right|_{I, \pi}, \quad \mu = \left. \frac{\partial N}{\partial \pi} \right|_{I, n} \quad (2.4)$$

где N - число операций, затраченное на сжатие «фазового газа», N - аналог внутренней энергии (обладает аддитивностью), I - информация, полученная в процессе вычислений.

Алгоритмическая температура T представляет число операций, затраченных на получение единицы информации. Давление p является числом операций, потраченных на изменение размерности, если в процессе вычислений это имело место. Слагаемое $\mu \cdot d\pi$ в (2.3) учитывает вероятностный характер вычислительного процесса (погрешности, использование случайных чисел). Здесь π - вероятность правильного ответа, $0 < \pi < 1$. В ряде случаев определенное снижение π ведет к существенному сокращению числа операций N (методы Монте-Карло, случайный поиск).

Второе начало. Термодинамическая необратимость.

Вычислительный процесс устойчив, если

$$dI > 0. \quad (2.5)$$

Опираясь на это неравенство можно исследовать алгоритмы на устойчивость. Это значительно более эффективный нетрадиционный способ, он не требует линеаризации и применим в сложных нелинейных случаях. Приобретенная информация:

$$\Delta I^{k,k+m} = H^k - H^{k+m}, \quad (2.6)$$

где H^k, H^{k+m} - вычислительная энтропия на шагах номер k и $k+m$.

Третье начало. Недостижимость температурного нуля:

$$T = \left. \frac{\partial N}{\partial I} \right|_{n,\pi} > 0. \quad (2.7)$$

Величина обратная алгоритмической температуре является пропускной способностью алгоритма. Это извлеченная информация, отнесенная к числу затраченных операций:

$$C^{K_1, K_2} = \frac{\Delta I^{K_1, K_2}}{\Delta N^{K_1, K_2}}. \quad (2.8)$$

Вариационная задача о поиске оптимального распределения начальной плотности «фазового газа», минимизирующего число операций ΔN при заданной информации ΔI приводит к распределению Л.Больцмана:

$$\rho^0(x_1, \dots, x_N) = \exp\left(-\frac{\Delta N}{T}\right) \cdot \left(\sum_{i=1}^n \exp\left(\frac{\Delta N}{T}\right)\right)^{-1}. \quad (2.9)$$

Отсюда получаются все известные соотношения статистической термодинамики, согласующиеся с изложенным феноменологическим подходом. Если согласно методу И.Ньютона линеаризовать локально отображение (2.1) и ввести информацию Хартли, то можно показать, что

$$\Delta I^{o,k} = -\sum_{i=1}^n \ln\left(\lambda_i^k + \chi_i \frac{1 - \lambda_i^{k-1}}{1 - \lambda_i}\right), \quad (2.10)$$

где λ_i - собственные числа некоторой матрицы A , χ_i - константы пропорциональные уровню шума для частот λ_i . В хорошо обусловленном случае, если принять $\lambda_s = \lambda$; $\chi_s = \chi$; $s = 1, 2, \dots, n$, а затраты на вычисления считать пропорциональными $k \cdot n(\nu + n)$, то получим выражение:

$$p(\nu + n) = I \cdot T, \quad (2.11)$$

которое можно назвать уравнением состояния алгоритма.

Описанный формализм позволяет, кроме исследования на устойчивость, находить оптимальные пути декомпозиции, выделять главные переменные, понижать размерность задачи, результативно рандомизировать вычисления.

Автором предложены принципы исследования и построения нейронной сети, основанные на термодинамическом формализме. При синтезе нейронной сети вместо числа операций N вводится величина ε , пропорциональная рассеянию энергии нейронной сетью:

$$\varepsilon = b_n \cdot n + b_m \cdot m, \quad (2.13)$$

где n – число нейронов, m – число связей между ними, b_n, b_m – энергии, соответственно рассеиваемые нейронами и связями.

Выражения (2.3), (2.4) перепишутся в виде:

$$d\varepsilon = T \cdot dI + p \cdot dn + \mu \cdot d\pi, \quad (2.14)$$

$$T = \left. \frac{\partial \varepsilon}{\partial I} \right|_{n, \pi}, \quad p = \left. \frac{\partial \varepsilon}{\partial n} \right|_{I, \pi}, \quad \mu = \left. \frac{\partial \varepsilon}{\partial \pi} \right|_{I, n, m}. \quad (2.15)$$

Если предположить, что все нейроны работают в областях быстрых переходов, где локально допустима линеаризация, то можно воспользоваться выражением типа (2.10). В этом случае k – порядковый номер нейронного слоя при прямом распространении сигнала (от входа к выходу). Опираясь на это, можно ставить задачи на выделение главных компонент, на упрощение, декомпозицию сети по наиболее слабым информационным связям, переход к новым переменным. Наличие слагаемого $\mu \cdot d\pi$ говорит, что рандомизация процессов в нейронной сети с использованием марковских алгоритмов является эффективной.

Среди приложений термодинамического подхода можно выделить следующие.

Устойчивость вычислительного процесса.

В фазовом пространстве можно ввести структуру в виде решетки, состоящей из одинаковых N -мерных кубических ячеек, и по числу частиц фазового газа, попавших в каждую ячейку, оценивать его плотность ρ^k . Это позволит проследить на каждом шаге, как в процессе вычислений изменяется энтропия [Ватолин, 71г.]:

$$H^k = - \int_x \rho^k \ln \rho^k \cdot dx_1 \dots dx_N. \quad (2.16)$$

Уменьшение энтропии, и, следовательно, извлечение информации, свидетельствует об устойчивости вычислений. Такой подход к оценке устойчивости превосходит традиционный, основанный на линеаризации и анализе собственных чисел.

Изменение размерности. Если воспользоваться технологией метода главных компонент [Саймон Хайкин] и перейти от координат (x_1, \dots, x_N) к новым (z_1, \dots, z_N) , то можно определить информационный вес каждой новой координаты как:

$$g_i^k = \ln \left(\lambda_i^k + \chi_i \frac{1 - \lambda_i^{k-1}}{1 - \lambda_i} \right). \quad (2.17)$$

Здесь λ_i^k , χ_i^k - собственные числа и уровни шумов на отрезке в k -шагов. Координаты, обладающие малым весом g_i^k , можно отбросить и понизить размерность. Если удастся добиться хорошей обусловленности $\lambda_i = \Lambda$ и низкого уровня шумов $K_i = 0$, то при условии сохранения количества информации можно достигнуть наименьшей размерности системы:

$$m = \sum_{i=1}^N \frac{g_i}{\ln \Delta} < N. \quad (2.18)$$

Однако, метод главных компонент достаточно затратная операция. В ряде случаев, оперируя только с координатами x_i [Ковалевский, Решетник], можно грубо оценить их вес как:

$$l_i = \ln \left(\sum_{j=1}^N \left| \frac{\partial F_i}{\partial x_j} \right| \right). \quad (2.19)$$

Подход, основанный на введении весов, позволяет не только понижать размерность, но и выполнять декомпозицию системы на блоки. Это относится как к внутренним, так и к внешним связям. В случае нейронной сети имеются в виду межнейронные связи. Разбиение на блоки ведется по самым слабым связям с наименьшими весами. Для каждого блока вводится своя температура (измеряется числом операций на единицу извлеченной информации). Вычисления начинаются с блока с наименьшей температурой и заканчиваются, когда температуры всех блоков уравниваются и извлечена требуемая информация.

Существенным способом ускорения вычислений является использование априорной и апостериорной информации. Для каждой задачи строится множество родственных задач, которые могут быть источником информации для данной задачи. Решения родственных задач могут быть использованы при построении конструкций, в виде которых ищется решение данной задачи. В случае с нейронными сетями это состоит во включении в сеть заранее обученных фрагментов.

Одна из актуальных проблем в теории нейронных сетей заключается в методике выбора размера скрытого слоя сети. Известны алгоритмы, которые обеспечивают автоматическое построение нейронной сети и дают возможность избежать избыточности нейронов. В основе алгоритмов сокращения лежит принцип постепенного удаления из нейронной сети синапсов и нейронов. Для них отсутствует методика определения числа нейронов скрытых слоев, которое является заведомо избыточным, также вследствие изначально большого числа нейронов обучение сети

происходит медленно. В конструктивных алгоритмах число нейронов в скрытых слоях изначально мало и постепенно увеличивается. При добавлении нейронов происходит увеличение значения функции ошибки после каждого добавления нового нейрона. В результате случайного задания значений параметров новых нейронов может появиться избыточность в числе нейронов скрытого слоя. Существенным недостатком является экспоненциальный рост времени вычислений при увеличении размерности сети.

Автором предлагается **метод синтеза оптимальной структуры** нейронной сети в процессе обучения для достижения наиболее высоких показателей качества своей работы. Разработанный метод включает несколько блоков:

1. Достраивание активного скрытого слоя. Выражается в добавлении нейронов на скрытый слой;

2. Добавление новых скрытых слоев при превышении установленного допустимого количества нейронов на текущем активном слое. При образовании нового слоя число нейронов на заполненном слое замораживается, нейроны могут добавляться только на новом слое;

3. Ветвление процесса обучения. Здесь определяется - было ли предыдущее изменение структуры нейронной сети удачным (2.21):

$$Q > Q' + S, \quad (2.21)$$

где Q , Q' – целевые функции ошибки соответственно до и после изменений, S – штраф за сложность при добавлении нейронов:

$$S = \alpha \cdot \sum_{i=1}^N |w_i| \quad (2.22)$$

где α - константа, w_i - весовые коэффициенты нейронной сети, N – общее кол-во весов.

Помимо описанных блоков алгоритм самоорганизации дополняется процедурами подстройки порогов согласно Головки. Благодаря подстройке сигнал на входе нейрона оказывается на рабочем участке функции активации, что приводит к повышению скорости обучения. Проведенные численные эксперименты с обучением нейронной сети аппроксимации стохастической функции показали, что предложенный метод самонастройки обеспечивает преимущество в точности работы порядка 10% относительной погрешности. Начиная обучение нейронной сети с небольшим количеством нейронов на скрытом слое удается добиться наиболее высоких процентов обучения.

Множество задач, решаемых нейронными сетями, связано со сжатием данных. Причина заключается в том, что обучающие образы могут содержать избыточную, взаимно связанную информацию, которую следует сокращать в целях уменьшения размерности системы и повышения

скорости обучения сети. Автором создана программа, исследующая возможности нейронной сети при сжатии и восстановлении графической информации с заданной точностью. Для сокращения размерности пространства поиска оптимальных весовых коэффициентов оправданным способом является разбиение единого скрытого слоя на несколько меньших слоев, каждый из которых связан со своими участками входного и выходного полей (рис.2.2). При этом число весов сокращается в n раз (n – число нейросетевых воронок после разбиения). Однако, при прочих равных условиях разбиение скрытого слоя приводит к большему числу шагов обучения для достижения аналогичной погрешности восстановления.

В диссертационной работе также исследованы возможности **сжатия информации** при помощи нейросетевой воронки. Приведены экспериментально установленные зависимости погрешностей восстановления информации от степени сжатия и структуры нейронной сети. При понижении размерности задачи нейросетевая воронка успешно заменяет метод главных компонент, содержащий такие затратные и трудно поддающиеся распараллеливанию операции как отыскание собственных чисел и собственных векторов матриц.

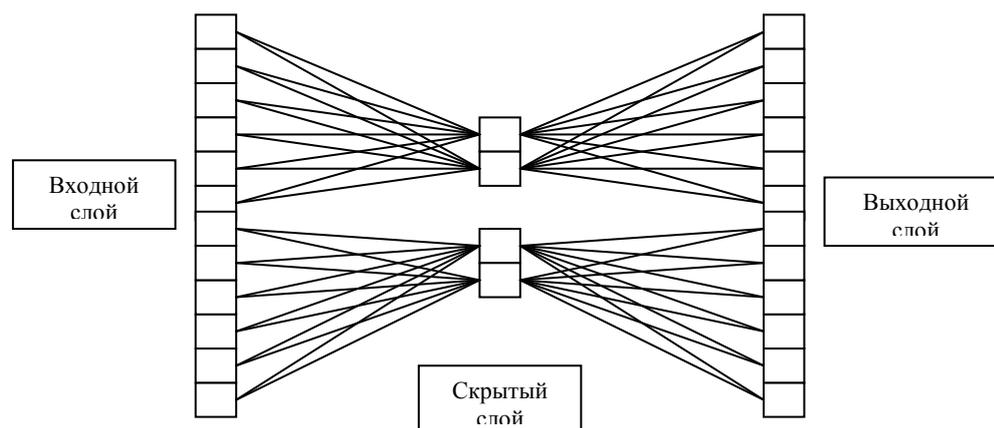


Рис.2.2 – Структура связей нейронной сети при разбиении скрытого слоя

Метод нейросетевого сжатия данных апробирован при создании программного комплекса диагностики групп заболеваний новорожденных неонатального периода. Его применение позволило понизить размерность нейросетевой структуры системы и решить проблему повышения точности выдаваемых заключений (п.5.2.3 диссертации).

Автором предлагается **стохастический метод увеличения числа образов** в обучающей выборке с помощью потенциальных функций, который позволяет обучить нейронную сеть в условиях дефицита обучающих данных. Известно, что точечный электрический заряд образует поле. В этом случае напряженность поля для каждой точки пространства определится при помощи выражения (2.23):

$$P = a \cdot \frac{q}{r^2} = a \cdot q / \left((x - x_*)^2 + (y - y_*)^2 + (z - z_*)^2 \right), \quad (2.23)$$

где a – коэффициент, q – величина заряда, r – расстояние от заданной точки до заряда, x_* , y_* , z_* – координаты заряда, x, y, z – координаты точки. Будем называть величину P «потенциалом». В случае, если имеются несколько зарядов, потенциал в каждой точке пространства будет состоять из потенциалов, образуемых всеми зарядами и может выступить в качестве меры удаленности этой точки от совокупности указанных зарядов.

Имеющиеся в начальный момент обучающие образы представляются как точки-источники потенциалов, группирующиеся по классам. Затем вызывается процедура, которая с учетом специфики задачи, используя случайные числа, генерирует новые образы вблизи исходных. Полученные таким способом образы относятся по методу потенциалов к одному из существующих классов. Итак, получены два множества: исходное и сгенерированное. Оба будут использованы для обучения нейросети.

Апробация метода выполнена при создании программного комплекса диагностики постгипоксических нарушений сердечно-сосудистой системы детей неонатального периода. Его использование позволило повысить точность заключений по направлениям диагностики дисфункции миокарда до 82% и ST-T-нарушений до 91% (п.5.2.2 диссертации). Оценка эффективности метода произведена на основе тестовой системы распознавания символов латинского алфавита (26 образов). Численные эксперименты показали, что оптимальным является двукратное увеличение обучающего множества. Имеется возможность большего расширения обучающей выборки за счет относительно небольшого понижения процента распознаваемости нейронной сети.

Исследованы возможности **распараллеливания** нейронной сети на многопроцессорной вычислительной технике. Применение технологии CUDA становится оправданным при распараллеливании нейронных сетей больших размерностей. Её эффективность теряется для сетей, содержащих менее нескольких десятков тысяч нейронов в одном слое. Технология MPI сталкивается с трудностями при обучении нейронных сетей, так как программная модель ИНС требует значительного количества пересылок данных между рабочими узлами MPI, поэтому в данной технологии препятствием является пропускная способность коммуникационной сети. Последний недостаток естественным образом устраняется в технологии OpenMP, которая хорошо подходит для программирования многопоточных нейросетевых приложений, поскольку работает с общей памятью.

В третьей главе рассматриваются вопросы, связанные с созданием гибридной технологии математического моделирования процессов, объединяющей динамический и нейросетевой подходы.

Предложен способ построения структуры нейронной сети с использованием заранее обученных нейросетевых фрагментов (рис.3.1). Обучение системы состоит в настройке весовых коэффициентов, учитывающих влияние каждого фрагмента на результирующий ответ. Такая нейронная сеть уже на стадии обучения содержит фрагменты с настроенными синаптическими связями, полученными ранее при решении задач, сопряженных с данной.

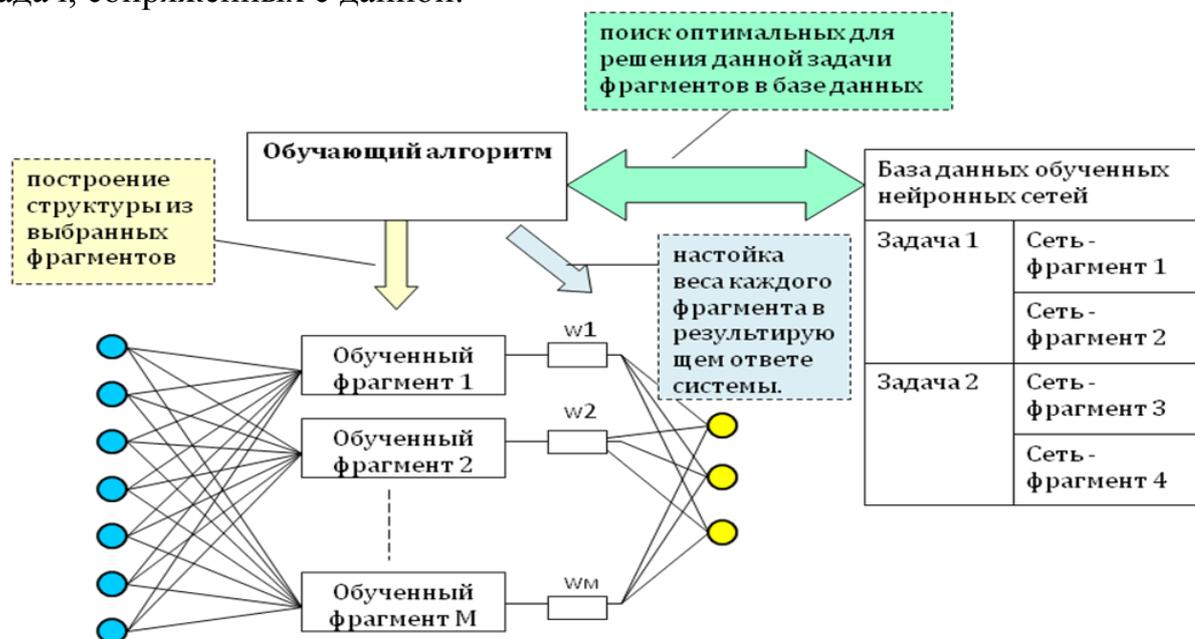


Рис. 3.1 – Возможности совершенствования структуры нейронных сетей

Здесь входной образ или его часть анализируются предварительно настроенными блоками. При обучении сети веса внутри блоков не меняются. Настройке подлежат только свободные веса w_1, w_2, \dots, w_N на выходах фрагментов, которые получены при помощи алгоритмов глобальной оптимизации (случайный поиск, генетический алгоритм, инерционный поиск). Ответ на выходе сети O_i формируется в виде линейной комбинации ответов обученных фрагментов-специалистов. Он также преобразуется с помощью функции активации.

Технология использования заранее обученных фрагментов оказала существенную помощь при моделировании задач механики сплошной среды со сложной картиной течений, в частности при создании метода нейросетевой интерполяции турбулентной вязкости потока (п. 4.2 диссертации).

Для оценки эффективности предложенной технологии также проведены численные эксперименты по обучению нейронных сетей различных архитектур аппроксимации стохастической периодической функции (3.1):

$$y_j = \sum_{i=1}^N A_i \cdot \sin(w_i \cdot t_j + \varphi_i), \quad i = 1, \dots, N, \quad (3.1)$$

$$A_i = \frac{1}{1+i^2}, \quad w_i = \frac{2 \cdot \pi \cdot i}{N}, \quad t_{j+1} = t_j + \tau,$$

где y_j – значение функции в момент времени t_j , A_i – амплитуда, w_i – частота, φ_i – фаза (случайная величина), $N = 20$ – число слагаемых в сумме.

Были взяты стандартная архитектура сети и структура с включением заранее настроенных фрагментов. Для настройки весовых коэффициентов обученных фрагментов сети использовалась аналогичная функция с другим значением шага по времени τ^* . Очевидно, задавая различные значения τ можно получать различные последовательности y_j , связанные, тем не менее, общим периодическим законом. При сравнении представленных графиков видно, что обучение нейронной сети с настроенными фрагментами происходит быстрее и её результаты обладают преимуществом в точности вычислений более 10 % (рис.3.2). Даже при длительном обучении нейронная сеть стандартной архитектуры не достигает сравнимого уровня точности работы.

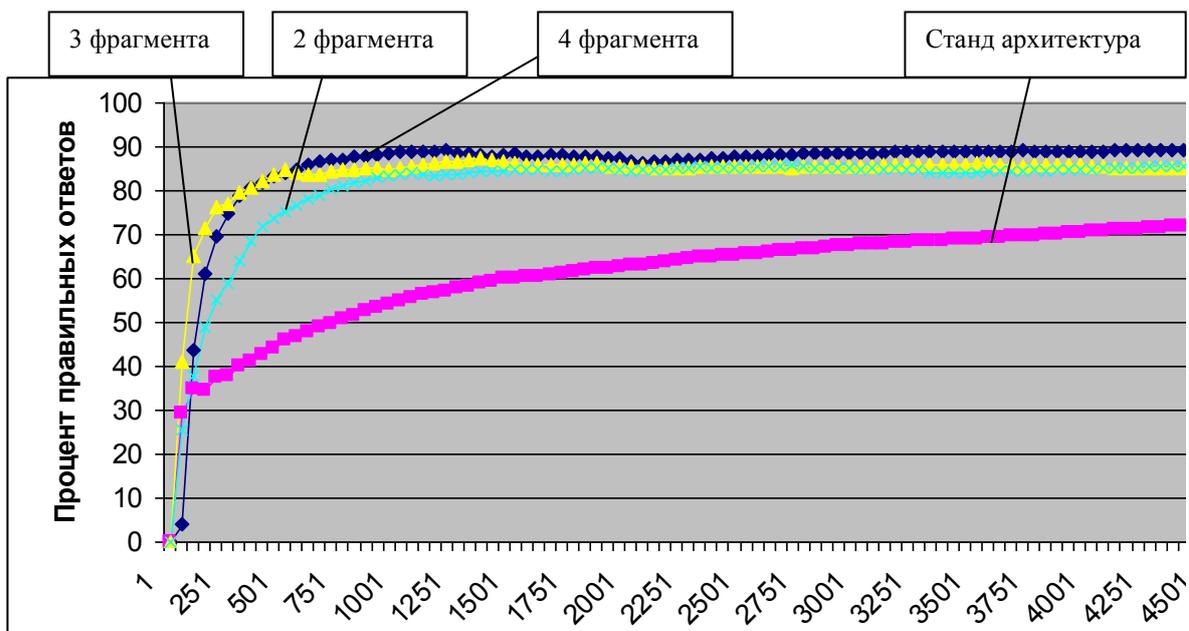


Рис.3.2 - Графики обучения нейронной сети со стандартной архитектурой и сетей с включением заранее настроенных фрагментов

Предложен **способ установления начальных условий** параметров при решении гидродинамической задачи о скрытых течениях в океане. Для решения задачи Коши существуют аналитические и численные методы. Однако, их применение существенно ограничивается в ряде приложений тем, что часть переменных может быть не наблюдаема, включая их начальные значения. Данная проблема была решена применительно к следующей гидродинамической задаче. Со спутников ведется наблюдение за течениями на поверхности океана. Опираясь на уравнения

гидродинамики, после достаточно длительного наблюдения за поверхностными течениями нужно восстановить величину и направления скоростей в глубине океана. При этом предполагалось, что можно ограничиться трехмерными уравнениями Рейнольдса в следующем виде:

$$\frac{\partial u_i}{\partial t} + \sum_{j=1}^3 u_j \frac{\partial u_i}{\partial x_j} = -\frac{1}{\rho} \frac{\partial P}{\partial x_i} + \sum_{j=1}^3 \frac{\partial}{\partial x_j} \left(\nu \frac{\partial u_i}{\partial x_j} \right) + F_i, \quad (3.2)$$

$$\sum_{i=1}^3 \frac{\partial u_i}{\partial x_i} = 0, \quad (3.3)$$

где u_i – искомые составляющие скорости, $i=1, 2, 3$; P – давление; ρ – плотность; x_i – декартовы координаты; ν – кинематическая турбулентная вязкость, вычисляемая с помощью К–Е – модели турбулентности; F_i – кориолисово ускорение, вызванное вращением Земли.

Очевидно, что данная задача относится к числу некорректных, и может быть решена лишь при условии применения методов регуляризации. Кроме того, начальные скорости для глубинных течений неизвестны.

Назначаются пробные начальные значения для скрытых переменных $\alpha_1^0, \dots, \alpha_m^0$ и заданные известные начальные значения для наблюдаемых x_1^0, \dots, x_n^0 . Система интегрируется каким-либо подходящим аналитическим или численным методом.

$$\begin{aligned} \frac{d\tilde{x}_i}{dt} &= F_i(t, x_1, \tilde{x}_N); \quad i=1, 2, \dots, N \\ \tilde{x}_i|_{t=t^0} &= x_i^0; \quad i=1, 2, \dots, n \\ \tilde{x}_{n+j}|_{t=t^0} &= \alpha_j^0; \quad j=1, 2, \dots, m \end{aligned} \quad (3.4)$$

В этих уравнениях тильдой отмечены получающиеся при этом решения, отличающиеся от действительных. Для указанных фиксированных моментов t^k ; $k=0, 1, 2, \dots, M$ находятся невязки между вычислительными $\tilde{x}_l(t^k)$ и заданными наблюдаемыми значениями x_l^k :

$$H_l^k = x_l^k - \tilde{x}_l(t^k). \quad (3.5)$$

Из них строится квадратичная мера близости полученного решения \tilde{x}_l к действительному движению данной динамической системы по наблюдаемым переменным:

$$Q = \sum_{l=1}^n \sum_{k=1}^M |x_l^k - \tilde{x}_l(t^k)|^2. \quad (3.6)$$

Эта мера является функцией от принятых начальных значений скрытых переменных $\alpha_1^0, \dots, \alpha_m^0$:

$$Q = Q(\alpha_1^0, \dots, \alpha_m^0).$$

Минимизацией этой меры по $\alpha_1^0, \dots, \alpha_m^0$, находятся начальные значения скрытых переменных $\hat{\alpha}_1^0, \dots, \hat{\alpha}_m^0$, обеспечивающих наилучшее приближение по наблюдаемым переменным:

$$Q(\hat{\alpha}_1^0, \dots, \hat{\alpha}_m^0) = \min_{(\alpha_1^0, \dots, \alpha_m^0)} Q(\alpha_1^0, \dots, \alpha_m^0), \quad (3.7)$$

и затем продолжается интегрирование системы обычным образом на продолженном отрезке времени $t > t^M$. Целевая функция $Q(\hat{\alpha}_1^0, \dots, \hat{\alpha}_m^0)$ часто оказывается многоэкстремальной и не отличается гладкостью. Наилучшим инструментом в этом случае оказывается созданный гибридный алгоритм глобальной оптимизации. Эта методика была успешно применена к указанной выше задаче о скрытых течениях в океане, а также к задаче о восстановлении размытых диффузией изображений (п.5.3 диссертации).

Разработана методика математического моделирования, соединяющая динамический и нейросетевой подходы (рис.3.3).

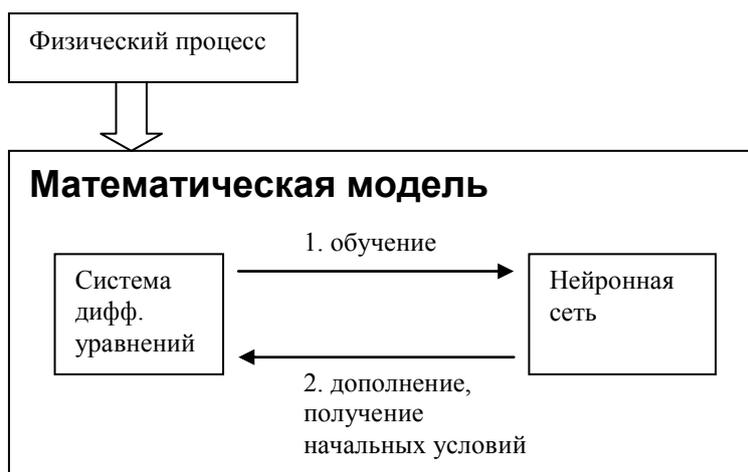


Рис. 3.3– Комбинированная математическая модель из нейронной сети и динамической модели

Моделирование процессов с помощью нейронных сетей также основывается на результатах длительного наблюдения за поведением открытых переменных. При этом значениями скрытых переменных не интересуются. Объединение подходов удается выполнить применением разработанного алгоритма усовершенствованного случайного поиска, который позволяет восстановить значения скрытых параметров динамической модели. Эффективность комбинированного метода моделирования, как показывают численные эксперименты, превышает показатели динамического и нейросетевого прогнозирования в отдельности. На первой стадии нейронная сеть наблюдает за расчетами динамической модели и по ним учится прогнозировать параметры процесса. При

достижении требуемого качества работы, обученная нейронная сеть может выступать в качестве математической программной модели объекта и использоваться для исследования его свойств и установления скрытых параметров или неизвестных начальных условий процесса.

Предложенные идеи были апробированы при моделировании гидродинамической задачи с использованием нейронной сети. Неустановившееся движение воды в открытых руслах описывается следующими дифференциальными уравнениями:

$$\frac{\partial \omega}{\partial t} + \frac{\partial Q}{\partial x} = q, \quad (3.8); \quad \frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(P - \frac{Q^2}{\omega} \right) = g\omega \left(i - \frac{Q|Q|}{K^2} \right) + R_x, \quad (3.9)$$

здесь $Q(x,t)$ - объемный расход, $\omega(x,h)$ - площадь поперечного сечения потока, $h = z(x,t) - z_0(x)$ - глубина потока, $z(x,t)$ - ордината свободной поверхности потока, $z_0(x)$ - ордината дна русла.

$$\omega = \int_0^h b(x, \xi) d\xi \quad (3.10); \quad P = g \int_0^h (h - \xi) b(x, \xi) d\xi \quad (3.11); \quad R_x = g \int_0^h (h - \xi) \frac{\partial b}{\partial x} d\xi \quad (3.12)$$

$b(x, \xi)$ - ширина поперечного сечения потока, $i = z'_0(x)$ - уклон дна, $K(x, h)$ - модуль расхода, $q(x)$ - путевой приток в основной поток с берегов, g - ускорение свободного падения.

$$K = \omega \cdot C \sqrt{R}, \quad (3.13)$$

C – коэффициент Шези, R – гидравлический радиус.

В разработанной компьютерной программе динамическая модель на основе представленных дифференциальных уравнений вычисляет значения объемного расхода $Q(x,t)$ в узлах сетки на заданном отрезке времени. При этом программная модель искусственной нейронной сети наблюдает за процессом и использует полученные в динамической модели значения $Q(x,t)$ для настройки весовых коэффициентов связей и выполнения собственного прогноза расхода. Численные эксперименты показали, что такая нейросетевая модель гидродинамического процесса может быть быстро обучена до высокой точности прогнозирования. Начиная с 30-ой итерации обучения разница в расчете дифференциальной модели и нейронной сети была менее 3-х процентов относительной погрешности во всех узлах сетки пространства.

Предложен способ быстрой оценки близости частиц в методе молекулярной динамики. Численные эксперименты с последовательными и параллельными программными моделями выполнены на примере задачи о динамике газопылевого облака, и показали увеличение скорости вычислений предложенного подхода по сравнению с традиционными схемами близости по Эйлери и Лагранжу от 2,2 раз в системе из 10^3 частиц и до 200 раз в системе из 10^6 частиц.

В четвертой главе рассматриваются теоретические и прикладные аспекты решения задач гидрогазодинамики с использованием нейросетевых технологий.

Множество процессов аэрогидродинамики обладают трудно формализуемой сложностью, не позволяющей выразить законы системы при помощи какой-то одной универсальной модели. Данное обстоятельство приводит к созданию множества специфических моделей, справедливых на узких диапазонах изменения параметров задачи. При этом модели могут предлагать решения различного качества, в том числе противоречивые. Нейронные сети, обладая интерполяционными возможностями, служат средством, объединяющим различные модели.

При решении задач механики сплошной среды могут присутствовать различные тонкие структуры: пограничные слои, ударные волны, следы, точки отрыва, зоны действия различных полуэмпирических моделей турбулентности. Известно, что решение таких задач с помощью чисто сеточных методов затруднительно. Наиболее сложными являются области взаимодействия ударных волн с турбулентными пограничными слоями. Предлагается данную пеструю картину течений собрать в одно целое с помощью нейросетевой технологии.

Пусть система уравнений газодинамики представлена:

$$F(\vec{x}, U(\vec{x})) = 0, \quad (4.1)$$

где F – некоторые нелинейные операторы, $U(\vec{x})$ – искомые поля, \vec{x} – точка из области Ω реального пространства, где рассматривается процесс.

К уравнениям (4.1) присоединяются граничные условия:

$$f(U)|_{\Gamma} = f_{\Gamma}(x'), \quad (4.2)$$

Γ – граница Ω , $x' \in \Gamma$, f – граничные операторы.

Решение находится в виде конструкций:

$$U(\vec{x}) = \Phi(\vec{x}, A) = \sum_{s \in \Omega} g_s(\vec{x}, \alpha_s, m_s) U_s(\vec{x}, \beta), \quad (4.3)$$

здесь U_s – частные решения для различных подобластей X_s , $A \equiv (\alpha_s, m_s, \beta)$ – свободные константы, от подбора которых зависит качество приближения. U_s могут быть как аналитическими, так и сеточными приближениями. Желательно при конструировании $\Phi(\vec{x}, A)$ удовлетворить граничные условия. Это можно сделать с помощью уже указанных нейронных функций g_s . В области Ω выбирается система контрольных узлов. Каждый такой узел представляет из себя основную точку, окруженную системой дополнительных. В каждом узле при произвольных, но конкретных параметрах A вычисляются значения полей U_s и находятся все необходимые частные производные разностным способом. Не следует отождествлять такое вычисление производных с традиционным методом сеток. Контрольные узлы могут отстоять друг от друга на значительном

расстоянии, а вспомогательные точки сосредоточены вблизи основной центральной, что обеспечивает высокую точность и не влияет на устойчивость вычислений. В контрольных узлах при любых A вычисляются невязки F для уравнений:

$$F_i(\vec{x}_j, A) = F(\vec{x}_j, \Phi(\vec{x}_j, A)), i = 1, 2, \dots, N, \quad (4.4)$$

Из них строится мера близости $Q(A)$ приближенного решения к точному в таком виде:

$$Q(A) = \sum_{i=1}^{\bar{N}} \sum_{j=1}^M \gamma_i |F(\vec{x}_j, A)|^{p_i}, \quad (4.5)$$

где $p_i > 0$; \bar{N} - число невязок; γ_i - их веса; M - количество контрольных узлов. Их значительно меньше, чем число узлов в сеточном методе. За оптимальные значения параметров A принимаются такие значения A^* , которые доставляют минимум целевой функции $Q(A)$. В качестве инструмента минимизации используется метод усовершенствованного случайного поиска в форме, предложенной в п.1.3.1 диссертации.

Данный метод был апробирован при **установлении параметров турбулентной вязкости** среды в задаче генерации газодинамического лазера со смешением сверхзвуковых струй (рис.4.1).

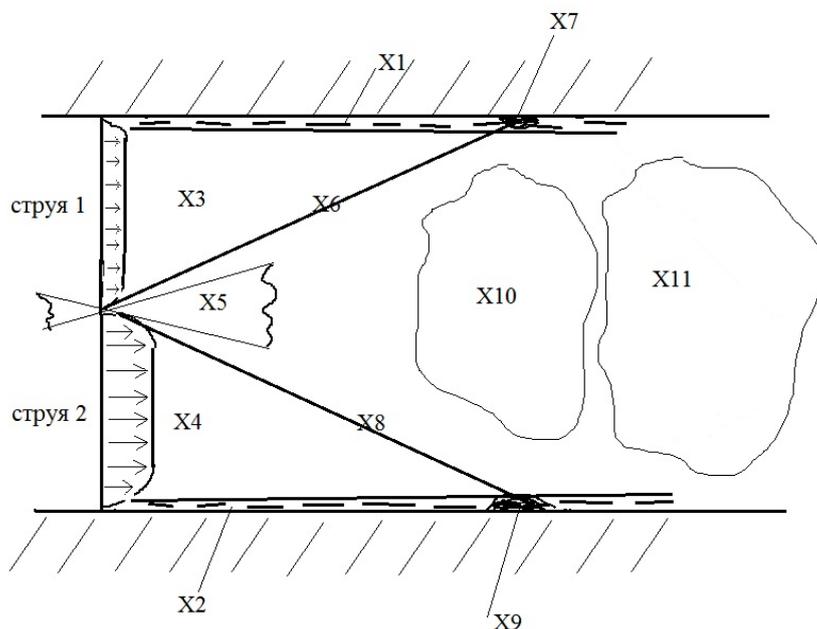


Рис. 4.1. Продольный вдув реагирующих сред

X_1, X_2 - турбулентные пограничные слои; X_3, X_4 - течения на входе в камеру перемешивания; X_5 - пограничный слой между струями; X_6, X_8 - ударные волны; X_7, X_9 - области взаимодействия ударных волн с турбулентными пограничными слоями; X_{10} - область действия К-Е модели турбулентности; X_{11} - область действия модели А.Н.Секундова

Выделяются области X_s ; $S = 1, 2, \dots, N$, каждая из которых характеризуется своей очевидной спецификой (ударная волна,

турбулентность определенного типа, пограничный слой струи, зона взаимодействия ударной волны и пограничного слоя и т.д.) Каждая из указанных областей X_s фиксируется множеством сигнальных точек $\vec{X}_{sr}; r = 1, 2, \dots, N_s; N_s$ - число сигнальных точек в области X_s . Для каждой области X_s вводится потенциал Э.М. Бравермана

$$\varphi_s(\vec{x}) = \sum_{r=1}^{N_s} \|\vec{x} - \vec{X}_{sr}\|^{-m_s} \quad (4.6)$$

m_s —положительная величина. $m_s > 1$.

Если произвольная точка \vec{x} попадает в область X_s или приближается к ней, то потенциал φ_s возрастает или принимает наибольшее значение. Для каждой области X_s вводится своя нейронная функция:

$$g_s(\vec{x}) = \frac{1 - \exp(-\alpha_s \varphi_s(\vec{x}))}{1 + \exp(-\alpha_s \varphi_s(\vec{x}))}, \quad (4.7)$$

которая обращается в число близкое к единице в области X_s и стремится к нулю вне ее. Быстрота перехода $g_s(\vec{x})$ от единицы к нулю регулируется постоянными m_s, α_s .

Турбулентную вязкость во всей изучаемой области можно вычислить:

$$v_t = \sum_{s=1}^N g_s \cdot v_{ts}, \quad (4.8)$$

Нейронная интерполяция восполняет значение v_t для тех областей, для которых в настоящее время нет соответствующей полуэмпирической модели. Аналогичная технология распространяется на определение положения ударных волн, удовлетворение граничных условий и т.д. Поскольку решения представляются в аналитическом виде, то отпадает надобность в дроблении шагов сетки в местах резких переходов. Это обеспечивается с помощью свойств нейронных функций g_s .

Разработана нейросетевая система **прогнозирования стока реки Березина**. Прогнозируемым параметром являлся годовой сток воды, который показывает количество выносимой рекой воды за год (измеряется в км³/год). Данными для обучения служила выборка, содержащая показатели стока реки Березина за 115 лет (1877-1991гг). Выполнен ряд численных экспериментов, направленных на определение оптимальной модели функционирования нейросети, включая испытания сигмоидальной и логарифмической моделей функционирования нейронов. Применена концепция глубокого обучения нейронной сети. Графики, отражающие действительные значения стока и спрогнозированные значения приведены на рис. 4.2, 4.3. Создана параллельная реализация нейросетевой системы прогнозирования с использованием технологии OpenMP, позволяющая повысить скорость работы приложения в 1,5 раза и более (в зависимости от аппаратных возможностей вычислительной среды).

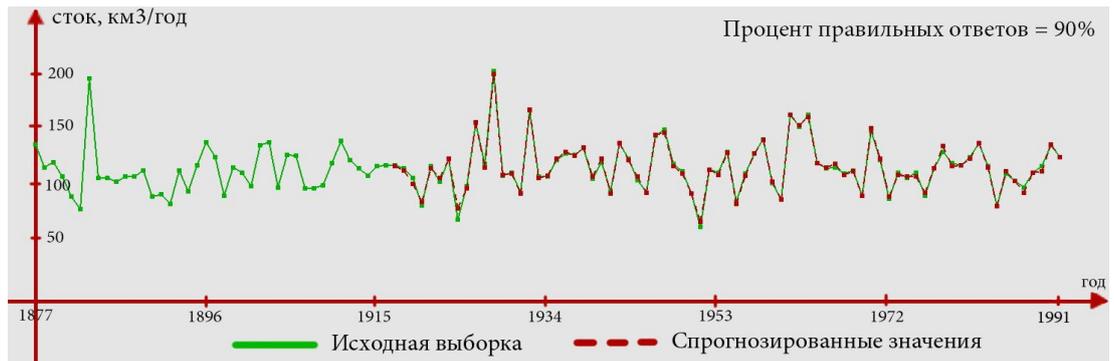


Рис. 4.2 Прогнозирование нейросети с сигмоидальной функцией активации

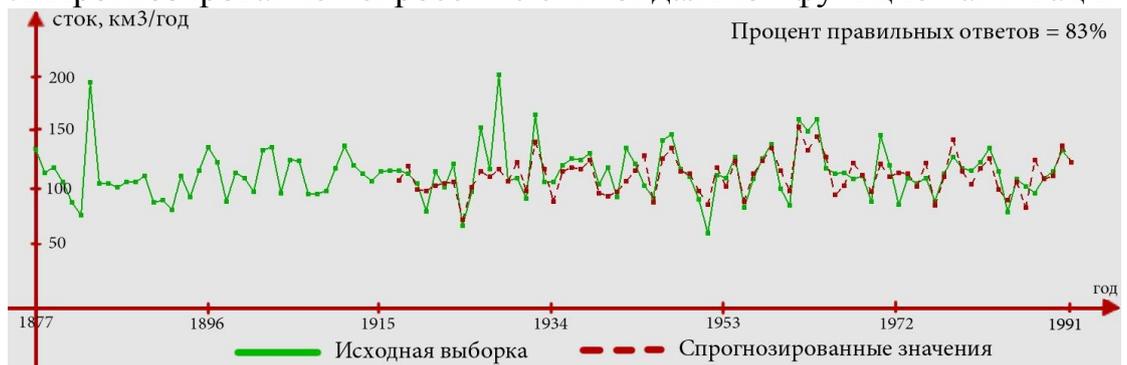


Рис. 4.3 Прогнозирование нейросети с логарифмической функцией активации

Предложен **гибридный способ прогнозирования**, основанный на методах Ивахненко и нейронных сетей. Результат прогноза получается следующим образом:

$$y = a_1 + a_2x_1 + a_3x_2 + a_4x_1x_2$$

где $x_{1,2}$ – известные значения в предыдущие моменты времени; y – предсказанное значение в будущий момент времени; $a_{1..4}$ – некоторые коэффициенты, меняются в интервале (-1; 1).

Оценка эффективности модели проводится методом наименьших квадратов. Для коррекции весов нейронной сети использовался метод обратного распространения ошибки. Создан комбинированный метод, в котором с помощью весового коэффициента δ регулируется участие алгоритмов, составляющих комбинацию.

$$H_i = \delta \cdot I_i + (1 - \delta) \cdot N_i$$

где δ – весовой коэффициент; I_i – результат полученный методом Ивахненко; N_i – результат, полученный нейронной сетью.

С комбинированным методом были выполнены численные эксперименты. В качестве прогнозируемой была взята тестовая стохастическая функция (3.1) и график солнечной активности за выбранный период. Показано, что комбинированный метод позволяет аппроксимировать тестовую функцию с меньшей погрешностью, чем нейросетевой метод и способ Ивахненко по отдельности. Численные

эксперименты с функцией, отражающей солнечную активность за период времени, дали аналогичные результаты.

В **пятой главе** рассматриваются созданные автором нейросетевые автоматические системы и программные комплексы.

Постгипоксические нарушения сердечно-сосудистой системы занимают одно из ведущих мест в структуре заболеваемости новорожденных. Разработан нейросетевой программный комплекс, направленный на **выявление** таких **патологий сердечно-сосудистой системы** как реполяризация миокарда левого желудочка (ST-T нарушения) и дисфункция миокарда. Система основана на анализе вариабельности сердечного ритма. Запись ВРС осуществляли у пятидесяти новорожденных детей. Ввиду ограниченного количества обучающих образов была использована разработанная технология размножения образов с помощью метода потенциальных функций. При использовании этого метода были сгенерированы новые искусственные образы, что позволило обучить нейронную сеть до работоспособного уровня. В сетях диагностики ST-T-нарушений и дисфункции миокарда удалось добиться распознаваемости соответственно 91% и 82%. По мере эксплуатации нейросетевой системы производится дообучение.

Создан программный нейросетевой комплекс, оценивающий **вероятности развития групп заболеваний новорожденных**, а также формирующий прогноз об исходе заболеваний. Нейронная сеть, на основе извлеченной из базы данных информации, определяет вероятности возникновения таких заболеваний как ретинопатия, церебральная лейкомаляция, гидроцефалия, бронхолегочная дисплазия, некротизирующий энтероколит, кровоизлияния. Прогноз об исходе этих заболеваний включает возможность выживания, частичного или полного выздоровления. Система принимает решение на основе анализа 50 параметров из истории пациента, его мамы и социально-бытовых условий семьи. Среди параметров, подающихся на вход нейронной сети, выделены три блока:

1 блок. Здоровье матери. Здесь вводятся данные, характеризующие наличие у матери новорожденного таких заболеваний как: артериальная гипертензия, сахарный диабет, ожирение, анемия, виды принимаемых лекарств, осложнения при беременности и другие (всего 30 показателей).

2 блок. Здоровье ребенка. На основе оценки внутриутробного развития, а также в результате послеродового осмотра могут учитываться следующие заболевания ребенка: пневмония, церебральная ишемия, анемия, врожденные пороки развития и другие (всего 15 показателей)

3 блок. Социально-бытовые условия семьи. (5 показателей)

При создании системы возникла проблема невозможности обучения нейронной сети, вследствие избыточности поступающей информации. Для решения проблемы применена технология выделения важных компонент

информации с помощью нейросетевого сжатия данных. При её использовании на достаточном числе итераций точность заключений составляла от 97 до 99%.

Артериальная гипертензия у беременных является одним из наиболее распространенных и опасных состояний. Особенно ухудшает перинатальные исходы присоединение преэклампсии (ПЭ) - частота неблагоприятного исхода при этом осложнении достигает 22 %. Прогнозирование и профилактика ПЭ затруднена в связи с тем, что данное заболевание может развиваться практически у каждой беременной, но вероятность реализации риска осложнения связана с сочетанием ряда факторов. Разработана программная нейросетевая система «Neuro_Chronic» для определения **вероятности присоединения преэклампсии (ПЭ)** у беременных женщин с хронической артериальной гипертензией. Данные для обучения были получены в результате анализа течения беременности и исходов родов у 548 пациенток с существовавшей ранее артериальной гипертензией - 318 с хронической артериальной гипертензией (ХАГ) и 230 с преэклампсией на фоне ХАГ. Система включает два модуля. В первом производится обучение программной модели нейронной сети на заданном множестве образов. Во втором модуле после заполнения полей для ввода параметров, полученных при сборе анамнеза и обследовании, выдается оценка развития ПЭ во время беременности у данной пациентки в виде вероятностной шкалы. Обучение системы проводилось разработанным автором гибридным методом глобальной оптимизации с подстройкой порогов нейронов согласно схеме Головки. При этом удалось достигнуть качества работы сети, составляющего более 90% правильных прогнозов. Использование данной системы повышает точность выявления у беременных с ХАГ предлагаемых предикторов развития ПЭ, что позволяет на амбулаторном этапе определить вероятность развития осложнения и провести профилактические мероприятия пациентам с высокой степенью риска.

Созданные системы внедрены и используются в отделах неонатологии и клинической неврологии, акушерства и гинекологии НИИ Материнства и детства им. В.Н. Городкова г. Иваново.

Разработана нейросетевая **система непрерывного микробиологического контроля жидкости**. Она позволяет автоматизировать и повысить качество исследования жидких сред на наличие опасных микроорганизмов. Непрерывный микробиологический контроль водной среды заключается в регулярном исследовании проб воды на наличие различных видов микроорганизмов. С целью повышения эффективности этого процесса и его автоматизации собрана установка, состоящая из микроскопа, видеокамеры, компьютера с нейросетевым математическим обеспечением и устройства для подачи воды, экологическое состояние которой оценивается. Анализ изображения при

помощи нейронной сети заключается в распознавании микробиологических объектов и подсчете их количества. Так, определяя концентрацию опасных микроорганизмов, формируется заключение о состоянии контролируемой среды. Обучение нейронной сети проводится предварительно на основании заранее подготовленных образов. При создании предлагаемой нейросетевой системы были решены задачи повышения четкости изображений, поступающих через микроскоп и видеокамеру, а также выделение границ объектов и определение их координат на изображении. Для повышения четкости изображений разработан программный метод, в котором подбирается такое изображение, которое при диффузии яркости его пикселей (так называемом размывании) даст картину близкую к исходному нечеткому изображению. Бинаризация изображения, подаваемого на вход сети, производилась с выделением цветового спектра, соответствующего палочке Коха. Численные эксперименты с компьютерной программой, моделирующей работу такого устройства, показали, что нейронная сеть успешно распознаёт присутствие палочки Коха на основании фотоснимка.

Разработана нейросетевая система **прогноза лесной пожарной опасности** с учетом влажности лесных горючих материалов, человеческого фактора и грозовой активности. Существующая в России методика основана на критерии Нестерова и разделении территории лесов на пять уровней пожарной опасности. При этом в ней не учитываются человеческий фактор и грозовая активность, которые являются ведущими среди причин возникновения лесных пожаров. Предложено усовершенствовать данную методику оценки средствами адаптивных нейросетевых технологий. В созданной системе выделены три блока анализируемой информации.

1. Блок влажности лесного горючего материала и влажности почвы. Рассчитывает опасность на основе влагосодержания почвы, осредненной влажности сухостоя и горимости леса по Нестерову.

2. Блок человеческого фактора и грозовой активности. Учитывает близость населенных пунктов, автомобильных дорог, присутствие объектов повышенной опасности, грозовую активность.

3. База данных о категориях природной пожарной опасности по всей области. Участки леса в зависимости от состава растительности, топографии территории и ее состояния делятся на пять категорий пожароопасности.

Система является адаптивной, что позволяет накапливать полезную информацию и, по мере работы, улучшать показатели. Для получения информации, необходимой для функционирования системы было разработано и апробировано устройство под названием «Электронный лесник» (рис.5.1).

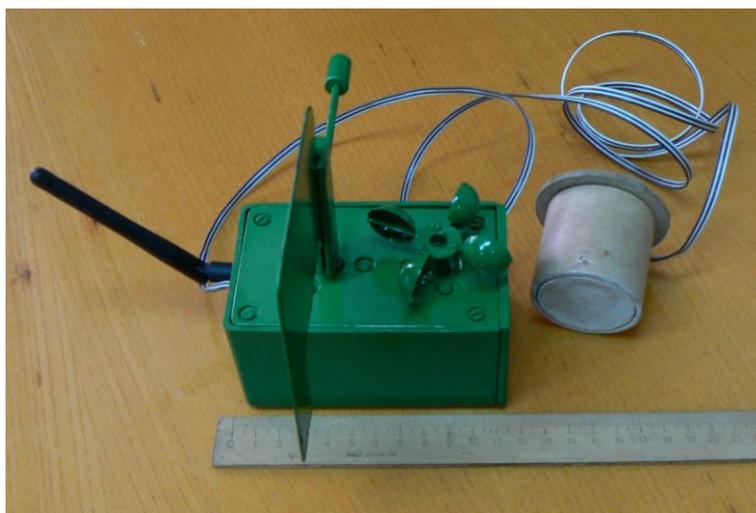


Рис.5.1 – «Электронный лесник»

Данное устройство измеряет и по радиоканалу сообщает в центр мониторинга данные о лесной пожарной опасности в районе установки. Передаваемые данные включают скорость и направление ветра, влажность лесного горючего материала, влажность почвы, температуру воздуха, количество ударов молнии в непосредственной близости от устройства за фиксированный отрезок времени.

Созданные научно-технические решения позволяют повысить оперативность реагирования центра по предотвращению лесных пожаров.

ДОСТИГНУТЫЕ РЕЗУЛЬТАТЫ

1. Для решения проблемы моделирования механики сплошной среды со сложной картиной течений и разными моделями турбулентности создана технология нейросетевой интерполяции турбулентной вязкости. Она позволяет определить значение параметров среды в произвольной точке пространства и объединяет достоинства сеточных и аналитических приближений.

2. Для создания технологии нейросетевой интерполяции была модифицирована теория термодинамического формализма и на её основе развиты концепции построения архитектуры нейронной сети:

2.1 Предложен метод конструирования нейронной сети с включением заранее обученных фрагментов, полученных при решении родственных задач. Метод позволяет построить такую архитектуру сети на основе априорной информации, которая является оптимальной для решения данной задачи.

2.2 Предложен алгоритм самоорганизации для формирования структуры нейронной сети в процессе обучения. Он предусматривает регулирование количества и размера ассоциативных слоев и автонастройку параметров сети, включая пороги срабатывания нейронов согласно схеме Головки.

3. Построена технология гибридного математического моделирования, объединяющая дифференциальные модели и нейросетевой подход. Способ применялся при моделировании паводковой ситуации совместно с предложенным методом установления неизвестных начальных условий процесса.

4. Для повышения качества медицинской диагностики заболеваний, выявление которых связано с необходимостью создания интеллектуальных средств анализа данных, разработаны нейросетевые программные комплексы.

4.1 Создана и апробирована нейросетевая система диагностики постгипоксических нарушений сердца новорожденных по направлениям дисфункция миокарда и ST-T нарушения. Система работает на основе анализа вариабельности ритма сердца. При её разработке была решена проблема нехватки обучающей информации. Для этого разработан метод расширения обучающей выборки с помощью потенциальных функций. Его использование позволило обучить нейросетевую систему до уровня соответственно 82 и 91 % точных заключений.

4.2 Создан и внедрен нейросетевой комплекс диагностики и прогнозирования развития групп заболеваний новорожденных. В процессе разработки была решена проблема выделения наиболее весомых параметров входной информации. Для этого развита технология сжатия данных нейросетевой воронкой по типу автоэнкодера, которая обладает преимуществом по сравнению с существующим методом главных компонент. Предложенный метод сжатия данных позволил обучить систему прогнозирования развития групп заболеваний новорожденных неонатального периода до уровня более 97 % правильных заключений.

4.3 Создана и внедрена нейросетевая система оценки присоединения преэклампсии на фоне хронической артериальной гипертензии у беременных женщин. В ходе создания решена проблема низкой точности работы системы вследствие невозможности отыскания глобального минимума целевой функции ошибки обучения. Проблема решена с помощью предложенного автором гибридного алгоритма глобальной оптимизации.

5. Разработан и усовершенствован гибридный алгоритм глобальной оптимизации. Он подключает при поиске решения различные алгоритмы: стохастический метод с выбором начальных размеров окрестности, инерционный стохастический поиск, градиентный поиск с памятью и генетический поиск с использованием каст особей. Алгоритм позволяет преодолевать локальные экстремумы при обучении нейронных сетей с многоэкстремальной функцией ошибки. Его применение позволило обучить систему диагностики преэклампсии до точности более 90% правильных заключений.

6. Создана нейросетевая система для непрерывного микробиологического контроля за состоянием водной среды. Аппаратная часть состоит из микроскопа, видеокамеры, компьютера с нейросетевым математическим обеспечением и устройства для забора воды. При создании системы разработан метод программного восстановления чёткости изображения, а также предложены алгоритмы, позволяющие выделять и идентифицировать объекты на изображении.

7. Существующая в России методика оценки лесной пожарной опасности несовершенна, поскольку основана на погодном факторе Нестерова. Для её совершенствования создана программно-аппаратная нейросетевая система оценки лесной пожарной опасности с учетом влажности воздуха и леса, человеческого фактора и грозовой активности. В рамках данной системы создано устройство под названием электронный лесник. Оно передает данные из лесной территории о погодных условиях, влажности почвы и лесного топлива в центр управления по предотвращению лесных пожаров.

8. Ряд новых математических технологий, обладающих вычислительной сложностью, реализован на многопроцессорных вычислительных устройствах с получением ускорения.

Основные положения диссертации изложены в публикациях:

Издания, включенные в перечень ВАК

1. Ясинский И.Ф., Применение нейросетевой технологии для обнаружения дефектов на движущемся полотне// Харахнин К.А., Ясинский И.Ф. Известия вузов. Технология текстильной промышленности.- 2003.-№4.- С.98-101
2. Ясинский И.Ф., Об алгоритме настройки нейронных сетей с помощью инерционной минимизации// Харахнин К.А., Сидоров С.Г., Ясинский Ф.Н., Ясинский И.Ф., Вестник ИГТА.-2003.-№3.-С.145-147
3. Ясинский И.Ф., Усовершенствованный случайный поиск//Ясинский И.Ф., Ясинский Ф.Н., Вестник ИГЭУ.-2004.-№3.-С.47-48.
4. Ясинский И.Ф., О нейросетевом контроле качества при поточном производстве, Известия вузов. Технология текстильной промышленности.- 2005.-№2.-С.113-115
5. Ясинский И.Ф., Нейросетевой контроль качества в текстильном производстве, Идентификация систем и задачи управления: сборник материалов V Междунар. конф. (SICPRO'06).-М.: ИПУ РАН, 2006
6. Ясинский И.Ф. О двух способах настройки нейронных сетей// Вестник ИГТА.-2006.-№4.-С.116-120.
7. Ясинский И.Ф. О перспективе использования многопроцессорной вычислительной техники для контроля качества при поточном

- производстве// Параллельные вычисления и задачи управления: сборник материалов III Межд. конф. (РАСО'06).-Москва: ИПУ РАН, 2006.
8. Ясинский И.Ф., Применение многопроцессорной вычислительной техники при контроле качества в поточном производстве//Ясинский Ф.Н., Ясинский И.Ф. Теоретические основы, конструирование численных алгоритмов и решение задач математической физики с приложением к многопроцессорным системам: сборник материалов 16-й Всероссийской конф.- Дюрсо: Институт прикладной математики им. М.В.Келдыша Российской Академии Наук (Москва) и МГУ им. М.В.Ломоносова (Москва), 2006.- С.61-62
 9. Ясинский И.Ф., О вычислении наноструктур волокнистых материалов//Клочков С.А., Соцкий В.В., Ясинский Ф.Н., Ясинский И.Ф., Вестник ИГЭУ.-2006.-№3.-С.79-81
 - 10.Ясинский И.Ф. Синтетический алгоритм оптимизации и настройки нейронных сетей // Известия вузов. Технология текстильной промышленности.-2007.-№3.-С.119-123
 - 11.Ясинский И.Ф. Генетический алгоритм поиска глобального минимума // Ясинский И.Ф., Сидоров С.Г., Ясинский Ф.Н. Вестник ИГЭУ.-2007.-№4.-С.24-26
 - 12.Ясинский И.Ф., Опыт прогнозирования успеваемости студентов при помощи нейросетевой технологии// Ясинский И.Ф., Семенова М.Б., Вестник ИГЭУ.-2007.-№4.-С.29-31.
 - 13.Ясинский И.Ф. Применение нейронных сетей для прогнозирования течения постгипоксических нарушений сердечно-сосудистой системы у новорожденных детей // Чаша Т.В., Харламова Н.В., Климова О.И., Ясинский И.Ф., Ясинский Ф.Н. Вестник ИГЭУ.-2009.-№4.-С.57-59
 - 14.Ясинский И.Ф. Обобщенная задача Коши и пути регуляризации некорректных задач // Ясинский И.Ф., Ясинский Ф.Н. Вестник ИГЭУ.-2010.-№3.-С.71-72
 - 15.Ясинский И.Ф. К вопросу об усилении и численной реализации полевой модели развития пожара// Потемкина О.В., Сидоров С.Г., Ясинский И.Ф., Ясинский Ф.Н. Вестник ИГЭУ.-2010.-№4.-С.
 - 16.Ясинский И.Ф. Разработка математической модели оценки лесной пожарной опасности на базе нейросетевого алгоритма с учетом данных о влажности лесных горючих материалов, человеческого фактора и грозовой активности// Ясинский И.Ф., Потемкина О.В., Ясинский Ф.Н. Вестник ИГЭУ.-2011.-№ 5.-С.63-66
 - 17.Ясинский И.Ф. Использование метода потенциальных функций для увеличения обучающей последовательности в нейросетевых системах// Вестник ИГЭУ.-2012.-№ 1.-С.42-44
 - 18.Yasinskiy I.F. Prediction and modeling of the forest fires using neural networks and supercomputers // Maliy I.A., Potemkina O.V., Yasinskiy I.F., Yasinskiy F.N., Sidorov S.G., Mochalov A.S., Netkachev V.V., Chernysheva L.P. Third

International Conference on Modelling, Monitoring and Management of Forest Fires 2012 – New Forest: Wessex Institute of Technology, 2012.-С.51-63.

19. Ясинский И.Ф. Термодинамический формализм для исследования и конструирования алгоритмов и нейронных сетей// Ясинский Ф.Н., Ясинский И.Ф. Вестник ИГЭУ.-2012.-№ 5.-С.51-54
20. Ясинский И.Ф. О совершенствовании процесса обучения нейронной сети при помощи заранее обученных фрагментов// Вестник ИГЭУ.-2012.-№ 5.-С.44-47
21. Ясинский И.Ф., Моделирование гидродинамической задачи при помощи комбинированной нейросетевой и динамической модели// Ясинский Ф.Н., Ясинский И.Ф. Вестник ИГЭУ.-2013.-№ 1.-С.77-79
22. Ясинский И.Ф., Метод самоорганизации нейронной сети для прогнозирования процессов со штрафом за сложность и произвольной структурой// Вестник ИГЭУ.-2013.-№ 3.-С.61-63
23. Ясинский И.Ф., Моделирование процессов разлива нефтепродуктов по водной поверхности с использованием суперкомпьютеров с графическими ускорителями// Ясинский Ф.Н., Сидоров С.Г., Малый И.А., Потемкина О.В., Ясинский И.Ф., Мочалов А.С., Неткачев В.В., Вестник ИГЭУ.-2013.-№ 6.-С.90-94.
24. Ясинский И.Ф. О применении нейросетевой технологии в газодинамических задачах// Ясинский И.Ф., Ясинский Ф.Н. Известия высших учебных заведений. Технология текстильной промышленности.-2015.-№2.-С.145-149
25. Ясинский И.Ф., Об ускорении вычислений при помощи быстрой оценки близости частиц в методе молекулярной динамики// Харитонов А.А., Ясинский И.Ф., Вестник ИГЭУ.-2017.-№ 4.-С.50-55
26. Panova I.A., Rokotyanskaya E.A., Yasinskiy I.F., Malyshkina A.I., Nazarov S.B., Pareyshvili V.V., Bogatova I.K. The neural network technology application for prediction of preeclampsia in pregnant women with chronic arterial hypertension. *Sovremennye tehnologii v medicine* 2018; 10(4): 151–158, <https://doi.org/10.17691/stm2018.10.4.18>
27. Ясинский И.Ф., Методы ускорения расчетов и повышения устойчивости полевой модели гидродинамических турбулентных процессов на CUDA // Гудухина А.А., Ясинский И.Ф. Вестник ИГЭУ.-2018.-№ 6.-С.72-80.

Публикации в других журналах и сборниках докладов конференций

28. Ясинский И.Ф., О методике исследования рентгеновских дифрактограмм волокнистых материалов с использованием нейротехнологий и многопроцессорной вычислительной техники// Изгородин А.К., Сидоров С.Г., Ясинский Ф.Н., Ясинский И.Ф., Физика волокнистых материалов: сборник материалов VI Междунар. науч.-практ. семинара.-Иваново: ИГТА, 2003.-С.20-24

29. Ясинский И.Ф., Обнаружение дефектов на движущемся полотне при помощи нейросетевой технологии//Харахнин К.А., Ясинский И.Ф., Молодые ученые – развитию текстильной и легкой промышленности: сборник материалов науч.-техн. конф. (Поиск-2004)-Иваново: ИГТА, 2004.- С.82
30. Ясинский И.Ф., Идентификация особенностей надмолекулярной структуры с помощью нейросетевой технологии и многопроцессорной вычислительной техники// Изгородин А.К., Коноплев Ю.В., Сидоров С.Г., Ясинский И.Ф., Ясинский И.Ф., Физика волокнистых материалов: сборник материалов VII Междунар. науч.-практ. семинара.-Иваново: ИГТА, 2004.- С.37-40
31. Ясинский И.Ф., Применение метода случайного поиска для настройки нейронных сетей// Ясинский И.Ф., Калинин Е.Н., Молодые ученые – развитию текстильной и легкой промышленности: сборник материалов науч.-техн. конф. (Поиск-2005).Ч.2.-Иваново: ИГТА, 2005.-С.97
32. Ясинский И.Ф., Процесс мышления и искусственный интеллект// Ясинский И.Ф., Шишкин С.А., Молодые ученые - развитию текстильной и легкой промышленности: сборник материалов науч.-техн. конф. (Поиск-2005).Ч.1.- Иваново: ИГТА, 2005.-С.25-26
33. Ясинский И.Ф., Оптическое устройство для нейросетевого распознавания дефектов на движущемся полотне// Ясинский И.Ф., Калинин Е.Н., Студенты и молодые ученые КГТУ-производству: сборник материалов 57 конф.-Кострома: КГТУ, 2005.-С.125-126
34. Ясинский И.Ф., Об обучении нейронной сети распознаванию дефектов на движущемся тканевом полотне// Ясинский И.Ф., Калинин Е.Н., Дни науки-2005: сборник материалов науч.-практ. конф.-С.-Петербург: СПГУТД, 2005.-С.224-225
35. Ясинский И.Ф., Нейросетевой контроль технологических и природных процессов//Калинин Е.Н., Харахнин К.А., Ясинский И.Ф. Экологические проблемы Ивановской области: сборник материалов межвуз. науч.-практ. конф.-Иваново: ИГТА, 2005 – С.66.
36. Ясинский И.Ф., Комбинированный динамический и нейросетевой прогноз паводковых ситуаций (гидрологический и экологический аспекты)// Сидоров С.Г., Ясинский И.Ф. Экологические проблемы Ивановской области: сборник материалов межвуз. науч.-практ. конф.-Иваново: ИГТА, 2005 – С.66-67.
37. Yasinskiy I.F., The system for the fabric defects control// Kalinin E.N, Yasinskiy I.F. Forth Central European Conference 2005, fibre-grade polymers, chemical fibres and special textiles-Liberec: Technical University, 2005.-С.189-190.
38. Ясинский И.Ф., О диагностике состояния новорожденных с использованием нейросетевой технологии// Харламова Н.В., Михайлов В.М., Чаша Т.В., Ясинский И.Ф., Ясинский И.Ф., Сб. матер. республ. конф.

- «Кардиологические проблемы в акушерстве, гинекологии и перинатологии» (г. Иваново, 27-29 сент. 2006 г.), с. 145-147.
39. Ясинский И.Ф., Опыт диагностики состояния новорожденных с помощью нейросетевой технологии// Харламова Н.В., Михайлов В.М., Назаров С.Б., Ясинский Ф.Н., Ясинский И.Ф., Сб. матер. конгресса «Детская кардиология- 2006». -М., 2006. -С.145-146.
40. Ясинский И.Ф., Об объединении генетических алгоритмов и случайного поиска в задачах оптимизации и распознавания образов// Ясинский И.Ф., Калинин Е.Н. Молодые ученые – развитию текстильной и легкой промышленности: сборник материалов науч.-техн. конф. (Поиск-2006). Ч.2.- Иваново: ИГТА, 2006.-С.123-125
41. Ясинский И.Ф., Применение многопроцессорной вычислительной техники для контроля качества в текстильном производстве// Калинин Е.Н., Ясинский И.Ф., Современные наукоемкие технологии и перспективные материалы текстильной и легкой промышленности: сборник материалов Междунар.науч.-техн конф. (ПРОГРЕСС-2006). Ч.2.-Иваново:ИГТА, 2006.- С.317
42. Ясинский И.Ф. Распараллеливание нейросетей// Ясинский И.Ф., Сидоров С.Г. Применение многопроцессорных суперкомпьютеров в исследованиях, наукоемких технологиях и учебной работе: сборник материалов регион. науч.-техн. конф.-Иваново:ИГТА, 2007.-С.31
43. Ясинский И.Ф., О системе нейросетевой диагностики состояния новорожденных и перспективах развития такой системы // Чаша Т.В., Харламова Н.В., Ясинский И.Ф., Применение многопроцессорных суперкомпьютеров в исследованиях, наукоемких технологиях и учебной работе: сборник материалов регион. науч.-техн. конф.-Иваново:ИГТА, 2008.-С.33-34
44. Ясинский И.Ф., Генетический алгоритм глобального поиска и его параллельная реализация // Сидоров С.Г., Корочкина Е.Е., Ясинский Ф.Н., Ясинский И.Ф. Применение многопроцессорных суперкомпьютеров в исследованиях, наукоемких технологиях и учебной работе: сборник материалов регион. науч.-техн. конф.-Иваново: ИГТА, 2008.-С.35
45. Ясинский И.Ф., Генетический алгоритм глобального поиска и его параллельная реализация // Александров А.И., Пятунин А.В., Ясинский Ф.Н., Ясинский И.Ф., Сидоров С.Г. Применение многопроцессорных суперкомпьютеров в исследованиях, наукоемких технологиях и учебной работе: сборник материалов регион. науч.-техн. конф.-Иваново:ИГТА, 2008.-С.44-45.
46. Ясинский И.Ф., О восстановлении изображений с помощью метода случайного поиска // Молодые ученые – развитию текстильной и легкой промышленности: сборник материалов науч.-техн. конф. (Поиск-2009). Ч.2.- Иваново: ИГТА, 2009.-С.333-334

47. Ясинский И.Ф. Реализация генетического алгоритма поиска глобального минимума на многопроцессорном кластере// Ясинский И.Ф., Сидоров С.Г., Ясинский Ф.Н. Высокопроизводительные параллельные вычисления на кластерных системах: сборник материалов междунар. конф.-Владимир: ВГУ, 2009.-С.348-351
48. Ясинский И.Ф. Опыт применения видеокарт для увеличения вычислительной мощности компьютера. Реализация генетического алгоритма поиска глобального минимума// Архипов А.Л., Ясинский И.Ф., Сидоров С.Г., Ясинский Ф.Н. Состояние и перспективы развития электротехнологии: сборник материалов междунар. науч.-техн. конф.-Иваново: ИГЭУ, 2009.-С.80
49. Ясинский И.Ф. Оптимизация вычислений для полевой модели развития пожара// Потемкина О.В., Сидоров С.Г., Ясинский И.Ф., Ясинский Ф.Н. Пожары и аварийная безопасность: сборник материалов междунар. науч.-практ. конф. Ч.1.-Иваново: МЧС, ИИ ГПС, 2010.-С.234
50. Yasinskiy I.F. Thermodynamic formalism for the study and formation of algorithms and neural networks// Yasinskiy I.F., Yasinskiy F.N. Int. J. Comp. Meth. and Exp. Meas., Vol. 1, No. 4 (2013) 456–465
51. Ясинский И.Ф., О самоорганизации нейронной сети, материалы XVII Международной научно-технической конференции «Состояние и перспективы развития электротехнологии -2013», 29-31 мая 2013 г., Иваново. - В 4 т. Т.3. - Иваново: ИГЭУ, 2013. - С. 341-344.
52. Ясинский И.Ф., Разработка нейросетевой системы для распознавания символов// Трунов В.С., Лобанов М.А., Стахеев А.А., Ясинский И.Ф., Энергия -2014: сборник материалов 9-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2014.-С.271-273
53. Ясинский И.Ф., Построение гибридного метода прогнозирования на базе методов А.Г.Ивахненко и нейронных сетей//Туманов Д.А. Ясинский И.Ф., Энергия -2015: сборник материалов 10-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2015.-С.146-147
54. Ясинский И.Ф., Об опыте реализации нейронной сети для прогнозирования функции//Чуваков Н.И., Ясинский И.Ф., Энергия -2015: сборник материалов 10-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2015.-С.154-155
55. Построение гибридного метода прогнозирования// Туманов Д.А. Ясинский И.Ф., Энергия -2016: сборник материалов 11-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2016.-С.120-121
56. Ясинский И.Ф., Об опыте применения нейронных сетей для прогнозирования процессов //Ясинский И.Ф., Д.А. Туманов, Н.И. Чуваков, материалы VII Международной научно-технической конференции «Электроэнергетика глазами молодежи-2016», 19 – 23 сентября 2016 г., Казань. – В 3 т. Т. 3. – Казань: Казан. гос. энерг. ун-т, 2016. –С. 117-120

57. Yasinskiy I.F. On experience of modeling of hydrodynamic problem using combined neural network and dynamic model, II International Scientific Congress "Innovations in Engineering 2016". Varna, pp.20-22.
58. Ясинский И.Ф., Построение прогнозирования на базе нейросетевого метода с нейронами разных типов. Параллельная реализация// Чуваков Н.И., Ясинский И.Ф., Энергия -2017: сборник материалов 12-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2017.-С.168-169
59. Yasinskiy I.F. Simulation of fluid flow in systems with different internal configuration using parallel technologies // Gudukhina A.A., Chernysheva L.P., Koltsova E.A., Уральский научный вестник.-2017.-№6, Т.3.-С.20-22.
60. Yasinskiy I.F. On Joint Functioning of the Neural Network and Differential Model, Indian Journal of Science and Technology, Volume 10, Issue 21, June 2017, DOI: 10.17485/ijst/2017/v10i21/112558
61. Ясинский И.Ф., Моделирование динамики жидкости в системе давление-скорость методом слабой сжимаемости//Попова Ю.И., Черенков М.А., Ясинский И.Ф., Энергия -2018: сборник материалов 13-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2018.-С.96
62. Ясинский И.Ф., Совершенствование генетического алгоритма оптимизации с помощью МВС// Попова Ю.И., Шагушин А.С., Васильев Д.М., Ясинский И.Ф., Энергия - 2018: сборник материалов 13-ой Международной науч.-техн. конф. Т.5.-Иваново: ИГЭУ, 2018.-С.102.

Патенты и свидетельства

63. Пат.2296991 РФ, МПК⁷G01N 33/36. Устройство для обнаружения и регистрации дефектов на движущейся ткани, Заявитель и патентообладатель ИГТА.-№2005116839; заявл. 01.06.05; опубл. 10.04.07, Бюл.№10.-8с.:ил. Авторы: Ясинский И.Ф., Харахнин К.А.
64. Свидетельство о гос. регистрации программы для ЭВМ №2010614788. Нейросетевая программа диагностики состояния новорожденных «Neuro_kardio_control» Заявитель и правообладатель ФГУ Ивановский НИИ материнства и детства им.В.Н.Городкова.-2010613085; заявл. 01.06.10; регистр.в Реестре программ для ЭВМ 22.07.10. Авторы: Назаров С.Б., Чаша Т.В., Ясинский И.Ф., Харламова Н.В., Климова О.И.
65. Свидетельство о гос. регистрации программы для ЭВМ №2018612460. Нейросетевая система прогнозирования присоединения преэклампсии у беременных женщин с хронической артериальной гипертензией «Neuro_chronic», Заявитель и правообладатель ФГБУ Ивановский НИИ материнства и детства им.В.Н.Городкова.-2017663211; заявл. 19.12.17; регистр.в Реестре программ для ЭВМ 16.02.18. Авторы: Малышкина А.И., Панова И.А., Рокотянская Е.А., Назаров С.Б., Ясинский И.Ф.
66. Свидетельство о гос. регистрации программы для ЭВМ №2018611614. Нейросетевая программная система прогнозирования состояния новорожденных «Neuro_prognosis», Заявитель и правообладатель ФГБУ

Ивановский НИИ материнства и детства им.В.Н.Городкова, Авторы: Харламова Н.В., Ясинский И.Ф., Чаша Т.В., Назаров С.Б.

Монографии и учебные пособия

67. Ясинский И.Ф., Численные методы и параллельные вычисления для задач механики жидкости, газа и плазмы: учебное пособие// Балаев Э.Ф., Пекунов В.В., Сидоров С.Г., Чернышева Л.П., Ясинский Ф.Н., Ясинский И.Ф., Иваново: ИГЭУ, 2003.-336 с.
68. Ясинский И.Ф., Введение в нейросетевые технологии: учебное пособие, Иваново: ИГТА, 2010.-120 с.: ил.
69. Ясинский И.Ф., Математическое моделирование горения и взрыва. Метод Гира. Химическая кинетика. Течение, сопровождающееся горением// Евсеев А.В., Потемкина О.В., Сидоров С.Г., Ясинский Ф.Н., Ясинский И.Ф., Иваново: МЧС ИИ ГПС, 2011.-94 с.:ил.
70. Ясинский И.Ф., Математическое моделирование горения и взрыва: часть 2. Прогнозирование и моделирование лесных пожаров// И.А.Малый, Ф.Н.Ясинский, С.Г.Сидоров, О.В.Потемкина, А.Л.Архипов, А.В.Евсеев, А.В.Евсеева, А.С.Мочалов, В.В.Неткачев, Ясинский И.Ф., Иваново: МЧС ИИ ГПС, 2014.-189 с.:ил.