Н.Н. Куссуль, А.Ю. Шелестов,
С.В. Скакун, А.Н. Кравченко

Интеллектуальные вычисления

в задачах обработки данных наблюдения Земли




НАЦІОНАЛЬНА
АКАДЕМІЯ
НАУК
УКРАЇНИ
1918

НАЦИОНАЛЬНАЯ АКАДЕМИЯ НАУК УКРАИНЫ
НАЦИОНАЛЬНОЕ КОСМИЧЕСКОЕ АГЕНТСТВО УКРАИНЫ
ИНСТИТУТ КОСМИЧЕСКИХ ИССЛЕДОВАНИЙ
МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ УКРАИНЫ
НТУУ «КИЕВСКИЙ ПОЛИТЕХНИЧЕСКИЙ ИНСТИТУТ»

Н.Н. Куссуль, А.Ю. Шелестов,
С.В. Скакун, А.Н. Кравченко

Интеллектуальные вычисления

в задачах обработки данных наблюдения Земли

Киев
«Наукова думка»
2007

УДК 629.78

Н.Н. Куссуль, А.Ю. Шелестов, С.В. Скакун, А.Н. Кравченко
Интеллектуальные вычисления в задачах обработки данных наблюдения Земли. – Киев: Наукова думка, 2007. – 196 с.
ISBN 978-966-00-0788-8.

Монография посвящена современным задачам и методам обработки данных наблюдения Земли. Детально рассмотрено применение интеллектуальных методов и методов интеграции данных к решению ряда задач, в частности мониторинга и прогнозирования наводнений, оценки состояния растительности и биоразнообразия, получения метеорологических параметров с использованием спутниковых данных и данных моделирования, структурной и параметрической идентификации сложных моделей, прогнозирования параметров космической погоды. Все научные положения проиллюстрированы результатами компьютерного моделирования.

Для специалистов в области интеллектуальных вычислений и математического моделирования, обработки спутниковых данных

Монографія присвячена сучасним задачам та методам обробки даних спостереження Землі. Детально розглянуто застосування інтелектуальних методів і методів інтеграції даних до розв'язання низки задач, зокрема моніторингу та прогнозування паводків, оцінювання стану рослинності та біорізноманіття, одержання метеорологічних параметрів з використанням супутникових даних і даних моделювання, структурної та параметричної ідентифікації складних моделей, прогнозування параметрів космічної погоди. Усі наукові положення проілюстровано результатами комп'ютерного моделювання.

Для фахівців у галузі інтелектуальних обчислень та математичного моделювання обробки супутникових даних.

Рекомендовано к печати ученым советом Физико-технического института Национального технического университета Украины «КПИ»
(протокол № 12/2007 от 26 ноября 2007 года)

Рецензенты:

В.С. Дейнека, академик НАН Украины, зав. отделом Института кибернетики им. В.М. Глушкова НАН Украины

В.И. Скурихин, академик НАН Украины, зам. директора МНУЦ ИТиС НАН и МОН Украины

В.П. Саворский, к. ф.-м. н., зав. отделом ФИРЭ РАН

ISBN 978-966-00-0788-8

© Н.Н. Куссуль, А.Ю. Шелестов,
С.В. Скакун, А.Н. Кравченко 2007

ПРЕДИСЛОВИЕ

Устойчивое развитие информационного общества невозможно без активного использования данных наблюдений Земли из космоса для удовлетворения таких жизненно важных потребностей и нужд человечества, как охрана окружающей среды, уменьшение ущерба от природных и техногенных катастроф, управление энергетическими и водными ресурсами, улучшение качества жизни и т.д. Насущная необходимость координации проведенных наблюдений, результаты которых характеризуют состояние Земли, отмечалась на Всемирном саммите, посвященном вопросам устойчивого развития, который проходил в Иоханесбурге в 2002 году. В настоящее время системы обеспечения пользователей данными наблюдений Земли создаются во многих странах мира, а также на межгосударственном уровне. В качестве примеров международных систем подобного типа назовем Европейскую систему GMES (Global Monitoring for Environmental Security) [1], а также всемирную «систему систем» GEOSS (Global Earth Observation System of Systems) [2]. Основная задача таких систем – интегрировать информацию, научные наработки и действующие системы мониторинга различных стран для решения глобальных экологических проблем и обеспечения устойчивого развития. Масштаб поставленной задачи требует развития новых эффективных методов обработки информации, совместного использования данных из разных источников, реализации сложных моделей физических процессов и развития методов усвоения данных.

Для эффективного анализа больших массивов данных разной природы и их комплексирования необходимо применение интеллектуальных вычислений. К этой области знаний сегодня относят методы, основанные на нечеткой логике, эволюционные вычисления, нейронные сети, статистический анализ и всевозможные комбинации этих подходов. Преимущество таких методов заключается в описании моделей не в виде аналитических зависимостей, а в виде «черного ящика», настройка параметров которого осуществляется на основе знания входной информации и реакции системы. Недостающую информацию обычно получают из дополнительных источников, в качестве которых выступают модели происходящих процессов, в частности метеорологические и гидрологические. Такие методы достаточно ресурсоемкие, но при этом они допускают естественное распараллеливание. Поэтому их эффективная реализация возможна только в распределенных системах, включающих высокопроизводительные вычислительные ресурсы.

В процессе выполнения нескольких конкурсных проектов Национальной академии наук Украины и международных грантов авторами накоплен опыт применения интеллектуальных вычислений для решения задач обработки спутниковой информации, а также разработаны новые методы, повышающие эффективность решения задач спутникового мониторинга. Часть этих разработок реализована в виде сервисов украинской системы обеспечения пользователей данными наблюдения Земли, кото-

рую можно рассматривать в качестве украинского сегмента системы GEOSS. Важно отметить, что три сервиса, созданные в Институте космических исследований Национальной академии наук Украины и Национального космического агентства Украины (ИКИ НАНУ–НКАУ), зарегистрированы в пилотной архитектуре GEOSS [3] в 2007 году среди первых 15 продуктов ведущих космических агентств.

В монографии обобщен опыт авторов, связанный с применением интеллектуальных вычислений для решения задач обработки спутниковых данных и экологического мониторинга. Книга состоит из двух частей. Первая часть посвящена решению прикладных задач, а вторая – вспомогательных. Диапазон рассматриваемых прикладных задач охватывает мониторинг и прогнозирование состояния почв и растительности, паводков, параметров космической погоды и т.п. В качестве вспомогательных задач рассматриваются идентификация структуры и параметров сложных моделей и фильтрация шума на изображениях. Все эти, на первый взгляд, совершенно разные задачи объединяет необходимость обработки спутниковых данных и общий подход к решению, основанный на интеллектуальных вычислениях.

Для каждой рассматриваемой задачи описываются традиционные методы их решения, а также предложенные специалистами ИКИ НАНУ–НКАУ модификации или новые подходы к решению этих задач. Кроме того, указываются используемые источники данных, приводятся результаты численного моделирования или экспериментальной проверки эффективности предлагаемых подходов, а при необходимости – особенности программной реализации этих методов. Большинство рассматриваемых задач либо уже реализованы в виде сервисов для Grid-системы обработки спутниковых данных, либо их реализация планируется в ближайшем будущем.

Прежде всего, изучается задача мониторинга состояния земной поверхности, для решения которой требуется выполнение целой цепочки независимых исследований, предполагающих комплексное использование разнородных данных и применение разных математических методов их обработки. Решение поставленной задачи включает устранение искажений на снимках, анализ дистанционных данных из различных источников, применение интеллектуальных методов для обработки больших объемов данных и решения слабоформализованных задач. Комплексное применение указанных методов направлено на получение наиболее полных сведений о состоянии земной поверхности. Учитывая высокую ресурсоемкость решения большинства подзадач, их целесообразно решать с использованием высокопроизводительной техники и параллельных вычислений.

Анализируются также отдельные задачи, которые имеют самостоятельное значение и в то же время могут рассматриваться как составляющие проблемы комплексного мониторинга на основе разнородных данных.

В первую очередь рассматривается задача картографирования затопленных территорий на основе радиолокационных данных. Для сегментации и классификации спутниковых изображений используются нейронные сети – самоорганизующиеся карты Кохонена. Предложенный подход верифицирован на данных спутника ERS-2 во время наводнения на р. Тиса в марте 2001 года. Получаемая таким образом информация может дополнять данные, используемые при решении задач мониторинга в интересах сельского хозяйства.

Затем исследуется задача прогнозирования паводков на основе построения каскада метеорологических и гидрологических моделей. Существенное преимущество усовершенствованного подхода состоит в увеличении сроков прогнозирования паводков до нескольких дней. Для настройки параметров гидрологических моделей применяется один из методов интеллектуального поиска – генетический алгоритм. Более подробно этот подход рассматривается во второй части книги. Результаты валидации моделей свидетельствуют об эффективности предложенного подхода к настройке моделей.

В контексте создания украинского сегмента GEOSS важная роль принадлежит задаче оценивания биоразнообразия Причерноморского региона Украины, реализованная в виде сервиса, совместно разработанного специалистами ИКИ НАНУ–НКАУ и Научного центра аэрокосмических исследований Земли НАНУ в рамках инновационного проекта НАНУ. Методика оценивания видового разнообразия на основе экосистемного подхода с использованием космических снимков разработана специалистами Научного центра аэрокосмических исследований Земли НАНУ. Специалисты ИКИ НАНУ–НКАУ модифицировали эту методику, применив нейросетевые методы для классификации типов земной поверхности, а также реализовали метод оценки биоразнообразия в виде сервиса в пилотной архитектуре GEOSS.

Далее анализируются возможности нейросетевой и статистической классификации данных дистанционного зондирования земли. Основное внимание уделяется следующим парадигмам: метод максимального правдоподобия; многослойный персептрон (Multilayer Perceptron — MLP), обучаемый различными методами первого и второго порядка; нейронная сеть на основе радиальных базисных функций, нейронная сеть типа ARTMAP, основанная на теории адаптивного резонанса.

Одна из наиболее проработанных и доведенных до практической реализации задач – построение карты облачности на основе спутниковых данных космического аппарата (КА) Meteosat с использованием алгоритма марковской сегментации. Для этой задачи характерны такие важные особенности, как высокая частота обновления данных и большая вычислительная сложность применяемого алгоритма сегментации, которые определяют необходимость параллельной реализации алгоритма, предназначенной для выполнения в среде MPI кластерной вычислительной системы. В настоящее время сервис построения карты облачности по данным спутника Meteosat второго поколения (MSG) работает в операционном режиме.

Важная составная часть мониторинга метеорологических процессов – анализ динамики развития облачности. Ключевым параметром облачности, необходимым для анализа ее развития, служит пространственное распределение скорости движения облаков, для восстановления которого авторами модифицированы методы вычисления оптических потоков по серии последовательных изображений, широко используемые при решении задач компьютерного зрения. Для учета специфики спутниковых данных, а именно существования больших смещений облаков на последовательных снимках, предложена модификация двух классических дифференциальных методов: Лукаса–Кенеда и Хорна–Шанка.

Следующей рассматривается задача прогнозирования параметров космической погоды по данным спутника ACE. Решение этой задачи построено на интеллектуаль-

ном и статистическом анализе данных другой природы: измерений интенсивности энергетических частиц в солнечном ветре, представленных в виде числовых рядов. Данная задача тоже относится к классу задач мониторинга и реализована в виде сервиса распределенной системы.

Во второй части рассматриваются служебные (сервисные или вспомогательные) задачи, которые сами по себе не имеют практического значения, но обеспечивают необходимое качество решения рассмотренных в первой части прикладных задач. К сервисным задачам в этом контексте относятся задачи предварительной обработки спутниковых данных и задачи настройки параметров и адаптации моделей. Поскольку оба класса задач относятся к ресурсоемким, для их эффективной реализации требуется распараллеливание.

В заключении анализируются основные подходы, используемые для решения поставленных задач. Кроме того, оценивается ресурсоемкость исследуемых методов и предлагаются варианты повышения эффективности алгоритмов реализации.

Описанные в монографии результаты получены коллективом научных сотрудников отдела космических информационных технологий и систем ИКИ НАНУ–НКАУ. Результаты, опубликованные ранее в периодических изданиях, приводятся со ссылкой на первоисточник. Авторский вклад в создание монографии распределяется следующим образом: общая концепция книги разработана Куссуль Н.Н. и Шелестовым А.Ю.; введение и заключение написаны Куссуль Н.Н., главы 1, 9, 10, 11 – Шелестовом А.Ю., главы 2, 4 – Скакуном С.В.; главы 3 и 6 – Кравченко А.Н., главы 5, 7, 8 – авторами совместно.

Описанные в монографии результаты получены в рамках проектов INTAS-CNES-NSAU "Data Fusion Grid Infrastructure" (Ref. No 06-1000024-9154), УНТЦ–НАНУ «Разработка эффективных Grid-технологий экологического мониторинга на основе спутниковых данных» (№3872), инновационного научно-технического проекта НАНУ "Создание пилотной версии информационной системы геофизичсекого мониторинга в рамках украинского сегмента GEOSS".

Авторы выражают благодарность коллегам — сотрудникам и аспирантам отдела космических информационных технологий и систем ИКИ НАНУ–НКАУ за активное участие в научных проектах, результаты которых отражены в монографии, а также за предоставление экспериментальных данных и помощь в технической обработке материала. Они также признательны рецензентам за внимательное отношение к работе и высказанные замечания и пожелания.

Часть I

ИНТЕЛЛЕКТУАЛЬНЫЕ ВЫЧИСЛЕНИЯ В ПРИКЛАДНЫХ ЗАДАЧАХ СПУТНИКОВОГО МОНИТОРИНГА

– комплексирование данных и моделей при решении задач дистанционного мониторинга и прогнозирования;

– мониторинг затоплений на основе радиолокационных спутниковых данных;

– создание каскадов гидрометеорологических моделей для прогнозирования паводков;

– нейросетевая классификация подстилающей поверхности по спутниковым данным;

– оценивание состояния и видового разнообразия растительности;

– анализ динамики облачности по спутниковым снимкам на основе метода оптичемких потоков;

– построение карты облачности по данным Meteosat;

– прогнозирование межпланетных ударных волн в солнечном ветре.

Глава 1

КОМПЛЕКСИРОВАНИЕ ДАННЫХ И МОДЕЛЕЙ ПРИ РЕШЕНИИ ЗАДАЧ ДИСТАНЦИОННОГО МОНИТОРИНГА И ПРОГНОЗИРОВАНИЯ

Современный уровень развития средств наблюдения, вычислительной техники и методов обработки данных позволяет ставить и успешно решать сложные задачи экологического мониторинга и прогнозирования на основе комплексного использования данных космических, авиационных и наземных измерений, применения моделей и высокопроизводительных вычислений. Синергетический эффект такого подхода положен в основу идеологии построения системы GEOSS. В данной главе с точки зрения комплексирования данных и моделей в качестве примера проанализирована задача оценки и прогнозирования состояния земной поверхности.

1.1. Комплексирование данных в задаче оценки состояния почв

В качестве примера рассмотрим задачу оценки состояния почв. Вопросам оценки состояния земной поверхности уделяется много внимания учеными и практиками всего мира. Оценка приобретает характер мониторинга при наличии системы наблюдений во времени, обобщения результатов и прогноза состояния почв и растительности в будущем. Дистанционное зондирование Земли (ДЗЗ) позволяет получать количественную оценку прогнозируемого урожая различных сельхозкультур, отмечать особенности сезонной вегетации, ее нарушения, что дает возможность предотвратить экологические катастрофы и биотерроризм. Решение подобных задач позволит обеспечить оптимальное использование природных ресурсов как в отдельных регионах, так и на международном уровне. Оценка и прогнозирование состояния земной поверхности играют важную роль в решении более серьезной проблемы, которая заключается в управлении экосистемами и их сохранении. Эти данные формируют информацию, необходимую для рационально-

го природопользования и, на более высоком уровне, для принятия решений, обеспечивающих устойчивое развитие общества.

На сегодняшний день не существует такого источника данных, чтобы информации, получаемой только из него, было достаточно для решения поставленной задачи, особенно если речь идет о мониторинге происходящих процессов. Наземные измерения нерегулярны (как в пространстве, так и во времени) и, кроме того, имеют высокую стоимость. Регулярность измерений и равномерное покрытие интересующих исследователя территорий можно обеспечить с помощью спутникового мониторинга, но и в этом случае возникает ряд проблем, связанных с использованием измерений в конкретных диапазонах. Так, оптические данные зачастую искажаются наличием на снимках облачности или дымки, а данные приборов сверхвысокочастотного диапазона отличаются низким пространственным разрешением и малой длиной волны, недостаточной для мониторинга почв, покрытых растительностью. Нельзя говорить и о единой модели, описывающей динамику состояния земного покрова с учетом всех факторов.

Поэтому для регулярного мониторинга земного покрова необходим комплексный анализ всех имеющихся данных, который позволяет составить наиболее полную картину о состоянии растительности и подстилающих грунтов. Для восполнения недостающей спутниковой информации необходимо использовать данные метеорологического и гидрологического моделирования, а для заверки получаемых результатов и валидации моделей – данные наземных измерений. С этой целью в [4] предложен подход, который заключается в совместном использовании аэрокосмических данных в различных спектральных диапазонах, полученных активными и пассивными методами. Структурная схема задачи оценки состояния почв представлена на рис. 1.1. Как видно из этого рисунка, задача оценки состояния земной поверхности разбивается на несколько подзадач, включающих предварительную обработку (фильтрацию) космических снимков, оценку параметров почвы (влажность, засоленность и т.д.), состояния растительности (химического состава, степени поврежденности), а также мониторинг изменений и прогнозирование исследуемых параметров.

Далее эти задачи рассматриваются более подробно. В частности, проводится анализ данных, необходимых для оценки и прогнозирования состояния почв и растительности, обсуждаются методы обработки этих данных, а также модели, применяемые для восполнения недостающей информации и прогнозирования интересующих параметров.



Рис. 1.1. Комплексирование данных и моделей при решении задачи оценки состояния поверхности Земли

1.2. Этапы и методы комплексной оценки и прогнозирования состояния земной поверхности

1.2.1. Анализ данных, необходимых для оценки и прогнозирования состояния почв и растительности

Наиболее перспективный диапазон с точки зрения задач изучения грунтов – сверхвысокочастотный (СВЧ-диапазон), слабо подверженный атмосферным искажениям. Он предоставляет наиболее полную информацию о почве, в том числе о влажности поверхности, а при соответствующих длинах волн – и об уровне залегания грунтовых вод. Однако снимки, сделанные в этом диапазоне с помощью существующего спутникового оборудования, отличаются либо очень низким пространственным разрешением (обычно 25–50 км на пиксель), либо высокой стоимостью. Кроме того, следует отметить, что на сегодняшний день не существует ни одного геостационарного спутника, ведущего

съемку в СВЧ-диапазоне. Таким образом, регулярное наблюдение за определенным участком поверхности Земли затруднительно и требует привлечения дополнительной информации из других источников.

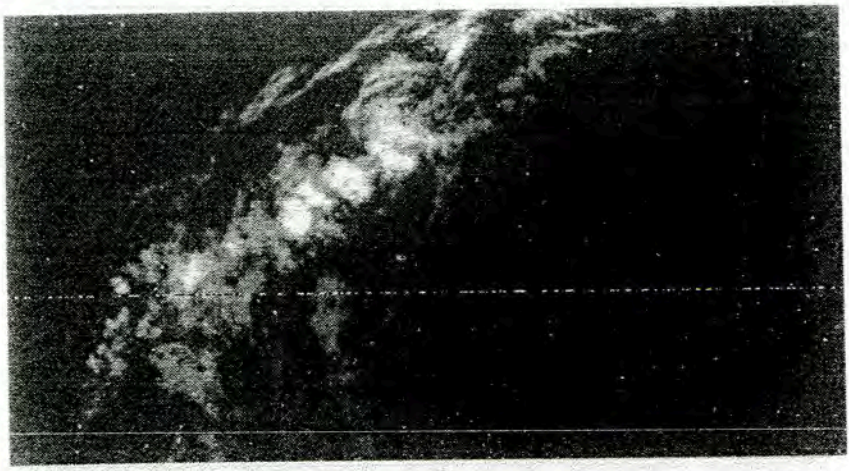
Существует еще одна особенность наблюдений в этом диапазоне. Как известно, и это подчеркивает в своей монографии [5] член-корреспондент НАН Украины Лялько В.И., наличие растительности оказывает существенное влияние на результаты дистанционного наблюдения в СВЧ-диапазоне. Иными словами, покрытая растительностью почва недоступна для приборов, ведущих съемку в диапазонах высоких частот. Поскольку данные СВЧ-диапазона можно эффективно использовать только для мониторинга открытых участков почвы, дополнительно возникает задача выделения участков, покрытых растительностью, и их классификации по степени влияния на результаты наблюдений подстилающей поверхности. Для этого в работе [5] предлагается использовать данные других диапазонов с последующей их обработкой интеллектуальными методами. Анализ и мониторинг растительного покрова целесообразно проводить на основе данных видимого и ближнего инфракрасного (ИК) диапазонов, для чего следует учитывать различие в спектральных свойствах хлорофилла в видимом и ближнем ИК диапазонах. Эта часть спектра может также предоставить некоторые вспомогательные данные для стержневой задачи – оценки состояния грунта.

Неотъемлемая составляющая решения любой задачи обработки спутниковых данных – валидация получаемых продуктов с помощью наземных измерений. Поэтому при решении прикладных задач, указанных в схеме на рис. 1.1, важнейшим источником информации служат данные наземных датчиков, метеостанций и т.п.

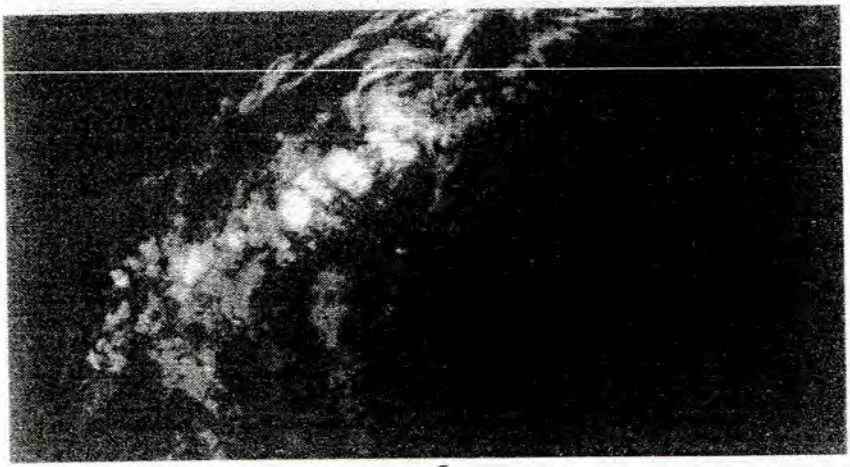
1.2.2. Фильтрация спутниковых данных

Получаемые со спутника изображения часто бывают искажены импульсным шумом. Это происходит в результате зашумления данных при передаче по каналам связи или из-за несовершенства датчиков.

Для устранения полос импульсного шума предложен новый подход, основанный на построении вероятностной модели импульсного шума общего вида и включающий эффективный алгоритм детектирования полос импульсного шума и адаптивный алгоритм восстановления изображения [6–9]. Он не только позволяет надежно выявлять полосы импульсного шума, но и, в отличие от описанных в литературе методов, обеспечивает сохранение деталей изображения после корректировки.



а



б

Рис. 1.2. Изображение, полученное со спутника Meteosat:
а – с горизонтальной полосой импульсного шума и равномерно распределенными по изображению отдельными зашумленными пикселями;
б – восстановленное изображение

Эффективность предложенного алгоритма подтверждается экспериментальными результатами, проведенными для стандартных тестовых

изображений, а также для космических снимков спутника Meteosat, искаженных реальным импульсным шумом (рис. 1.2).

Детальное описание предложенной вероятностной модели импульсного шума общего вида, разработанного подхода и его параллельной реализации приводится в главе 9. Следует отметить, что задача фильтрации возникает на этапе предварительной обработки спутниковых данных не только при решении данной конкретной задачи, но и в любых задачах обработки изображений, в том числе спутниковых снимков.

1.2.3. Методы оценки состояния почв и растительности

1.2.3.1. Построение индексов

Для оценки состояния почв и растительности применяются различные индексы, представляющие собой математические соотношения определенных характеристик отражения в этих диапазонах. Для оценки состояния растительности наибольшее распространение получил индекс NDVI (Normalized Difference Vegetation Index). Этот показатель характеризует интенсивность процессов фотосинтеза. Другой распространенный индекс – EVI (Enhanced Vegetation Index). Для оценки состояния почв применяют индекс VWI.

NDVI (нормализованный относительный индекс растительности) – это простой показатель количества фотосинтетически активной биомассы (его обычно называют вегетационным индексом), который вычисляется по формуле

$$\mathrm{NDVI} = \frac{\mathrm{NIR} - \mathrm{RED}}{\mathrm{NIR} + \mathrm{RED}},$$

где NIR – отражение в ближней инфракрасной области спектра; RED – отражение в красной области спектра.

NDVI может быть рассчитан на основе любых мультиспектральных снимков высокого, среднего или низкого разрешения, имеющих спектральные каналы в красном (0,55–0,75 мкм) и инфракрасном (0,75–1,0 мкм) диапазонах.

Для отображения индексов, в частности NDVI, используется стандартизированная шкала значений в диапазоне –1..1. Благодаря особенности отражения в (NIR–RED)-областях спектра природные объекты, не связанные с растительностью, имеют фиксированное значение NDVI (табл. 1.1).

Таблица 1.1. **Значения индексов NDVI некоторых наземных объектов**

Тип объекта	Отражение в красной области спектра	Отражение в инфракрасной области спектра	Значение NDVI
Густая растительность	0,1	0,5	0,7
Разреженная растительность	0,1	0,3	0,5
Открытая почва	0,25	0,3	0,025
Облака	0,25	0,25	0
Снег и лед	0,375	0,35	-0,05
Вода	0,02	0,01	-0,25
Искусственные материалы (бетон, асфальт)	0,3	0,1	-0,5

Карты NDVI часто используются как один из промежуточных или дополнительных слоев для более сложного анализа при оценке продуктивности лесов и земель сельскохозяйственного назначения, биоразнообразия, мониторинге влажности почв и решения других эколого-климатических задач.

Приведем пример. На рис. 1.3 представлены значения «улучшенного» вегетационного индекса EVI (Enhanced Vegetation Index), полученного на основе данных сенсора MODIS спутника Терра. Данные относятся к началу (апрель–май) (рис. 1.3, *а* и 1.3, *в*) и середине (июнь–июль) (рис. 1.3, *б* и 1.3, *г*) вегетационного периода в 2006 и 2007 гг. соответственно. Как и NDVI, индекс EVI изменяется в пределах от –1 до 1. На рис.1.3, *в* и 1.3, *г* видно развитие засухи в 2007 г. При одинаковом состоянии растительности в апреле–мае 2006 и 2007 гг. (рис. 1.3, *а* и 1.3, *в*), летом 2007 г. отчетливо видно засушливые территории на юге Украины. Результаты работы сервиса мониторинга засух для территории Украины представлены на вклейке (рис. В.1).

Однако методы, основанные на вычислении индексов, не самодостаточны, поскольку обладают рядом недостатков, а именно:

– необходимость предварительной радиометрической коррекции (калибровки) данных;

– существенная зависимость от погодных условий: результаты сильно искажаются наличием облачности и дымки;

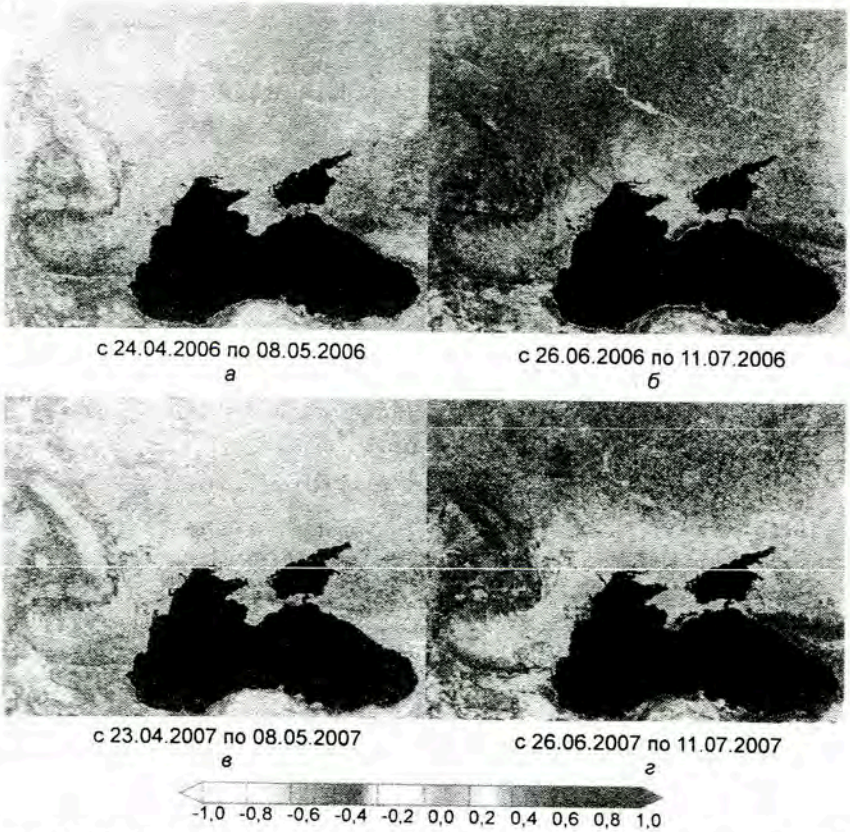


Рис. 1.3. Значения вегетационного индекса EVI для территории Украины за 2006 и 2007 годы

– необходимость для большинства задач сравнения полученных результатов с предварительно собранными данными тестовых участков (эталонов), в которых должны учитываться сезонные эколого-климатические показатели как самого снимка, так и тестовых площадок на момент сбора данных;

– применимость метода только во время сезона вегетации для исследуемого региона.

Следовательно, возникает задача использования более сложных методов анализа спутниковой информации.

1.2.3.2. Статистические методы и марковские поля

Важный аспект комплексного подхода к анализу спутниковых данных – их статистическая обработка, в частности применение методов кластеризации на основе марковских полей. С помощью аппарата случайных полей можно выполнять текстурную сегментацию изображений, что особенно актуально при обработке спутниковых снимков. Авторы успешно применяют этот подход для построения маски облачности по снимкам метеорологического спутника Meteosat. Выделение маски облачности позволяет исключить из рассмотрения те районы, для которых спутниковая информация в данный момент неинформативна, повышая таким образом точность оценки параметров почв и растительности в остальных регионах. Более подробно вопросы построения маски облачности рассмотрены в главе 7.

1.2.3.3. Интеллектуальные методы оценки состояния почв и растительности

Один из наиболее адекватных подходов к оценке состояния почв и растительности – применение интеллектуальных методов, в частности нейросетевых. Анализу применимости различных нейросетевых парадигм для решения задач обработки спутниковой информации посвящена глава 4. Кратко остановимся на использовании интеллектуальных методов для оценки состояния растительности.

Спектральные характеристики светового потока, отраженного от объектов на Земле, – удобный и высокоинформативный источник данных для дистанционных исследований. Их можно использовать для оценки состояния растительности с целью определения степени зараженности и загрязненности (например, в случае биологической атаки террористов). В работах [9, 10] показано, что параметры спектральных кривых, представляющих зависимость интенсивности отражения от длины волны, связаны с основными физиологическими показателями, характеризующими состояние растений, в частности с содержанием хлорофилла в тканях растения. Поэтому актуальной представляется задача разработки методов выявления поврежденных растений (и определения их химического состава, в том числе содержания хлорофилла) на основе спектральных кривых.

Поскольку определение химического состава (в данном случае концентрации хлорофилла) представляет собой задачу распознавания образов, для которой неизвестны статистические характеристики опре-

деляемых классов, но получены большие объемы данных наблюдений, ее целесообразно решать на основе интеллектуальных методов, в частности с использованием нейронных сетей.

Результаты экспериментов по обучению классификатора и более точному определению содержания хлорофилла с помощью интерполятора красноречиво свидетельствуют о необходимости применения модульных нейронных сетей и распараллеливания процесса распознавания (классификации). Эффективность применения модульных нейронных сетей для решения задачи выявления поврежденных растений и определения уровня хлорофилла в них подтверждается экспериментами, которые детально описываются в главе 5.

1.2.4. Методы прогнозирования состояния почв и растительности

Рассмотренные ранее задачи оценивания и распознавания представляют собой составную часть более общей и сложной задачи прогнозирования состояния почв и растительности. Для решения этой комплексной задачи применяются как традиционные прогнозные модели (например, регрессионные, или статистические), так и интеллектуальные методы (в частности, нейросетевые, или методы построения «оптических потоков»).

Применение статистических прогнозных моделей базируется на отслеживании трендов и динамических характеристик данных, собранных за несколько лет, а в идеале – за несколько десятилетий. Подобный подход используется в Институте космических исследований Российской академии наук для прогнозирования урожайности на основе спутниковых данных.

Методы прогнозирования динамики физических параметров на основе «оптических потоков» детально рассматриваются в главе 6. Этот подход заимствован из теории обработки мультимедиа-информации, где он первоначально применялся для распознавания образов на последовательности кадров видеосъемки. Мы использовали этот подход для прогнозирования динамики облачности по последовательности снимков спутника Meteosat. Нейросетевые прогнозные модели хорошо зарекомендовали себя в различных предметных областях. Они особенно эффективны при наличии больших объемов экспериментальных данных и отсутствии информации для построения аналитических зависимостей.

1.2.5. Применение моделей

Решение задач мониторинга и прогнозирования невозможно без использования данных моделирования, позволяющих восполнить недостающую спутниковую информацию. С целью получения дополнительной информации для задач экологического мониторинга применяют метеорологические и гидрологические модели. В настоящее время существует целый ряд подобных моделей, реализованных в программном обеспечении (как коммерческом, так и с открытым кодом). Однако для эффективного использования их в каждом конкретном регионе требуются адаптация и настройка моделей в соответствии с конкретными краевыми и начальными условиями. При этом актуальна задача разработки методов усвоения данных в такие модели, а также построения каскадов моделей, когда результаты работы одной модели становятся входной информацией для другой. У авторов данной монографии есть некоторый опыт адаптации и настройки метеорологических и гидрологических моделей для территории Украины, ими разработаны интеллектуальные методы адаптации моделей для любого региона. Эти методы основываются на применении генетических алгоритмов оптимизации. Более подробно вопросы каскадирования и валидации моделей рассматриваются в главе 3, а предлагаемый метод идентификации моделей на основе эволюционных вычислений – в главе 11 (вторая часть).

1.2.6. Реализация параллельных алгоритмов обработки данных

Время, затрачиваемое персональным компьютером с применением сложных методов анализа данных зачастую оказывается неприемлемо большим. Этим обусловлена необходимость реализации соответствующих алгоритмов в параллельной форме для выполнения в распределенной системе с использованием высокопроизводительной техники. Для решения этой задачи требуются специальные знания в области архитектуры параллельных вычислительных машин и методов программирования для них. Вопросам распараллеливания алгоритмов решения задач обработки спутниковых данных, в частности алгоритмов фильтрации, посвящена глава 10 (вторая часть).

1.3. Обсуждение

На примере задачи комплексного оценивания и прогнозирования состояния почв и растительности рассмотрены возникающие проблемы, обсуждены характеристики данных, необходимых для ее решения, а также методы решения подобных задач. Показано, что для эффективного решения поставленной задачи необходимо интегрировать информацию, получаемую из различных источников, в том числе данные спутниковых и наземных измерений. Для их обработки применяется широкий спектр методов, среди которых особого внимания заслуживают интеллектуальные методы обработки данных. Важный элемент при решении задач экологического мониторинга – использование моделей (в том числе метеорологических и гидрологических). С учетом слабой формализуемости задач по обработке данных и настройке моделей, а также наличия больших объемов данных наблюдений на первый план при их решении выходят интеллектуальные методы обработки информации, основанные на применении нейронных сетей, нечеткой логики, эволюционных вычислений и различных их комбинаций. Для ускорения процедуры обработки данных целесообразно использовать распределенные системы, включающие многопроцессорную технику. В частности, многие вычислительные эксперименты проводились на суперкомпьютерах семейства СКИТ, разработанных в Институте кибернетики НАНУ. Кластеры семейства СКИТ, а также многопроцессорный компьютер ИКИ НАНУ–НКАУ используются для решения некоторых из упомянутых задач в режиме мониторинга. Более подробно эти частные задачи и предлагаемые методы их решения описываются в последующих главах монографии.

Глава 2
МОНИТОРИНГ ЗАТОПЛЕНИЙ НА ОСНОВЕ РАДИОЛОКАЦИОННЫХ СПУТНИКОВЫХ ДАННЫХ

Наводнения относятся к наиболее масштабным природным стихийным бедствиям, которые приводят к гибели людей и значительному материальному ущербу [11]. В последние годы страны Центральной и Восточной Европы часто страдают от затоплений, вызванных ливневыми дождями. Украина также подвержена наводнениям, особенно в Закарпатье. Во время наводнений 2001 года, по данным Министерства чрезвычайных ситуаций Украины, 9 человек погибло, 12 000 были эвакуированы, более 1500 домов уничтожены и более 30 000 домов затоплены. Поэтому задача мониторинга и прогнозирования рисков, связанных с наводнениями, чрезвычайно актуальна в контексте развития национальных систем мониторинга, а также международных систем, в частности глобальной системы систем GEOSS, разработанной по инициативе комитета GEO [12].

Эффективный мониторинг и прогнозирование наводнений, а также управление рисками, связанными с наводнениями, невозможны без привлечения данных наблюдений Земли из космоса. Одна из важнейших задач, которые возникают при мониторинге наводнений – это задача оценки площадей затопленных территорий. Такая информация необходима при оценке ущерба, причиненного наводнениями, и может использоваться как входная информация в гидрологических моделях для моделирования и прогнозирования наводнений, а также как дополнительная – при решении задач мониторинга, проводимого в интересах сельского хозяйства.

Обычно паводковые ситуации сопровождаются значительным облачным покровом, который ограничивает возможность получения данных в оптическом диапазоне. В таких случаях более эффективно использование радиолокационных данных (в сантиметровом и дециметровом диапазонах), достоверность которых не зависит от погодных условий.

Как правило, выявление затопленных территорий на основе радиолокационных изображений включает следующие этапы.

1. Калибровка данных.
2. Орторектификация.
3. Геопривязка для совмещения с другими данными.
4. Фильтрация.
5. Тематическая обработка данных для определения затопленных территорий.
6. Тестирование и верификация результатов.

Для сегментации радиолокационных изображений целесообразно использовать нейронные сети Кохонена [13], которые представляют собой одну из реализаций интеллектуального подхода к анализу данных и позволяют автоматически выявить статистически значимые свойства входной информации. Тестирование предложенного подхода выполняется на радиолокационных данных, полученных прибором SAR со спутника ERS-2 в рамках гранта Европейского космического агентства (EKA) Category-1 "Wide Area Grid Testbed for Flood Monitoring using Spaceborne SAR and Optical Data" (№ 4181).

2.1. Описание существующих подходов

На сегодняшний день радиолокационные данные широко применяются для мониторинга наводнений [14]. Специалистами разработан ряд методов для определения затопленных территорий. Рассмотрим их более подробно.

В [15] предложено анализировать разновременные снимки одной территории, сделанные во время паводковой ситуации и без нее, а также их представление в виде композита RGB. На результирующем изображении затопленные территории отображаются определенным цветом (обычно синим). В работах [16, 17] для определения затопленных территорий на основе данных спутника RADARSAT-1 использовался метод пороговой сегментации. Причем значение порога выбиралось вручную. Авторы утверждают, что точность предложенного подхода для открытой местности достигает 90 %, а для гористой – 85 %.

В работе [18] радиолокационные данные со спутника ERS-2, наряду с данными, полученными в оптическом диапазоне (Landsat TM, IRS WIFS/LISS, NOAA AVHRR), использовались для мониторинга наводнений 2001 года в Венгрии. Затопленные территории определялись с помощью коэффициента изменения двух изображений: одного – сделанного во время наводнения, другого – без наводнения. Результаты определения затопленных территорий на основе радиолокационных

данных, полученных со спутника ERS-2/SAR, и оптических с применением IRS/LISS хорошо согласуются.

Спутниковые данные ERS-2/SAR и Envisat/ASAR были применены для определения площадей водоемов [19]. В предложенном подходе сначала использовался метод пороговой сегментации, затем подстройка параметров выполнялась оператором-экспертом вручную путем визуального анализа изображений. Точность оценки метода по сравнению с наземными измерениями составила 98 %.

В работе [20] данные спутника RADARSAT-1 использовались для мониторинга наводнений 1997 года на Красной реке в США. При этом затопленные территории определялись на основе метода обучения с учителем (supervised classification) – метода параллелепипедов.

Следует отметить, что, несмотря на простоту и высокую скорость описанных методов, они не лишены недостатков, а именно:

1) необходимость ручной настройки пороговых значений и параметров для сегментации изображений;
2) отсутствие пространственной взаимосвязи между пикселями изображения;
3) необходимость привлечения оператора к обработке изображений;
4) необходимость наличия опыта у оператора для анализа радиолокационных изображений.

Кроме того, применение указанных методов для сегментации радиолокационных изображений усложняется тем, что информация поступает только в одном спектральном диапазоне. Это ухудшает различимость классов объектов и соответственно увеличивает ошибки сегментации. Следует также заметить, что особенности фильтрации высокочастотного сигнала (спекла) могут привести к потере полезной информации.

Для преодоления указанных недостатков авторами данной книги предложен новый подход для определения затопленных территорий, основанный на автоматической нейросетевой сегментации изображения с использованием пространственных взаимосвязей между пикселями изображения [21, 22]. Сегментация и классификация изображений выполняются с применением нейронных сетей Кохонена [13]. К преимуществам нейронных сетей этого типа следует отнести адаптивную настройку весовых коэффициентов на основе самоорганизации (без учителя), автоматическое выявление статистически значимых признаков в обучающей выборке данных, отсутствие необходимости в сложных моделях фильтрации для удаления спекла.

2.2. Входные спутниковые данные

Для апробации предлагаемого метода определения затопленных наводнениями территорий использованы радиолокационные изображения, полученные прибором SAR со спутника ERS-2 во время наводнения на р. Тиса в марте 2001 года (рис. 2.1) и без наводнения в апреле того же года (рис. 2.2). Данные предоставлены ЕКА в рамках гранта Category-1 "Wide Area Grid Testbed for Flood Monitoring using Spaceborne SAR and Optical Data" (№ 4181).

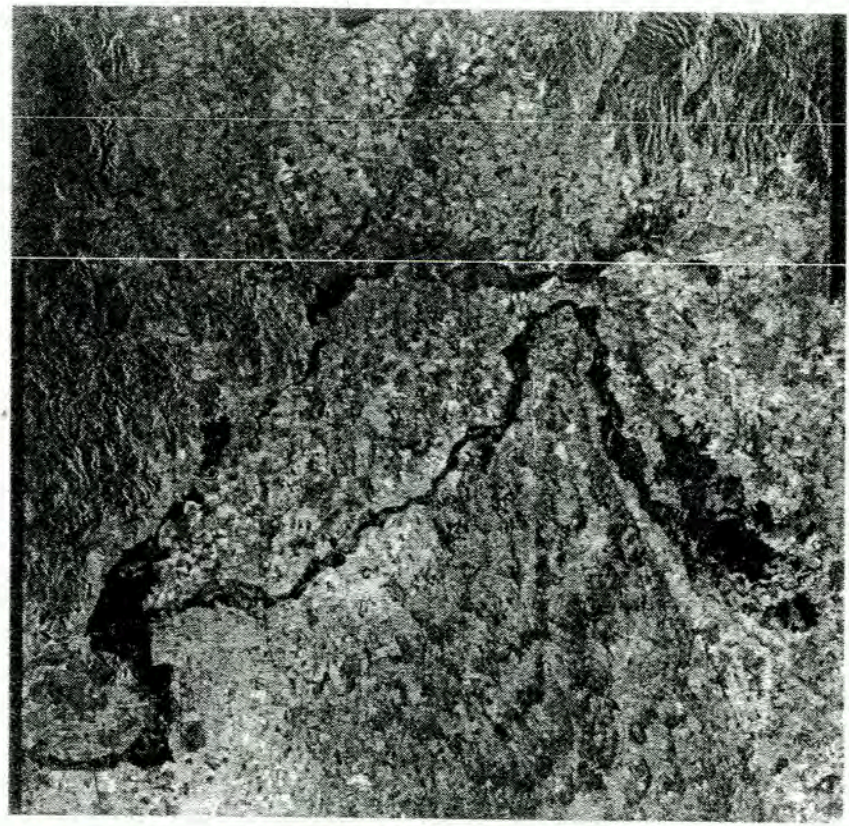


Рис. 2.1. Изображение ERS-2/SAR р. Тиса во время наводнения. Дата съемки: 10.03.2001 (© ESA 2001)

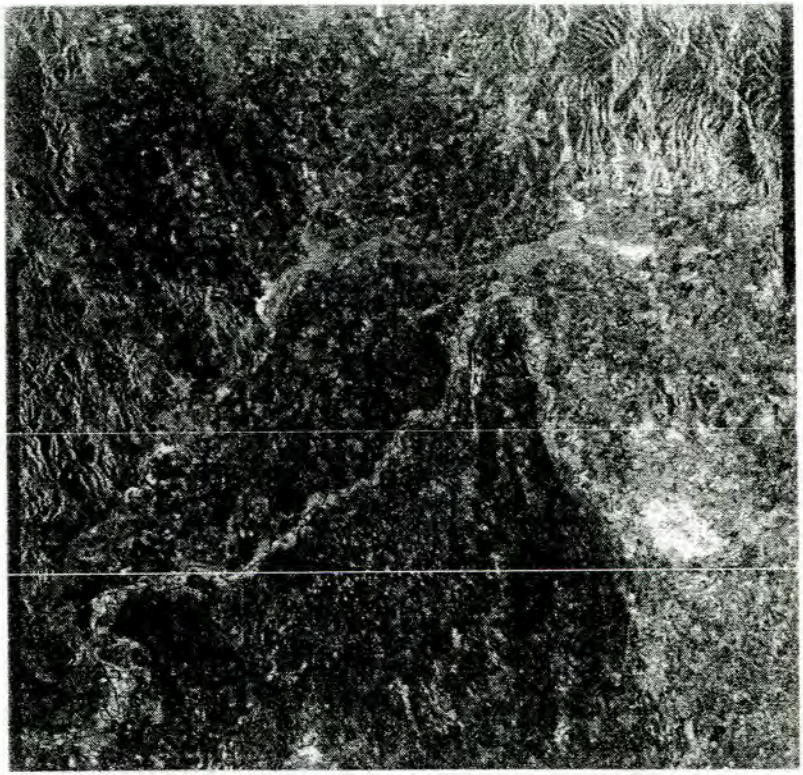


Рис. 2.2. Изображение ERS-2/SAR р. Тиса без наводнений. Дата съемки: 14.04.2001 (© ESA 2001)

Исходные данные ERS-2/SAR предоставлены в формате Envisat SLC (Single Look Complex) [23] с пространственным разрешением 4 м.

Более точная геопространственная привязка радиолокационных данных со спутника ERS-2 и валидация полученных результатов для исследуемой территории обеспечивалась привлечением следующих дополнительных данных:

– спутника Landsat-7/ETM+; дата съемки 30.09.2000;

– Европейского проекта Corine Land Cover [24] по классификации земного покрова; использовалась версия CLC 2000, которая предоставляет информацию о классах земной поверхности (44 класса) с пространственным разрешением 100 м для всех стран Европейского Союза.

С учетом дополнительной информации для обучения нейросетевой модели (настройки весовых коэффициентов) выбраны тестовые пиксели, которые соответствуют как территориям с водой (условно отнесем их к классу «Вода»), так и без воды (класс «Суша»). Всего для обучающей выборки отобрано 42 955 пикселей, из которых 12 939 относятся к классу «Вода», и 30 016 – к классу «Суша».

2.3. Метод определения затопленных наводнениями территорий

В процессе реализации совместного гранта INTAS–CNES–NSAU «Data Fusion Grid Infrastrucutre» и проекта ESA CAT-1 авторами разработан новый метод картографирования затопленных территорий, основанный на применении интеллектуальных, в частности нейросетевых, методов обработки данных [21, 22]. Предложенный метод определения затопленных наводнениями территорий включает предварительную и тематическую обработки. Последняя сводится к сегментации изображения с помощью нейронных сетей Кохонена и его классификации на типы «Вода» и «Суша». Рассмотрим эти этапы более детально.

2.3.1. Предварительная обработка изображений

Предварительная обработка радиолокационных изображений состоит из следующих этапов.

1. *Преобразование в географическую проекцию.* Исходные спутниковые данные ERS-2/SLC поставляются в формате Envisat [23] с контрольными точками на земной поверхности GCP (Ground Control Point). Эти точки используются для геопривязки изображения. При этом результирующее изображение имеет формат GeoTIFF. Кроме того, на основе комплексного изображения SLC вычислена интенсивность каждого пикселя изображения.

2. *Калибровка изображения.* Для калибровки радиолокационных изображений ERS-2/SAR использована стандартная процедура, описанная в работе [25]. В соответствии с этой процедурой исходные значения пикселя в DN (digital number) преобразуются в коэффициент обратного рассеивания σ_0 согласно формуле

$$\sigma_0 = \frac{[\mathrm{DN}]^2}{K}\frac{\sin(\alpha)}{\sin(\alpha_{ref})}, \quad \sigma_0, dB = 10\log(\sigma_0),$$

где α – локальный угол наклона, $\alpha_{ref} = 23°$, K – калибровочная константа (в данном случае $K = 93325{,}3$).

3. *Географическая привязка.* Для данных спутника ERS-2 выполняется дополнительная географическая привязка. В качестве базового изображения использовано изображение Landsat-7/ETM+.

2.3.2. Обработка изображений с использованием нейронных сетей Кохонена

Самоорганизующиеся карты Кохонена — это одна из архитектур искусственных нейронных сетей (НС), работа которых основана на конкурентном принципе обучения [13]. При этом сама НС представляет собой двумерную решетку, в узлах которой расположены нейроны (элементарные обрабатывающие элементы). В процессе работы сети нейроны конкурируют между собой за право перейти в состояние возбуждения. Выходом сети считается нейрон-победитель. В соответствии с идеей Розенблатта [13] для реализации конкурентного принципа обучения используются латеральные тормозящие связи (отрицательные обратные связи) между нейронами, обеспечивающие изменение не только весовых коэффициентов нейрона-победителя, но и нейронов в некоторой его окрестности.

Весовые коэффициенты ω_j всех нейронов из окрестности нейрона-победителя i при переходе от момента времени n к $n+1$ модифицируются следующим образом [13]:

$$i(x) = \arg\min_{j=\overline{1,l}} \|x - \omega_j\|,$$

$$\omega_j(n+1) = \omega_j(n) + \eta(n) h_{j,i(x)}(n)(x - \omega_j(n)), \quad j = \overline{1, l}, \qquad (2.1)$$

где η – коэффициент скорости обучения, $h(n)$ – функция окрестности нейрона-победителя, x – вектор обучающего множества; $\|\cdot\|$ – евклидова норма.

Значение весового вектора ω_i нейрона-победителя i приближается к x. Векторы синаптических весовых коэффициентов отслеживают распределение входных векторов в соответствии с выбором окрестности, обеспечивая тем самым топологическое упорядочение карты признаков во входном пространстве.

В качестве функции окрестности $h_{j,i(x)}(n)$ в выражении (2.1) обычно выбирается ступенчатая функция или функция Гаусса, а для скорости обучения $\eta(n)$ используется следующая эвристика:

$$\eta(n) = \eta_0 e^{-\frac{n}{\tau_2}}, \quad \eta_0 = 0{,}1; \quad n = 0,1,2..., \tag{2.2}$$

где τ_2 – временная константа.

Нейронные сети Кохонена широко применяются для сегментации изображений в разных предметных областях. При этом возможна их последующая классификация [13]. В процессе обработки изображений важен выбор информативных признаков, которые будут использованы в качестве входных значений НС. Обработку изображений обычно выполняют не попиксельно, а используют данные некоторой окрестности пикселя. В качестве информативных признаков можно выбирать значения интенсивности пикселей, значения производных, разнообразные фильтры, преобразования (например, преобразование Фурье) и т.д. [26]. В описываемом подходе на вход НС в качестве информативных признаков предлагается подавать значения интенсивностей пикселей из некоторой окрестности. В частности, авторами проведена серия экспериментов, в которой размер окрестности составлял 3×3, 5×5, 7×7, 9×9 и 11×11.

Для оценки качества обучения НС Кохонена использовались следующие величины.

1. Погрешность дискретизации или квантования (quantization error) обученной сети Кохонена. Данная величина определяет качество сегментации изображения и вычисляется согласно соотношению

$$QE = \frac{1}{N}\sum_{t=1}^{N}\left\|x_t - \omega_{i(x_t)}\right\|, \quad i(x_t) = \arg\min_{j=1,J}\left\|x_t - \omega_j\right\|,$$

где N – размер обучающей выборки.

2. Процент правильно классифицированных образов, т.е. результаты классификации НС на тестовых данных.

2.4. Экспериментальные результаты

Для определения оптимальной архитектуры и параметров НС Кохонена проведена серия экспериментов. При этом варьировались следующие параметры:

– размер окрестности каждого пикселя радиолокационного изображения, который определяет количество нейронов во входном слое нейронной сети;

– количество нейронов выходного слоя, соответствующего количеству кластеров, на которые будут сегментированы изображения.

Другие параметры НС Кохонена, которая использовалась для сегментации радиолокационных изображений, имели такие значения:

– структура соседства: шестиугольная (рис. 2.3, *а*);

– функция окрестности: гауссова (рис. 2.3, *б*);

– начальное значение коэффициента обучения: 0,1;

– количество эпох обучения: 20.

Для инициализации весовых коэффициентов НС использован следующий подход. Элементы обучающего множества обрабатывались методом анализа главных компонентов. Затем выбирались собственные векторы, соответствующие первым двум наибольшим собственным числам. Начальные значения весовых коэффициентов НС выбирались из векторов линейного подпространства, натянутого на эти два собственных вектора, соответствующих максимальным собственным числам матрицы корреляции.

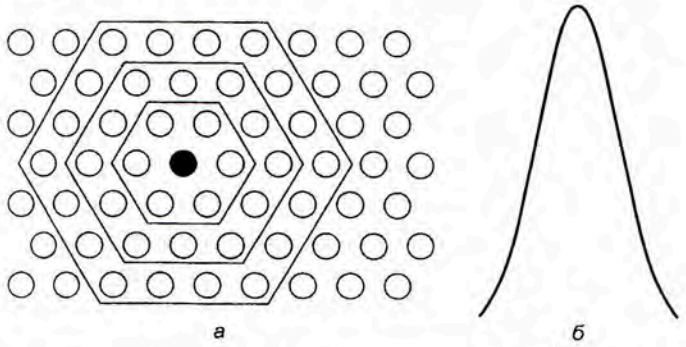


Рис. 2.3. Структура соседства (*а*) и функция окрестности (*б*) НС Кохонена

Результаты зависимости ошибки квантования и количества правильно классифицированных пикселей от размера окрестности для сети Кохонена с решеткой нейронов 5×5 представлены в табл. 2.1.

Таблица 2.1. **Ошибка квантования и количество правильно классифицированных пикселей в зависимости от размера окрестности пикселя**

Размер окрестности пикселя	Ошибка квантования нейронной сети	Процентное значение правильно классифицированных тестовых пикселей		
		«Суша»	«Вода»	Всего
3×3	17,11	99,12	97,54	98,64
5×5	11,80	99,85	99,58	99,76
7×7	8,89	99,81	99,86	99,90
9×9	7,12	99,99	99,53	99,86
11×11	5,95	99,94	99,84	99,91

Уже для окрестности 7×7 достигнуто значение 99,90 % правильно классифицированных пикселей на всех тестовых данных. Именно это значение окрестности и выбрано для сегментации изображений.

Результаты применения для определения затопленных наводнениями территорий предложенного подхода с использованием самоорганизующихся карт Кохонена представлены на рис. 2.4. На рис. 2.4, *а* показано исходное спутниковое изображение ERS-2/ SAR с затопленными территориями, поглощающими сигнал радара (эти участки показаны черным и темно-серым цветами). На рис. 2.4, *б* показаны результаты сегментации изображения с использованием самоорганизующихся карт Кохонена, на котором легко заметить наличие различных кластеров. Дополнительные данные со спутника Landasat-7/ETM+ и классификационная информация Corine 2000 Land Cover использовались для классификации результатов, а именно для отнесения каждого нейрона к одному из двух типов: «Вода» или «Суша». Результаты маркировки показаны на рис. 2.4, *в*: темно-серый цвет имеют затопленные участки или участки с повышенным содержанием влаги, незатопленные области показаны светлым цветом.

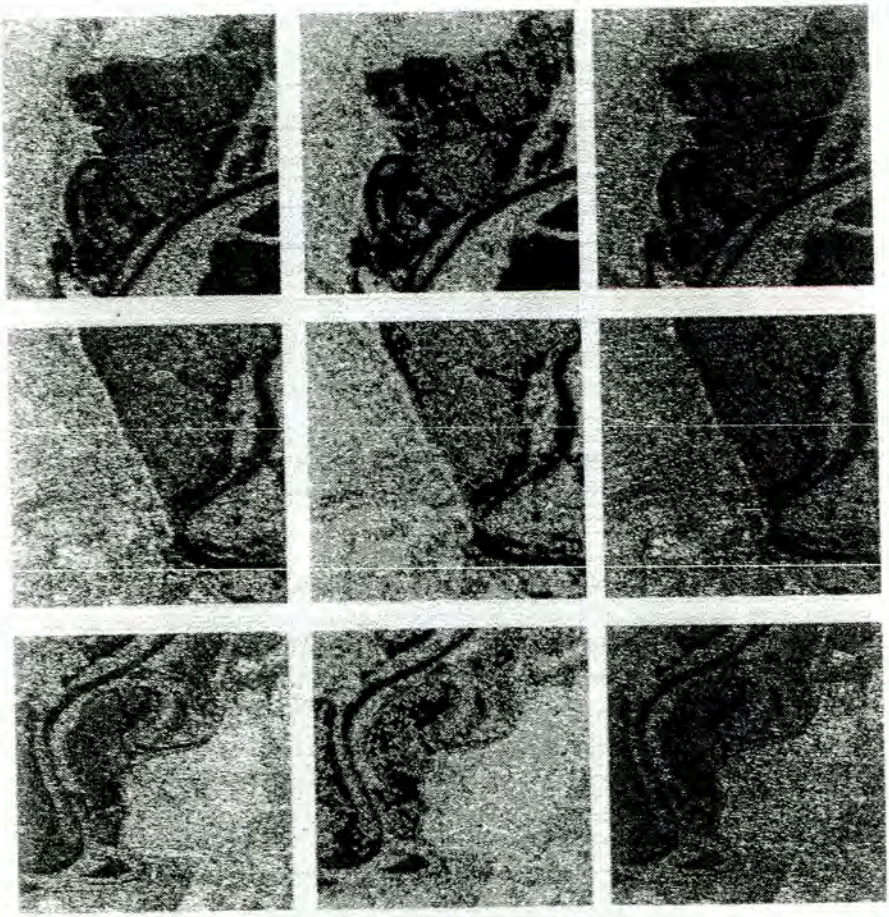


Рис. 2.4. Этапы определения затопленных территорий: *а* – исходное изображение ERS-2, *б* – сегментированное изображение, *в* – маска затоплений (© ESA 2007)

Результаты классификации изображения ERS-2 на классы «Вода» и «Суша» представлены на рис. 2.5.

Результаты работы сервиса мониторинга затоплений для территорий Украины и Китая представлены на вклейке (рис. В.2 и рис. В.3).

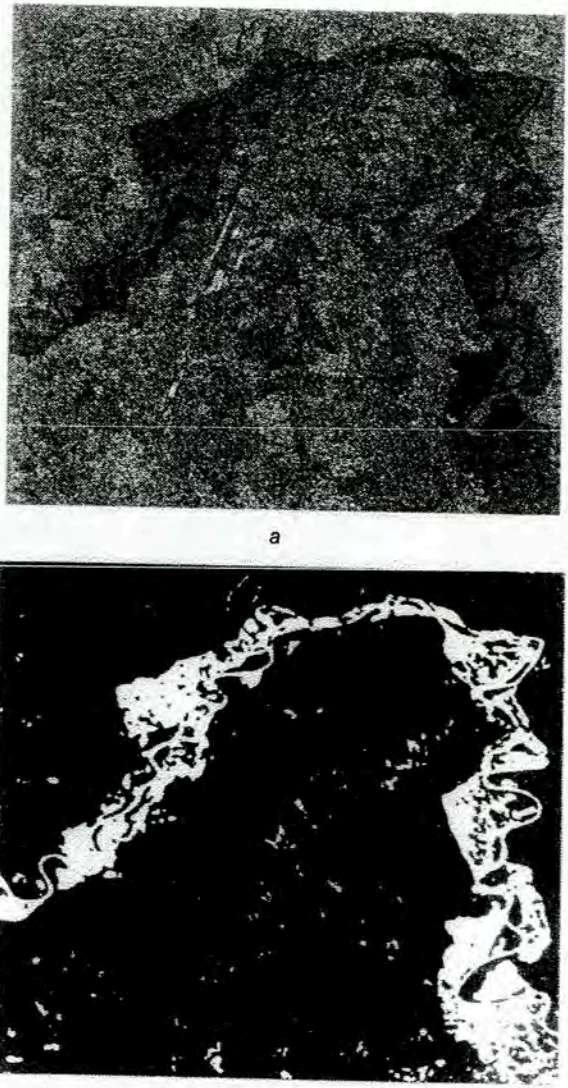


Рис. 2.5. Результаты классификации изображения ERS-2: *а* – исходное радиолокационное изображение; *б* – результирующее классифицированное изображение (белым цветом обозначены пиксели, относящиеся к классу «Вода»)

2.5. Обсуждение

В данной главе описан новый подход к определению затопленных территорий с привлечением спутниковых данных, который основан на использовании НС. Информация о затоплениях может эффективно использоваться в гидрологических моделях, а также в качестве дополнительных данных при решении задач мониторинга, результаты которого учитываются при ведении сельского хозяйства. Для сегментации и классификации радиолокационных изображений нами были использованы самоорганизующиеся карты Кохонена, которые позволяют автоматически выделить статистически значимые свойства входных данных. В качестве входных признаков используются значения коэффициента обратного рассеивания для окрестности пикселя 7×7. Преимущество предложенного подхода по сравнению с известными методами определения площадей затопленных территорий состоит в том, что обрабатывается не каждый пиксель в отдельности, а используется контекстная (текстурная) информация, определяемая значениями соседних пикселей из некоторой окрестности. Кроме того, предложенный метод позволяет автоматически настраивать коэффициенты модели на основе принципов самоорганизации или использовать так называемое обучение без учителя. Это дает возможность применять данный метод при разработке автоматических сервисов экологического мониторинга. Точность классификации построенной НС с размерностью входа 49 и решеткой нейронов 5×5 на тестовых данных (не включающих пограничные пиксели) составила 99,90 %, что существенно выше известных результатов классификации с привлечением других методов.

Глава 3

СОЗДАНИЕ КАСКАДОВ ГИДРОМЕТЕОРОЛОГИЧЕСКИХ МОДЕЛЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ПАВОДКОВ

Основной способ оценки рисков, связанных с паводками, – это анализ бассейнов рек с привлечением гидрологических моделей. Решение оперативных задач оценки рисков требует использования моделей в режиме прогноза для создания кратко- и среднесрочных прогнозов моментов возникновения паводковых ситуаций, хода паводков, оценки их последствий.

Традиционные методы кратко- и среднесрочного прогнозирования паводков состоят в использовании данных наблюдений в качестве входных данных при гидрологическом моделировании бассейнов рек. В некоторых странах такие подходы используются в оперативном режиме. Входные данные для моделирования включают результаты точечных наземных измерений метеорологических параметров (количество осадков, температура воздуха), данные метеорологических радаров, оценки интенсивности осадков по спутниковым снимкам, уровни и расходы воды и т.д. Использование результатов измерений ограничивает сроки заблаговременных гидрологических прогнозов характерным временем отклика гидрологической системы. Использование метеорологических прогнозов в качестве входных данных для гидрологического моделирования долгое время было ограничено, поскольку типичное пространственное разрешение глобальных метеорологических моделей (100 км) достаточно только для исследований континентального масштаба.

В настоящее время благодаря стремительному росту доступных вычислительных ресурсов и непрерывному развитию метеорологических моделей появилась возможность усовершенствования традиционных методов. Современное направление в прогнозировании паводков заключается в использовании прогнозных значений метеорологических параметров и создании каскадов метеорологических и гидрологических моделей. Типичное пространственное разрешение региональных метеорологических моделей составляет 10–30 км. Кроме того, существуют модели (например, MM5, WRF), которые специально предназначены для

моделирования с высоким пространственным разрешением (1–10 км). Применение таких моделей позволяет проводить гидрологические исследования на региональном и даже на локальном уровне. Существенное преимущество такого подхода в том, что он позволяет увеличение заблаговременности прогнозов паводков. Современные глобальные метеорологические модели генерируют прогнозы сроком до 7–10 дней, а региональные – до 2–4 дней. Подобное увеличение заблаговременности прогнозов паводков особенно важно в случае краткосрочных паводков, для которых характерное время реакции бассейна (и соответственно заблаговременность традиционных прогнозов) ограничено 3–6 часами.

3.1. Гидрологические модели. Основные понятия и классификация

Рассмотрим основные понятия, связанные с гидрологическим моделированием, а также классификацию гидрологических моделей.

Под *гидрологической системой* будем понимать множество физических, химических и биологических процессов, которые воздействуют на входные переменные (например, осадки) и преобразуют их в выходные переменные (например, расходы воды в речных створах) [27].

Переменная системы – это характеристика, которая может быть измерена. При измерении в разные моменты времени переменная может принимать разные значения. Примерами переменных являются ежедневные осадки, сток, интенсивность испарения, температура, инфильтрация, влажность грунта и др.

Параметр системы – это количественная характеристика системы, характеризующаяся большей стабильностью, чем переменная. Примерами параметров могут служить площадь водосбора, средний уклон бассейна, характеристики землепользования и т.д.

Модель – это упрощенное представление системы, которая описывает наиболее важные компоненты системы в целом.

Речной бассейн можно рассматривать как гидрологическую систему. Граница системы в данном случае определяется линией водораздела (рис. 3.1). Информация об осадках, распределенных по поверхности речного бассейна, – это входные данные системы, а выходные переменные – речной сток в замыкающем створе бассейна, интенсивность испарения с поверхности бассейна, подповерхностный сток и т.д. Исходя из концепции системного анализа, основные усилия при создании гидро-

логической модели бассейна должны быть сосредоточены на построение связи между входом и выходом, а не на сложной задаче представления деталей системы, которые могут быть не важны с точки зрения практического использования. В то же время понимание протекающих в системе физических процессов может существенно облегчить построение и валидацию модели.

Цель анализа гидрологической системы состоит в изучении ее поведения и прогнозировании выходных параметров.

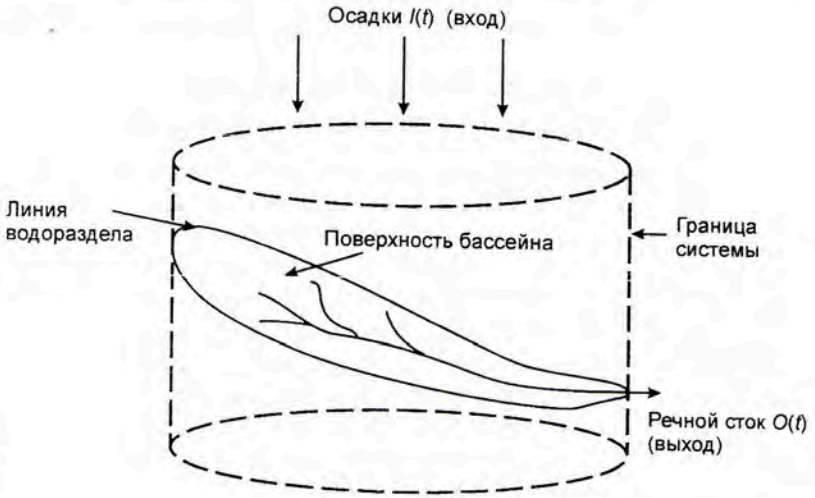


Рис. 3.1. Речной бассейн как гидрологическая система

В общем виде модель гидрологической системы можно представить в терминах «вход-выход». Представим входные и выходные переменные системы функциями времени $I(t)$ и $O(t)$, соответственно. Переменная времени t принадлежит промежутку T. Система преобразует вход в выход следующим образом:

$$O(t) = \Omega[I(t)]. \tag{3.1}$$

Оператор Ω представляет собой передаточную функцию между входом и выходом. В большинстве случаев этот оператор – сложная нелинейной функция входных переменных со многими параметрами, которые требуют идентификации.

Существует несколько различных классификаций гидрологических моделей. Например, модели могут быть линейными и нелинейными, инвариантными относительно времени и неинвариантными и т.д. Однако основные критерии, которые позволяют определить применимость конкретной модели для решения практических задач, – это детальность описания физических процессов в модели и ее пространственное представление.

С точки зрения детальности описания физических процессов гидрологические модели можно разделить на теоретические, эмпирические и концептуальные.

Теоретические модели (физические модели) представляют собой следствия наиболее важных физических законов, которые определяют протекание явлений в системе и имеют логическую структуру, подобную взаимосвязям реального мира. Такие модели могут быть полезными при исследовании реакции системы на изменения климата, ландшафта, характеристик землепользования. К теоретическим гидрологическим моделям можно отнести модели стока бассейнов, основанные на уравнениях Сен-Венана; модели инфильтрации, построенные на основе теории потоков в пористой среде; модели испарения, основанные на теории турбулентности и диффузии; модели подземных вод, которые используют фундаментальные уравнения переноса жидкости. Пример такой модели – модель SHE [28].

Эмпирические модели (модели «вход-выход», модели типа «черный ящик») не представляют ценности в понимании физических процессов, поскольку их параметры не имеют прямого физического смысла и могут быть оценены только при одновременном измерении входа и выхода. Тем не менее, эмпирические модели могут быть полезным инструментом при принятии решений. Примерами таких моделей служат стохастические модели временных рядов, например модели авторегрессии – скользящего среднего.

Концептуальные модели сочетают в себе свойства теоретических и эмпирических моделей. Гидрологическая модель считается концептуальной, если форма функции Ω в уравнении (3.1) предложена в результате рассмотрения физических процессов, действующих на переменные входа для определения переменных выхода. В основу концептуальных моделей положены физические законы, которые рассматриваются в достаточно упрощенном виде. Существует много моделей, принадлежащих к этому классу, например модель HSPF (Hydrological Simulation

Program – Fortran) (http://water.usgs.gov/software/hspf.html), разработанная в США [3, 29].

В терминах пространственной дискретизации, или разрешающей способности, выделяют три класса моделей (рис. 3.2), среди которых простейшая – сосредоточенная модель. В рамках этой модели речной бассейн рассматривается как единое целое. Сложнее полураспределенная модель, в которой речной бассейн делится на подбассейны, каждый из которых рассматривается как единое целое. Наиболее сложными являются полностью распределенные модели. В таких моделях бассейн задается на регулярных или нерегулярных сетках, в виде конечных элементов и т.д. Большинство существующих моделей принадлежит к классу полураспределенных моделей.

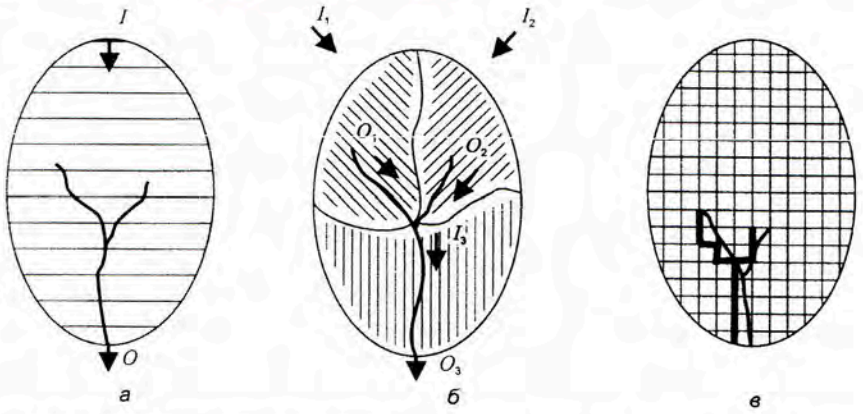


Рис. 3.2. Пространственное представление распределенных и сосредоточенных моделей (*I* – вход, *O* – выход): *а* – сосредоточенные модели; *б* – полураспределенные модели; *в* – распределенные модели

3.2. Существующие подходы к прогнозированию паводков

В качестве примера системы краткосрочного прогнозирования паводков, которая построена на основе каскада моделей, рассмотрим систему, созданную Институтом информатики Академии наук Словакии совместно со Словацким гидрометеорологическим институтом (Slovak hydro-meteorological institute, SHMI).

Система создана для прогнозирования паводковых ситуаций в бассейне реки Вах – притоке Дуная (площадь водосбора ~500 км^2). Система прогнозирования создана в рамках ряда проектов европейских рамочных программ FP5 и FP6 (проекты CROSSGRID, MEDIGRID, K-WF GRID). На сегодняшний день в системе реализован каскад метеорологических, гидрологических и гидравлических моделей [4, 30], (http://ups.savba.sk/kwfgrid/ffsc/index.html) (рис. 3.3).

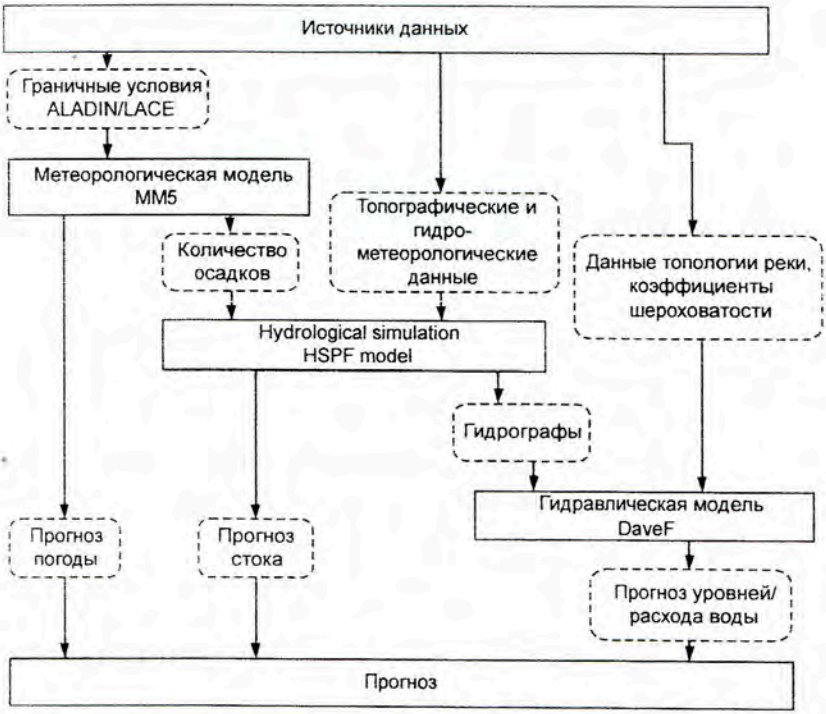


Рис. 3.3. Каскад моделей системы прогнозирования паводков Института информатики Академии наук Словакии

Задача метеорологического блока каскада заключается в создании количественных прогнозов осадков для территории речного бассейна. В качестве модели используется общедоступная модель прогноза погоды MM5 [5, 31] (http://www.mmm.ucar.edu/mm5/). Прогнозирование

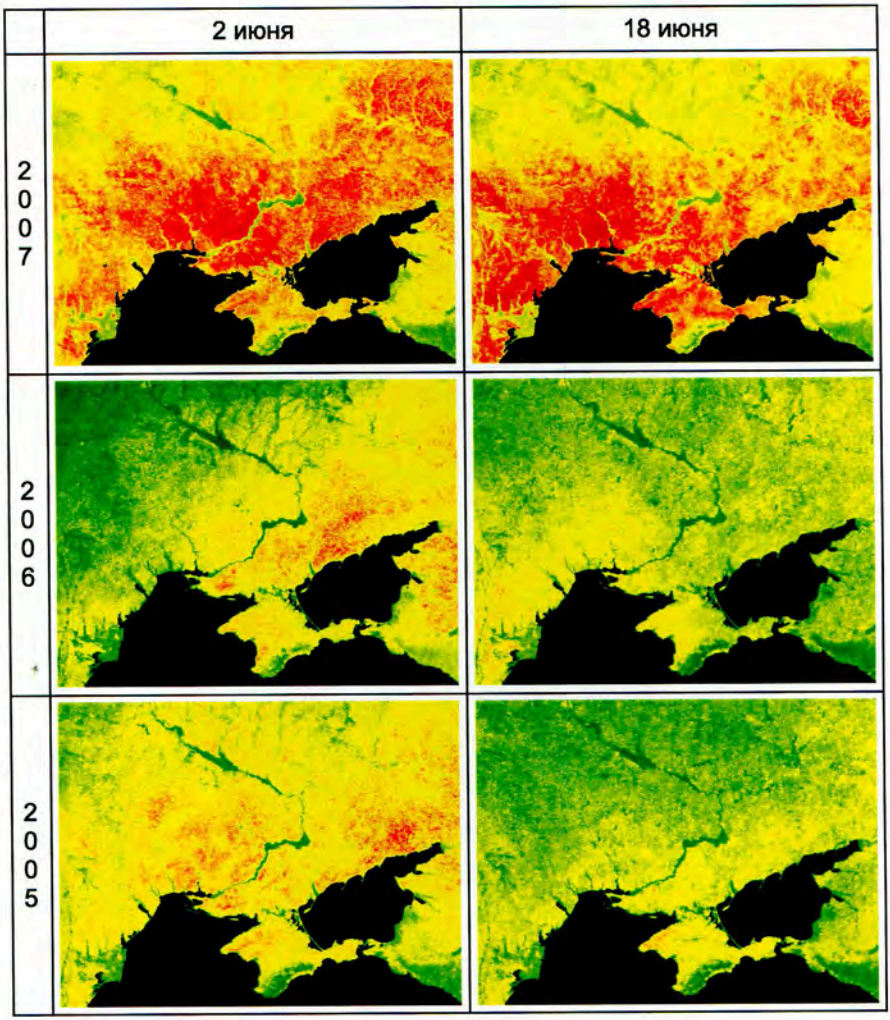


Рис. В.1. Результаты мониторинга засух на территории Украины

выполняется на 48 часов с пространственным разрешением 7 км. Для запуска региональной метеорологической модели и получения прогноза необходимо задать различные краевые условия. В данном случае краевые условия задаются на основе региональной модели с низким пространственным разрешением ALADIN/LACE, которая, в свою очередь, вложена в глобальную модель ARPEGE.

Прогнозы ALADIN/LACE предоставляются Словацким гидрометеорологическим институтом.

Данные метеорологических прогнозов служат входными данными для гидрологического блока, предназначенного для прогнозирования гидрографов (изменения расходов воды во времени) в заданных речных створах. Расположение створов может совпадать с расположением гидропостов, это позволит калибровать гидрологическую модель. В качестве модели используется апробированная модель HSPF [3].

Данные гидрологического прогноза поступают в гидравлический блок, задача которого – составление прогноза распространения возможного паводка. Гидравлический блок позволяет получить прогнозы расходов и уровней води, а также прогноз относительно территории, которая будет затоплена. В качестве гидравлической модели в Словакии используется модель DaveF, разработанная на основе двумерной гидравлической модели FESWMS [6, 32].

3.3. Метод прогнозирования паводков на территории Закарпатья

Для моделирования рисков, связанных с паводками с учетом особенностей территории в Закарпатье, нами предложено адаптировать существующие подходы к прогнозированию паводковых ситуаций, в частности подходы, которые были разработаны и используются в Словакии. За основу метода прогнозирования взято построение каскада моделей, состоящего из трех блоков: метеорологического, гидрологического и гидравлического (рис. 3.4). Рассмотрим эти блоки более детально.

Метеорологический блок. Основу блока составляет модель численного прогноза погоды NWP (Numerical Weather Prediction), предназначенная для создания четырехмерных распределений в пространстве–времени основных метеорологических параметров. Модели NWP делятся на глобальные модели циркуляции атмосферы и региональные. В качестве примеров глобальных моделей назовем модели GFS (Global Forecast System) и

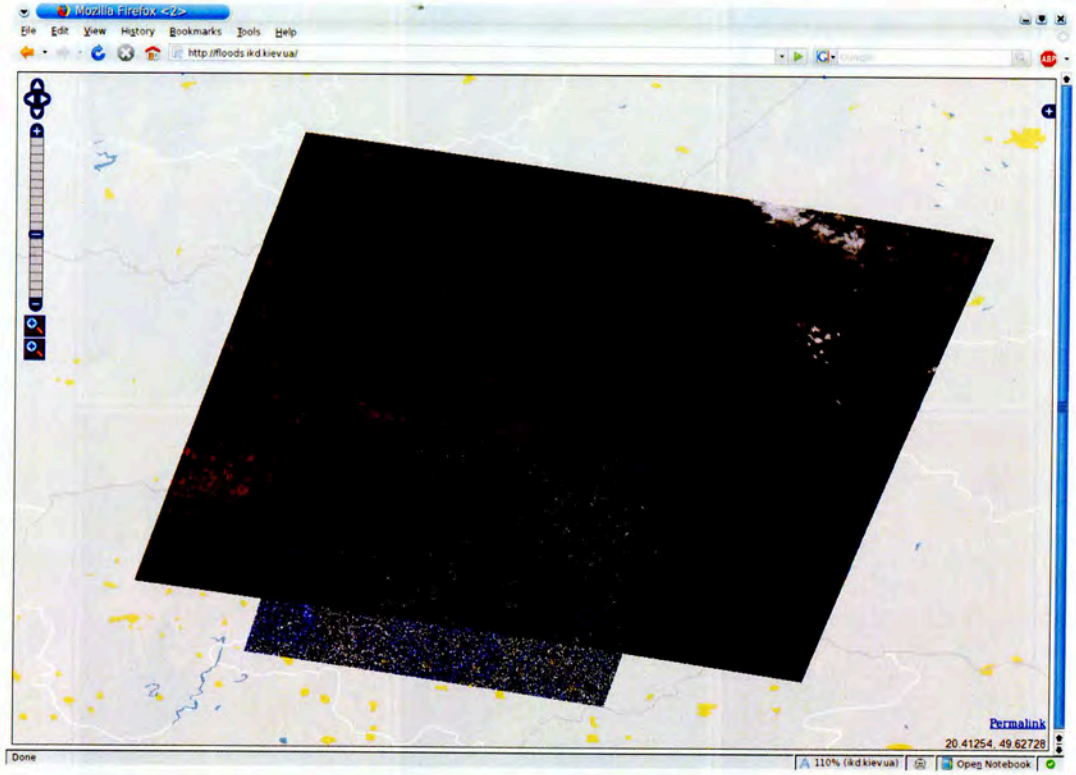


Рис. В.2. Визуализация результатов обработки радиолокационных данных спутника ERS-2/SAR для определения затопленных территорий на р. Тиса (март 2001 г.)

TL799L91 (http://www.ecmwf.int/products/forecasts/guide/The_ECMWF_global_atmospheric_model.html), которые используются соответственно центром NCEP (National Centre for Environmental Prediction) и центром ECMWF (European Centre for Medium-Range Weather Forecasts). Среди региональных моделей прогноза погоды прежде всего следует отметить модели с открытым кодом MM5 (http://www.mmm.ucar.edu/mm5/) и WRF (http://www.wrf-model.org/index.php,http://www.mmm.ucar.edu/wrf/users/) [7, 33].

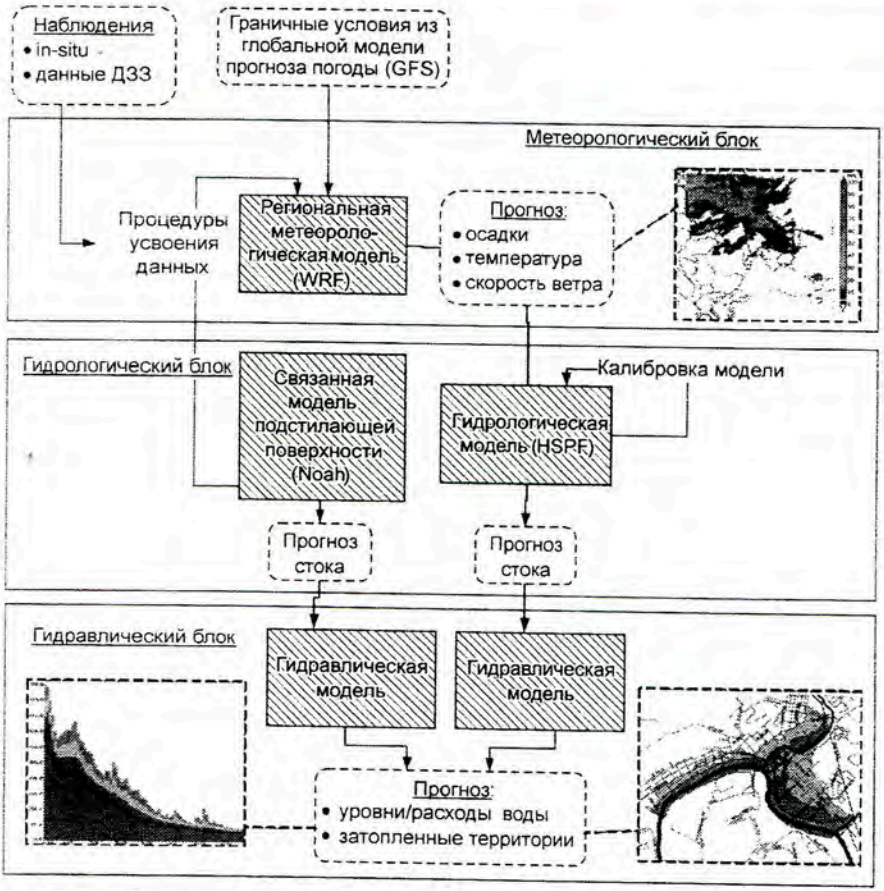


Рис. 3.4. Каскад моделей системы прогнозирования паводков для территории Закарпатья

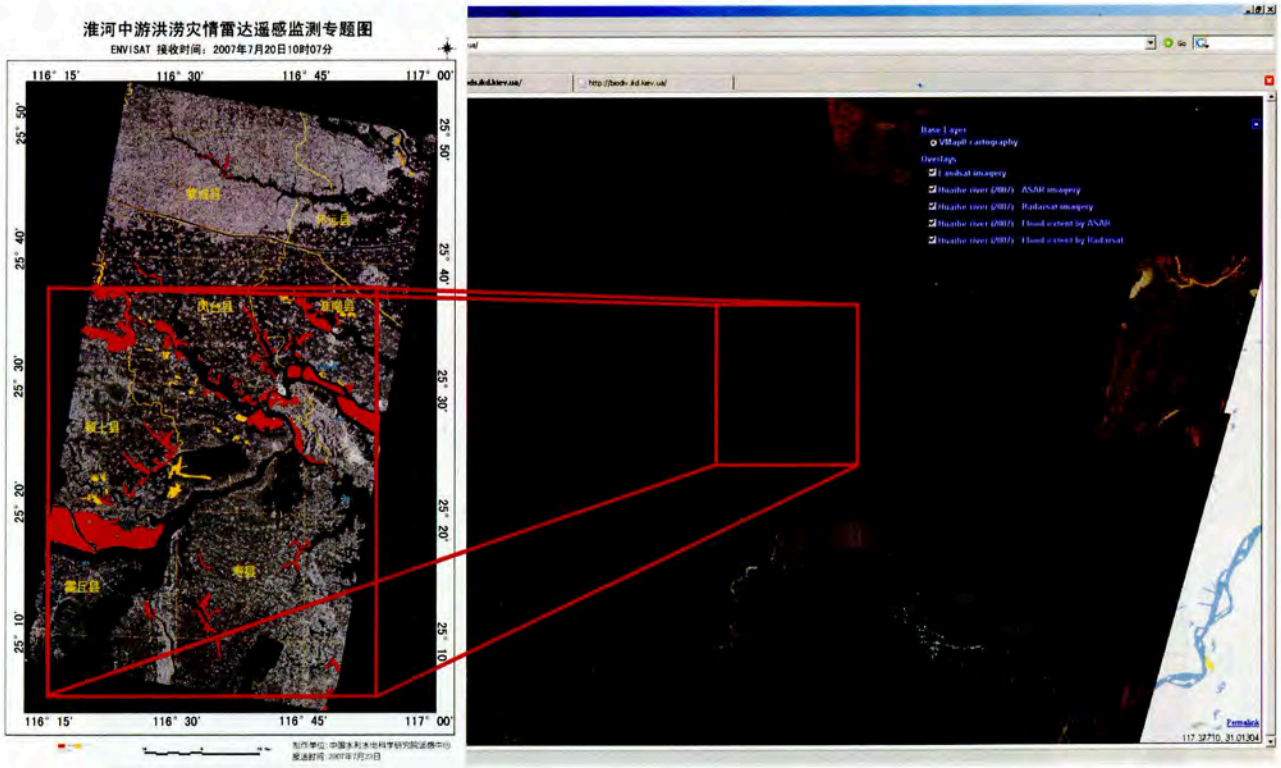


Рис. В.3. Визуализация результатов обработки радиолокационных данных спутников ENVISAT/ASAR WSM и RADARSAT-1 для определения затопленных территорий на р. Хуайхе, Китай (июль 2007 г.)

Для глобальных моделей характерно низкое пространственное разрешение, которое, однако, улучшается вместе со стремительным развитием средств высокопроизводительных вычислений. Региональные модели прогноза погоды мезомасштабные, они специально приспособлены для моделирования с высоким пространственным разрешением. Для запуска таких моделей необходимы данные глобального моделирования для задания краевых условий региональной модели.

Использование моделей численного прогнозирования погоды отмечается высокой сложностью прогнозов и требует применения высокопроизводительной вычислительной техники. Получение прогнозов с высоким пространственным разрешением усложняется при увеличении горизонтального разрешения модели. Это обусловлено стремительным возрастанием необходимых для моделирования вычислительных ресурсов, а именно квадратичным ростом объема необходимой памяти и кубическим ростом времени вычислений. В современных системах моделирования погоды эта проблема решается с помощью каскада вложенных сеток с увеличивающимся пространственным разрешением.

В качестве модели численного прогноза погоды в данном блоке используется региональная модель WRF. Система моделирования WRF разрабатывается и поддерживается многими организациями США, среди которых NCAR, NOAA, AFWA. С точки зрения реализации эта система является гибкой и переносимой, позволяет проводить параллельные вычисления на высокопроизводительной технике. Следует отметить, что система WRF в основном ориентирована на использование на территории США. Так что для ее применения на территории Украины необходима дополнительная адаптация.

На данный момент модель WRF функционирует в операционном режиме в ИКИ НАНУ–НКАУ. Построение прогнозов погоды (на 72 часа) выполняется регулярно каждые 6 часов. Прогнозы строятся на сетке 200×200 с размером элемента сетки 10×10 км. Для учета кривизны поверхности Земли сетка модели задана в равноугольной проекции Ламберта. Для представления вертикальных распределений параметров она имеет 31 вертикальный уровень. В качестве краевых условий модели используются данные глобальной модели GFS, поступающие из сети Internet с серверов NOMADS (National Operational Model Archive & Distribution System) [34]. Подготовку данных для моделирования обеспечивает система WRFSI. Время вычисления прогноза на 72 часа в данной конфигурации составляет 4 часа на кластере ИКИ НАНУ–НКАУ(два

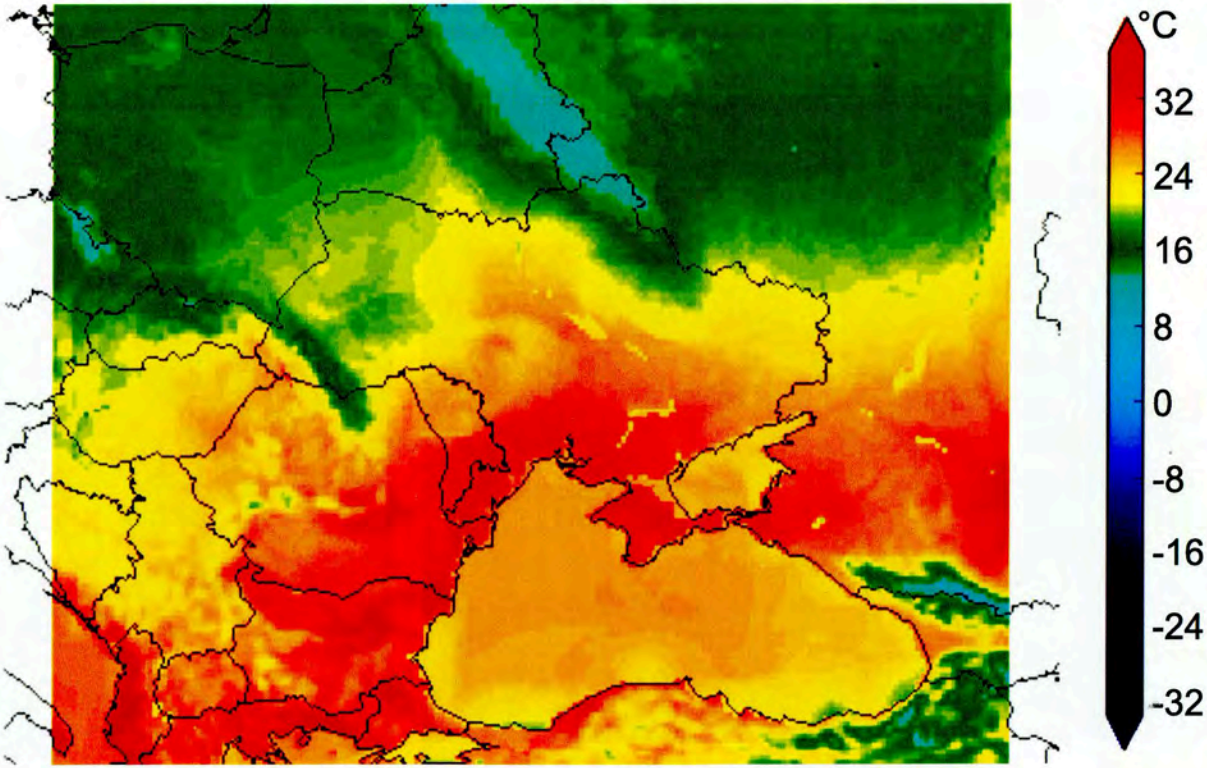
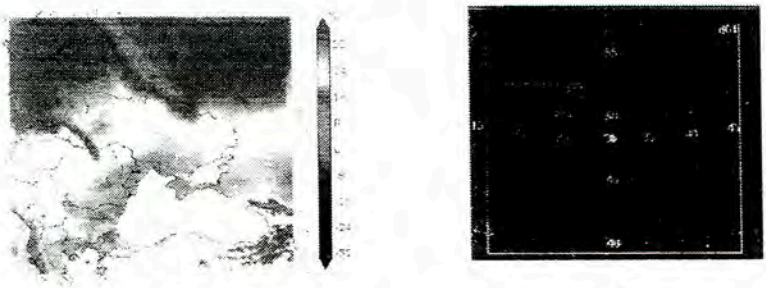


Рис. В.4. Результаты прогнозирования приземной температуры с использованием модели WRF (2007-07-23 06:00 UTC)

двухпроцессорных узла с процессорами AMD Opteron 2.2 ГГц) [35]. Работу модели иллюстрирует рис. 3.5.



а *б*

Рис. 3.5. Пример работы модели WRF:
а – прогноз температуры на 2 м, полученный для территории Украины на 09:00 по времени 23.07.2007; *б* – конфигурация системы вложенных для территории Закарпатья

С целью восстановления метеорологических данных для территории Закарпатья модель WRF сконфигурирована из двух вложенных сеток, как показано на рис. 3.5, *б*. Начальная сетка d01 – это основная сетка модели с горизонтальным пространственным разрешением 10 км, сетка d02 имеет разрешение 10 км, сетка d03 – 3,3 км. Размеры сеток d01, d02 и d03 составляют 65×65, 100×130 и 65×100 узлов соответственно. В такой конфигурации модель WRF позволяет получить прогнозы для территории Закарпатья с пространственным разрешением 3,3 км. При необходимости пространственное разрешение можно улучшить до 1,1 км (с увеличением вычислительных затрат в 27 раз).

Поскольку моделирование погоды с высоким горизонтальным пространственным разрешением представляет собой вычислительно сложную задачу и требует привлечения значительных вычислительных ресурсов, для ее решения используются кластеры СКИТ-1 и СКИТ-3 Института кибернетики НАНУ [35]. Их использование позволило существенно ускорить вычислительный процесс (табл. 3.1, рис. 3.6, *а*). При этом с возрастанием количества вычислительных узлов наблюдается почти линейный рост продуктивности (рис. 3.6, *б*). Например, при использовании восьми узлов кластера СКИТ-3 ускорение вычислений по сравнению с одним узлом составило 7,09 (при идеальном ускорении 8), а при использовании 64 узлов работа модели ускоряется в 43,6 раза (см. табл. 3.1).

Таблица 3.1. **Время вычисления одной итерации модели WRF на кластере СКИТ-3**

Количество узлов	Количество ядер процессоров	Время вычисления одной итерации, с	Ускорение вычислений
1	4	4,36	1
2	8	2,49	1,75
4	16	1,22	3,57
8	32	0,615	7,09
16	64	0,35	12,46
32	128	0,18	24,22
64	256	0,1	43,6

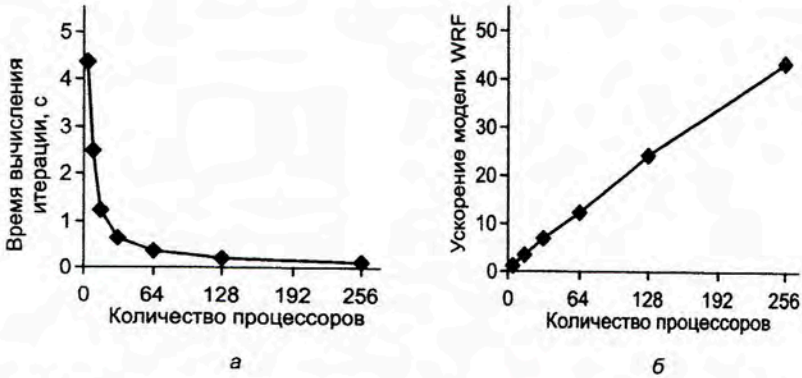


Рис. 3.6. Производительность модели WRF на кластере СКИТ-3: *а* – время вычисления одной итерации; *б* – ускорение работы модели в зависимости от количества узлов

Гидрологический и гидравлический блоки. Авторами монографии предлагаются два варианта реализации гидрологического блока. В рамках первого варианта нужно адаптировать к территории Закарпатья гидрологическую модель HSPF, применяемую в системе [30]

для территории Словакии. Для калибровки модели необходимо использовать данные наземных наблюдений осадков и температуры воздуха, а также уровней воды, измеряемых системой АИВС «Тиса», которые доступны в сети Internet. В качестве второго варианта предлагается использовать модель подстилающей поверхности Noah [36] – распределенную модель, интегрированную в метеорологическую модель WRF. Выходными переменными Noah служат профили влажности и температуры грунта, температура поверхности, расходы воды. Пример работы модели Noah показан на рис. 3.7. Гидравлический блок предлагается дополнить моделью распространения паводков на основе модели FESWMS и моделей временных рядов.

Отметим, что применимость гидравлических и гидрологических моделей достигается путем их адаптации для конкретной территории, а также калибровки и валидации.

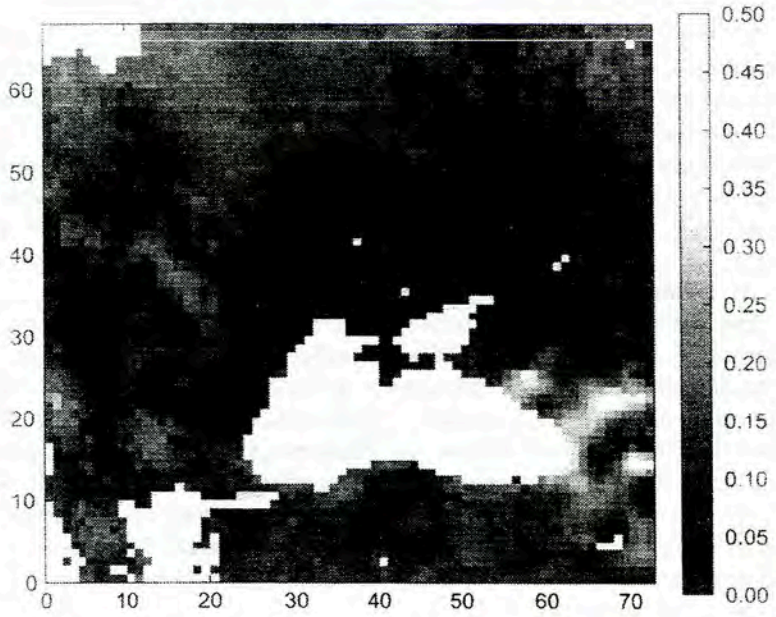


Рис. 3.7. Результаты работы модели Noah. Среднемесячная влажность грунта (0–10 см) в июле 2007 г.

3.4. Валидация моделей

Для валидации метеорологическая модель WRF и гидрологическая модель Noah сконфигурированы для территории Украины с разрешением 30 км. При этом с апреля по август 2007 года выполнялся непрерывный запуск моделей. Были проведены два эксперимента: WRFCO (без усвоения данных глобального анализа) и WRFDA (с усвоением). Усвоение данных абсолютно необходимо, поскольку региональная модель не позволяет отслеживать динамику глобальных метеорологических процессов и с течением времени отклоняется от реального состояния атмосферы. В обоих экспериментах для задания краевых условий модели WRF использовались данные NCEP GDAS.

Использовались простейшие средства четырехмерного усвоения данных анализа (analysis nudging), встроенные в модель WRF. Существуют также и другие способы учета глобальной динамики атмосферы при длительных экспериментах, в частности повторная инициализация модели данными глобального анализа (например, раз в неделю или в месяц). Однако на практике, как показано в работе [37], результаты моделирования по ряду основных параметров при повторной инициализации модели оказываются хуже, чем при использовании методов усвоения данных глобального анализа.

Результаты валидации модели по данным метеостанций показали, что в эксперименте WRFDA модель WRF восстанавливает значение температуры воздуха (на высоте 2 м) с точностью 2 градуса. В то же время в эксперименте WRFCO точность восстановления ниже и ухудшается с течением времени (рис. 3.8, *а*).

Для качественного анализа работы модели Noah использовалась информация о подстилающей поверхности, полученная на основе данных радиометра MODIS. В частности, точность восстановления температуры поверхности оценивалась с помощью продукта MOD11 «Land Surface Temperature and Emissivity Product» [38]. Анализ полученных результатов показал, что модель Noah требует дальнейшей адаптации для территории Украины. Она хорошо моделирует температуру поверхности на территории Румынии и правобережной Украины и в то же время дает заниженную оценку температуры для территории левобережной Украины (рис. 3.9).

Результаты работы моделей WRF и Noah представлены на вклейке (рис. В.4 и рис. В.5).

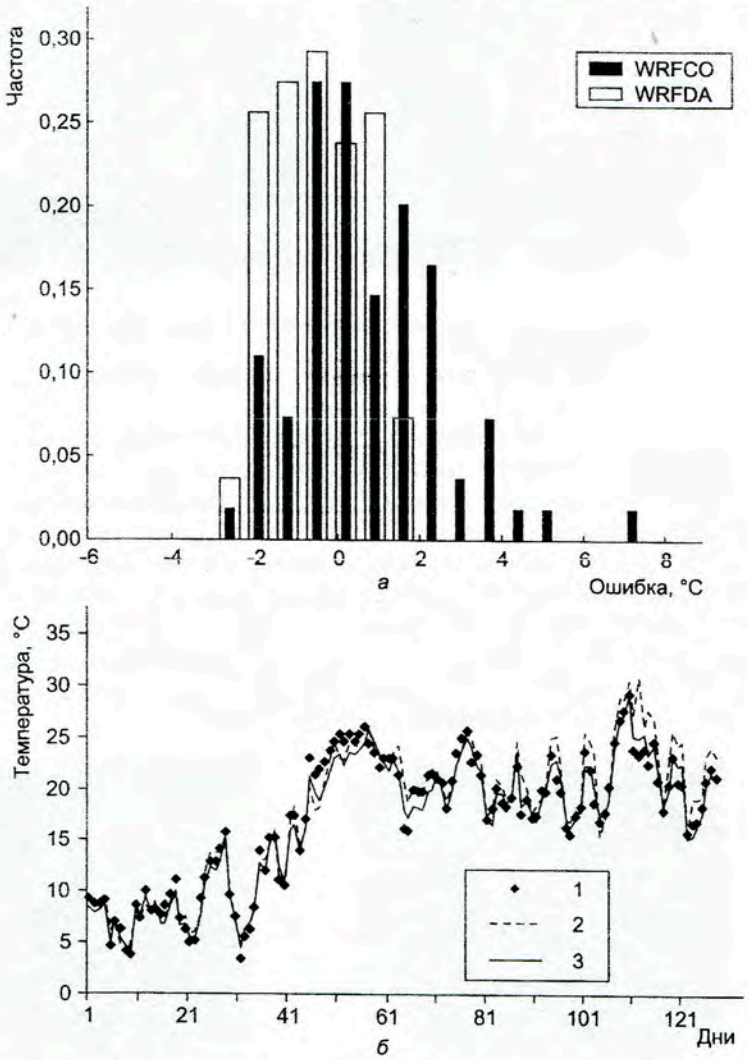
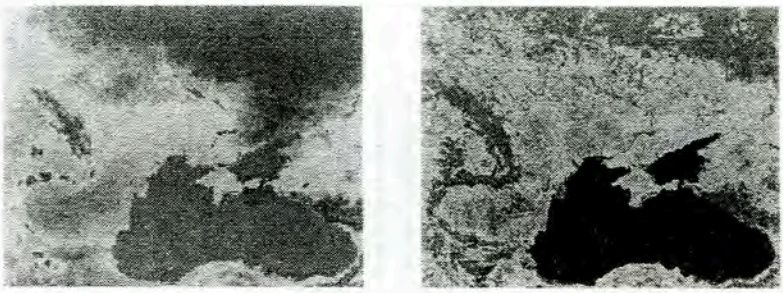


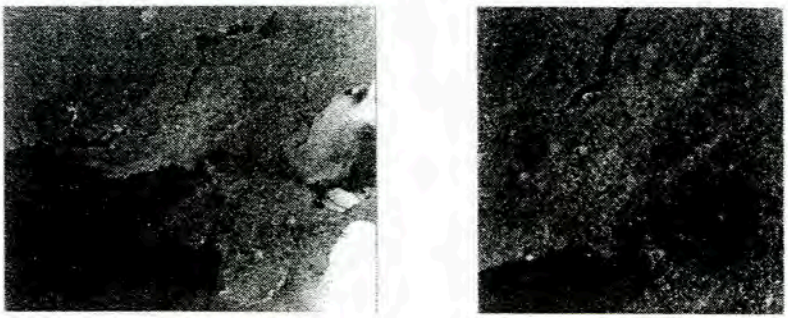
Рис. 3.8. Валидация метеорологической модели WRF. Результаты восстановления среднесуточной температуры воздуха, г. Киев, апрель–август 2007 года: *1* – данные измерений; *а* – ошибки модели в экспериментах WRFCO и WRFDA; *б* – результаты моделирования в экспериментах WRFCO (2) и WRFDA (3)



а *б*

Рис. 3.9. Средние восьмидневные значения дневной температуры поверхности за период 05.012007–05.08.2007:
а – данные модели Noah; *б* – данные MODIS (продукт MOD11)

Мы считаем перспективным направлением исследований использование для валидации моделей подстилающей поверхности радиолокационных спутниковых данных, поскольку эти данные предоставляют уникальную возможность оценки влажности поверхностного слоя с высоким пространственным разрешением. На рис. 3.10 приведен радиолокационный снимок прибора ASAR, установленного на спутнике Envisat. Более светлые области снимка соответствуют зонам с большей влажностью. Распределение увлажненных территорий соответствует шаблону зон выпадения осадков, что позволяет косвенно проверять качество прогнозов метеорологической модели.



а *б*

Рис. 3.10. Возможность оценки влажности по радиолокационным космическим снимкам: *а* – данные ASAR Wide Swath за 04.09.2007; *б* – фрагмент снимка в районе г. Херсона. Данные предоставлены ЕКА

3.5. Обсуждение

Таким образом, создание каскадов моделей – это простой и эффективный способ объединения существующих моделей из различных прикладных областей и перспективный подход к решению междисциплинарных задач. Такой подход применен для интеграции модели численного прогнозирования погоды, гидрологической и гидравлической моделей с целью прогнозирования наводнений в украинских Карпатах. Использование каскада моделей позволяет улучшить существующие методы прогнозирования паводков, в частности, увеличить заблаговременность прогнозов. В то же время для применения существующих моделей в новых условиях или для новых территорий необходима их адаптация.

Предварительная валидация разработанного каскада моделей показала, что метеорологическая модель WRF пригодна для получения региональных прогнозов погоды и восстановления полей метеорологических параметров. Анализ функционирования гидрологической модели Noah позволяет отнести ее к перспективным средствам качественного прогнозирования основных параметров подстилающей поверхности на качественном уровне, однако для получения количественных оценок необходимо ее дальнейшая валидация.

При адаптации и валидации гидрометеорологических моделей важным источником информации являются данные ДЗЗ, в частности данные о температуре подстилающей поверхности, получаемые с современных радиометров инфракрасного диапазона. Перспективно также получение оценок влажности поверхностного слоя грунта по радиолокационным данным для анализа эффективности работы всего каскада в целом.

Глава 4
НЕЙРОСЕТЕВАЯ КЛАССИФИКАЦИЯ ПОДСТИЛАЮЩЕЙ ПОВЕРХНОСТИ ПО СПУТНИКОВЫМ ДАННЫМ

За последние несколько лет произошли качественные улучшения характеристик съемочной аппаратуры для ДЗЗ. Многократно увеличилось спектральное разрешение (например, до 144 каналов у прибора Hyperion спутника EO-1), на порядок возросло радиометрическое разрешение (например, до 14 бит у сканера MODIS спутников Terra и Aqua) и т.д. Это, в свою очередь, привело к тому, что спутниковые снимки нового качества представляют собой ценную информацию, которая может эффективно использоваться для решения многих задач сельского хозяйства, мониторинга природных ресурсов и экологического мониторинга.

Одна из важнейших задач при обработке спутниковых данных – классификация подстилающей поверхности. Это связано с тем, что данные о типах поверхности используются во многих региональных и глобальных моделях климата и экосистем [39], для оценки биоразнообразия [40] и при решении других задач. Стоит также отметить, что задача классификации – одна из приоритетных в рабочем плане по разработке системы GEOSS на 2007–2009 гг. В частности, с исследованиями в этом направлении связаны два рабочих пакета: "EC-07-P1 Global Vegetation and Land Cover" и "EC-07-P2 Global Forest Monitoring".

В настоящее время существует множество программ для создания продуктов по классификации земной поверхности, которые различаются системами классификации, покрытием, используемыми данными, технологиями построения и методами обработки. Среди них прежде всего следует отметить европейский проект Corine [41], американский National Land Cover Data (NLCD) [42], которые в качестве основы используют данные спутника Landsat, а также MODIS Land Cover and Land-Cover Change [43], который использует данные прибора MODIS спутника Terra и глобальную систему классификации программы International Geosphere-Biosphere Program (IGBP) [44]. Отметим, что для территории Украины доступны лишь данные по глобальной классификации земной поверхности с разрешением не менее 1 км. Поэтому задача создания продуктов с использованием данных более высокого разрешения остается актуальной.

4.1. Обзор существующих подходов к классификации данных ДЗЗ

Наибольшее распространение получили такие подходы к решению задач классификации, как статистические [45] и нейросетевые методы [13]. В настоящее время при выборе подхода к классификации земного покрова по данным ДЗЗ зачастую предпочтение отдается нейросетевым методам. НС обеспечивают адаптивный и устойчивый подход к анализу и обобщению информации, который не требует априорных знаний о статистическом распределении данных. Например, в работе [46] НС сравниваются со статистическим параметрическим методом для обработки изображений спутника Landsat/MSS и топографических данных. Анализ показал, что в случае, когда статистическое распределение данных неизвестно, нейросетевой метод классификации более предпочтителен.

Существующее разнообразие различных нейросетевых архитектур и методов обучения НС позволяет выбрать наиболее оптимальную для поставленной задачи конфигурацию, найти компромисс между скоростью, размерностью сети и эффективностью работы. В то же время такое разнообразие возможностей приводит к необходимости проведения большого количества экспериментов для получения достоверных и наиболее соответствующих задаче вариантов решения.

В работах [47, 48] анализируется возможность применения многослойного персептрона для классификации данных ДЗЗ. Результаты работы многослойного персептрона сравнивались с методом классификации Байеса, и получено подтверждение того, что с помощью многослойного персептрона (MLP) можно получить достоверные результаты. В [49] рассмотрены примеры использования MLP для классификации данных ДЗЗ. Авторы этой работы предлагают интересную комбинацию алгоритмов кластеризации и моделей дисперсии для обучения MLP в тех случаях, когда нет точных данных.

В работе [50] предложена самоорганизующаяся экспертная система для выявления взаимосвязей между объектами на космических изображениях. Работа такой системы основана на использовании НС типа ARTMAP. В работе [51] предложена и описана структурированная НС для классификации спутниковых данных. Архитектура «одна сеть – один класс» предлагается для улучшения разделения данных. Каждая сеть обеспечивается нейронной сетью на основе радиальной базисной функции. В работе [52] для классификации изображений, полученных радаром

с синтезированной апертуры (ERS-2/SAR), предложен подход, который основан на использовании древовидных НС. По мнению авторов, такая архитектура позволяет интерпретировать работу нейронной сети.

Во всех перечисленных работах чаще всего выбирается один тип НС без указания аргументов в пользу избранного подхода. Поэтому возникает необходимость сравнительного анализа результатов применения различных НС и методов их обучения для получения количественных данных об эффективности их применения.

В докладах [53, 54] проанализированы различные нейросетевые и статистические подходы к классификации данных ДЗЗ – такие, как многослойный персептрон, обучаемый по методу обратного распространения ошибки [55], EDBD (Extended-Delta-Bar-Delta) [56], НС типа ARTMAP [57], основанная на теории адаптивного резонанса [58]. Статистическая классификация космических изображений выполнялась с использованием метода максимального правдоподобия. Для разных классов лучшие результаты – наибольшее количество правильно классифицированных образов – достигались разными методами, что объясняется сложностью топологии исходных данных.

В данной главе исследования, результаты которых опубликованы в [53, 54, 59], развиваются путем применения методов обучения НС второго порядка и использования сетей на основе радиальных базисных функций для обработки данных спутника Landsat. Основные приведенные результаты опубликованы в работе [60].

4.2. Выбор данных для обучения НС

Для обучения НС требуется обучающий набор данных, на основании которых проводится обучение. Необходимость выполнения многократных экспериментов приводит к тому, что обучающее множество начинает играть ключевую роль в выборе модели, т.е. результат обучения становится отражением корректности подбора обучающих данных. Для получения независимого критерия качества модели необходимо контрольное множество, которое используется один раз при проверке результатов обучения сети. При большом количестве экспериментов есть риск выбрать «удачную» сеть, дающую хороший результат на контрольном множестве. Чтобы этого избежать, используют еще одно множество наблюдений – тестовое. Для формирования контрольного и тестового множеств применяют метод перекрестной проверки (cross-

validation) [61]. Имеющиеся данные случайным образом разбиваются на обучающее, контрольное и тестовое множества. После каждого этапа обучения они меняются местами. Показателем качества обучения служит усредненная по контрольным выборкам ошибка. Такой метод позволяет избежать подстраивания параметров сети под определенный набор данных.

При отборе данных необходимо помнить несколько основных правил. Все множества – обучающее, контрольное, тестовое – должны быть репрезентативными как все вместе, так и каждое в отдельности. Иными словами, они должны содержать признаки и образы всех интересующих исследователя объектов. Если это условие не выполняется, то полученная модель работает неточно. Сеть обучается тому, чему проще всего обучиться, т.е. сеть нужно обучать на данных, которые содержат все условия. Еще лучше, когда количество наблюдений для каждого класса одинаково. Это позволяет избежать искажения результатов в пользу большего множества.

Далее рассмотрим НС, которые обучаются с учителем. Для таких сетей необходимо определить набор эталонных данных. Образы можно получить из нескольких источников. Эталонами могут быть результаты замеров на местности, приведенные к нужному виду. Кроме этого, данные о спектральных свойствах объектов можно получить в лаборатории или из библиотек спектральных кривых. Спектральные кривые обладают следующими важными свойствами:

1) отражают физиологические показатели растительности, характеризующие состояние растений (содержание хлорофилла, влажность, объем зеленой массы на исследуемом участке и т.д.);
2) показывают наличие антропогенных объектов на снимке (дороги, дома, плотность застройки);
3) содержат информацию о водных объектах.

Эти данные необходимо приводить к такому же виду, какой имеет информация, получаемая из космоса, в зависимости от количества каналов прибора и диапазонов измерения, а также с учетом функций отклика прибора [59]. Кроме перечисленных методов доступны данные международных программ, например проекта Corine по классификации наземных объектов [41].

Для сравнительного анализа работы различных НС с обучением с учителем было использовано изображение, полученное мультиспектральным прибором ETM+ спутника Landsat-7 [24, 62]. Прибор пре-

доставляет данные с пространственным разрешением 30 м. Для эксперимента взяты каналы с 1-го по 5-й и 7-й. Размерность входных векторов составляла 6 элементов. На выходе был представлен вектор из 8 элементов – по количеству определяемых классов. Для определения эталонных данных использовалась информация проекта Corine по классификации земной поверхности. На тестовом снимке определены следующие 8 классов (в скобках указан код классификации согласно проекту Corine): лиственный лес (311), хвойный лес (312), смешанный лес (313), пашня (211), пастбище (231), вода (51), искусственные материалы (1), открытая местность с разреженной растительностью (33) [53, 54].

4.3. Анализ применимости различных нейросетевых парадигм для решения задач классификации спутниковых данных

Существует множество различных архитектур и методов обучения НС. Каждая модификация создана для решения определенного класса задач. В программном пакете ST Neural Networks классификацию можно осуществлять с помощью многослойного персептрона, НС на основе радиальных базисных функций, НС Кохонена, вероятностной и линейной НС [63].

Для классификации используется номинальная выходная переменная, которая принимает конечное множество значений. Для разделения объектов более чем на два класса применяется номинальная переменная вида один-из-*N*. При таком кодировании на каждый класс выделяется один элемент, так что каждое конкретное состояние представляется значением 1,0 в одном соответствующем элементе и 0,0 – во всех других. Чтобы уверенно определить класс по набору выходных значений сеть должна решить, достаточно ли близки они к 0 или к 1. Для принятия такого решения по выходным значениям используются пороги принятия и отвергания, которые можно модифицировать в процессе обучения. При анализе выходных значений принадлежность элемента класса определяется в том случае, если значение соответствующего выходного элемента выше порога принятия, а всех остальных элементов – ниже порога отвергания. Если данное условие не выполняется, то класс не определяется.

4.3.1. Результаты работы MLP

Сеть MLP состоит из элементов, построенных в послойную топологию с прямой передачей сигнала [13]. Входной слой служит для ввода значений входных переменных. Каждый нейрон из скрытых слоев или выходного слоя соединен со всеми элементами предыдущего слоя (рис. 4.1). Определение количества промежуточных слоев и количества элементов в них – важный вопрос при конструировании сети. Чаще всего архитектуру сети определяют по результатам опытов. При классификации рассматривалась НС с одним скрытым слоем и различным количеством нейронов в нем: 5, 7, 15, 30, 45.

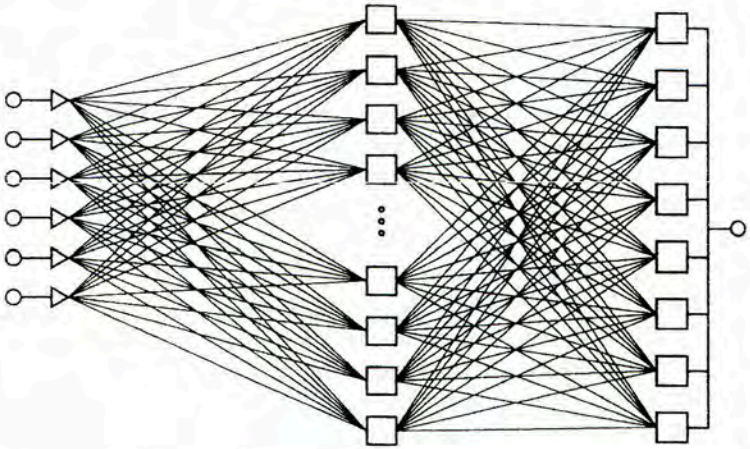


Рис. 4.1. Многослойный персептрон

В процессе обучения MLP фактически выполняется поиск значений весов и порогов каждого элемента, которые бы минимизировали ошибку прогноза, выдаваемого сетью. Иными словами, модель, реализуемая сетью, подгоняется под имеющиеся обучающие данные. Ошибка работы сети (функция ошибок) – результат сравнения результатов сети с целевыми значениями.

Существуют разнообразные алгоритмы обучения MLP. Эффективность их применения зависит от исходных данных, класса поставленной задачи и требуемого результата.

4.3.2. Анализ работы алгоритма обучения MLP Back Propagation

Минимизация функционала ошибки выполняется с использованием метода градиентного спуска:

$$W(t) = W(t-1) - \eta \frac{\partial E}{\partial W}(t),$$

где η – параметр скорости обучения, $E(t)$ – квадрат ошибки сети на t-м шаге обучения, W – матрица весов.

Градиент вычисляется с помощью метода обратного распространения. Алгоритм обратного распространения действует итеративно. На каждом шагу (эпохе) на вход сети подаются обучающие входные данные, выходные результаты работы сети сравниваются с эталонными данными и вычисляется ошибка. Значение ошибки используется для корректировки весов, после чего все действия повторяются. Процесс обучения прекращается после достижения нужного уровня ошибки [55].

Размерность входных векторов составляет 6 элементов. На выходе одна номинальная переменная, принимающая 8 значений – по числу классов. Количество элементов в скрытом слое варьируется между 5 и 45 нейронами (см. рис. 4.1). В обучающем множестве используется порядка 100 тысяч векторов. Тестовое и контрольное множества содержат 1 тысячу векторов данных.

Для начала были проведены эксперименты по поиску оптимального количества нейронов в скрытом слое. При анализе результатов работы сети принимались во внимание те сети, процесс обучения которых занимает как можно меньше времени, но при этом такая сеть должна дать достаточно хорошие результаты классификации. После сравнения НС с 5, 7, 15, 30 и 45 нейронами при равных других условиях сделан выбор в пользу сети с 15 нейронами в скрытом слое. Обучение такой сети занимает на заданной выборке данных 150 секунд (вычисления проводились на компьютере Pentium 4 с 1 Гб оперативной памяти), и при этом увеличение количества нейронов приводит лишь к замедлению в три раза работы НС без достаточно заметного улучшения результатов классификации. Например, на 50 эпохах НС с 15 нейронами в скрытом слое давала в среднем результат 87,2 %, а с 45 нейронами – 89,0 %.

Дальнейшие эксперименты были направлены на поиск оптимальных параметров обучения выбранной сети – коэффициентов обучения, коэффициентов принятия-непринятия, количества эпох обучения.

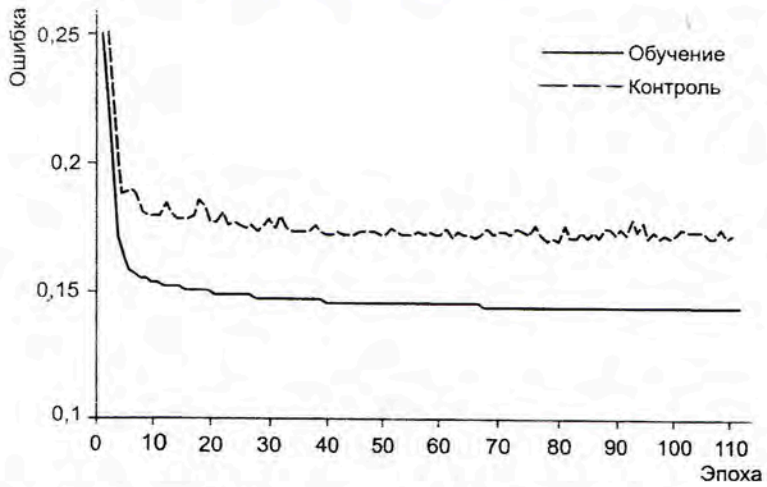


Рис. 4.2. График среднеквадратичной ошибки обучения НС на обучающем и контрольном множествах

Анализ хода обучения НС показал, что нет необходимости использовать более 50 эпох обучения, так как уже после 40 эпох ошибка сети значительно снижается и в последующем остается практически неизменной (рис. 4.2), соответственно и увеличение количества эпох с 50 до 100 на результаты классификации влияет незначительно.

Ход обучения НС (см. рис. 4.2) и скорость ее обучения во многом зависят от параметров обучения. Чем меньше коэффициент обучения, тем точнее будет результат вычисления весов, но тем дольше будет продолжаться весь процесс обучения. Второй параметр обучения – фактор момента, который определяет степень влияния на весовые коэффициенты изменений, сделанных на предыдущих шагах. Плавно изменяющийся график подтверждает корректный подбор параметров обучения НС.

При решении задач классификации важную роль играют коэффициенты принятия/непринятия. Номинальные переменные, служащие признаком принадлежности к классу, принимают значения в интервале от 0 до 1. Принадлежность к классу определяется порогом принятия: если значение соответствующего элемента переменной выше порога

принятия, а значения остальных элементов ниже уровня непринятия, то заданный объект принадлежит к соответствующему классу. Рис. 4.3 иллюстрирует принцип работы номинальных переменных. Здесь наиболее ярко выделены те элементы, уровень активации которых близок к 1 (выходные переменные VAR_2 = 0,1452, VAR_3 = 0,0608, VAR_4 = 0,0063, VAR_5 = 0,8131). Незаштрихованные элементы имеют низкий уровень активации, близкий к 0 (выходные переменные VAR_1, VAR_6, VAR_7, VAR_8). Победителем становится элемент, значение которого выше порога принятия – VAR_5; значит, заданный объект принадлежит к 5-му классу.

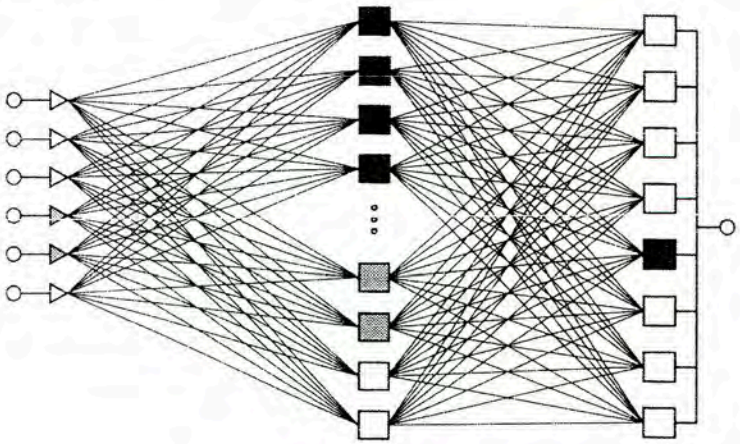


Рис. 4.3. Уровни активации и принцип работы номинальных переменных

После ряда экспериментов с обучением MLP методом обратного распространения ошибки были определены наилучшие, с точки зрения скорости и результатов классификации, параметры НС: архитектура сети – один скрытый слой с 15 нейронами; параметры классификации – порог принятия 0,1, порог непринятия 0,9; параметры обучения – 50 эпох, коэффициент скорости обучения 0,25, момент обучения 0,3.

Материалы табл. 4.1–4.3 свидетельствуют о том, что менее точным есть определение принадлежности объектов к классу «смешанный лес» (3). Это объясняется схожестью спектральных характеристик всех классов лесов.

Таблица 4.1. **Статистика классификации для обучающего множества по результатам работы MLP, %**

Номер	Класс	1	2	3	4	5	6	7	8	Всего
1	Лиственный лес	99,35	0,01	0,65	0,01	0,03	1,69	0,42	0,00	
2	Хвойный лес	0,00	95,95	51,69	0,44	4,47	0,04	0,13	0,00	
3	Смешанный лес	0,30	3,13	46,38	0,12	0,03	0,19	0,14	0,00	
4	Пашня	0,04	0,03	0,29	91,15	4,08	0,84	9,22	0,58	
5	Пастбище	0,00	0,83	0,79	5,53	90,80	0,44	2,20	0,08	
6	Вода	0,16	0,00	0,01	0,02	0,00	96,2	0,15	0,00	
7	Искусственные материалы	0,14	0,01	0,04	2,59	0,45	0,55	84,29	7,25	
8	Открытая местность	0,00	0,00	0,00	0,08	0,01	0,00	3,32	92,0	
Всего										
Правильно		99,35	95,95	46,38	91,15	90,80	96,20	84,29	92,00	88,91
Ошибочно		0,63	4,02	53,47	8,79	9,07	3,74	15,57	7,91	11,02
Неизвестно		0,02	0,02	0,15	0,05	0,14	0,06	0,14	0,08	0,07

Таблица 4.2. **Статистика классификации для контрольного множества по результатам работы MLP, %**

Номер	Класс	1	2	3	4	5	6	7	8	Всего
1	Лиственный лес	99,52	0,00	0,48	0,00	0,00	0,55	0,42	0,00	
2	Хвойный лес	0,00	95,29	45,74	0,53	3,75	0,00	0,34	0,00	
3	Смешанный лес	0,10	3,75	52,51	0,15	0,00	0,18	0,17	0,00	
4	Пашня	0,00	0,00	0,19	91,36	4,50	0,55	11,18	0,00	
5	Пастбище	0,00	0,95	0,97	4,97	90,78	0,28	2,61	0,00	
6	Вода	0,19	0,00	0,00	0,08	0,00	97,98	0,17	0,00	
7	Искусственные материалы	0,00	0,00	0,00	2,69	0,75	0,37	80,92	8,06	
8	Открытая местность	0,00	0,00	0,00	0,19	0,00	0,00	4,03	91,94	
Всего										
Правильно		99,52	95,29	52,51	91,36	90,78	97,98	80,92	91,94	88,37
Ошибочно		0,29	4,71	47,39	8,61	9,00	1,93	18,91	8,06	11,54
Неизвестно		0,19	0,00	0,10	0,04	0,21	0,09	0,17	0,00	0,09

Таблица 4.3. **Статистика классификации для тестового множества по результатам работы MLP, %**

Номер	Класс	1	2	3	4	5	6	7	8	Всего
1	Лиственный лес	99,57	0,00	0,09	0,00	0,00	0,76	0,35	0,00	
2	Хвойный лес	0,00	94,60	45,64	0,15	4,35	0,00	0,00	0,00	
3	Смешанный лес	0,11	4,63	53,36	0,07	0,11	0,00	0,17	0,00	
4	Пашня	0,11	0,05	0,27	91,21	4,14	0,76	12,51	0,94	
5	Пастбище	0,00	0,72	0,55	6,00	90,46	0,10	2,36	0,00	
6	Вода	0,11	0,00	0,00	0,00	0,00	97,81	0,35	0,00	
7	Искусственные материалы	0,11	0,00	0,00	2,46	0,64	0,48	81,36	9,43	
8	Открытая местность	0,00	0,00	0,00	0,11	0,00	0,00	2,80	89,62	
Всего										
Правильно		99,57	94,60	53,36	91,21	90,46	97,81	81,36	89,62	87,94
Ошибочно		0,43	5,40	46,55	8,79	9,23	2,09	18,55	10,38	12,00
Неизвестно		0,00	0,00	0,09	0,00	0,32	0,10	0,09	0,00	0,06

4.3.3. Анализ работы метода обучения EDBD (Extended Delta-bar-Delta)

Этот метод обучения сети основан на индивидуальном для каждого веса подборе коэффициентов скорости обучения. При обучении НС методом EDBD используется параметр момента связи, который представляет собой число, пропорциональное предыдущему изменению веса:

$$\partial W(t+1) = \eta(t) g(t) + m(t) \partial W(t),$$

где η – параметр скорости обучения, m – значение момента связи, g – градиент изменения весов, W – матрица весов (используется для ускорения обучения).

В процессе классификации с использованием MLP процедура перекрестной проверки выполнялась для НС с одним скрытым слоем и разным количеством скрытых нейронов: 5, 15, 20, 25, 35 и 45. При этом для обучения НС использовался метод EDBD. Количество эпох составляло 500, начальное значение коэффициента обучения – 0,7, значение фактора момента – 0,5. Наибольшее количество правильно классифицированных векторов (88,85 %) получено для НС с 45 скрытыми нейронами (табл. 4.4).

Таблица 4.4. **Результаты обучения MLP методом EDBD, %**

Номер	Класс	Архитектура НС (количество скрытых нейронов)					
		5	15	20	25	35	45
1	Лиственный лес	97,63	98,78	98,99	99,02	99,15	98,97
2	Хвойный лес	80,95	83,57	83,99	84,20	84,64	85,67
3	Смешанный лес	67,09	68,70	68,12	68,38	68,00	67,37
4	Пашня	85,44	87,72	88,24	89,03	89,84	89,56
5	Пастбище	86,16	90,42	91,55	90,41	91,01	91,43
6	Вода	97,14	97,71	97,66	97,75	97,63	97,64
7	Искусственные материалы	69,09	83,45	84,09	83,99	83,46	83,56
8	Открытая местность	95,57	96,82	96,28	96,53	96,79	96,52
Всего		84.88	88,40	88,62	88,68	88,81	88,85

4.3.4. Анализ работы алгоритма обучения сопряженных градиентов (Conjugate Gradient)

Метод сопряженных градиентов – это алгоритм обучения MLP, который осуществляет последовательный линейный поиск в пространстве ошибок, выбирая при поиске не противоречащие друг другу (сопряженные) направления. Найдя точку минимума вдоль некоторой прямой, выбираем сопряженное направление таким образом, чтобы производная и дальше оставалась нулевой. Поскольку на каждом шаге обучения метод проводит вычисления по всему набору данных, то при наличии большого количества образов обучения значительно замедляется обучение сети. Например, для сети с параметрами 6–15–8 обучение в 50 эпох длилось около 24 минут. При этом результаты классификации составили всего 65 %. Дальнейшие эксперименты значительных улучшений по классификации не дали.

4.3.5 Анализ результатов работы квази-ньютоновского метода обучения второго порядка

Квази-ньютоновский метод – это улучшенный метод обучения MLP. В процессе обучения процедура нелинейного оценивания анализирует функцию потерь в различных точках для определения направ-

ления изменения параметров. Такие вычисления требуют большого количества системных ресурсов и замедляют процесс обучения [13].

Результаты применения квази-ньютоновского метода обучения представлены в табл. 4.5. При этом в качестве основы использовалась сеть с архитектурой 6–15–8, т.е. сеть с одним скрытым слоем из 15 нейронов. Эксперименты показали, что использование квази-ньютоновского метода дает достаточно хорошие результаты только после 500 эпох обучения, а это занимает слишком много времени. Увеличение количества нейронов в скрытом слое приводит к увеличению времени обучения, но не дает достаточно хороших результатов (табл. 4.6).

Таблица 4.5. **Результаты обучения сети квази-ньютоновским методом (архитектура сети 6–15–8)**

Количество эпох	Время, с	Обучение	Контроль	Тест
50	150	64,3	52,0	53,2
100	300	66,4	56,2	58,4
150	600	67,7	57,6	61,6
200	900	74,4	66,6	68,0
500	1800	85,8	86,8	85,4

Таблица 4.6. **Результаты обучения сети квази-ньютоновским методом (обучение в течение 100 эпох)**

Архитектура сети	Время, с	Обучение	Контроль	Тест
6–5–8	150	63,8 %	54,6 %	54,6 %
6–7–8	180	51,7 %	53,6 %	48,0 %
6–15–8	300	66,4 %	56,2 %	58,4 %
6–30–8	540	70,6 %	62,0 %	59,6 %
6–45–8	900	70,6 %	65,2 %	67,2 %

Сопоставление всех рассмотренных методов и результатов их применения приводит к выводу, что метод обратного распространения предпочтительнее, когда объем данных очень велик и требуется быстро найти решение.

4.3.6. Применение НС на основе радиальных базисных функций (RBF)

НС на основе RBF состоят из одного скрытого слоя, выполняющего нелинейное преобразование входных данных, и выходного слоя из линейных элементов (рис. 4.4) [13].

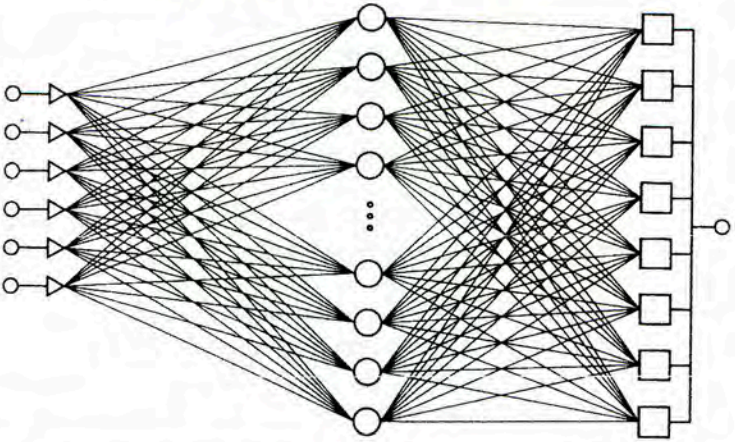


Рис. 4.4. Радиальная базисная функция

Чаще всего в качестве RBF используется гауссовское распределение, которое задается центром и отклонением:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp - \frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2,$$

$$-\infty < x < \infty, \quad \sigma > 0, \quad -\infty < \mu < \infty,$$

где μ – среднее, σ – стандартное отклонение.

Обучение сети RBF происходит в несколько этапов. Сначала определяются центры и отклонения радиальных элементов, затем оптимизируются параметры линейного выходного слоя.

Расположение центров должно соответствовать кластерам, реально присутствующим в исходных данных. Для их определения чаще всего используются два метода: выбор значений из самой выборки и алгоритм *K*-средних. В первом случае в качестве центров выбираются несколько случайных точек избранного множества. Во втором случае

алгоритм стремится выбрать такие центры, которые соответствовали бы центрам кластеров обучающих данных.

Величина отклонений определяет насколько точно сеть может интерполировать данные между известными точками. Иначе говоря, необходимо найти такие отклонения, при которых сеть будет обладать способностью к обобщению данных. Есть несколько способов определения отклонений. В случае явного определения отклонения задаются пользователем. При изотропном определении отклонения вычисляют с учетом количества радиальных элементов и устанавливают равными для всех. Другой метод – K ближайших соседей – устанавливает отклонения индивидуально для каждого элемента и позволяет учитывать детали.

После того как выбраны параметры радиальных элементов, с помощью стандартного метода линейной оптимизации определяют параметры выходного слоя.

Результаты работы НС на основе RBF

Сначала необходимо определить количество радиальных элементов в скрытом слое. Для этого был проведен ряд экспериментов, результаты которых приведены в табл. 4.7. Они показывают, что достаточно эффективной работы сети можно добиться при 20 и более нейронов в скрытом слое. Дальнейшее увеличение количества скрытых нейронов приводит к значительному замедлению работы НС, как на этапе обучения, так и на этапе тестирования.

Таблица 4.7. **Подбор архитектуры НС на основе RBF**

Архитектура сети	Обучение	Контроль	Тест	Время обучения, с
6–4–8	62,52	58,40	56,40	30
6–6–8	69,50	64,80	65,80	30
6–7–8	70,27	65,60	66,20	40
6–15–8	69,50	64,80	65,80	60
6–20–8	83,55	82,60	82,20	85
6–30–8	85,31	84,00	85,20	120
6–40–8	86,43	85,20	86,00	180
6–50–8	86,63	86,60	86,60	240

Разные методы определения центров и отклонений радиальных элементов приводят к различным результатам классификации. Чаще всего расчет коэффициентов индивидуально для каждого элемента незначительно улучшает работу НС, но при этом сильно замедляет процесс обучения. Результаты классификации с использованием RBF-сетей даны в табл. 4.8–4.11.

Таблица 4.8. **Результаты классификации сети на основе RBF для обучающего множества, %**

Номер	Класс	1	2	3	4	5	6	7	8	Всего
1	Лиственный лес	99,97	0,19	9,14	0,62	0,17	8,14	2,14	1,53	
2	Хвойный лес	0,00	92,89	44,38	0,37	5,14	0,02	0,10	0,00	
3	Смешанный лес	0,00	5,53	44,31	0,03	0,03	0,00	0,04	0,00	
4	Пашня	0,01	0,54	1,13	95,85	23,24	1,66	16,11	0,95	
5	Пастбище	0,00	0,66	0,52	1,63	70,79	0,12	1,56	0,04	
6	Вода	0,00	0,00	0,01	0,01	0,00	89,76	0,08	0,00	
7	Искусственные материалы	0,02	0,00	0,00	1,31	0,20	0,18	76,94	12,32	
8	Открытая местность	0,00	0,00	0,00	0,14	0,18	0,00	2,80	85,15	
Всего										
Правильно		100,0	92,9	44,3	95,9	70,8	89,8	76,9	85,2	86,3
Ошибочно		0,0	6,9	55,2	4,1	29,0	10,1	22,8	14,8	13,6
Неизвестно		0,0	0,2	0,5	0,0	0,3	0,1	0,2	0,0	0,2

Таблица 4.9. **Результаты классификации сети на основе RBF для контрольного множества, %**

Номер	Класс	1	2	3	4	5	6	7	8	Всего
1	Лиственный лес	99,89	0,23	6,45	0,43	0,18	7,95	1,47	1,13	
2	Хвойный лес	0,00	90,29	36,43	0,23	3,96	0,00	0,10	0,00	
3	Смешанный лес	0,00	7,98	54,20	0,00	0,00	0,00	0,10	0,00	
4	Пашня	0,00	0,52	1,41	96,29	20,74	2,77	21,37	1,69	
5	Пастбище	0,00	0,70	0,44	1,96	74,56	0,00	2,25	0,00	
6	Вода	0,00	0,00	0,00	0,00	0,00	88,91	0,10	0,00	
7	Искусственные материалы	0,00	0,00	0,00	0,86	0,28	0,18	70,88	13,56	
8	Открытая местность	0,11	0,00	0,00	0,17	0,09	0,00	2,94	83,62	
Всего										
Правильно		99,9	90,3	54,2	96,3	74,6	88,9	70,9	83,6	85,0
Ошибочно		0,1	9,4	44,7	3,6	25,3	10,9	28,3	16,4	14,7
Неизвестно		0,0	0,3	1,1	0,1	0,2	0,2	0,8	0,0	0,3

Таблица 4.10. **Результаты классификации сети на основе RBF для тестового множества, %**

Номер	Класс	1	2	3	4	5	6	7	8	Всего
1	Лиственный лес	99,87	0,39	7,92	0,43	0,20	5,38	1,34	0,98	
2	Хвойный лес	0,00	88,84	32,58	0,20	4,58	0,00	0,08	0,00	
3	Смешанный лес	0,00	9,66	57,69	0,07	0,00	0,00	0,00	0,00	
4	Пашня	0,13	0,44	0,64	97,05	16,72	1,76	22,39	2,94	
5	Пастбище	0,00	0,50	0,36	1,32	77,81	0,11	1,92	0,00	
6	Вода	0,00	0,00	0,00	0,00	0,00	92,64	0,00	0,00	
7	Искусственные материалы	0,00	0,00	0,00	0,83	0,40	0,00	70,84	16,67	
8	Открытая местность	0,00	0,00	0,00	0,07	0,10	0,00	3,09	79,41	
Всего										
Правильно		99,9	88,8	57,7	97,1	77,8	92,6	70,8	79,4	85,6
Ошибочно		0,1	11,0	41,5	2,9	22,0	7,3	28,8	20,6	14,2
Неизвестно		0,0	0,2	0,8	0,0	0,2	0,1	0,3	0,0	0,2

4.3.7. Применение НС на основе теории адаптивного резонанса для классификации

Теория адаптивного резонанса ART (Adaptive Resonance Theory) призвана решить проблему стабильности–пластичности, которая состоит в следующем: память должна оставаться пластичной, т.е. способной к запоминанию новых образов, но при этом сохранять стабильность, которая гарантирует, что образы не будут уничтожаться и разрушаться в процессе функционирования НС. В настоящее время разработаны разные типы НС на основе теории ART. Для классификации данных ДЗЗ авторы используют сеть типа ARTMAP.

ARTMAP представляет собой НС, обучаемую с учителем, которая состоит из двух взаимосвязанных самоорганизующихся модулей: ART*a* и ART*b*. При обучении на вход ART*a* подается входной вектор *a*, а на вход ART*b* – желаемый вектор *b*. Каждый из этих модулей относит свой входной вектор к одному из нейронов (категории) выходного слоя. При этом категории модулей ART*a* и ART*b* связаны ассоциативной сетью. Если входной вектор не соответствует ни одной из запомненных ранее категорий (этот процесс контролируется параметром подобия ρ (vigilance parameter)), то создается новая путем запоминания образа. Новый образ может создавать дополнительные классификационные категории, но не может заставить измениться существующую память. Кроме того, новые

категории будут создаваться в том случае, если категории входного вектора a и желаемого выхода b не будут соответствовать друг другу. Более подробное описание принципов работы НС ARTMAP можно найти в работах [57, 64].

Для моделирования работы сети ARTMAP авторами использовалось программное обеспечение ClasserScript v1.1 [65], доступное на Web-узле http://profusion.bu.edu/techlab/.

Таблица 4.11. **Статистика классификации по результатам работы НС на основе ART**

Номер	Класс	Параметры подобия					Всего
		0,1	0,2	0,3	0,5	0,95	
1	Лиственный лес	98,92	99,68	99,56	98,52	99,88	99,31
2	Хвойный лес	79,58	80,86	80,34	79,16	80,88	80,16
3	Смешанный лес	69,14	68,16	68,66	69,36	68,14	68,69
4	Пашня	81,50	81,50	81,72	81,88	83,50	82,02
5	Пастбище	76,48	74,26	75,34	74,10	78,94	75,82
6	Вода	96,70	96,60	96,76	97,40	93,76	96,24
7	Искусственные материалы	79,38	77,28	78,32	77,12	76,78	77,78
8	Открытая местность	96,42	97,36	97,00	97,54	98,24	97,31
Всего		83,68	83,80	83,74	83,24	84,22	83,74

Для формирования обучающего и тестового множеств применялась пятикратная перекрестная проверка в качестве статистического средства проверки достоверности результатов классификации. В рамках такого подхода исходное множество эталонных образов разбивается на пять подмножеств одинакового размера, т.е. каждое такое подмножество содержит около 20 % данных каждого класса. Обучение нейросетевых моделей и настройка параметров нормального распределения с применением метода наибольшего правдоподобия выполняются на всех подмножествах, кроме одного. На этом оставшемся подмножестве проводится тестирование и вычисляется количество правильно классифицированных образов: CR и CRi ($i = \overline{1, L}$). Такая процедура повторяется пять раз, при этом каждый раз для тестирования используются разные подмножества, не применяемые при обучении.

Были приняты такие значения параметра подобия ρ: 0,1; 0,2; 0,3; 0,5; 0,95. Для обучения использовалась одна эпоха. Увеличение количества эпох не приводило к увеличению количества правильно классифицированных образов. Наибольшие количества правильно классифицированных векторов (84,22 %) получено для НС ρ = 0,95 (табл. 4.11).

Сравнительный анализ применения для решения рассматриваемой задачи различных нейросетевых архитектур приведен в табл. 4.12.

4.4. Сравнительный анализ результатов нейросетевой классификации

Таблица 4.12. **Сравнение результатов работы различных нейросетевых архитектур, %**

Номер	Архитектура сети Класс	Обратного распространения ошибки	Квази-ньютоновский	Сопряженных градиентов	РБФ	ARTMAP
1	Лиственный лес	99,6	100,0	99,9	99,9	99,3
2	Хвойный лес	94,6	98,3	96,3	88,8	80,2
3	Смешанный лес	53,4	0,5	35,2	57,7	68,7
4	Пашня	91,2	87,2	92,7	97,1	82,0
5	Пастбище	90,5	0,0	0,0	77,8	75,8
6	Вода	97,8	0,0	0,0	92,6	96,2
7	Искусственные материалы	81,4	58,8	67,2	70,8	77,8
8	Открытая местность	89,6	0,0	0,0	79,4	97,3
Всего		87,9	58,5	64,35	85,6	83,7

Анализ результатов проведенных экспериментов показывает, что для разных классов наилучший результат достигается разными методами. Это можно объяснить сложностью входных данных и сложными свойствами разделимости. В среднем по всей выборке данных наилучшие результаты дает MLP, обученный методом обратного распространения ошибки. Кроме того, обучение этим методом занимает значительно меньше времени.

4.5. Сравнение результатов нейросетевых и статистических методов классификации спутниковых данных

Метод наибольшего правдоподобия – один из самых популярных статистических методов, используемых для классификации данных ДЗЗ. Этот метод относит входной вектор (образ) к тому классу, для которого

значение апостериорной вероятности максимально. В случае использования многомерного распределения Гаусса апостериорная вероятность имеет следующий вид:

$$f_i(x|\mu_i,\Sigma_i) = (2\pi)^{\frac{p}{2}}|\Sigma_i|^{\frac{1}{2}}\exp\left(-\frac{1}{2}(x-\mu_i)^{\mathrm{T}}(\Sigma_i)^{-1}(x-\mu_i)\right). \qquad (4.1)$$

Здесь μ_i и Σ_i – соответственно вектор математического ожидания и ковариационная матрица для i-го класса, L – количество классов, $x \in \mathbf{R}^p$ – входной вектор. В случае равномерного распределения классов принадлежность входного вектора к тому или иному классу определяется выражением

$$x \in \hat{i} \Leftrightarrow \hat{i} = \arg\max_{1 \le i \le L} d_i(x), \qquad (4.2)$$

где

$$d_i(x) = \ln(f_i(x)) = -\frac{1}{2}\left((x-\mu_i)^{\mathrm{T}}(\Sigma_i)^{-1}(x-\mu_i) + \ln|\Sigma_i|\right) + C.$$

На практике, как правило, параметры распределений неизвестны. Поэтому вектор математического ожидания μ_i и ковариационную матрицу Σ_i определяют на основе данных обучающего множества. Так, для математического ожидания используют оценку

$$\hat{\mu}_i = \frac{1}{M_i}\sum_{j=1}^{M_i} x_i^j, \qquad (4.3)$$

где x_i^j – j-й образ, относящийся к классу i; M_i – количество обучающих образов класса i.

Для ковариационной матрицы

$$\hat{\Sigma}_i = \frac{1}{M_i - 1}\sum_{j=1}^{M_i}(x_i^j - \hat{\mu}_i)(x_i^j - \hat{\mu}_i)^{\mathrm{T}}. \qquad (4.4)$$

К недостаткам метода максимального правдоподобия следует отнести:

- необходимость достаточного набора образов обучающего множества для оценки параметров распределения Гаусса: вектора математического ожидания и ковариационной матрицы;
- необходимость вычисления обратной ковариационной матрицы, которая становится вырожденной в случае значительной корреляции

между компонентами входных векторов или наличия нерепрезентативной выборки данных;

- трудность использования в тех случаях, когда исходные данные не подчиняются заданному статистическому распределению (в нашем случае нормальному).

Результаты классификации на тестовом наборе данных с использованием метода максимального правдоподобия представлены в табл. 4.13.

Таблица 4.13. **Результаты перекрестной проверки для метода максимального правдоподобия**

Класс	Результат, %
1	98,73
2	83,68
3	67,68
4	89,66
5	92,82
6	96,57
7	82,18
8	96,75
Всего	88,02

Результаты сравнения нейросетевых классификаторов и метода максимального правдоподобия приведены в табл 4.14.

Таблица 4.14. **Результаты сравнения различных классификаторов, %**

Класс	Классификатор		
	MLP	Максимального правдоподобия	НС на основе ARTMAP
1	98,97	98,73	99,88
2	85,67	83,68	80,88
3	67,37	67,68	68,14
4	89,56	89,66	83,50
5	91,43	92,82	78,94
6	97,64	96,57	93,76
7	83,56	82,18	76,78
8	96,52	96,75	98,24
Всего	88,85	88,02	84,22

Наилучший результат (88,85 %) на всем тестовом множестве был получен для MLP, обучаемого по методу EDBD. Сравнивая результаты классификации отдельно по классам, получаем, что для разных классов наилучшие результаты классификации были достигнуты разными методами: для классов 2, 6 и 7 – MLP; для классов 1, 3 и 8 – НС на основе ARTMAP; для классов 4 и 5 – метод максимального правдоподобия. Наихудшие результаты классификации были получены для класса 3 «смешанный лес» (68,14 %). Это связано с тем, что в смешанном лесу есть и лиственные (класс 1), и хвойные деревья (класс 2), что приводит к смешиванию спектральных характеристик соответствующих объектов.

4.6. Обсуждение

В данной главе проведен сравнительный анализ нейросетевых и статистических методов для классификации данных ДЗЗ. Для этого использованы данные Landsat-7/ETM+, а также данные по классификации земной поверхности European Corine Land Cover 2000. Наилучшие результаты классификации получены с использованием MLP, обучаемого по методу EDBD. В то же время анализ результатов классификации для разных классов отдельно показал, что наилучшие результаты достигались разными методами. Это, по-видимому, связано со сложной структурой и топологией данных, которые использовались в настоящем исследовании. Поэтому для разных классов следует применять разные методы классификации.

С целью улучшения результатов классификации спутниковых снимков целесообразно проанализировать применение модульных НС, а также ассоциативных машин (committee machines). Эти подходы предусматривают использование разных компонентов в рамках единой архитектуры (например, НС с разными параметрами или комбинация нейросетевых и статистических методов).

Глава 5
ОЦЕНИВАНИЕ СОСТОЯНИЯ И ВИДОВОГО РАЗНООБРАЗИЯ РАСТИТЕЛЬНОСТИ

В Украине накоплен значительный опыт в решении прикладных задач с использованием космических данных, а также разработаны информационные системы, в том числе связанные с оцениванием состояния растительности и биоразнообразия [66]. В частности, задача оценивания видового разнообразия Причерноморского региона решалась в рамках инновационного проекта НАН Украины, выполняемого совместно ИКИ НАНУ–НКАУ и Национальным центром аэрокосмических исследований Земли (НЦАКИЗ) НАН Украины. В рамках данного проекта создан информационный сервис оценки видового разнообразия растительности Причерноморского региона Украины, который соответствует одному из приоритетных направлений развития системы GEOSS. Поскольку сервис реализован с учетом открытых стандартов и принципов развития системы GEOSS, то созданную информационную инфраструктуру можно рассматривать как пилотную версию украинского сегмента GEOSS. Разработанная пилотная информационная система основана на стандартах представления и передачи геопространственной информации, разрабатываемых в рамках международной инициативы INSPIRE [67]. В настоящее время сервис зарегистрирован среди 15 первых информационных сервисов пилотной архитектуры GEOSS.

Важный аспект рассматриваемых задач – естественная возможность распараллеливания процесса обработки данных. В задаче оценки состояния растительности параллельную обработку данных целесообразно реализовать с помощью модульных НС. Поскольку оценка биоразнообразия выполняется на основе разных продуктов обработки спутниковых данных, то процессы их получения и необходимые дальнейшие вычисления тоже естественным образом распараллеливаются.

В данной главе основное внимание уделяется роли интеллектуальных вычислений в решении рассматриваемых задач, а также способам эффективной реализации предложенных методов обработки.

5.1. Определение содержания хлорофилла в растениях с помощью модульных НС

Спектральные характеристики отраженного света – это удобный и высокоинформативный источник данных при дистанционном исследовании объектов. Их можно использовать для оценки состояния растительности с целью определения степени зараженности и загрязненности. В работах [68, 69] показано, что параметры спектральных кривых, отражающих зависимость интенсивности отражения от длины волны, связаны с основными физиологическими показателями, характеризующими состояние растений, в том числе с содержанием хлорофилла в тканях растений. Поэтому актуальна задача разработки методов выявления поврежденных растений (и определения их химического состава, в частности содержания хлорофилла) на основе спектральных кривых. Для решения подобной задачи в [70] используется метод компонентного анализа. Недостаток этого подхода заключается в необходимости вычисления матрицы корреляции при изменении множества экспериментальных данных, низкая помехоустойчивость метода, а также высокая вычислительная сложность. Поскольку задача определения химического состава (в данном случае концентрации хлорофилла) представляет собой задачу распознавания образов, ее целесообразно решать на основе интеллектуальных методов, в частности нейросетевых. Эффективный метод выявления поврежденных растений на основе экспериментальных данных и определения уровня хлорофилла в них рассмотрен в первой части настоящей главы [71].

5.1.1. Постановка задачи и обоснование метода решения

Пусть имеется множество экспериментальных данных о спектральных характеристиках отраженного излучения некоторого вида растений, представленных в виде набора кривых, иллюстрирующих зависимость интенсивности излучения от длины волны. Для каждой кривой экспериментально определен уровень хлорофилла в тканях растения.

Требуется построить эффективный метод выявления поврежденных растений и определения уровня хлорофилла в них.

В качестве экспериментальных данных используем спектральные кривые (рис. 5.1), полученные для озимой пшеницы в Институте физиологии растений и генетики НАН Украины [72].

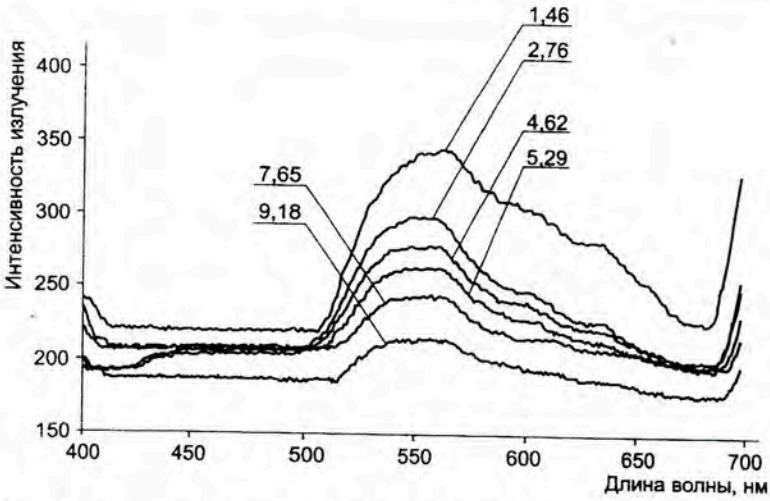


Рис. 5.1. Зависимость интенсивности отраженного излучения от длины волны при различных концентрациях хлорофилла

На рис. 5.1 видно, что спектральные кривые содержат около 350 точек, количество которых определяет размерность входного слоя сети. Очевидно, что при столь высокой размерности входных данных для обучения НС на большой выборке потребуется использовать сложную нейросетевую архитектуру и процесс обучения будет длительным. Уменьшить сложность решаемой задачи можно путем снижения размерности входного пространства (выделения информативных признаков) или за счет декомпозиции задачи на более простые. Выделение информативных признаков из входных данных представляет собой предмет отдельного исследования. Одним из подходов при его проведении может стать использование анализа главных компонентов или других, возможно нелинейных, методов самоорганизации. В данной работе сложность решаемой задачи предлагается снизить путем разбиения задачи на более простые и решения каждой подзадачи с помощью отдельной НС или так называемых модульных НС [73]. Впервые этот подход предложен в [74].

Идея применения модульных НС сводится к следующему. На первом этапе поступающие входные данные разбиваются на два класса – поврежденные и неповрежденные, а впоследствии более тщательно-

му анализу подвергаются только данные, классифицированные как поврежденные. Это существенно снижает количество обучающих примеров в задаче точного определения химического состава и тем самым сокращает время обучения НС, повышая ее производительность (в обучении не участвуют заведомо низкоинформативные данные). Предложенная идея экспериментально подтверждена на примере обработки спектральных характеристик озимой пшеницы.

5.1.2. Архитектура модульной НС

Для определения уровня поврежденности (зараженности) растений предлагается использовать модульную НС, в состав которой входят классификатор и интерполятор (рис. 5.2). Классификатор осуществляет предварительную сортировку данных (грубая классификация), которая заключается в разделении входных данных на два класса: поврежденные и неповрежденные. В качестве классификатора можно использовать любую подходящую для этой цели архитектуру (метод потенциальных функций, RBF-классификатор, RTC-классификатор и т.д.). Ввиду небольшого количества примеров в обучающей выборке для экспериментов была выбрана простейшая однослойная сеть персептронного типа, обучаемая с учителем. Если выход классификатора равен 0 (т.е. входной образ классифицирован как поврежденный), то он подается на вход интерполятора, выход которого отражает точное содержание хлорофилла в растении. В качестве интерполятора использовались многослойные НС прямого распространения. В эксперименте как метод обучения использовались алгоритм обратного распространения ошибки и методы оптимизации второго порядка.

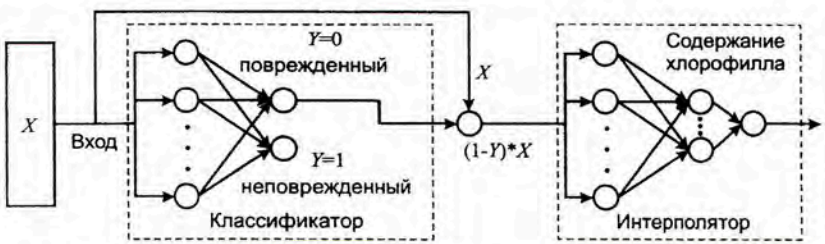


Рис. 5.2. Архитектура используемой модульной НС

5.1.3. Результаты экспериментов

Решение задачи классификации с помощью традиционной нейросетевой архитектуры. Прежде чем переходить к исследованию эффективности модульной архитектуры определим наилучшие параметры обучения НС, предположив, что задача решается с помощью единой сети, и найдем количественные показатели процесса обучения. Впоследствии воспользуемся ими для сравнения эффективности различных архитектур (модульной и традиционной).

Для решения задачи определения содержания хлорофилла использована следующая архитектура НС:

Количество скрытых слоев	1
Количество нейронов во входном слое	350
Количество нейронов в скрытом слое	10
Количество нейронов в выходном слое	1
Активационные функции входного и скрытого слоев	Сигмоидальные
Активационные функции выходного слоя	Линейные
Коэффициенты обучения для всех слоев	0,1
Моменты для всех слоев	0,15

Начальные значения матриц связей выбирались случайным образом из диапазона [–1, 1]. Сеть обучалась в режиме интерполятора с точностью 0,05 при значениях выходов, показанных в легенде на рис. 5.2.

Предложенная архитектура применялась для обучения сети на данных, графически представленных на рис. 5.1. Исходные данные отображают зависимость интенсивности отраженного излучения от длины волны. Для каждой зависимости проведен анализ содержания хлорофилла в растениях.

В экспериментах применялись НС прямого распространения, которые были обучены различными методами оптимизации первого и второго порядков для определения наиболее эффективного. Эксперименты проводились для различных начальных значений весовых коэффициентов и различных методов обучения первого и второго порядков.

Методы второго порядка показали свою нестабильность при работе с имеющимися данными. Так, метод обучения Флетчера–Пауэла [13]

не сходится, а метод Левенберга–Марквардта [13] дает очень нестабильные результаты (решения и скорость обучения существенно различаются для разных начальных приближений). Количество эпох обучения варьировалось от 117 до 456.

Метод обратного распространения ошибки применялся в двух режимах: кумулятивном и интерактивном. При кумулятивном режиме обучения ошибка на выходе сети снижается лишь до определенного уровня. Интерактивный метод обучения позволяет получить стабильные результаты для различных начальных приближений матриц связей. Длительность обучения при использовании данного метода составила порядка 2600 эпох.

Таким образом, для решения данной задачи оптимален метод обратного распространения ошибки при указанной архитектуре сети.

Проводились также эксперименты по выбору наилучших параметров обучения. На рис. 5.3–5.5 показаны зависимости количества эпох обучения (циклов обработки данных из обучающей выборки, состоящей из 9 элементов) от изменения коэффициента скорости обучения и момента. Как видно из этих рисунков, наилучшие значения такие: коэффициент скорости обучения – 0,06, фактор момента – 0,195. Именно эти значения следует применять в качестве первого приближения при использовании предложенной методологии для обработки больших объемов данных.

Полученные результаты далее используются для сравнения эффективности применения различных нейросетевых архитектур.

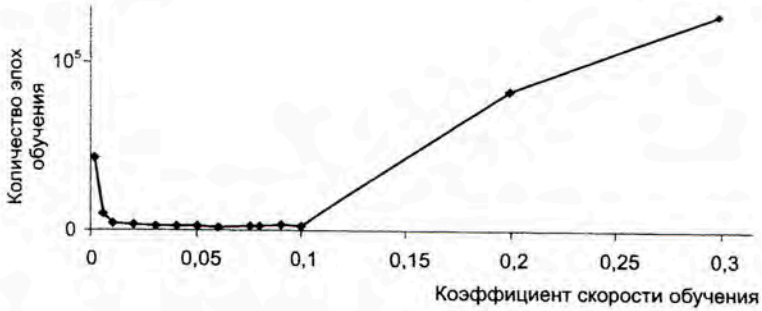


Рис. 5.3. Зависимость количества эпох обучения от коэффициента скорости обучения (в большом диапазоне)

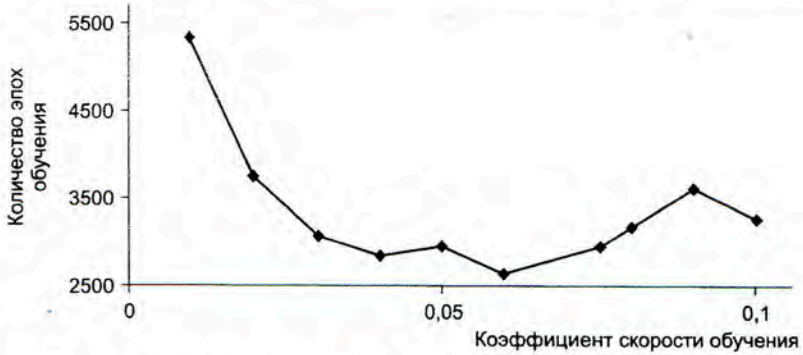


Рис. 5.4. Зависимость количества эпох обучения от коэффициента скорости обучения (в малом диапазоне)

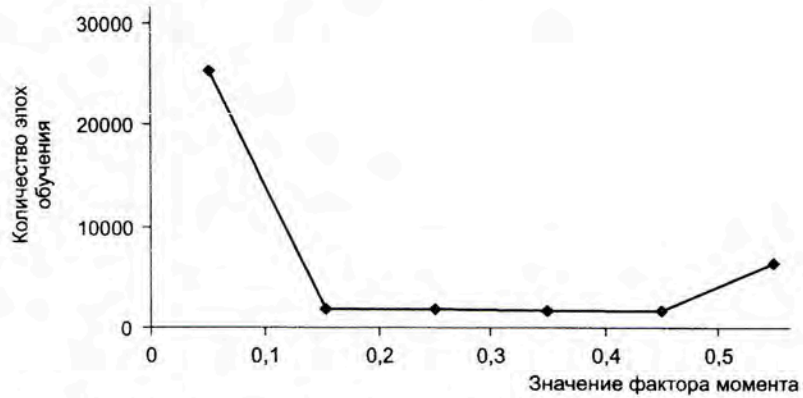


Рис. 5.5. Зависимость количества эпох обучения от фактора момента

Результаты экспериментов для модульной НС. Чтобы повысить эффективность применения НС для решения задачи определения концентрации хлорофилла предлагается использовать описанную модульную нейросетевую архитектуру.

Сначала требуется провести обучение классификатора на всем обучающем множестве. В качестве классификатора используется однослойная сеть персептронного типа двух модификаций.

1. Классификатор, содержащий в выходном слое два бинарных нейрона (каждый из которых соответствует отдельному классу). Еди-

ничное значение первого выходного нейрона соответствует неповрежденному растению, а единичное значение второго – поврежденному. Точность обучения – 0,45.

2. Классификатор со скалярным бинарным выходом. При этом 1 на выходе сети означает принадлежность входного вектора классу неповрежденных растений, а 0 – классу поврежденных. Точность обучения тоже составляла 0,45.

Практические эксперименты показали, что оба классификатора обучаются достаточно быстро (первый классификатор – за 300–400 эпох, а второй – около 20 эпох). Это свидетельствует о преимуществе второй модификации классификатора.

Теперь рассмотрим обучение интерполятора. После классификации выборка делится на две части. Четыре вектора соответствуют неповрежденным растениям и не требуют дополнительной обработки, а пять векторов соответствуют поврежденным растениям, для которых нужно определять уровень хлорофилла более точно.

Эти пять векторов используются для обучения интерполятора для точного определения уровня содержания хлорофилла в поврежденных растениях.

В качестве интерполятора применяется описанная многослойная НС. Однако в данном случае она обучалась на выборке существенно меньшего размера.

Результаты обучения такой сети при указанных параметрах обучения и точности обучения 0,05 показаны на рис. 5.6, 5.7.

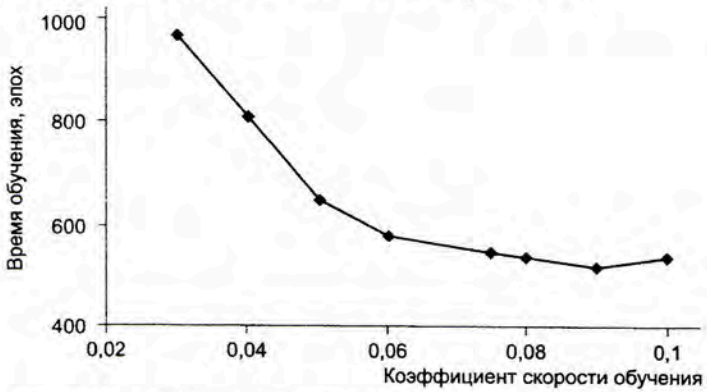


Рис. 5.6. Зависимость времени обучения интерполятора от коэффициента скорости обучения

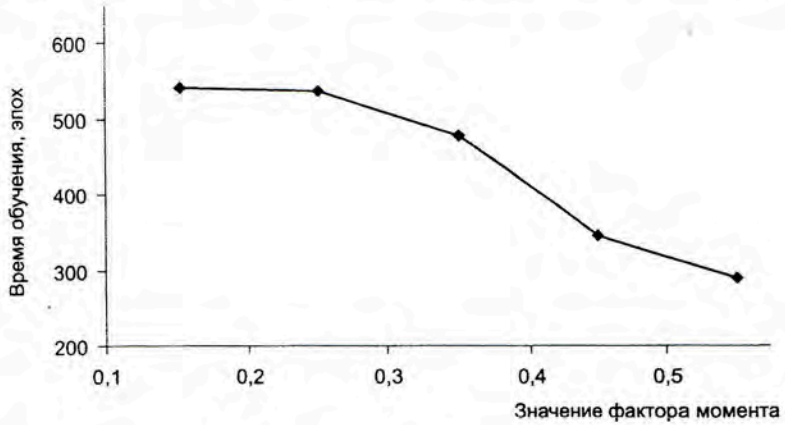


Рис. 5.7. Зависимость времени обучения интерполятора от фактора момента

5.1.4. Сравнение эффективности модульной и традиционной нейросетевой архитектуры

Проведенные эксперименты иллюстрируют преимущества применения модульной архитектуры, которые заключаются в снижении времени обучения. На рис. 5.8 показаны результаты сравнения общего количества итераций обучения традиционной НС T и интерполятора в составе модульной сети M (для одинаковых нейросетевых архитектур). На этом рисунке приведено отношение этих величин (T/M – отношение количества итераций обучения традиционной НС к количеству итераций обучения интерполятора в составе модульной сети) для различных параметров обучения.

Поскольку в обоих случаях архитектура сети одинакова, количество итераций обучения однозначно определяет время этого процесса. Как видно из рис. 5.8, время обучения модульной НС в 6–12 раз меньше времени обучения традиционной НС. (Временем обучения классификатора можно пренебречь, поскольку оно на несколько порядков меньше времени обучения многослойной НС, используемой для решения задачи распознавания в качестве интерполятора.)

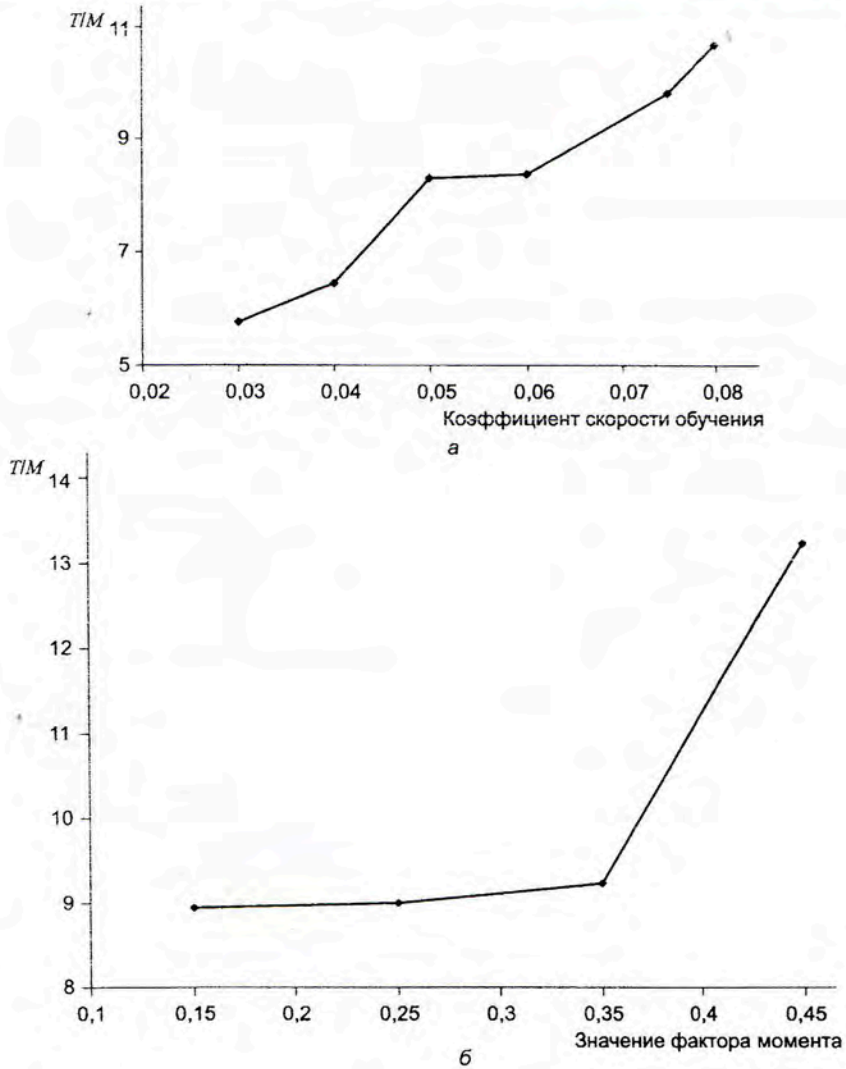


Рис. 5.8. Сравнительный анализ времени обучения традиционной и модульной нейросетевых архитектур, ось абсцисс – значения коэффициентов скорости обучения (*а*), и факторов момента (*б*); ось ординат – отношение времени обучения традиционной сети ко времени обучения модульной)

5.1.5. Обсуждение

Результаты экспериментов подтверждают эффективность применения модульных НС для решения задачи выявления поврежденных растений и определения уровня хлорофилла в них. Можно ожидать, что при увеличении размеров обучающей выборки такая тенденция не только сохранится, но и усилится. Выполненные эксперименты по обучению классификатора и более точному определению содержания хлорофилла с помощью интерполятора явно свидетельствуют о необходимости предпочтения модульных НС.

Дальнейшие исследования целесообразно развивать в направлении полного спектрального анализа растений (определение более полного их химического состава) при расширении архитектуры НС (рис. 5.9). Для снижения размерности входных данных и выделения информативных признаков целесообразно использовать метод анализа главных компонентов.

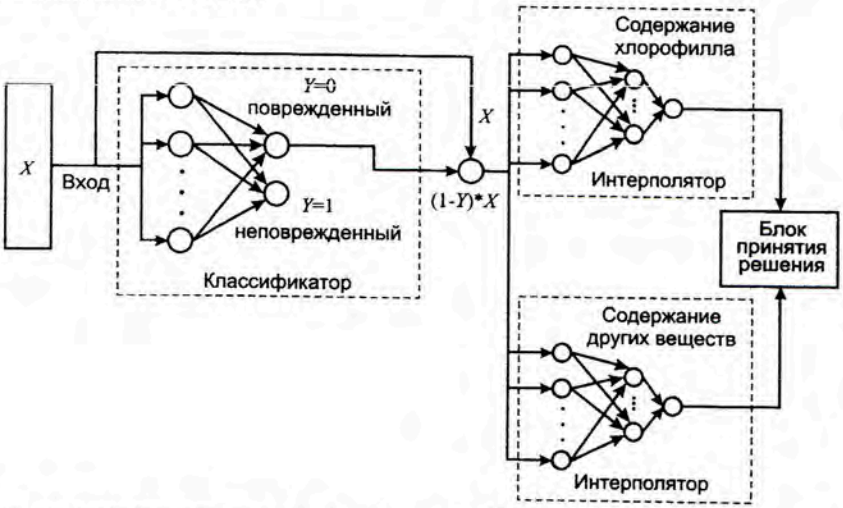


Рис. 5.9. Предлагаемая модульная архитектура НС для расширенного анализа химического состава растений

5.2. Оценка видового разнообразия

Рассмотрим алгоритм оценивания видового разнообразия растительности Причерноморского региона Украины, разработанный специалистами НЦАКИЗ НАН Украины, его модификацию, предложен-

ную специалистами ИКИ НАНУ–НКАУ, а также подход к его реализации в виде информационного сервиса в контексте развития украинского сегмента системы GEOSS.

5.2.1 Методика оценивания видового разнообразия

Среди приоритетных тематических направлений, которые определены в десятилетнем плане развития «системы систем» GEOSS, важное место принадлежит задачам оценивания и улучшения экологического состояния окружающей среды. К таким задачам относятся мониторинг состояния растительности и экосистем, проблема оптимального землепользования и оценка биоразнообразия. Биоразнообразие – одна из основных характеристик состояния экосистем. Важнейший источник информации для изучения и картографирования видового многообразия территорий – спутниковые данные и геоинформационные технологии [75]. Видовое разнообразие характеризуется двумя показателями: видовым богатством (общим количеством видов) и равномерностью распределения видов [76].

В исследованиях видового многообразия, в частности при его оценивании, широко используется энтропийный индекс Шеннона [77]:

$$B = \sum_{i=1}^{N} P_i \log_2 P_i \,, \tag{5.1}$$

где N – количество видов, P_i – значимость i-го вида.

Необходимостью учета в индексе не только богатства видов, но и равномерности их распределения по любым признакам обусловлена трудоемкость необходимых вычислений. Привлечение в процесс вычислений индекса видового многообразия по Шеннону данных ДЗЗ и современных информационных технологий обработки аэрокосмических изображений может дать ряд существенных преимуществ. В частности, это позволит значительно расширить территорию исследований, получить реальную информацию относительно пространственного распределения растительных группировок и обеспечить возможность ее постоянного обновления. В свою очередь, представление данных в цифровом виде даст возможность обеспечить их эффективную обработку и визуализацию.

Для построения методики оценивания видового многообразия в НЦАКИЗ ИГН НАНУ был использован экосистемный подход [78], согласно которому оценивание биоразнообразия может опираться на интегральные характеристики, обеспечивающие «представительство» всех биокомпонентов. В табл. 5.1 приведены факторы, влияющие на биоразнообразие, которые могут быть определены по данным ДЗЗ [79]. Для получения численных характеристик указанных факторов использовались стандартные информационные продукты сенсоров ДЗЗ MODIS и AMSR-E, а также данные численной модели рельефа DEM, созданной в рамках космической миссии SRTM. Описание продуктов, использованных для решения поставленной задачи, приведено в табл. 5.2.

Таблица 5.1. **Факторы, которые влияют на многообразие видов и могут быть определены по данным ДЗЗ**

Фактор	Показатель	Диапазон значений	Оптимальное значение
Рельеф местности	Среднесуточное солнечное излучение	0–300 Вт/м^2 в сутки	Максимум
Вода	Влажность почв	0–100 %	–"–
Тепло	Дневная и ночная температура	253–323 K	293 K
Осадки	Среднегодовое количество воды	0–200 мм	Максимум
Растительность	Вегетационный индекс	$-1 \div +1$	–"–
Жизненная активность	Относительное количество усвоенного растительностью излучения	$-1 \div +1$	–"–
Жизненная эффективность	Чистая производительность растительности	0–600 кг/м^2 карбона в год	–"–

Таблица 5.2. **Стандартные информационные продукты ДЗЗ, которые используются для оценки видового многообразия**

Сенсор	Продукт	Пространственное разрешение	Период обновления
MODIS	MOD12Q1, типы покрытий ландшафта	1 км	96 суток и ежегодно
	MOD03A2, геолокационные данные	1 км	Ежедневно
	MOD05L2, общий водосбор	1 км, 5 км	Половина суток – день и ночь
	MOD11A1, температура поверхности	1 км	Половина суток – день и ночь
	MOD13Q1, вегетационные индексы	250 и 500 м, 1 км	16 суток и ежемесячно
	MOD15A2, лиственное покрытие	250 и 500 м, 1 км	16 суток, ежемесячно и ежегодно
	MOD17A3, производительность растительности	500 м и 1 км	8 суток и ежегодно
AMSR-E	AE_Land3, уровень влажности почв	74×43 км	Ежедневно
SRTM	DEM – цифровая модель рельефа	90 м	Не изменяется

Для определения зависимости видового разнообразия от ряда факторов в НЦАКИЗ ИГН НАНУ использована модель на основе нечеткой логики [80]. Основная идея методики сводится к следующему.

Пусть известны количественные значения F_i, $i = 1, \ldots, n$, факторов, которые влияют на оценку биоразнообразия B, где n – общее количество факторов. Для каждого из m классов земного покрытия ландшафта можно определить потенциально возможное разнообразие видов $B_0^{(j)}$, $j = 1,\ldots,n$, которое при использовании индекса Шеннона (5.1) составляет

$$B_0^{(j)} = \log_2 N_0^{(j)}. \qquad (5.2)$$

Далее на основе известных экологических моделей, статистических зависимостей или экспертных представлений о влиянии этого фактора на видовое многообразие для каждого из n факторов F_i определяется вид функции принадлежности $\mu_i(F_i)$ влияния для всего диапазона возможных значений F_i. Общую функцию принадлежности можно найти на основе нечеткой конъюнкции:

$$\mu_0 = \bigwedge_{i=1}^{n} \mu_i(F_i). \tag{5.3}$$

После определения ограничивающей функции принадлежности (5.3) и показателя потенциального видового многообразия (5.2) можно получить текущую оценку индекса видового многообразия:

$$B = \mu_0 B_0. \tag{5.4}$$

5.2.2. Модификация метода оценки биоразнообразия на основе нейросетевой классификации типов покрывающей поверхности

Один из важнейших факторов, определяющих видовое разнообразие, – тип земного покрова. В настоящее время существует множество программ, направленных на создание продуктов по классификации земной поверхности, которые различаются системами классификации, покрытием, используемыми данными, технологиями построения и методами обработки. Среди них следует выделить европейский проект Corine [24] и американский – National Land Cover Data (NLCD) [42], которые в качестве основы используют данные спутника Landsat, а также проект MODIS Land Cover and Land-Cover Change [43], основанный на данных прибора MODIS спутника Terra и использующий глобальную систему классификации программы International Geosphere-Biosphere Program (IGBP) [44]. Следует отметить, что для территории Украины доступны лишь данные по глобальной классификации земной поверхности с разрешением не менее 1 км. Кроме того, самые свежие данные классификации поверхности для Украины датируются 2000 годом. Поэтому так актуальна задача создания более эффективных методов классификации покрытий ландшафта.

Специалистами ИКИ НАНУ–НКАУ [81] предложена модификация метода оценки биоразнообразия на основе использования результатов нейросетевой классификации земного покрова. Отказ от использования стандартных продуктов, предоставляющих результаты классификации земного покрова, позволяет выполнять видовую классификацию участка ландшафта по данным дистанционного зондирования на регулярной основе (несколько раз в сезон или месяц) и не использовать зачастую устаревшие данные. Таким образом, предлагаемая модификация метода обеспечивает независимую от наличия стандартных продуктов оценку видового биоразнообразия и позволяет строить временные последовательности полученных оценок, выявляя тренды и опасные тенденции изменения видового биоразнообразия.

Предлагаемый подход к классификации земного покрова и результаты численных экспериментов детально рассмотрены в главе 4, посвященной задаче нейросетевой классификации данных спутниковых наблюдений.

5.2.3. Реализация программной инфраструктуры с сервисом оценки видового многообразия

При реализации информационного сервиса [40] для оценивания видового многообразия по спутниковым данным можно выделить такие крупноблочные операции:

- загрузка исходных данных;
- попиксельное совмещение исходных данных;
- применение методики оценивания многообразия.

Рассмотрим эти операции более подробно.

Исходные данные для оценивания видового разнообразия. В процессе оценивания видового разнообразия возникает необходимость регулярного получения больших объемов разнородных данных из различных источников. В табл. 5.3 приведена информация об источниках исходных данных, которые требуются для решения поставленной задачи. При этом следует отметить, что исходные данные SRTM DEM достаточно получить один раз. Получение всей остальной информации необходимо обеспечить на регулярной основе.

Таблица 5.3. **Источники входных данных, требуемых для решения задачи оценки вуидового разнообразия**

Тип входных данных	Источник данных	Web-адреса
MOD03A2, геолокационные данные MOD05L2, общий водосбор	LAADS (Level 1 and Atmosphere Archive and Distribution System)	http://ladsweb.nascom.nasa.gov/index.html
MOD11A1, температура поверхности MOD12Q1, типы покрытий ландшафта MOD13Q1, вегетационные индексы MOD15A2, лиственное покрытие MOD17A3, производительность растительности	LP DAAC (Land Processes Distributed Active Archive Center)	http://edcdaac.usgs.gov/main.asp
AE_Land3, влажность почв	NCIDS (National Snow and Ice Center)	http://nsidc.org/
SRTM DEM, цифровая модель рельефа	CGIAR-CSI	http://srtm.csi.cgiar.org/

Все продукты MODIS, кроме MOD03A2 и MOD05L2, принадлежат к третьему уровню обработки и покрывают поверхность Земли регулярной сеткой. Исследуемым территориям по схеме покрытия MODIS соответствуют квадраты с координатами H19V03; H19V04; H20V03; H20V04; H21V03; H21V04.

В отличие от других данных MODIS продукты MOD03A2 и MOD05L2 принадлежат ко второму уровню обработки и представляют собой непосредственные результаты измерений спутника, обработанные по определенному алгоритму. Для получения необходимых для работы файлов сначала следует получить и обработать файлы метаданных. Эти метаданные описывают информацию, хранящуюся в файлах данных, и содержат координаты углов соответствующего спутникового изображения.

Совмещение входных данных. Операции (5.2)–(5.4) осуществляют для всех элементов космических изображений, которые содержат значение F_i. Очевидно, что перед началом оценивания видового разнообразия все задействованные информационные уровни должны быть попиксельно совмещены между собой.

Цель попиксельного совмещения данных заключается в преобразовании множества геопространственных изображений в такую форму, при которой пикселям с одинаковыми относительными ортогональными координатами соответствуют участки с одинаковыми реальными географическими координатами. Результатом совмещения должен быть ряд изображений с одинаковым пространственным разрешением и размером пикселей, которые покрывают один и тот же участок земной поверхности.

Для исследования выбран Причерноморский регион Украины, включая полуостров Крым. Границы исследуемого участка показаны на рис. 5.10.

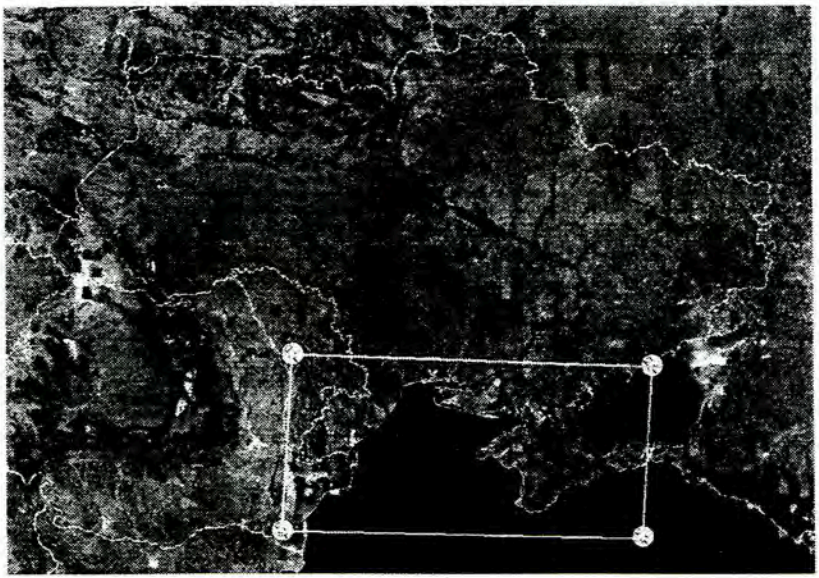


Рис. 5.10. Границы исследуемого участка территории Украины

Таблица 5.4. **Инструментарий для попиксельного совмещения исходных данных**

Тип входных данных	Инструментарий	Адрес
MOD05L2, общий водосбор	MODIS Swath Reprojection Tool	http://edcdaac.usgs.gov/landdaac/tools/mrtswat/index.asp
MOD12Q1 типы покрытий ландшафта	MODIS Reprojection Tool	http://lpdaac.usgs.gov/landdaac/tools/modis/index.asp
MOD11A1 температура поверхности		
MOD13Q1 вегетационные индексы		
MOD15A2, лиственное покрытие		
MOD17A3, производительность растительности		
AE_Land3, влажность почв	GDAL (Geospatial Data Abstraction Layer)	http://www.remotesensing.org/gdal/
SRTM DEM, численная модель рельефа		

Для выполнения операций совмещения и перепроектирования исходных данных использован стандартный инструментарий (табл. 5.4). Необходимость применения разнообразных программных средств для выполнения одной задачи обусловлена тем, что форматы исходных данных существенно различаются и не всегда полностью соответствуют международным стандартам.

В качестве общей проекции для исходных данных выбрана равновеликая коническая проекция Альберта [82]. Данная проекция поддерживается практически всеми инструментальными средствами, и в ней отсутствуют искажения площади элементов. Параметры избранной проекции приведены в табл. 5.5.

Таблица 5.5. **Параметры общей проекции исходных данных**

Параметр	Значение
Первая стандартная параллель	40
Вторая стандартная параллель	50
Центральная широта	45
Центральная долгота	30
Сдвиг на север	0
Сдвиг на восток	0

Средства программной реализации и результаты оценки видового многообразия. Для программной реализации методики оценивания видового разнообразия использован алгоритмический язык Python с расширением Numeric Python, в котором содержится векторная реализация операций над массивами. Кроме того, для ускорения работы программы часть функциональности (векторная реализация ряда вспомогательных вычислительных функций) реализована в виде бинарных расширений Python на алгоритмическом языке С. Это дало возможность ускорить выполнение соответствующих операций на несколько порядков.

Результат работы разработанных программных компонентов состоит в получении геопривязанного файла в формате GeoTIFF, который содержит оценку индекса видового разнообразия растительности Причерноморского региона Украины (рис. 5.11).

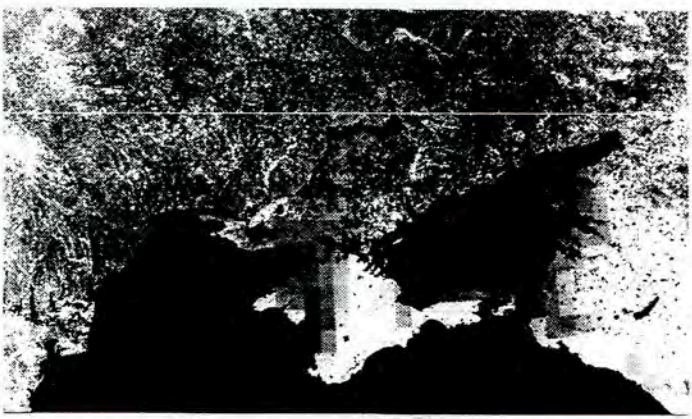


Рис. 5.11. Карта биоразнообразия за период с 07.04.2006 по 23.04.2006

Реализация сервиса оценки видового многообразия. Для представления полученных результатов в сети Internet разработано картографическое Web-приложение, которое предоставляет пользователю возможность просмотра информации об индексе видового многообразия растительности Причерноморского региона Украины. Web-интерфейс этого приложения разработан с использованием каркаса Cartoweb (http://www.cartoweb.org/). Принципы разработки картографических Web-сервисов более подробно рассмотрены в работе [83]. Web-приложение интегрировано с Internet-порталом системы GEO-UA, который можно

найти по адресу http://geo-ukraine.org.ua. Примеры пользовательского интерфейса сервиса приведены на рис. 5.12 и рис. 5.13.

Результаты работы сервиса оценки биоразнообразия для территории Украины представлены на вклейке (рис. В.6 и рис. В.7).

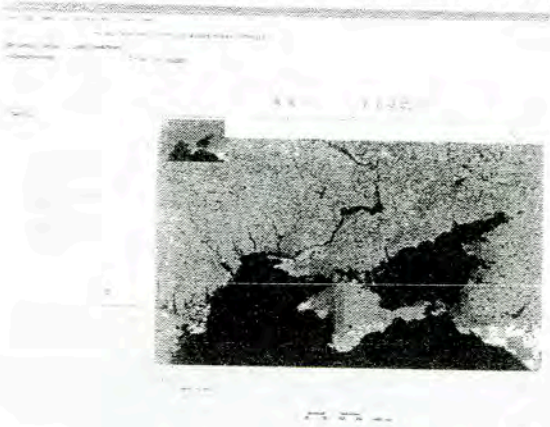


Рис. 5.12. Пример результата работы сервиса оценки биоразнообразия в окне браузера



Рис. 5.13. Результаты работы сервиса оценки биоразнообразия с увеличенным масштабом

5.2.4. Обсуждение

Разработанный сервис позволяет оперативно и регулярно получать данные об уровне видового разнообразия на исследуемой территории Украины, а также отмечать глобальные изменения в его состоянии. Это обеспечивает возможность своевременного отслеживания отрицательных тенденций в развитии экологии регионов и поддержки принятия решений в области природопользования.

Полученные результаты следует рассматривать как важный вклад Украины в развитие глобальной «системы систем» наблюдения за окружающей средой GEOSS. Реализованный картографический сервис соответствует открытым стандартам OGC WMS и OGC WCS, что обеспечивает возможность его интеграции с другими картографическими сервисами и GIS-системами.

Дальнейшее усовершенствование сервиса оценивания видового разнообразия возможно за счет использования космических снимков более высокого пространственного разрешения и определения тенденций изменения экосистем на основе многолетних наблюдений. Это позволит получить качественно новые научные и прикладные результаты, которые станут основой более эффективного решения задач обеспечения экологической безопасности и значительного повышения качества и точности принятия управленческих решений в области природопользования. Отработанные технологические решения следует рассматривать как фундамент развития украинского сегмента «системы систем» GEOSS и создания новых инновационных информационных продуктов и сервисов.

Развитие программы GMES и системы GEOSS предусматривает обработку больших объемов спутниковых данных с применением сложных моделей (например, метеорологических, моделей процессов энергомассообмена в геосистемах и т.д.). Поэтому создание информационных сервисов и распределенных систем невозможно без использования суперкомпьютерной техники, высокопроизводительных вычислений и Grid-инфраструктуры [84].

Глава 6

АНАЛИЗ ДИНАМИКИ ОБЛАЧНОСТИ ПО СПУТНИКОВЫМ СНИМКАМ НА ОСНОВЕ МЕТОДА ОПТИЧЕСКИХ ПОТОКОВ

С увеличением частоты природных катастроф и размеров материального ущерба все более необходимым становится оперативный мониторинг чрезвычайных метеорологических явлений. Современные спутниковые данные представляют особый интерес для решения оперативных задач метеорологии и обладают рядом преимуществ по сравнению с контактными измерениями. Спутниковые снимки имеют меньшую стоимость, поступают с высокой регулярностью и представляют собой «синоптический взгляд» на происходящие процессы, что выгодно отличает их от данных точечных нерегулярных измерений.

Важная составная часть мониторинга метеорологических процессов – анализ динамики развития облачности. Ключевым параметром облачности, необходимым для анализа ее развития, служит пространственное распределение скорости движения облаков. В настоящее время в большинстве операционных продуктов обработки спутниковых данных для вычисления скоростей движения облачности используются простейшие методы сопоставления, в том числе корреляционные. Недостаток этих методов заключается в большой вычислительной сложности в случае высоких скоростей облаков.

Для восстановления полей скоростей движения облаков целесообразно применять методы вычисления оптических потоков по серии последовательных изображений, которые широко используются при решении задач компьютерного зрения [85]. С целью исследования применимости этого подхода отобраны и реализованы два классических дифференциальных метода: Лукаса–Кенеда [86] и Хорна–Шанка [87]. Для учета специфики спутниковых данных, в частности существования больших смещений облаков на последовательных снимках, выполнена модификация отобранных методов. Оценка качества восстановления полей скоростей классическими методами и их модификациями проводилась на модельных изображениях и реальных спутниковых данных.

Поля скоростей, вычисляемые по серии спутниковых снимков, могут быть использованы для решения следующих задач:

- оценка состояния атмосферы;
- автоматическая идентификация метеорологических явлений синоптического масштаба, например вихревых структур [88] и мониторинга их развития [89].

Кроме того, поля скоростей могут использоваться в качестве входных параметров в процедурах усвоения данных при численном прогнозировании погоды или как дополнительный информационный признак при классификации облачного покрова, в том числе с использованием марковских случайных полей [90, 94].

6.1. Характеристики спутниковых данных

Все искусственные спутники Земли, предназначенные для получения данных ДЗЗ, можно разделить на два класса: геостационарные и низкоорбитальные. Геостационарные спутники расположены в плоскости экватора Земли на высоте приблизительно 36 тыс. км. Для этих спутников характерно широкое покрытие территории Земли и высокая временна́я разрешающая способность. Вследствие своего расположения геостационарные спутники не могут покрыть всю территорию Земли, в частности полярные территории. На сегодняшний день из-за значительной высоты над поверхностью Земли эти спутники не могут предоставлять данные в микроволновом диапазоне. Пример таких спутников: аппараты серии Meteosat, MSG, GOES, GMS. В минимальной конфигурации подобные аппараты ведут съемку в трех спектральных диапазонах – видимом, тепловом инфракрасном и поглощения водного пара.

Низкоорбитальные спутники расположены на высоте 400–800 км над поверхностью Земли. Они характеризуются значительно большей пространственной и спектральной разрешающей способностью, способны покрывать всю территорию Земли, а также регистрировать электромагнитное излучение в широком диапазоне длин волн: в видимом, инфракрасном и микроволновом. Примеры таких спутников: метеорологические спутники серии NOAA и спутники Terra и Aqua с сенсором MODIS. По количеству доступных спектральных каналов данный класс спутников значительно преобладает над геостационарными, например сенсор MODIS имеет 36 спектральных каналов в видимом и инфра-

красном диапазонах. Главный недостаток подобных спутников – низкая (по сравнению с геостационарными) временна́я разрешающая способность.

Для решения задачи анализа динамики развития облачности, в частности оценки скорости движения облаков, необходимы спутниковые данные с высокой частотой съемки. Поэтому для средних и экваториальных широт следует предпочесть данные геостационарных спутников, а для полярных регионов более приемлемо использовать несколько низкоорбитальных спутников, например спутников серии NOAA/MetOp с сенсором AVHRR.

Территория Украины находится в зоне покрытия европейских метеорологических геостационарных спутников MSG-1 (Meteosat Second Generation), MSG-2, Meteosat-5/7, которые поддерживаются европейской организацией по использованию метеорологических спутников EUMETSAT [91]. В ИКИ НАНУ–НКАУ обеспечивается устойчивый прием данных MSG-1, Meteosat-5 и Meteosat-7. В настоящей работе используются данные Meteosat-7 в тепловом инфракрасном диапазоне.

6.2. Методы построения оптических потоков

Основная задача методов вычисления оптических потоков состоит в восстановлении полей скоростей или смещений элементов изображения по последовательностям снимков. В рамках данного подхода для моделирования движения облаков используется модель *оптического потока*, которая предполагает сохранение измеряемой величины вдоль траекторий движения [92]:

$$I(\mathbf{x},t) = I(\mathbf{x} - \mathbf{v}t, 0), \qquad (6.1)$$

где I – интенсивность пикселей изображения (измеряемая величина), зависящая от времени; $\mathbf{v} = (u,v)^{\mathrm{T}}$ – скорость элементов изображения; $\mathbf{x} = (x,y)^{\mathrm{T}}$ – пространственные координаты элементов изображения.

Согласно [92], [93], методы вычисления оптического потока относятся к одной из следующих трех групп:

- дифференциальные методы, которые позволяют определить параметры движения элементов изображения с помощью пространственно-временных производных интенсивности;
- частотные методы, позволяющие определить параметры движения в области пространственных частот;

• методы сопоставления, которые предназначены для вычисления смещения изображения путем сопоставления его характерных элементов.

С учетом специфики данных геостационарных спутников Земли для дальнейших исследований выбраны дифференциальные методы. Для корректной работы этих алгоритмов, помимо обычных условий, необходима лишь дифференцируемость изображений в пространстве и по времени. Это довольно естественное условие, выполняющееся для спутниковых изображений атмосферы.

В случае дифференцируемости функции интенсивности изображения из приближения Тейлора первого порядка и формулы (6.1) можно получить линейное уравнение ограничения на скорость:

$$\nabla I(\mathbf{x},t)\mathbf{v} + I_t(\mathbf{x},t) = 0, \tag{6.2}$$

где $I_t(\mathbf{x},t)$ – частная производная по времени от $I(\mathbf{x},t)$;

$\nabla I(\mathbf{x},t) = \left(I_x(\mathbf{x},t), I_y(\mathbf{x},t)\right)^{\mathrm{T}}$ – пространственный градиент интенсивности; $\nabla I\mathbf{v}$ обозначает обычное скалярное произведение.

Равенство (6.2) позволяет найти только компоненту скорости $\mathbf{v}_n = s\mathbf{n}$, нормальную по отношению к пространственным линиям постоянной интенсивности. Нормальная скорость s и нормальное направление $\mathbf{n}$ можно получить из равенств [92]

$$s(\mathbf{x},t) = \frac{-I_t(\mathbf{x},t)}{\left\|\nabla I(\mathbf{x},t)\right\|_2}, \quad n(x,t) = \frac{\nabla I(\mathbf{x},t)}{\left\|\nabla I(\mathbf{x},t)\right\|_2}. \tag{6.3}$$

Для восстановления обеих компонент скорости необходимы дополнительные ограничения к уравнению (6.2).

Для апробации подхода к построению полей скоростей по серии снимков с помощью оптических потоков применены и программно реализованы два классических дифференциальных метода – методы Лукаса–Кенеда и Хорна–Шанка.

Метод Лукаса–Кенеда [86] локальный, что выражается в разбиении изображения на прямоугольные фрагменты, которые обрабатываются по отдельности. Алгоритм вычисляет значение скорости в центральном пикселе фрагмента. Полученная таким образом регулярная сетка затем интерполируется на все пиксели изображения. Для каждого фрагмента значение оптического потока восстанавливается путем минимизации критерия

$$\sum_{\mathbf{x}\in\Omega} W^2(\mathbf{x})\left[\nabla I(\mathbf{x},t)\mathbf{v} + I_t(\mathbf{x},t)\right]^2,$$

где $W^2(\mathbf{x})$ – функция, которая определена на фрагменте изображения Ω.

В отличие от алгоритма Лукаса–Кенеда, метод Хорна–Шанка [87] глобальный и заключается в поиске минимума некоторого критерия по всему изображению. При этом минимизации подлежит критерий

$$\int_{\Omega}\left[\nabla I\mathbf{v} + I_t\right]^2 + \lambda\left(\left\|\nabla u\right\|_2^2 + \left\|\nabla v\right\|_2^2\right)d\mathbf{x}, \qquad (6.4)$$

где параметр λ определяет меру заданной гладкости оптического потока, который необходимо получить.

6.3. Модификации классических методов

Анализ классических методов, работающих с данными геостационарных спутников, позволяет выделить следующие их основные недостатки: невозможность учета больших смещений элементов изображения и использование упрощенной модели эволюции изображений во времени.

Для преодоления первого недостатка разработаны модификации классических методов: итеративный метод Лукаса–Кенеда и иерархический метод Хорна–Шанка.

Суть модификаций методов состоит в вычислении смещений элементов изображения путем итеративного применения классических версий алгоритмов. Для смещений уравнение оптического потока, т. е. уравнение сохранения интенсивности элементов изображения вдоль траекторий движения, принимает следующий вид:

$$I(\mathbf{x},T) = I(\mathbf{x}-\mathbf{d},0); \qquad (6.5)$$

здесь I – интенсивность изображения, определенная на поле зрения Ω; T – время между двумя кадрами в последовательности изображений; $\mathbf{x}\in\Omega$ – элемент поля зрения; $\mathbf{d}(\mathbf{x},t)$ – смещение элемента изображения $\mathbf{x}$.

В этом случае задача вычисления оптического потока по существу представляет собой задачу минимизации функционала вида

$$F\left[I_1(\mathbf{x}) - I_0(\mathbf{x}-\mathbf{d})\right], \qquad (6.6)$$

где $I_0(\mathbf{x}) = I(\mathbf{x},0)$, $I_1(\mathbf{x}) = I(\mathbf{x},T)$.

Тем не менее, вследствие нелинейной структуры интенсивности I задача минимизации становится слишком сложной, в частности в методе Хорна–Шанка минимизация (6.6) эквивалентна решению нелинейных уравнений Эйлера–Лагранжа. Для упрощения задачи проведем линеаризацию $I_0(\mathbf{x}-\mathbf{d})$ по $\mathbf{d}$. В этом случае задачу минимизации можно представить в виде

$$F\left[I_1(\mathbf{x}) - I_0(\mathbf{x}) + \nabla I_0(\mathbf{x})\mathbf{d}\right]. \tag{6.7}$$

В модифицированном алгоритме Лукаса–Кенеда минимизация (6.7) проводится последовательным применением классической версии алгоритма. При этом одно из изображений смещается в соответствии с оптическим потоком, вычисленным на предшествующем шаге:

$$\mathbf{d}_{i+1} = \mathbf{d}_i + \arg\min_{\Delta\mathbf{d}} F\left[I_1(\mathbf{x}) - I_0(\mathbf{x}-\mathbf{d}_i) + \nabla I_0(\mathbf{x}-\mathbf{d}_i)\Delta\mathbf{d}\right], \tag{6.8}$$

где $\mathbf{d}_i$ и $\mathbf{d}_{i+1}$ – значения оптического потока на шаге i и $I+1$ соответственно.

В модифицированном алгоритме Хорна–Шанка дополнительно к итеративному подходу предложено использовать иерархический (грубо-точный) подход. В рамках этого подхода строится иерархия изображений:

$$I_i^{(0)} = I_i, \quad i = \overline{0,1},$$
$$I_i^{(j+1)}(\mathbf{x}) = I_i^{(j)}(r\mathbf{x}), \quad i = \overline{0,1}, \quad j = \overline{0,n}, \tag{6.9}$$

где n – количество уровней иерархии; r – коэффициент уменьшения линейных размеров изображений.

На каждом уровне иерархии применяется классический алгоритм вычисления оптического потока. Затем полученное значение потока распространяется на нижние уровни иерархии.

6.4. Оценка эффективности работы алгоритмов

Оценка качества работы алгоритмов Лукаса–Кенеда, Хорна–Шанка и их модификаций проводилась количественно на искусственных изображениях с известным оптическим потоком и визуально – на реальных изображениях спутника Meteosat, для которых значение оптического потока неизвестно. Примеры тестовых изображений приведены на рис. 6.1, 6.2.

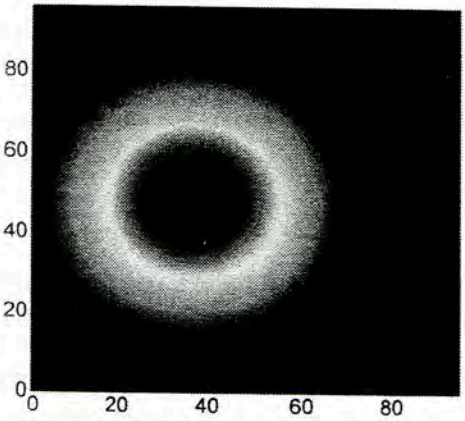


Рис. 6.1. Тестовое изображение функции плотности распределения Гаусса со стандартным отклонением 20 пикселей

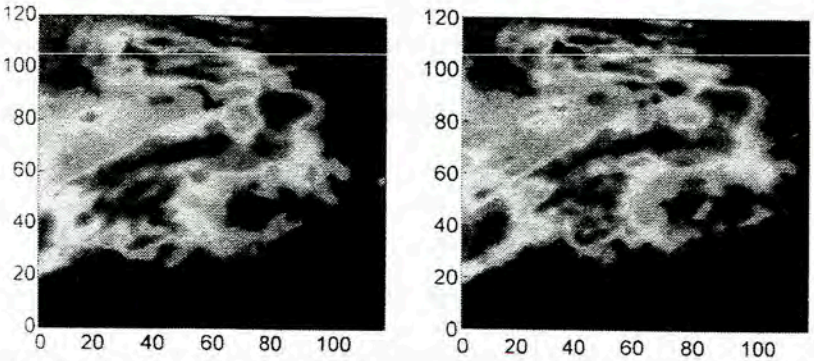


Рис. 6.2. Тестовые изображения, полученные с КА Meteosat в инфракрасном диапазоне с интервалом 30 мин

На искусственных изображениях со значительными значениями смещений изображений лучшие результаты показали модифицированные версии алгоритмов. Для изображений с регулярными функциями интенсивности, например изображений гауссианов, наилучшие результаты показал модифицированный метод Лукаса–Кенеда, а для изображений с нерегулярной структурой – модифицированный метод Хорна–Шанка. Графики точности восстановления оптического потока классическими и модифицированными алгоритмами показаны на рис. 6.3.

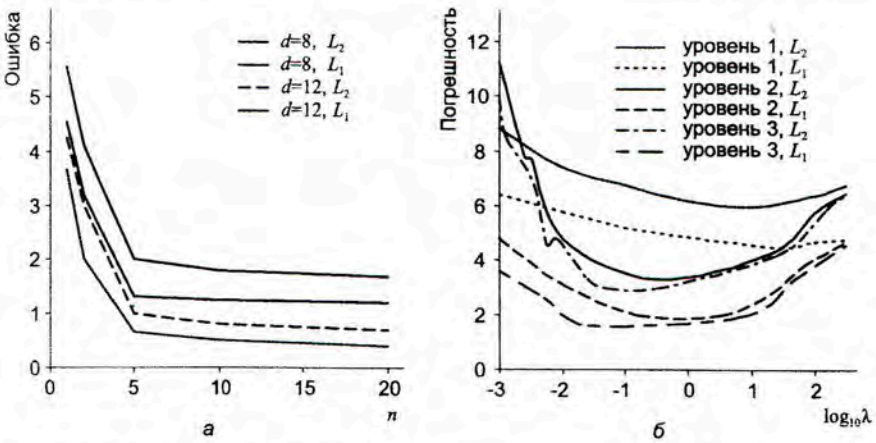


Рис. 6.3. Графики средней погрешности восстановления оптического потока: модифицированным алгоритмом Лукаса–Кенеда для изображений гауссиана в зависимости от количества итераций n при разных значениях размера окна d (*а*); классическим и модифицированным алгоритмами Хорна–Шанка с количеством уровней иерархии 2 и 3 для изображений КА Meteosat в зависимости от параметра регуляризации λ (*б*)

На рис. 6.3, *а* показаны ошибки по норме L_1 (пунктирной линией) и среднеквадратические ошибки (сплошной линией) восстановления полей смещений объектов модифицированным методом Лукаса–Кенеда для серии изображений гауссиана (см. рис. 6.1), одно из которых смещено относительно другого на 10 пикселей. Независимо от размера окна алгоритма наблюдается быстрое уменьшение значений ошибок при увеличении числа итераций от одной, что соответствует классической версии алгоритма, до пяти.

На рис. 6.3, *б* показаны ошибки восстановления по нормам L_1 и L_2 полей смещений объектов модифицированным методом Хорна–Шанка для последовательности снимков КА Meteosat (рис. 6.2). Классический алгоритм (показан точечной линией) не может восстановить значение оптического потока на всем интервале изменения параметра регуляризации λ. В то же время модифицированный алгоритм (показан пунктирными и сплошными линиями) восстанавливает оптический поток достаточно точно в области средних значений λ.

6.5. Обсуждение

Таким образом, в данной главе рассмотрен вопрос применимости методов вычисления оптических потоков для решения задачи восстановления полей скоростей облаков по данным геостационарных спутников Земли. Благодаря использованию упрощенных описаний процессов в атмосфере эти методы не требуют высокопроизводительных вычислений и дают результаты с приемлемой точностью на небольших промежутках времени.

Выполнена модификация методов вычисления оптических потоков Лукаса–Кенеда и Хорна–Шанка с учетом специфики снимков геостационарных спутников.

Оценена эффективность работы классических и модифицированных методов на синтезированных и реальных данных. На основе полученных результатов можно утверждать, что модифицированные алгоритмы лучше работают на данных, содержащих значительные смещения элементов изображения. На снимках КА Meteosat наилучшие результаты показал модифицированный алгоритм Хорна–Шанка.

К основным направлениям дальнейших исследований можно отнести следующие.

- Использование более сложных моделей динамики развития облаков вместо модели оптического потока.
- Использование данных из других спектральных диапазонов и адаптация алгоритмов для обработки снимков КА MSG.
- Решение задачи классификации облачного покрова с использованием полей скоростей в качестве дополнительного информационного признака.
- Сравнение результатов моделирования с данными непосредственных наблюдений и данными моделей численного метеорологического прогнозирования.

Глава 7
ПОСТРОЕНИЕ КАРТЫ ОБЛАЧНОСТИ ПО ДАННЫМ METEOSAT

КА Meteosat представляет собой геостационарный спутник, космические снимки которого используются при решении практических задач из области гидрометеорологии. Этот КА ведет съемку земного диска с получасовым периодом в трех спектральных диапазонах – видимом, инфракрасном и диапазоне водяного пара.

Обычно для построения карт облачности используются мульти- и гиперспектральные спутники, ведущие съемку земного диска во многих (более десяти) спектральных диапазонах. На основе информации об интенсивностях излучения можно делать выводы об уровне облачности для каждого отдельного участка земной поверхности. К сожалению, временная разрешающая способность таких спутников обычно невелика, что не позволяет получать оперативную информацию для произвольного района земной поверхности. Таким образом, использование снимков КА Meteosat, покрывающих весь земной диск с получасовым интервалом, для решения различных прикладных задач наиболее приемлемо.

Однако следует заметить, что три канала КА Meteosat не предоставляют данных, которых было бы достаточно для определения уровня облачности каждого отдельного участка земного диска. Этим обусловлена необходимость использования для анализа спутниковых данных алгоритмов, учитывающих их пространственную и временную структуру. Один из таких алгоритмов – марковская сегментация, позволяющая определять принадлежность пикселя изображения к некоторому классу с учетом его окрестности. Марковская сегментация дает возможность учитывать различные распределения интенсивностей по классам и позволяет обойтись без глобальных параметров, что особенно актуально при исследовании такого неоднородного объекта, как земная атмосфера. Однако в вычислительном плане алгоритм марковской сегментации достаточно сложен и при обработке больших изображений может потребовать значительных временных затрат. Именно поэтому возникает необходимость разработки параллельного аналога этого алгоритма [93, 94], который рассмотрен в одной из последующих глав [94, 95].

7.1. Описание данных спутника Meteosat

В настоящее время организацией EUMETSAT поддерживается серия метеорологических спутников Meteosat на геостационарной орбите на нулевой долготе, а также на долготе 57°E. Рассмотрим характеристики существующих спутников более детально.

7.1.1. Характеристика данных спутника Meteosat-7

Спутник Meteosat-7, последний из серии первого поколения, запущен в 1997 г. Сначала он находился на нулевой долготе, но впоследствии был переведен на долготу 57°E. Аппаратура, установленная на этом аппарате, позволяет получать изображения Земли в трех спектральных каналах каждые 30 минут. Примеры изображений представлены на рис. 7.1: *а,б* – отраженное солнечное излучение. Такие снимки дают информацию о сумме водяного пара в средней части атмосферы. Спутник Meteosat, собирает информацию об облаках, атмосферной влажности и поверхностных характеристиках всей Земли. Информацию из видимого канала имеет смысл получать только днем, однако инфракрасный канал и изображения в диапазоне водяного пара доступны круглосуточно.

Основной прибор, установленный на этом КА – радиометр видимого и инфракрасного диапазонов MVIRI (The Meteosat Visible and Infrared Imager) [94, 95], который позволяет осуществлять наблюдение за облачным покровом Земли, измерять влажность верхних слоев тропосферы и температуру поверхности моря. MVIRI ведет съемки в трех спектральных диапазонах: видимом (VIS, 0,45–1,0 мкм), полосе поглощения водяного пара (WV, 5,7–7,1 мкм) и инфракрасном (IR, 10,5–12,5 мкм). Он генерирует изображения полного земного диска на высоте 36 000 км над экватором каждые 30 минут круглосуточно.

Изображения в видимом диапазоне получаются путем регистрации отраженного излучения в видимой части спектра и доступны только на протяжении светового дня. Изображения в инфракрасном канале и канале водяного пара доступны круглые сутки, поскольку датчик регистрирует тепловое излучение, а не отраженный сигнал. IR-изображения показывают температуру облаков, поверхности Земли и океанов. WV-датчик регистрирует тепловое излучение водяного пара в средней атмосфере и, таким образом, позволяет оценить ее распределение.

Используя данные в трех спектральных областях, можно получать информацию о гидрометеорологических факторах со всей поверхности земного шара, а также отслеживать их эволюцию. Изображения, поступающие с интервалом в 30 минут, можно использовать для создания анимированных последовательностей, которые иллюстрируют изменения погодных условий. Чрезвычайно важна информация и о распределении облаков.

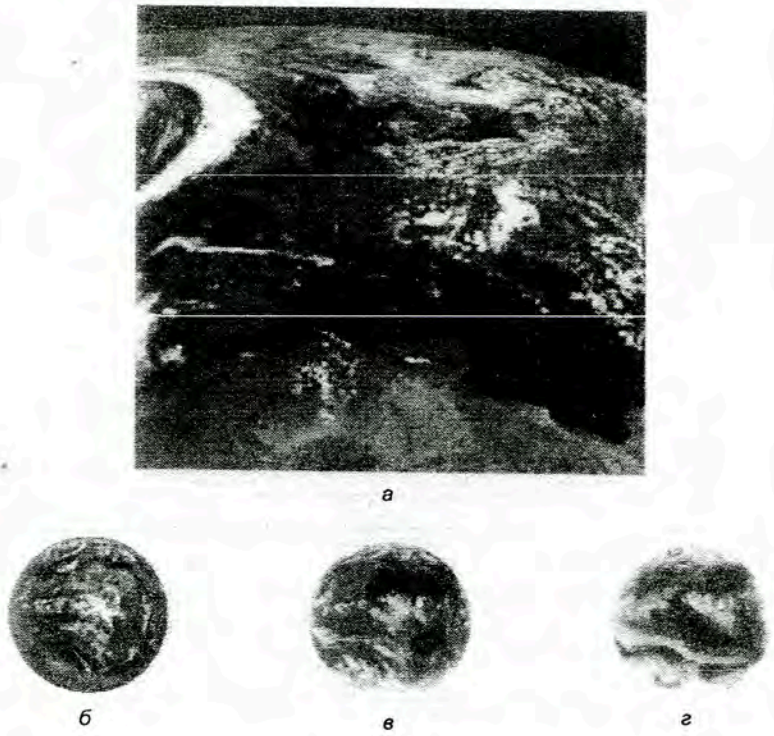


Рис. 7.1. Примеры изображений, полученных с КА Meteosat-7:
а – в видимом канале для Европейского сектора; *б* – изображение полного земного диска в видимом диапазоне; *в* – изображение полного земного диска в температурном инфракрасном диапазоне (холодные зоны показаны белым цветом, теплые – темными оттенками); *г* – изображение полного земного диска в диапазоне водяного пара (около 6 мкм)

Изображения с КА Meteosat-7 поступают в электронной форме как отдельные пакеты (8 бит, 256 градаций серого), каждый из которых состоит из пикселей. IR- и WV-каналы используют массив в 2,500×2,500 пикселей для полного земного диска, тогда как для VIS-каналов необходимы различные детекторы для достижения размеров в 5000×5000. Каждый пиксель покрывает область около 5×5 км для IR и WV, 2,5×2,5 км – для канала VIS.

Большая часть солнечного излучения, отраженного поверхностью Земли и облаками, лежит в спектральном диапазоне между 0,3 мкм и 2,0 мкм, с максимальной энергией при длине волны, близкой к 0,6 мкм. Поверхностная энергия переходит почти в IR-диапазон, но 99 % всей отраженной солнечной энергии приходит на длинах волн менее 4 мкм. В этом диапазоне атмосфера неодинаково прозрачная. Вследствие поглощения атмосферных газов переданное излучение искажается на специфических полосах. Кроме того, происходит повышенное поглощение энергии атмосферным водяным паром в диапазоне выше 0,7 мкм.

7.1.2. Meteosat второго поколения

В 1988 году организацией EUMETSAT принято решение о концентрации усилий на совершенствовании основной технологии получения изображений, дополненной анализом воздушных масс. Обновленная технология будет использоваться для получения изображений облачности, а анализ воздушных масс позволит вести наблюдение за температурой, влажностью и количеством озона в атмосфере. Исследования и разработки в этом направлении велись на протяжении нескольких лет. В октябре 1992 года были сформулированы требования и начаты работы над подготовительной программой, в июне 1994 года – над программой по подготовке средств Meteosat второго поколения (Meteosat Second Generation – MSG).

Цель программы MSG состоит в создании трех новых спутников, предоставляющих информацию улучшенного дизайна. Первый из этих спутников, Meteosat-8, запущен в 2002 году. Запуск второго – Meteosat-9 – осуществлен 21 декабря 2005 г. После этапа ввода в эксплуатацию в июле 2006 года спутник Meteosat-9 занял позицию спутника Meteosat-7, а последний, в свою очередь, был переведен на позиции над Индийским океаном.

В основу новых спутников положена концепция спутников первого поколения, однако передовые технологии позволили существенно увеличить поток передаваемых данных. Все три спутника используют 12 каналов; изображения генерируются каждые 15 минут. Новые приборы позволяют получать в 20 раз больше информации и с лучшим качеством (табл. 7.1). Схема обработки данных КА Meteosat приведена на рис. 7.2.

Таблица 7.1. **Основные характеристики каналов MSG**

Канал	Диапазон, мкм	Канал	Диапазон, мкм
VIS 0,6	0,56–0,71	WV 6,2	5,35–7,15
VIS 0,8	0,74–0,88	WV 7,3	6,85–7,85
IR 1,6	1,50–1,78	IR 8,7	8,30–9,10
IR 3,9	3,48–4,36	O_3 9,7	9,38–9,94
IR 10,8	9,8–11,8	CO_2 13,4	12,40–14,40
IR 12,0	11,00–13,00	High Res VIS	0,5–0,9

Для приема данных Meteosat, а также других данных об окружающей среде (метеорологические и наземные измерения), в ИКИ НАНУ–НКАУ установлена широковещательная система EUMETCast, основанная на использовании технологии DVB (Digital Video Broadcasting). Для передачи данных широкому кругу потребителей в системе EUMETCast используются коммерческие телекоммуникационные геостационарные спутники (в частности, для Европы – спутник Hotbird-6). Система EUMETCast – это вклад организации EUMETSAT в систему GEONETCast, которая представляет собой часть глобальной системы GEOSS.

Основные свойства системы EUMETCast:

– возможность защищенной доставки данных группам пользователей с поддержкой разных политик данных;

– поддержка любых форматов данных;

– технология DVB обеспечивает масштабируемость системы и возможность покрытия земной поверхности в разных регионах;

– возможность получения разных потоков данных с помощью одной приемной станции;

– использование доступного аппаратного обеспечения DVB для приема данных.

Для приобретения права на получение данных, предоставляемых в рамках системы EUMETCast, ИКИ НАНУ–НКАУ подписано лицензионное соглашение с организацией по эксплуатации метеорологических спутников EUMETSAT, а также получено и установлено специализированное программное обеспечение EUMETCast Client Software (TELLICAST) и USB-Ключ EUMETCast Key Unit (EKU) для приема и дешифровки потока данных.

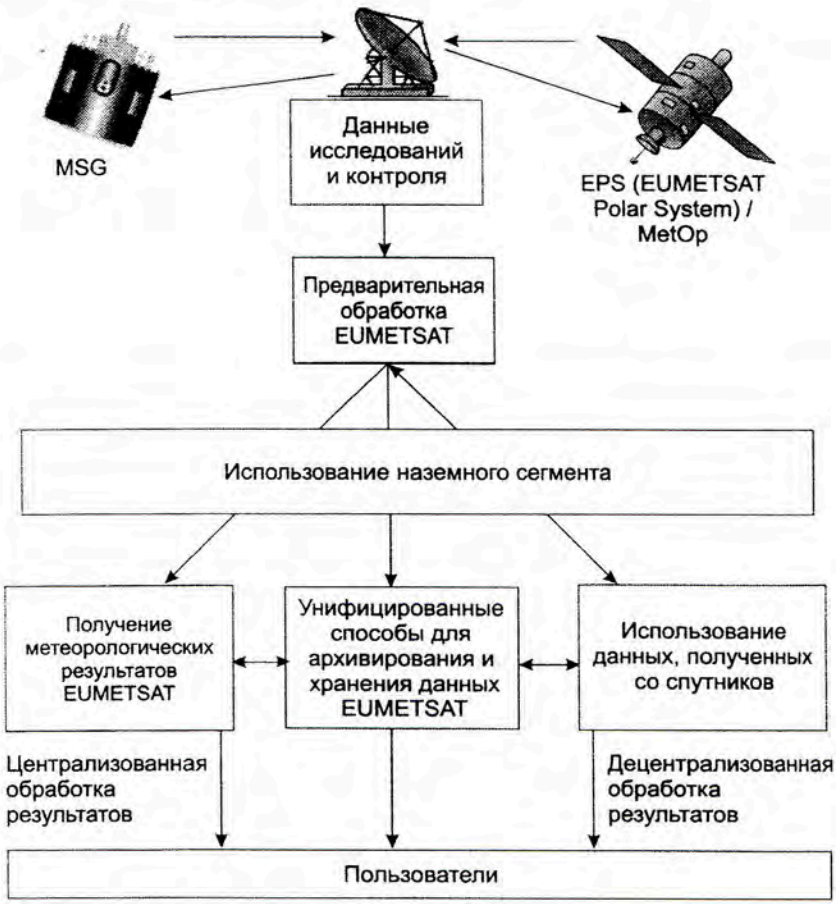


Рис. 7.2. Схема обработки данных КА Meteosat

В настоящее время налажено регулярное и оперативное получение данных со следующих спутников:

– MSG-1 (рис. 7.3);

– Meteosat-5, Meteosat-7;

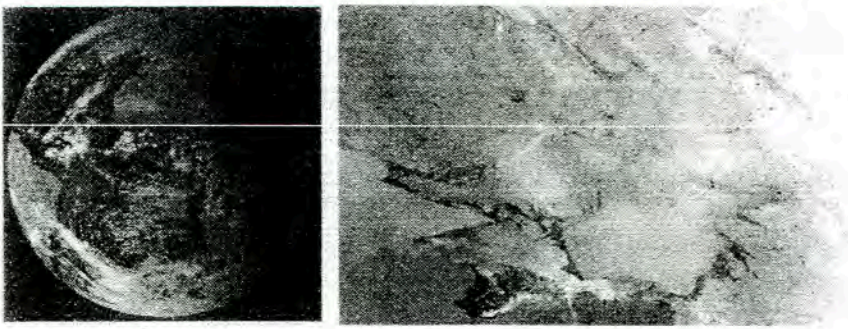
– NOAA;

– GOES East/West;

– MTSAT;

– MetOp-1 (первый европейский полярно-орбитальный метеорологический спутник, рис. 7.3).

Кроме того, принимаются данные метеорологических наблюдений DWDSAT и метеорологические продукты SAF (Satellite Application Facilities), которые генерируются на основе данных спутника MSG-1.



а *б*

Рис. 7.3. Данные, полученные системой EUMETCast со спутников MSG-1 (*а*) и MetOp (*б*)

7.2. Общее описание марковского подхода к сегментации

В качестве объекта исследования выберем прямоугольное изображение S размером $n \times m$ пикселей, содержащее пиксели s_{ij}, где i и j лежат в пределах $\overline{1,n}$ и $\overline{1,m}$ соответственно. Окрестностью точки s_{ij} назовем произвольное множество $\partial_{ij} \subset S \quad \exists \; s_{ij} \notin \partial_{ij}$. С каждым пикселем s_{ij} связывается интенсивность X_{ij}, которая принимает случайные

значения (обычно из интервала $\overline{0,\ 255}$, который соответствует переходу от черного цвета к белому в градациях серого). Кроме того, с каждым пикселем s_{ij} связывается неизвестная метка Y_{ij}, также принимающая случайные значения. Конкретные значения, которые принимают эти случайные величины, обозначим x_{ij} и y_{ij} соответственно. Таким образом, можно сказать, что изображению S соответствуют множества переменных $X = \{X_{11},...,X_{nm}\}$ и $Y = \{Y_{11},...,Y_{nm}\}$.

Марковские случайные поля (МСП) широко используются для классификации изображений [96]. В теореме Хаммерсли-Клиффорда доказана их эквивалентность физическим статистическим моделям Гиббса [96]. Эта теорема дает также представление для вероятности конкретной классификации $P(Y)$ в форме

$$P(Y) = \frac{1}{z} e^{\beta V(Y)} = \frac{1}{z} e^{\beta \sum_{i,j} V_{i,j}(\sigma_{ij} \cap \{y_{ij}\})}. \qquad (7.1)$$

Здесь z – нормирующая константа (необходимая для выполнения условия $\sum_{Y} P(Y) = 1$); параметр β обычно называют корреляционным параметром изображения; V – так называемая потенциальная функция, структура которой тесно связана с оптимальной сегментацией на МСП. Заданием определенной потенциальной функции можно моделировать физические особенности сегментации. Правая часть равенства показывает, что потенциальную функцию V можно разложить на сумму потенциалов, определенных в каждой точке: $V = \sum_{i,j} V_{ij}$.

В качестве примера использования такого подхода можно привести ситуацию, когда наблюдаемая интенсивность X_{ij} зависит только от локальных значений Y_{ij} и условное распределение случайной величины Y_{ij} гауссовское. Теорема Байеса взаимосвязи априорной вероятности и апостериорной дает полную модель взаимосвязи интенсивности и меток [97]:

$$P(Y \mid X) \infty P(X \mid Y)P(Y) = \frac{1}{z} \exp\{\sum_{i,j} \beta_{ij} n_{ij}(y_{ij})\} \times$$
$$\times \prod_{i,j} \frac{1}{\sqrt{2\pi}\sigma_{ij}} \exp\{-\frac{1}{2\sigma_{ij}^2}(x_{ij} - \mu_{ij})^2\}. \qquad (7.2)$$

В этом уравнении, σ_{ij} – дисперсия случайной величины X_{ij}; μ_{ij} – математическое ожидание случайной величины X_{ij}, n_{ij} – количество пикселей в окрестности ∂_{ij}, у которых метка Y совпадает с Y_{ij}.

Цель сегментации можно сформулировать следующим образом: максимизировать $P(Y \mid X)$ при определенной заданной интенсивности X. Это соответствует определению максимума для апостериорной оценки:

$$Y : Y^* = \arg\max_y \{P(Y \mid X)\}. \tag{7.3}$$

Для максимизации предлагается использовать алгоритм Iterated Conditional Modes (ICM) [96], который представляет собой вычислительный эффективный метод поиска локального максимума $P(Y \mid X)$ на структуре со свойствами МСП.

7.3. Последовательная реализация алгоритма марковской сегментации

Приведем последовательный алгоритм ICM, используемый для решения задачи классификации. В последующих разделах будет описана его параллельная реализация.

Используем следующие обозначения:

x – значения интенсивностей всего изображения;

y_0, y – начальная и текущая сегментации;

$\hat{\mu}_c, \hat{\sigma}_c$ – среднее значение и дисперсия интенсивности по классу c;

$\hat{\beta}, \hat{\beta}_{ij}$ – значения корреляционного параметра для всего изображения и для отдельного пикселя (i, j);

Последовательный алгоритм ICM формально можно описать следующим образом.

1. Используя значения интенсивности x, выполнить сегментацию методом k-средних и получить начальную сегментацию y_0.

2. Начать цикл:

a) установить текущую сегментацию $y=y_0$;

b) с использованием текущей сегментации y и значения интенсивности x вычислить значения $(\hat{\mu}_c, \hat{\sigma}_c)$ по каждому классу c;

c) разбить изображение на фрагменты. С помощью текущей сегментации y оценить корреляционный параметр $\hat{\beta}$ для каждого фрагмента;

d) интерполировать полученные значения $\hat{\beta}$ и получить значения корреляционного параметра $\hat{\beta}_{ij}$ для каждого пикселя (i, j);

e) выполнить одну итерацию ICM. При вычислении потенциальной функции использовать значения оценок $(\hat{\mu}_c, \hat{\sigma}_c, \hat{\beta}_{ij})$ текущую сегментацию y и интенсивность x. Сохранить полученную сегментацию в y_0;

f) если y_0 и y не удовлетворяют условиям сходимости, повторить шаг 2.

Наиболее практичное условие сходимости – ограничение количества итераций для цикла 2. Это не требует длительной процедуры проверки и гарантирует фиксированное время выполнения алгоритма.

7.4. Анализ последовательной реализации алгоритма ICM

Анализ предложенного алгоритма показывает, что распараллеливание можно выполнить лишь внутри шага 2, поскольку сам цикл не распараллеливается, а этап вычисления начальной сегментации по алгоритму *k*-средних не требует значительных вычислительных ресурсов. Наиболее естественно распараллеливание по тем фрагментам изображения, которые используются для вычисления и дальнейшей интерполяции корреляционного параметра. Три внутренних цикла (п. c, e и частично b) состоят из абсолютно независимых вычислений, которые можно эффективно распределить по различным процессорам. При этом каждый процессор будет выполнять модификацию последовательного алгоритма над своим фрагментом, но не разбивать свою часть изображения для вычисления корреляционного параметра, а вычислять его один раз для всего фрагмента (рис. 7.4).

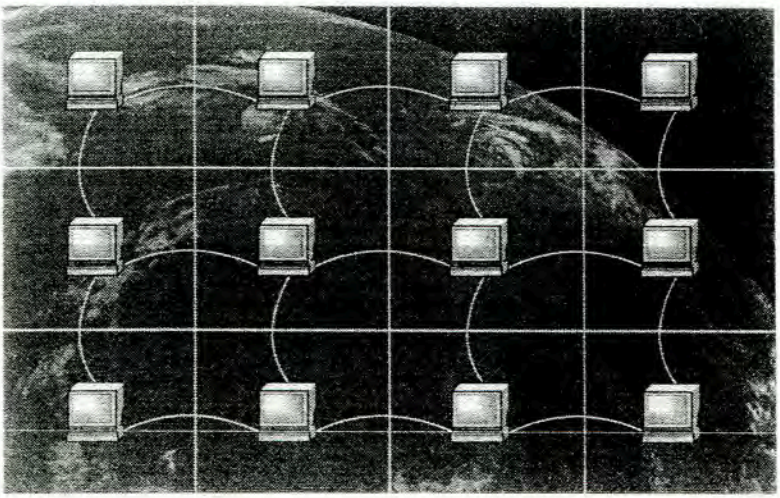


Рис. 7.4. Схема распределения изображения по вычислительным узлам

7.5. Параллельная реализация алгоритма марковской сегментации

Каждому вычислительному узлу передается несколько фрагментов изображения. В частном случае каждому процессору может передаваться один фрагмент. Для вычисления нового значения сегментации в алгоритме ICM используются значения интенсивности и текущей сегментации соседних пикселей, поэтому после каждой итерации процессоры должны обменяться границами своих частей изображения.

Алгоритм параллельной марковской сегментации можно сформулировать следующим образом.

1. Главный процессор считывает значения интенсивности x, выполняет сегментацию методом k-средних и получает начальную сегментацию y_0.

2. Главный процессор рассылает другим процессорам соответствующие части исходного изображения и начальной сегментации.

3. Все процессоры (включая главный) переходят к следующим вычислениям:

a) устанавливается текущая сегментация $y=y_0$;

b) на основе текущей сегментации y и значения интенсивности x вычисляют значения оценок (μ_c, σ_c) и количества пикселей N_c для каждого класса c;

c) все процессоры обмениваются вычисленными значениями (μ_c, σ_c, N_c), затем вычисляют значения оценок (μ_c, σ_c) для соответствующей части изображения;

d) на основе текущей сегментации y процессорами вычисляется значение корреляционного параметра $\hat{\beta}$ для своей части изображения;

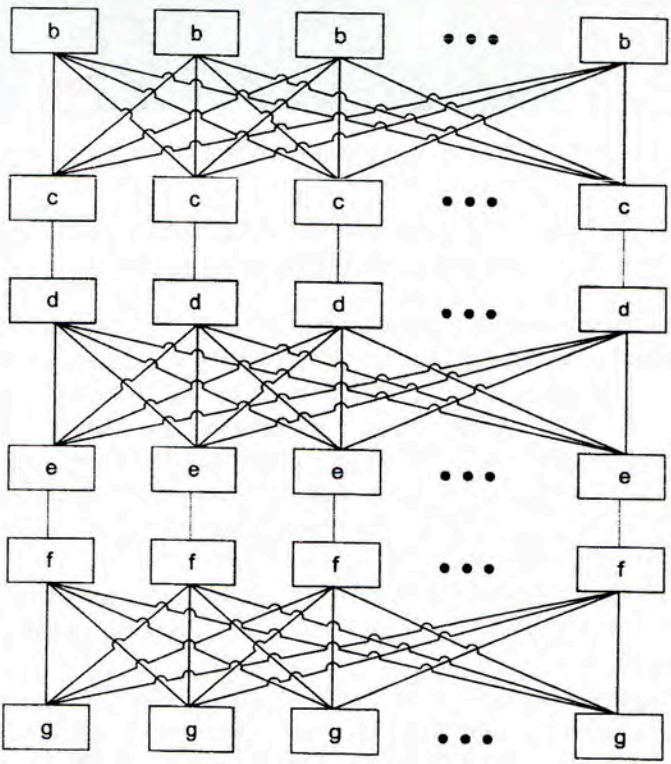


Рис. 7.5. Схема обмена сообщениями между вычислительными узлами на различных этапах цикла 3

e) все процессы обмениваются полученными значениями $\hat{\beta}$ и на основе билинейной интерполяции вычисляют значения корреляционного параметра $\hat{\beta}_{ij}$ для каждого пикселя (i, j) соответствующей части изображения;

f) выполняется одна итерация алгоритма ICM. Для вычисления потенциальной функции используют значения оценок $(\mu_c, \sigma_c, \hat{\beta}_{ij})$, текущую сегментацию y и интенсивность x. Полученная сегментация сохраняется в y_0;

g) процессы обмениваются границами своих частей изображения;

h) если y_0 и y не удовлетворяют условиям сходимости, следует повторить шаг 3.

4. Процессоры отсылают вычисленные значения сегментации главному процессору.

На рис. 7.5 представлен обмен данными между процессорами на различных этапах распараллеленного цикла. Каждому процессору соответствует столбец схемы, а обмен данными представлен линиями связей.

7.5.1. Программная реализация алгоритма

В основу реализации параллельной формы алгоритма положен стандарт MPI (Message Passing Interface) [98]. Выбор этого стандарта обусловлен его широкой распространенностью, легкостью объединения с программным кодом на языке C++ и наличием специальных функций, предназначенных для группового обмена данными. В процессе программирования наибольшие сложности были связаны с выполнением синхронизации границ фрагментов изображений, что более подробно рассматривается в следующем подразделе. Разработанный параллельный алгоритм позволяет естественным образом распределять вычисления по наиболее распространенным архитектурам кластеров: сеточной, тороидальной и гиперкубической (рис. 7.6–7.8). Кроме того, с некоторыми дополнительными коммуникационными издержками алгоритм может использоваться и в обычной локальной сети со звездообразной топологией.

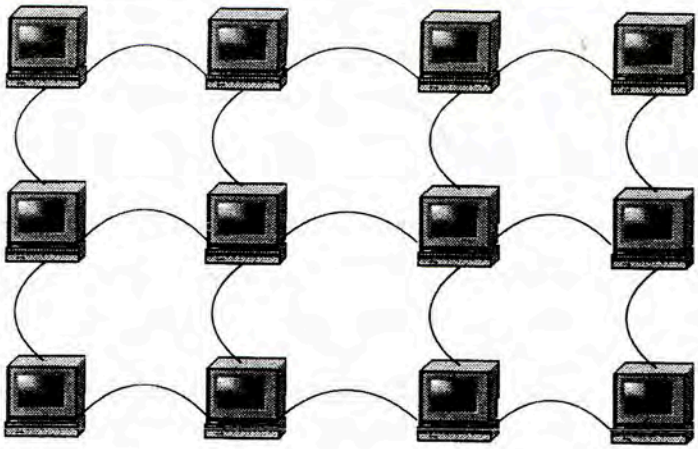


Рис. 7.6. Сеточная архитектура

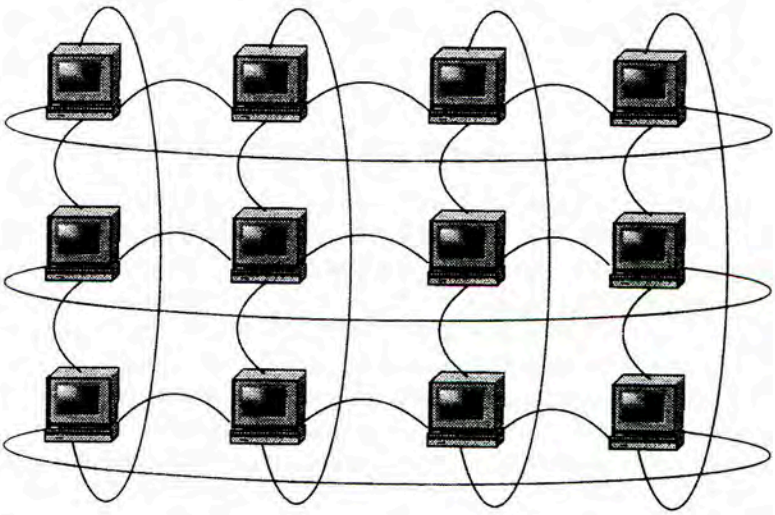


Рис. 7.7. Тороидальная архитектура

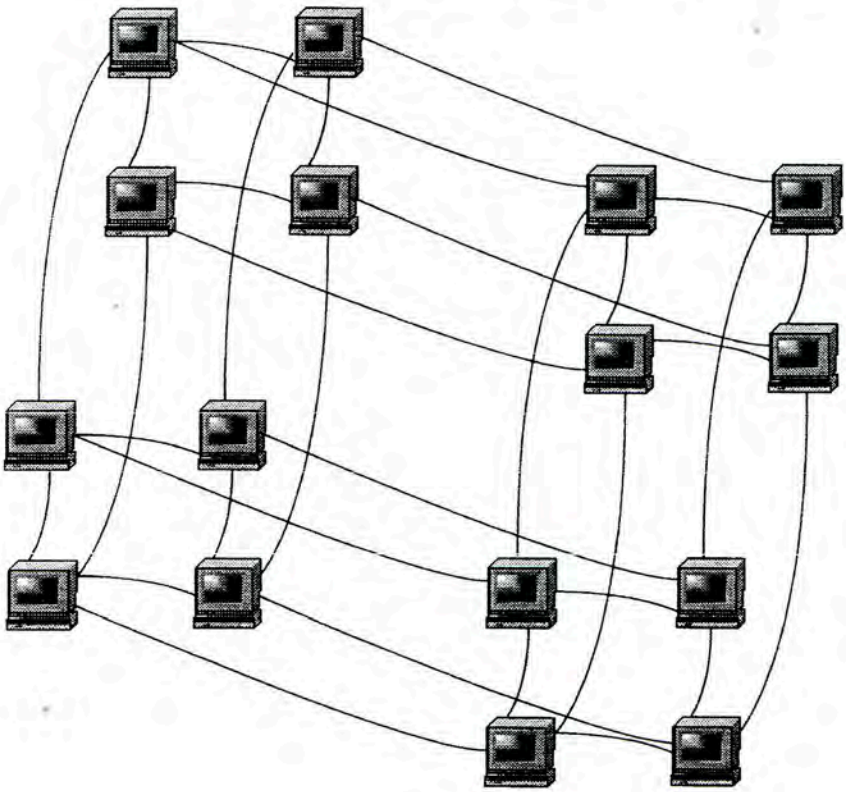


Рис. 7.8. Гиперкубическая архитектура

7.5.2. Синхронизация границ фрагментов изображения

При выполнении параллельного алгоритма марковской сегментации необходимо обеспечить синхронизацию границ фрагментов, которые обрабатываются различными процессорами. С точки зрения программной реализации эта задача достаточно сложна. На рис. 7.9 показаны те участки фрагментов изображения, которые должны быть переданы для выполнения синхронизации.

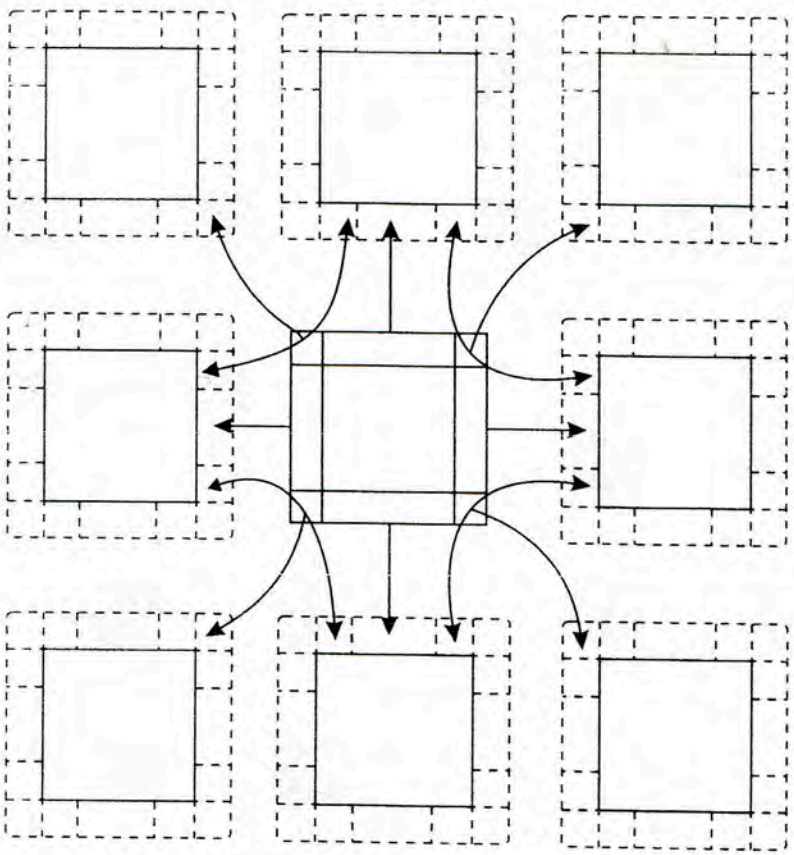


Рис. 7.9. Схема отношений границ фрагментов изображения на различных вычислительных узлах

Как видно из рис. 7.9, каждый фрагмент изображения содержит восемь фрагментов, подлежащих пересылке, и шестнадцать фрагментов, которые должны быть переданы его «соседями».

Основная сложность связана с тем, что при синхронном обмене сообщениями на основе MPI отправляющий процессор должен явно быть связан с процессором-получателем, а получающий процессор - с процессором-отправителем. Возврат из функции передачи и получения сообщения не будет выполнен до тех пор, пока не будет установлено

соединение. Таким образом, для корректного выполнения синхронизации все вызовы функций передачи/получения сообщений должны быть строго согласованы между собой. На рис. 7.10–7.12 графически представлен алгоритм, позволяющий избежать взаимных блокировок процессоров и корректно выполнить синхронизацию.

С каждым процессором связывается метка по принципу, который проиллюстрирован на рис. 7.10.

1	2	1	2	1
3	4	3	4	3
1	2	1	2	1
3	4	3	4	3
1	2	1	2	1

Рис. 7.10. Шаблон маркирования фрагментов изображения

Метку каждого процессора можно определить на основе выражения

$$N = x \bmod 2 + 2(y \bmod 2), \tag{7.4}$$

где x, y – координаты процессора MPI в разбиении изображения.

Синхронизация выполняется за четыре шага. На каждом шаге каждый процессор выполняет определенную функцию, которая зависит от его метки и номера шага. Эти функции выполняют прием или передачу сообщений в определенном направлении. Всего необходимо реализовать четыре функции, которые далее обозначаются как A, B, C, D. Действия, выполняемые каждой из этих функций, показаны на рис. 7.11.

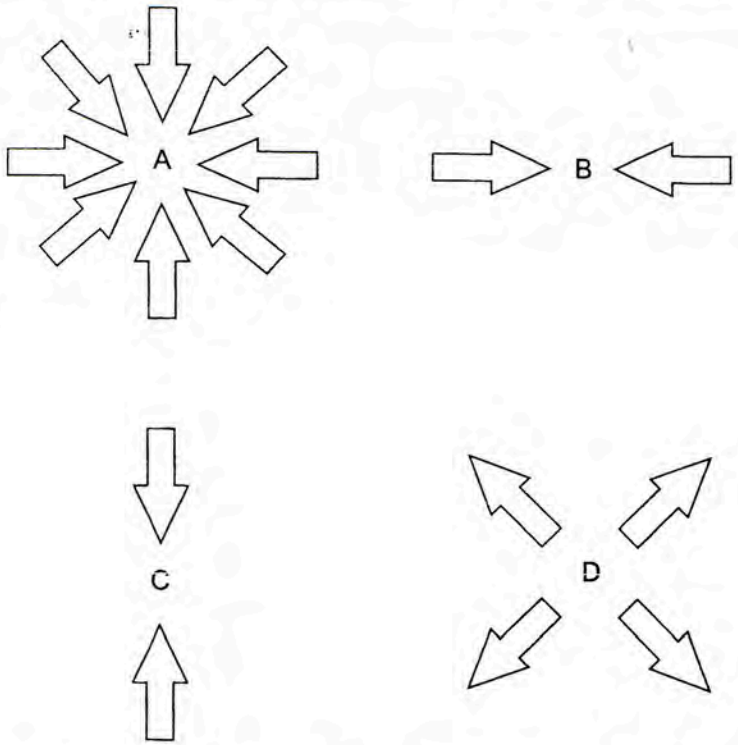


Рис. 7.11. Направления получения и передачи сообщений на различных этапах синхронизации границ фрагментов изображения

Как видно из рис. 7.11, во время выполнения функции A процессор принимает сообщения, содержащие границы всех окружающих его фрагментов изображения. При выполнении функций B, C и D процессор отсылает свои границы в соответствующих направлениях. Так, при выполнении функции B отсылаются восточная и западная границы, а также угловые участки в восточном и западном направлении.

После завершения выполнения одной функции приема/передачи сообщений алгоритм переходит на следующий шаг, которому соответствует другая функция приема/передачи. Номер шага соответствует метке, отображающей его положение (рис. 7.12).

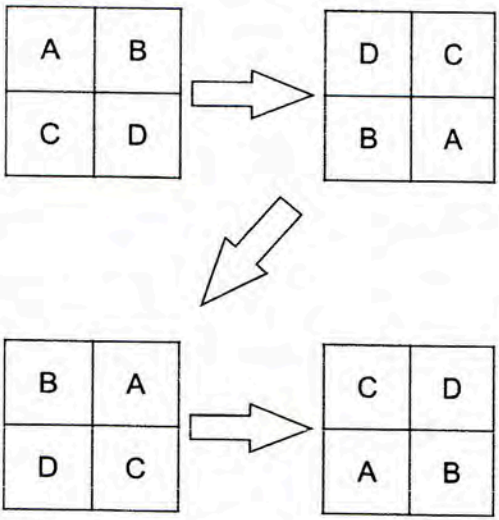


Рис. 7.12. Схема перехода между различными разбиениями на каждом этапе синхронизации границ

Программно эту зависимость легче всего задать с помощью таблицы, которая ставит в соответствие метку процесса и номер шага определенной функции.

Таким образом, на каждом шаге алгоритма синхронизации обеспечивается согласованность передачи и приема сообщений различными процессорами. Это позволяет обойти проблему взаимной блокировки процессов.

На языке псевдокода алгоритм синхронизации краев фрагментов изображения можно представить следующим образом:

```
switchFunction = function(int f, int i)
begin
      func[4][4] = {
            {0, 3, 1, 2},
            {1, 2, 0, 3},
            {2, 1, 3, 0},
            {3, 0, 2, 1}
      };
     switchFunction = func[f][i];
end;
```

```
    f = x%2 + 2*(y%2);

    for i = 1..4
    begin
          switch (switchFunction(f, i))
          begin
          case 0:
                exchangeStageA(neiborhoods);
                break;
          case 1:
                exchangeStageB(neiborhoods);
                break;
          case 2:
                exchangeStageC(neiborhoods);
                break;
          case 3:
                exchangeStageD(neiborhoods);
                break;
          end;
end.
```

7.5.3. Коэффициент ускорения и его оценки

Согласно [99], один из важнейших параметров параллельных алгоритмов – коэффициент ускорения, показывающий выигрыш во времени в зависимости от количества задействованных процессоров. В общем случае он определяется следующим образом:

$$R = \frac{\sum_{i=1}^{s} p_i \pi_i}{\max\limits_{1 \le i \le s} \pi_i}, \tag{7.5}$$

где s – количество процессоров в системе, p_i – загруженность i-го процессора, π_i – пиковая производительность i-го процессора.

Максимальное ускорение достигается в том случае, когда все s устройств имеют одинаковую пиковую производительность и полностью загружены. В этом случае $R = s$.

Другая важная характеристика параллельных алгоритмов – доля последовательных вычислений. Она определяется выражением

$$\beta = \frac{n}{N}, \tag{7.6}$$

где n – количество операций, которые должны выполняться последовательно, N – общее количество операций в алгоритме.

В соответствии с законом Амдала отношение между ускорением и долей последовательных вычислений можно выразить следующим образом:

$$R = \frac{s}{\beta s + (1-\beta)}. \tag{7.7}$$

Еще одна представляющая интерес характеристика – относительная длительность последовательных операций γ. Она вводится в предположении, что параллельная часть алгоритма полностью занимает s устройств и полное время выполнения алгоритма равняется единице. Относительная длительность γ и доля последовательных операций β связаны соотношением

$$\gamma = \frac{s\beta}{1 + (s-1)\beta}. \tag{7.8}$$

Относительная длительность последовательных операций так же, как и доля последовательных операций в алгоритме, позволяет определить коэффициент ускорения:

$$R = s - (s-1)\gamma. \tag{7.9}$$

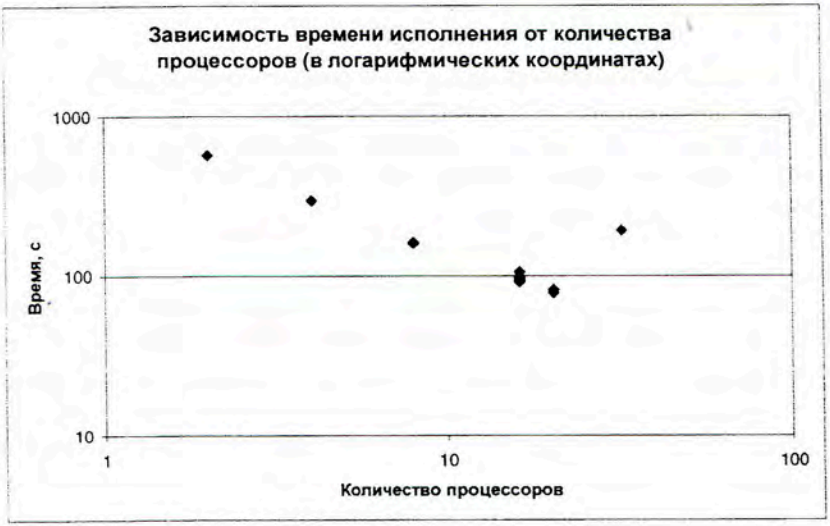
Эта формула называется формулой Густавсона-Барсиса.

Законы Амдала и Густавсона-Барсиса выражают одну и ту же характеристику параллельного алгоритма, однако их практическое применение несколько различается. Формула Амдала хорошо подходит для прогноза возможного ускорения, когда величину β можно непосредственно подсчитать. Формула Густавсона-Барсиса применима для оценивания уже достигнутого ускорения, когда величина γ может быть непосредственно измерена.

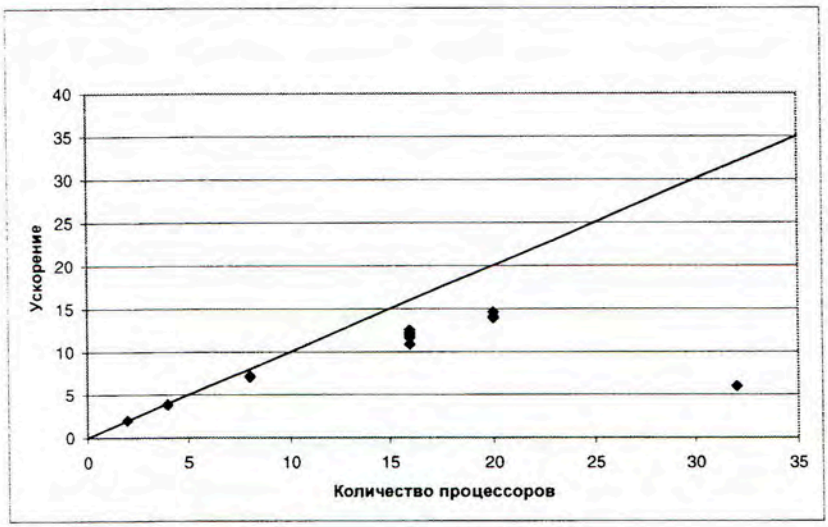
7.6. Результаты экспериментов

Алгоритм марковской сегментации был применен для выделения облаков на снимке IR-канала спутника Meteosat-7 [94, 95].

На рис. 7.13 представлены диаграммы зависимостей времени выполнения и ускорения в зависимости от количества используемых процессоров.



а



б

Рис. 7.13. Экспериментальные зависимости времени (*а*) и ускорения (*б*) от количества процессоров

В ходе экспериментов при увеличении количества вычислительных узлов до 20 наблюдался устойчивый рост производительности с минимальными потерями в ускорении. Однако на 32 процессорах проявилось резкое падение производительности. Очевидно, это связано с разделяемой природой коммуникационной среды Ethernet, с помощью которой выполнялся обмен данными между вычислительными узлами. После некоторого количества одновременных запросов на разрешение коллизий начинает затрачиваться непропорционально много времени. Следует ожидать, что после перехода на специализированную среду, например SCI, падения производительности на большом количестве процессоров не произойдет.

Глава 8

ПРОГНОЗИРОВАНИЕ МЕЖПЛАНЕТНЫХ УДАРНЫХ ВОЛН В СОЛНЕЧНОМ ВЕТРЕ

Понятие «космическая погода» объединяет комплекс внешних по отношению к Земле процессов в верхних слоях атмосферы и ионосфере, которые влияют на функционирование космических и наземных систем, а также на биосферу и здоровье людей [100]. Во многом эти процессы обусловлены солнечной активностью. В последнее время актуальность исследований космической погоды возрастает, поскольку космические бури часто приводят к существенным повреждениям высокотехнологических систем связи, спутников, навигационных систем и электрических сетей. Например, геомагнитная буря 13 марта 1989 года вызвала девятичасовое отключение одной из самых больших электростанций Северной Америки Hydro-Quebec в провинции Квебек (Канада) [101]; ущерб оценивается в 13,2 млн. долларов. Во время этой бури была повреждена атомная станция в Нью-Джерси (США), что нанесло ущерб еще в несколько миллионов долларов. Больше всего космическая активность влияет на космические станции и спутниковые системы. В 1973 году станция Skylab вышла на нестабильную орбиту и со временем сгорела в атмосфере Земли вследствие того, что солнечная активность оказалась выше прогнозированной (http://www-pao.ksc.nasa.gov/history/skylab/skylab-operations.htm). Аномальный выброс радиации, вызванный так называемым «Днем Бастилии» 14 июля 2000 года, стал причиной появления белых линий на CCD-матрице аппарата SOHO. Несмотря на прогнозируемое снижение солнечной активности последние годы характеризуются рядом чрезвычайно опасных солнечных выбросов. С октября по ноябрь 2003 года наблюдалась серия аномальных солнечных вспышек, которые привели к отключению энергосистемы в Швеции, повреждениям спутников и первого в истории предупреждения об опасности радиационного влияния для пассажиров самолетов на высоте в 25000 футов [102]. Вспышка 28 октября 2003 года имела наибольшее влияние на Землю с 1859 года, когда оказалась разорвана телеграфная связь. Во время последней солнечной вспышки 13–16 декабря 2006 года пострадало несколько космических

миссий, в частности Envisat и Cluster; кроме того, произошло широкомасштабное отключение коммуникационных систем в Китае. В связи с этими событиями ЕКА заявило о необходимости активизации исследований космической погоды и создания систем ее прогнозирования (http://www.esa.int/SPECIALS/ESOC/SEMB49QJNVE_0.html).

В периоды повышения солнечной активности, частота которых на протяжении 11-летних солнечных циклов возрастает, в короне Солнца рождаются потоки рентгеновского излучения и солнечных энергетических частиц (СЭЧ). Кроме того, происходят выбросы больших масс плазмы (КВМ) и магнитного поля в межпланетное пространство, образующие в солнечном ветре (СВ) ударные волны (УВ) как аномальное усиление интенсивности СВ, которые вызывают возмущения магнитосферы Земли. Интервал между временем формирования УВ и достижением ею Земли составляет несколько дней, а в случае точной направленности на Землю – полтора-два дня. Прогнозирование времени прихода УВ и ее пиковой интенсивности позволит принять соответствующие меры по минимизации отрицательного воздействия солнечной активности. Именно поэтому дистанционная идентификация УВ в СВ и определение времени ее прихода на Землю представляют собой одну из важнейших задач мониторинга и краткосрочного прогнозирования космической погоды в околоземном пространстве.

8.1. Подходы к прогнозированию УВ

Дистанционные наблюдения КВМ с помощью коронографов теоретически позволяют строить прогноз УВ на несколько суток. Однако для этого необходимо разработать адекватную модель распространения и выброса КВМ в гелиосфере и распространения СВ в межпланетном пространстве, что существенно усложнено отсутствием требуемых данных. Другой подход к решению задачи прогнозирования состоит в использовании эмпирических моделей, которые базируются на методах физических, интеллектуальных и системного анализа. В большинстве подобных моделей используют данные спутника ACE и космического аппарата SOHO. К классу физических прежде всего следует отнести следующие модели:

1) модель STOA (Shock Time Of Arrival), основанная на теории подобия взрывных волн [103, 104];
2) модель ISPM (Interplanetary Shock Propagation Model), в которой имитируются 2,5-измеряемые магнитогидродинамические (МГД) потоки [105];

3) кинетическая модель СВ HAF (Hakamada-Akasofu-Fry) [106];
4) трехмерная МГД-модель [107].

Для решения задачи прогнозирования космической погоды иногда применяются модели нелинейной авторегрессии со скользящим средним и экзогенным дополнением (NARMAX) [108, 109]. Главный недостаток всех перечисленных моделей – высокая вычислительная сложность и низкая точность получаемого прогноза, а также необходимость использования дополнительной информации, которую зачастую получить достаточно трудно.

Для создания адаптивных систем анализа данных о космической погоде используют и НС. В работе [110] нейросетевой подход предлагается применять для прогнозирования времени прибытия УВ на Землю по данным инструмента EPAM (модуля мониторинга протонов, электронов и альфа-частиц) спутника ACE. Началом развития УВ авторы считают значительное увеличение интенсивности частиц на всем энергетическом спектре. Для решения задачи прогнозирования в [110] применяются рекуррентные НС, которые обучены и протестированы только на 56 УВ за период с 1997 по 2001 год, в то время как их общее количество за это время составляет 160. Средняя ошибка прогноза прибытия УВ за 24 часа – 8,9 часа, а за 12 часов – 4,6 часа.

Рассмотрим изложенный в [110] подход, на основе которого предлагается более эффективная процедура определения начала УВ, а также усовершенствованный метод определения времени прибытия УВ. Кроме того, покажем разработанный авторами подход, который позволяет заранее (в начале зарождения УВ) определить степень ее опасности.

Предлагаемая схема предполагает использование трех модулей [111, 112]: модуля идентификации начала УВ, модуля классификации УВ и модуля прогнозирования времени ее прибытия. Работа первого модуля основана на пороговой фильтрации по обобщенным характеристикам потока протонов СВ. Второй и третий модули реализованы с использованием НС и позволяют определить тип УВ и время ее прибытия соответственно. Все три модуля используют данные инструмента EPAM спутника ACE, а их результаты верифицированы на независимых наблюдениях солнечных вспышек, проведенных центром Института земного магнетизма, ионосферы и распространения радиоволн Российской академии наук (ИЗМИРАН) [113].

8.1.1. Данные ACE/EPAM

Основная цель запуска в 1997 году КА ACE заключается в измерении параметров солнечной короны, СВ и т.д. Спутник ACE производит наблюдения в так называемой точке Лагранжа L1 – либрационной точке около линии Земля–Солнце на расстоянии 1,5 млн км от Земли, что составляет приблизительно 1 % расстояния между Землей и Солнцем. Прибор EPAM спутника ACE выполняет измерения спектра заряженных частичек в точке L1 и может использоваться для идентификации и наблюдения за УВ в СВ. Данные измерений свободно распространяются через Интернет [114, 115]. В предлагаемых моделях в качестве входных данных используются пять энергетических каналов инструмента EPAM (табл. 8.1).

Таблица 8.1. **Измерения инструмента ACE/EPAM LEMS30**

Канал	Энергетический диапазон (Ме)	Частицы
P1	0,047–0,065	Протоны
P3	0,112–0,187	Протоны
P5	0,310–0,580	Протоны
P6	0,580–1,06	Протоны
P7	1,06–1,91	Протоны

Для верификации предложенных моделей использована дополнительная информация:

– данные о протонах, электронах и альфа-частицах СВ (SWEPAM) спутника ACE, который предоставляет подробную информацию о текущем состоянии СВ;

– данные о геомагнитных штормах и космических бурях, опубликованные на сайте ИЗМИРАН [113].

Все эксперименты проводились на основании данных солнечной активности в 2000 году, в котором зафиксировано 40 УВ.

8.1.2. Модуль прогнозирования УВ

С помощью измерений, выполненных спутником ACE, можно зафиксировать УВ и некоторые ее параметры, например, количество заряженных частиц, скорость и плотность потока вблизи магнитосферы Земли. Благодаря тому, что радиоволны распространяются в тысячи

раз быстрее, чем СВ, сигнал об увеличении солнечной активности, поступивший со спутника ACE, может опередить прибытие УВ на 10–40 минут. Достоверность такого прогноза (продолжительностью до 1 часа) составляет около 100 %, поскольку он основывается на прямых наблюдениях возле самой границы околоземного пространства. К сожалению, временная ограниченность не позволяет использовать его в большинстве прикладных задач. Для построения прогноза с большим запасом времени (на 24–48 часов) применяется физическая модель распространения УВ в СВ, которая позволяет выделить в процессе прибытия УВ на Землю несколько этапов.

Как уже упоминалось, резкое увеличение интенсивности СЭЧ во всех энергетических диапазонах называют началом развития УВ. Критический порог интенсивности СЭЧ, после превышения которого начинаются значительные геомагнитные возмущения и возникает потенциальная опасность для различных систем и живых существ, называют пиком интенсивности. Обычно интервал времени между началом развития УВ и первым опасным пиком составляет 12–48 часов, в зависимости от скорости СВ и направления распространения УВ.

Для предупреждения УВ в режиме реального времени предлагается система их прогнозирования в СВ, которая состоит из трех модулей (рис. 8.1): детектора УВ и двух нейросетевых модулей для определения типа и времени прибытия УВ.

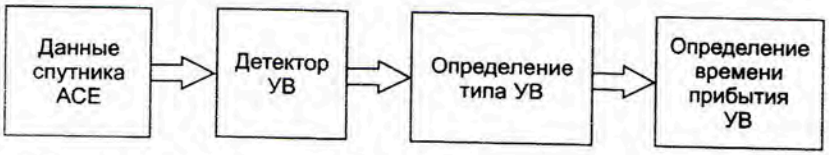


Рис. 8.1. Архитектура системы прогнозирования

8.1.3. Алгоритм идентификации УВ

Модуль детектора УВ реализует предложенный в [116] алгоритм идентификации развития УВ. Этот момент определяется с помощью порогового фильтра, который использует обобщенные характеристики наблюдений инструмента EPAM спутника ACE для идентификации развития УВ в СВ. В качестве входа используются две обобщенные скорости интенсивности потока: первая получена путем интеграции производных

интенсивностей протонов (скоростей) в отдельных каналах, а другая, наоборот, – производная скорости в объединенном канале.

Алгоритм идентификации УВ, подробно описанный в работе [116], состоит из таких этапов.

Предварительная обработка входных данных с использованием линейного сглаживания.

Определение обобщенных характеристик: интенсивности частиц для обобщенного канала и изменения интенсивности потока для обобщенной скорости.

Определение роста интенсивности общего потока с использованием порогового фильтра по обобщенным скоростям.

Для идентификации момента возникновения УВ используются следующие обобщенные характеристики:

1) $P(t)$ – интенсивность обобщенного канала как объединение данных всех информативных каналов EPAM;

2) $V_M(t)$ – обобщенная мультипликативная скорость как объединение скоростей роста интенсивности в отдельных каналах;

3) $V_C(t)$ – обобщенная скорость как изменение интенсивности в обобщенном канале.

Эти значения вычисляются в соответствии с выражениями

$$P(t) = \prod_{i=1}^{N} P_i(t), \; V_i(t) = \frac{dP_i(t)}{dt},$$

$$V_M(t) = \prod_{i=1}^{N} V_i(t), \; V_C(t) = \frac{dP(t)}{dt},$$

где $P_i(t)$ – интенсивность в канале i в момент времени t; $\frac{dP_i(t)}{dt} = \frac{P_i(t) - P_i(t-\Delta t)}{\Delta t}$ – численное выражение производной интенсивности в канале $P_i(t)$; Δt – промежуток времени между последовательными измерениями.

Численные значения порога для предложенного алгоритма получены на основе исторических данных (прежде всего за 2000 год) путем минимизации общей погрешности при максимизации количества определенных УВ:

$$L_M = \arg \min_{L_M, t \in T} \max_{L_M, t \in T} (V_M(t) \geq L_M),$$

$$L_C = \arg \min_{L_C, t \in T} \max_{L_C, t \in T} (V_C(t) \geq L_C) .$$

Здесь L_M – значение порога для первого фильтра; L_C – значение порога для второго фильтра; T – массив значений дат с выраженными скачками СВ.

Значения времени и интенсивности УВ в предлагаемом алгоритме верифицируются по скорости и плотности СВ согласно измерениям прибора SWEPAM спутника ACE. Аномальные скачки этих характеристик традиционно связывают с предыдущими УВ и широко используют в исследованиях космической погоды.

Для работы в режиме реального времени используют комбинированный двойной фильтр, в котором начало развития УВ определяют либо по первому, либо по второму фильтру. Если обобщенная скорость (или $V_C(t)$) потока протонов превышает определенный порог, то такая аномальная активность рассматривается как начало развития УВ. Момент возникновения УВ определяют согласно двойному предикату (DP):

$$DP=(V_M(t)\geq L_M)\vee(V_C(t)\geq L_C),$$

где $\vee$ – логическое "ИЛИ".

Результаты экспериментов показывают конкурентоспособность описанного подхода. Так, с использованием данных за 2000 год удалось идентифицировать 89 % периодов активности, которые определяются по наблюдениям инструмента SWEPAM. Разработанный алгоритм автоматического определения УВ более точен по сравнению с алгоритмом, описанным в [110], что подтверждается данными независимых наблюдений [113]. Более того, он надежно определяет УВ разных типов, включая слабые и умеренные волны, которые не рассматривались в работе [110].

8.1.4. Алгоритм классификации УВ

Модуль определения типа УВ (см. рис. 8.1) обеспечивает нейросетевую классификацию УВ на безопасные и опасные. В общем случае, согласно классификации NOAA [117], УВ делятся на пять классов: S1 (слабая), S2 (умеренная), S3 (сильная), S4 (опасная) и S5 (очень опасная). В данной главе УВ разделяются на два класса: безопасные (S1 и S2) и опасные (S3, S4, S5).

Для классификации используется авторегрессионная модель с внешним входом NARX, НС прямого распространения и входными данными, дополненными временным окном [118]. Многочисленные эксперименты показали, что такая модель может эффективно обучается и получаемые на ее основе результаты оказываются лучшими по сравнению с другими известными методами, включая более сложные модели рекуррентных НС, которые используют в [110].

В предлагаемом алгоритме классификации УВ в качестве входных данных для сети используется информация об интенсивности по каналам в текущий момент времени и за девять предыдущих измерений (размер временного окна составляет 50 минут):

$$NN_{\text{INPUT}} = \left\{ \hat{P}_i(t - k\Delta t), \quad i = \overline{1, N}, \ k = \overline{0, 9} \right\}.$$

Здесь $\hat{P}_i(t)$ – нормализованная интенсивность в канале i в момент времени t; N – количество информативных каналов (в данном случае N=5); Δt – промежуток времени между последовательными измерениями (5 минут).

Для нормализации данных предлагается применять асимметрическое афинное преобразование вида

$$\hat{x}_j = \begin{cases} \text{th}\left(\dfrac{x_j - x_c}{x_{\max} - x_c} K \right), & \text{если } x_j \geq x_c, \\ \dfrac{x_j - x_c}{x_c - x_{\min}} K, & \text{если } x_j \leq x_c, \end{cases}$$

где $\hat{x}_j$, x_j – нормализованное и начальное j-е значения параметра; xc – среднее значение параметра (медиана); $x_{\max}$ – наибольшее значение параметра; $x_{\min}$ – наименьшее значение параметра; K – коэффициент сжатия (K=1).

Как классификатор применяется НС прямого распространения $NN_{50\times70\times1}$, входной слой которой содержит 50 нейронов, скрытый – 70, а выходной состоит из одного нейрона. Выход НС интерпретируется следующим образом: если $NN_{\text{OUTPUT}} > 0$ – текущие наблюдения относятся к опасной УВ, иначе – к безопасной.

8.1.5. Алгоритм прогноза времени прибытия УВ

Для прогнозирования времени прибытия УВ используем НС прямого распространения с 65 входами, 90 нейронами в скрытом слое и одним выходным нейроном – $NN_{65\times90\times1}$:

$$NN_{\text{INPUNT}} = \left\{ \begin{matrix} \{ \hat{P}_i(t-k\Delta t),\ \hat{V}_i(t-k\Delta t),\ \hat{P}(t-k\Delta t), \hat{V}_C(t-k\Delta t), \hat{V}_M(t-k\Delta t),\ i=\overline{1,\ N} \} \\ k=\overline{0,\ 4} \end{matrix} \right\};$$

в этом выражении $\hat{P}_i(t)$ – нормализованное значение интенсивности в канале i в момент времени t; $\hat{V}_i(t)$ – нормализованная сглаженная скорость в канале i; $\hat{P}(t)$ – нормализованное значение интенсивности обобщенного канала; $\hat{V}_C(t)$ – нормализованная обобщенная скорость в обобщенном канале; $\hat{V}_M(t)$ – нормализованная обобщенная скорость по скоростям отдельных каналов; N – количество информативных каналов; Δt – промежуток времени между последовательными измерениями (5 минут).

8.2. Результаты экспериментов

Опишем кратко результаты, полученные в процессе проведения научных экспериментов по выявлению УВ и их классификации [111, 112].

8.2.1. Результаты идентификации УВ

На основе предложенного алгоритма с двойным фильтром для 2000 года были определены 40 УВ, пять из которых не имеют ни одного достаточно опасного пика интенсивности. В 18 из них наблюдаются лишь слабые пики ($P_1(t) \geq 10^4$), в двенадцати – умеренные пики ($P_1(t) \geq 10^5$) и в пяти – пики большой интенсивности ($P_1(t) \geq 10^6$).

На рис. 8.2 приведены графическая интерпретация процесса прибытия УВ и их классификация в соответствии с мощностью пиков в реальном времени. По оси абсцисс отложены отдельные УВ, а по оси ординат – время с момента идентификации УВ до окончания периода активности. Достижение первого пика определенной интенсивности для каждой УВ выделено изменением цвета. На рис. 8.2 показано, что большинство УВ за несколько суток развивается от потоков с небольшой интенсивностью до опасных пиков.

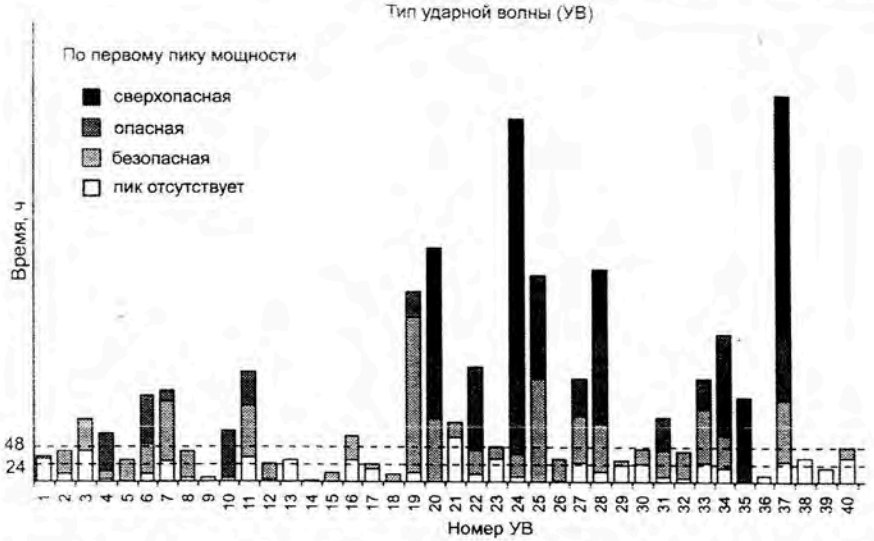


Рис. 8.2. Классификация УВ по первым пикам разной мощности в режиме реального времени для УВ за 2000 год

Результаты применения алгоритма к историческим данным дали возможность зафиксировать начало развития УВ в 89 %, что почти втрое превышает результат фильтра, предложенного в работе [110]. Полученные результаты позволили создать систему определения УВ в режиме реального времени, которая успешно функционирует с сентября 2006 года на портале системы «Космическая погода» (соответствующие результаты можно найти по адресу http://spaceweather.org.ua).

8.2.2. Результаты классификации УВ

Полученный перечень УВ за 2000 год используется как входные данные для модуля классификации. При проведении экспериментов векторы наблюдений в отдельные моменты времени по каждой УВ были преобразованы в общий массив данных, который, в свою очередь, был разбит на обучающую выборку (9954 вектора) и тестовую (6636 векторов). Для обучения применяется одна из разновидностей алгоритма обратного распространения ошибки по методу градиентного спуска — алгоритм Resilient Propagation (Rprop) [119], в частности его адаптивная реализация iRPROP [120]. Алгоритм относится к классу

алгоритмов группового обучения, в которых коррекция веса в сети проводится после предъявления всех учебных векторов. Основное преимущество выбранного алгоритма обучения заключается в простоте реализации при большой скорости сходимости для сложных НС.

В качестве оценки эффективности НС используется среднеквадратичная погрешность (MSE):

$$\mathrm{MSE} = \frac{\sum_{t=0}^{t=NT-1} \left(NN_{\mathrm{OUTPUT}}(\mathrm{IN}_t) - \mathrm{OUT}\right)^2}{NT},$$

где $NN_{\mathrm{OUTPUT}}(\mathrm{IN}_t)$ – выход НС от входа IN_t, OUT_t – желаемый выход сети, NT – размер учебной или тестовой выборки.

Классификация УВ выполняется для НС с разным количеством скрытых нейронов. Наилучший результат получен для сети с 70 нейронами в скрытом слое, поэтому именно такая архитектура реализуется в модуле определения типа УВ (рис. 8.1). Для этой архитектуры среднеквадратичная погрешность по учебной выборке составляет 0,0969854; погрешность на тестовых данных, которые не использовались при обучении, – 0,0980823.

Способность НС различать разные классы УВ характеризуют следующие параметры:

– средний выход (MOC), который соответствует среднему выходу НС за период с момента ее идентификации до завершения периода активности:

$$\mathrm{MOC}^d = \frac{\sum_{t=t_{onset}}^{t=t_{IPshock}} NN_{\mathrm{OUTPUT}}(\mathrm{IN}_t^d)}{t_{IPshock} - t_{onset}},$$

где $NN_{\mathrm{OUTPUT}}(\mathrm{IN}_t^d)$ – выход НС от входа IN_t^d для УВ $d = \overline{1,40}$; t_{onset}, $t_{IPshock}$ – время начала УВ и прибытия первого пика;

– процент правильных ответов (CAR), который показывает количество правильных ответов НС за период с момента ее идентификации до окончания периода активности:

$$\mathrm{CAR}^d = \frac{\sum_{t=t_{onset}}^{t=t_{IPshock}} P(\mathrm{sign}(NN_{\mathrm{OUTPUT}}(\mathrm{IN}_t^d)), \mathrm{OUT}^d)}{t_{IPshock} - t_{onset}},$$

где $P(x, y)$ – предикат, который при условии $x = y$ равен единице, а в других случаях – нулю; ; sign() – функция сигнума.

Результаты применения обученной НС для классификации УВ приведены в табл. 8.2.

Таблица 8.2. **Результаты тестирования по отдельным УВ**

Номер	Дата и время начала	Дата и время окончания	Класс УВ −1 (безопасная) или +1 (опасная)	Параметры классификации $\overline{d = 1,40}$		
				MSE^d	MOC^d	CAR^d
1	01.01.2000 12:25: 00	02.01. 2000 02:00:00	−1	0,2310	−0,1034	0,6426
2	09.01. 2000 10:25:00	11.01. 2000 06:45:00	−1	0,2420	−0,1455	0,4545
3	19.01. 2000 10:30:00	23.01. 2000 06:45:00	−1	0,1413	−0,3009	0,8976
4	27.01. 2000 04:10:00	30.01. 2000 07:00:00	1	0,218	0,3195	0,5569
5	06.02. 2000 09:20: 00	07.02. 2000 04:25:00	−1	0,9810	0,9809	0
6	10.02. 2000 11:45: 2000	14.02.2000 07:55:00	1	0,0640	0,7382	0,9069
7	18.02. 2000 08:40: 2000	21.02. 2000 12:10:00	1	0,0813	0,6082	0,9039
8	24.02. 2000 04:15:00	26.02. 2000 12:50:00	−1	0,3901	0,1222	0,5873
9	01.03. 2000 01:45:00	01.03. 2000 02:05:00	−1	0,0685	−0,4850	1
10	22.03. 2000 02:20:00	25.03. 2000 04:40:00	1	0,1078	0,6423	0,7727
11	04.04. 2000 09:35:00	08.04. 2000 06:30:00	1	0,0017	0,9779	1
12	23.04. 2000 01:25:00	24.04. 2000 03:00:00	−1	0,0972	−0,3955	0,98
13	28.04. 2000 03:00:00	29.04. 2000 10:10:00	−1	0,1249	-0,3614	0,872
14	01.05. 2000 04:05:00	01.05. 2000 06:35:00	−1	0,1442	−0,2513	0,9354
15	02.05. 2000 01:40:00	03.05. 2000 02:55:00	−1	0,5938	0,5411	0
16	06.05. 2000 06:05:00	09.05. 2000 01:55:00	−1	0,2361	−0,0869	0,6465
17	11.05. 2000 11:00:00	13.05. 2000 01:30:00	−1	0,1283	−0,3005	0,9185
18	13.05. 2000 06:10:00	14.05. 2000 05:15:00	−1	0,1051	−0,3514	1
19	14.05. 2000 07:20:00	25.05. 2000 12:25:00	1	0,0842	0,5584	0,9287

Продолжение табл. 8.2

Номер	Дата и время начала	Дата и время окончания	Класс УВ −1 (безопасная) или +1 (опасная)	Параметры классификации $\overline{d = 1,40}$		
				MSE^d	MOC^d	CAR^d
20	04.06. 2000 11:10:00	15.06. 2000 01:20:00	1	0,0048	0,9374	1
21	16.06. 2000 02:50:00	19.06. 2000 06:25:00	−1	0,1617	−0,3062	0,7967
22	22.06. 2000 12:00:00	28.06. 2000 02:55:00	1	0,2580	0,2524	0,5636
23	29.06. 2000 04:20:00	01.07. 2000 09:15:00	−1	0,1413	−0,4383	0,8028
24	09.07. 2000 01:10:00	29.07. 2000 12:40:00	1	0,0956	0,6757	0,8058
25	05.08. 2000 08:25:00	18.08. 2000 02:20:00	1	0,1048	0,4951	0,8729
26	02.09. 2000 05:55:00	03.09. 2000 03:00:00	−1	0,6651	0,6279	0
27	04.09. 2000 08:20:00	08.09. 2000 09:00:00	1	0,0536	0,7899	0,8848
28	12.09. 2000 06:10:00	21.09. 2000 05:20:00	1	0,0022	0,9812	1
29	28.09. 2000 12:25:00	29.09. 2000 07:35:00	−1	0,0777	−0,4869	0,9794
30	03.10. 2000 01:05:00	05.10. 2000 02:30:00	-1	0,1396	−0,3242	0,8626
31	11.10. 2000 12:30:00	14.10. 2000 08:50:00	1	0,0244	0,7626	1
32	16.10. 2000 07:35:00	18.10. 2000 04:00:00	−1	0,2008	−0,1239	0,6811
33	26.10. 2000 12:45:00	30.10. 2000 12:55:00	1	0,0233	0,8257	0,9968
34	30.10. 2000 01:15:00	06.11. 2000 10:40:00	1	0,0845	0,6013	0,8343
35	08.11. 2000 11:25:00	14.11. 2000 05:30:00	1	0,0623	0,7576	0,8461
36	22.11. 2000 06:15:00	23.11. 2000 02:50:00	−1	0,2555	−0,0143	0,3173
37	23.11. 2000 03:55: 2000	11.12. 2000 07:10:00	1	0,0755	0,6789	0,9107
38	12.12. 2000 06:25:00	14.12. 2000 06:20:00	−1	0,0161	−0,8292	0,9976
39	18.12. 2000 09:15:00	19.12. 2000 06:50:00	−1	0,4116	0,1881	0,5192
40	22.12. 2000 11:55:00	24.12. 2000 04:55:00	−1	0,0385	−0,6752	0,9772

Примеры применения обученной НС в режиме реального времени для УВ разного типа (безопасных и опасных) приведены на рис. 8.3 и рис. 8.4 соответственно.



Рис. 8.3. Результаты классификации безопасной УВ (19.01.2000–23.01.2000)



Рис. 8.4. Результаты классификации опасной УВ (18.02.2000–21.02.2000)

Безопасная УВ (рис. 8.3), которая наблюдалась на протяжении 4 дней и характеризовалась лишь слабыми пиками интенсивности потока протонов, большую часть времени классифицировалась НС как безопасная (на рисунке выходы лежат в нижней (отрицательной) полуплоскости относительно оси абсцисс). И наоборот, опасная УВ (рис. 8.4) еще в начале развития была правильно отнесена к классу опасных (выходы на рисунке лежат в верхней (положительной) полуплоскости), что со временем подтвердилось соответствующими УВ.

Среди 23 безопасных УВ правильно определено 80,59 % входных значений, т.е. погрешность второго рода для приведенной модели составляет 0,1941. Среди критических 17 опасных типов УВ правильно определено 91,6 % входных значений, т.е. погрешность первого рода составляет 0,084. Общий процент правильных ответов НС – 88 %.

8.2.3. Результаты прогнозирования времени прибытия УВ

Полученные данные об УВ значительной мощности за 2000 год были разбиты на обучающую выборку (4017 входных векторов) и тестовую (2679 входных векторов). В результате экспериментов по определению оптимального количества нейронов в скрытом слое наилучший результат в терминах среднеквадратичной погрешности получен для сети с 90 скрытыми нейронами. При обучении НС среднеквадратичная погрешность составила 0,0969854; погрешность на тестовых данных, которые не использовались при обучении, – 0,0980823.

Применение обученной НС (рис. 8.5) позволило получить прогноз со средней точностью 77 % в диапазоне прогнозов от 6 до 48 часов до начала прибытия УВ, но при кратковременном прогнозе (за 6 часов) прибытия УВ средняя точность прогноза уменьшается. Однако практическую ценность имеет долгосрочный прогноз, поскольку он позволяет заблаговременно принять меры по предотвращению опасных последствий, поэтому кратковременный прогноз (до 6 часов) можно не принимать во внимание.

Средняя погрешность прогноза на 24 часа вперед составляет 6,23 часа, а на 6 часов вперед — 2,78842 часа. На рис. 8.6 приведены результаты сравнения нейросетевого прогноза с реальными наблюдениями.

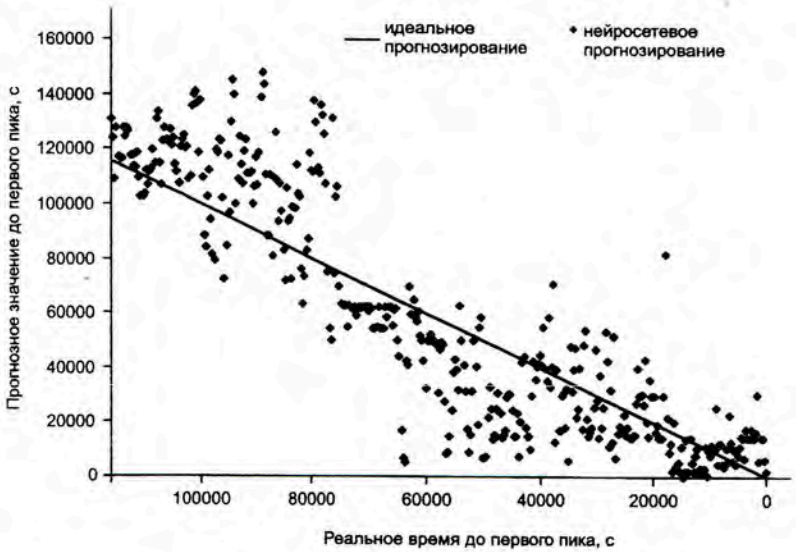


Рис. 8.5. Результаты прогноза прибытия УВ (10.02.2000–14.02.2000)

8.3. Обсуждение

Рассмотрены научные основы построения автоматической системы прогнозирования УВ в СВ. Система состоит из трех отдельных модулей: модуля идентификации начала УВ, классификации типа УВ и прогноза времени ее прибытия. Все три модуля ориентированы на использование данных инструмента EPAM спутника ACE и верифицированы на независимых данных ИЗМИРАН.

Проведенные эксперименты показали [111, 112], что предложенный подход более точен по сравнению с другими известными методами. Оптимизированный алгоритм определения начала развития УВ позволяет определять 89 % УВ, что в три раза превышает результаты модели [110]. Модуль классификации позволяет разделять УВ на опасные и безопасные с точностью 91 %. Для прогноза времени прибытия использована более простая НС прямого распространения. Средняя погрешность про-

гноза на 24 часа вперед составила 6,23 часа, а на 12 часов – 2,79 часа. Эти результаты также значительно лучше результатов модели [110], поскольку при построении прогноза на 24 часа ее средняя погрешность составляет 8 часов, а на 12 – 6 часов. Таким образом, предложенная архитектура обеспечивает более точный прогноз (по сравнению с [110]) при использовании более простых прогнозных моделей.

Описанные результаты положены в основу оперативного сервиса прогнозирования УВ, который можно найти на портале системы «Космическая погода» (http://www.spaceweather.org.ua).

Часть II

ВСПОМОГАТЕЛЬНЫЕ ЗАДАЧИ, РЕШАЕМЫЕ В РАМКАХ СИСТЕМЫ EOGRID

Помимо прикладных задач, направленных на удовлетворение потребностей конечных пользователей, в рамках EOGrid приходится решать служебные (сервисные или вспомогательные) задачи, которые сами по себе не имеют практического значения, но обеспечивают необходимое качество решения основных прикладных задач. В данном контексте к сервисным задачам следует отнести предварительную обработку спутниковых данных, а также настройку параметров и адаптацию моделей.

Задача фильтрации полос импульсного шума отнесена к первому типу. Это обусловлено тем, что с одной стороны, подобные искажения присущи спутниковой информации, используемой для решения прикладных задач, а с другой — на их примере можно наглядно продемонстрировать разработанную в ИКИ НАНУ-НКАУ методологию повышения эффективности решения подобных задач за счет распараллеливания и получаемые в результате преимущества.

Второй важный тип служебных задач – идентификация и настройка моделей, задействованных при решении прикладных задач. Структурная идентификация моделей, в том числе моделей объектов управления, представляет собой одну из важных и наиболее ресурсоемких задач этого класса. На примере моделей объектов управления рассмотрим метод структурной и параметрической идентификации математических моделей с использованием интеллектуальных вычислений. Для идентификации порядка и параметров модели будем применять генетические алгоритмы, моделирующие процесс биологической эволюции видов, а в качестве критерия оптимальности выберем сходимость нечеткого алгоритма оценивания состояний.

Глава 9
УСТРАНЕНИЕ ПОЛОС ИМПУЛЬСНОГО ШУМА НА ИЗОБРАЖЕНИЯХ

Получаемые со спутника изображения зачастую искажены импульсным шумом. Это происходит в результате зашумления данных при передаче по каналам связи или из-за несовершенства используемых датчиков. Обычно зашумленные пиксели равномерно распределяются по поверхности изображения и для восстановления искаженных изображений применяется медианный фильтр. Поскольку медианный фильтр обрабатывает каждый пиксель изображения, то он корректирует как зашумленные, так и незашумленные пиксели, что может привести к размыванию и/или искажению изображения. Эта проблема становится особенно актуальной, если размер окна фильтрации достаточно велик. Для преодоления недостатков классического медианного фильтра применяются различные методы, которые базируются на детектировании искаженных пикселей и их восстановлении, например [121, 122, 123].

Однако иногда на изображении появляются полосы импульсного шума, т.е. последовательности пикселей, имеющие случайные значения яркости. Тогда указанные методы работают неэффективно, поскольку многие зашумленные пиксели, находящиеся на полосе, не обнаруживаются.

Попытка решения этой проблемы описана в работе [124]. Но предложенный алгоритм обладает некоторыми недостатками. В частности, в нем используется много параметров, а после восстановления на изображении может появляться контрастная линия, если полоса импульсного шума находится в неоднородной области изображения.

Для устранения полос импульсного шума в работах [6, 7] предлагается использовать новый подход, включающий более эффективный алгоритм детектирования полос импульсного шума и адаптивный алгоритм восстановления изображения. Этот подход предполагает выполнение простых операций и требует задания лишь единственного порогового значения, которое легко определить. При этом предложенный метод преодолевает проблему появления контрастной линии после восстановления изображения.

9.1. Общая модель импульсного шума

Рассмотрим модель импульсного шума общего вида, включающего не только изолированные зашумленные пиксели, но и целые полосы импульсного шума. При этом решим задачу определения наилучшего фильтра для устранения импульсного шума, присущего реальным цифровым изображениям.

В литературе описано несколько моделей импульсного шума, используемых для имитации искажения изолированных пикселей и небольших полос шума. Так, в работе [6, 7] предложена модель полосы шума, основанная на цепи Маркова с двумя состояниями. Однако реальным цифровым изображениям, в том числе космическим снимкам, присуща зашумленность общего вида, включающая как изолированные пиксели импульсного шума, так и целые искаженные полосы. Следовательно, существующие модели не позволяют имитировать шум общего вида, характерный для реальных цифровых изображений. Поэтому имеет смысл ввести новую модель импульсного шума общего вида, включающего как искаженные изолированные пиксели, так и целые полосы импульсного шума.

Пусть q – вероятность искажения изолированного пикселя, p – вероятность искажения строки пикселей. Обозначим β_i случайную величину, удовлетворяющую следующему условию:

$$\beta_i = \begin{cases} 1 & \text{с вероятностью } p, \\ 0 & \text{с вероятностью } 1-p. \end{cases} \tag{9.1}$$

Тогда если $\beta_i = 1$, то i-я строка изображения искажена, и $\beta_i = 0$ – в противном случае.

Пусть $\hat{x}_{ij}$, x_{ij} – наблюдаемое и исходное значения пикселя с координатами (i, j) соответственно. Плотность распределения $f(\bullet)$ (для изображения в 256 градациях серого) импульсного шума общего вида, включающего как изолированные искаженные пиксели, так и целые строки зашумленных пикселей, можно определить следующим образом:

$$f(\hat{x}_{ij} \mid \beta_i = 1) = \frac{1}{256} \sum_{k=0}^{255} \delta(\hat{x}_{ij} - k), \tag{9.2}$$

$$f(\hat{x}_{ij} \mid \beta_i = 0) = (1-q)\delta(\hat{x}_{ij} - x_{ij}) + \frac{q}{256} \sum_{k=0}^{255} \delta(\hat{x}_{ij} - k), \tag{9.3}$$

где $\delta(\bullet)$ – дельта-функция Дирака, задаваемая соотношением

$$\int_{-\infty}^{\infty} f(x)\delta(x-a)dx = f(a).$$

Выражение (9.2) описывает вероятность искажения (или вероятность получения любого значения в диапазоне [0, 255]) пикселей, находящихся в i-й строке. Первое слагаемое в правой части формулы (9.3) задает вероятность наличия незашумленных изолированных пикселей в i-й строке, а второе – определяет вероятность искажения изолированного пикселя в этой строке случайным импульсным шумом. Предложенная вероятностная модель описывает шум общего вида, присущий реальным цифровым изображениям. Она учитывает вероятность искажения целых строк изображения, а также возможность зашумления отдельных пикселей. Эту модель можно использовать для имитации реального импульсного шума. Она позволяет сгенерировать шум с любыми заданными вероятностными характеристиками для существующих тестовых изображений, что даст возможность реализовать корректный эксперимент по определению наилучшего фильтра для цифровых изображений.

9.1.1. Процедура фильтрации импульсного шума общего вида

Как следует из проведенных экспериментов и полученных результатов, невозможно определить единственный фильтр, который был бы одинаково высокоэффективным при различных типах шума. Следовательно, для устранения шума каждого вида целесообразно применять отдельный фильтр. Поэтому блок-схема процедуры фильтрации общего вида предлагается в виде, представленном на рис. 9.1.



Рис. 9.1. Модель процесса фильтрации импульсного шума общего вида (содержащего как отдельные зашумленные пиксели, так и целые полосы)

Кроме того, поскольку фильтры для восстановления зашумленных полос оказываются недостаточно действенными, то актуальной становится задача разработки нового эффективного метода фильтрации полос шума.

Таким образом, можно сформулировать задачу определения фильтра f для устранения полос импульсного шума, удовлетворяющего условию

$$f = \arg\max_{f^S \in F^S} \sum_{k \in K} MQ(O_k, f^S(X_k)), \tag{9.4}$$

где F^S – множество имеющихся методов фильтрации полос импульсного шума; K – множество тестовых изображений, в которое включаются стандартные и космические изображения; Q – критерий «отношения амплитуд сигнал–шум»; O_k, X_k – исходное и искаженное k-е изображения из множества K соответственно; M – математическое ожидание.

Именно эта задача и решается далее.

9.2. Существующий подход к восстановлению искаженных изображений

Рассмотрим задачу устранения полос импульсного шума на космических снимках, или задачу фильтрации изображения. Для простоты будем рассматривать только горизонтальные полосы шума (рис. 9.2). Именно этот случай характерен для реальных космических снимков. Однако предлагаемый метод без ограничения общности можно применять и для устранения вертикальных полос шума. Полосу импульсного шума можно смоделировать заменой полной строки изображения случайными значениями из диапазона возможных значений. В частности, для изображения в градациях серого (8 бит/пиксель) значения яркости для полосы импульсного шума равномерно распределены в диапазоне [0, 255].

Прежде чем перейти к описанию предлагаемого подхода, кратко опишем алгоритм фильтрации шума, предложенный в [124].

Рассмотрим окно размером 3×3 пикселя, центр которого имеет координаты (i, j). Путь $x_{i,j}^{\text{center}}$ – значение яркости центрального пикселя с координатой (i, j); $r_{k,h}^1, r_{k,h}^2, \text{L}, r_{k,h}^8$ $(k \in [i-1, i+1],\ h \in [j-1, j+1],\ k \neq i$ или $p \neq j)$ – значения пикселей внутри окна фильтрации, расположенные в порядке возрастания, т.е. $r_{k,h}^1 \le r_{k,h}^2 \le L \le r_{k,h}^8$.

Пиксели с высокой вероятностью искажения можно обнаружить с помощью понятия «разности рангов» [124]. Разностью рангов будем называть значение

$$d^R = \begin{cases} r_{k,h}^R - x_{i,j}^{\text{center}}, & x_{i,j}^{\text{center}} \le ROM, \\ x_{i,j}^{\text{center}} - r_{k,h}^{R-9}, & x_{i,j}^{\text{center}} > ROM, \end{cases}$$

где $ROM = (r_{k,h}^4 + r_{k,h}^5)/2$ – средняя величина ранга для данного окна фильтрации. Можно считать, что пиксель $x_{i,j}^{\text{center}}$ зашумлен, если для R=1, 2, 3, 4 выполняется неравенство

$$d^R > T^R, \quad R = \overline{1,4},$$

где $T^1 < T^2 < T^3 < T^4$ – заданные значения порогов.

В статье [124] полосой импульсного шума предлагается считать строку, содержащую более 30 % искаженных пикселей. После выявления зашумленных строк согласно [124] значение яркости каждого пикселя полосы шума заменяется средней яркостью его ближайших соседей, находящихся вне полосы шума на одинаковом расстоянии. Однако такой подход во многом эвристичен. Поэтому предлагается более строгий метод детектирования полос шума и более эффективный способ восстановления изображения.

9.3. Способ устранения полос импульсного шума

Основная идея детектирования полос импульсного шума сводится к следующему. В большинстве случаев значения яркости зашумленных пикселей значительно отличаются от яркости соседних неискаженных пикселей. (Если значение яркости отличается незначительно, то такой шум визуально не заметен на изображении.) Поэтому разность между значениями яркости текущего пикселя до и после восстановления с помощью медианного фильтра обеспечивает эффективный способ идентификации зашумленного пикселя. Такой подход к детектированию зашумленных пикселей применяется, например, в [125, 126, 127, 128].

Для каждой пары (i, j) вычислим значение

$$DIF_{i,j} = \left| x_{i,j} - MED(W_{i,j}) \right|,$$

где $W_{i,j}$ – множество пикселей внутри окна фильтрации с центром (i, j), MED – операция усреднения значения яркости в рамках окна

фильтрации с центром (i, j). Значения $DIF_{i,j}$ используем для детектирования полос импульсного шума.

Рассмотрим множество

$$DIF = \{DIF_{i,j} \mid i = \overline{1,M},\ j = \overline{1,N}\}.$$

Просуммируем значения $DIF_{i,j}$ для каждой строки j на изображении,

$$DIF_j = \sum_{i=1,M} DIF_{i,j},$$

и построим гистограмму DIF (рис. 9.2). Для выявления вертикальных полос импульсного шума необходимо построить аналогичную гистограмму по столбцам изображения. Строки гистограммы, значения которых превышают порог T, определяют полосы импульсного шума.

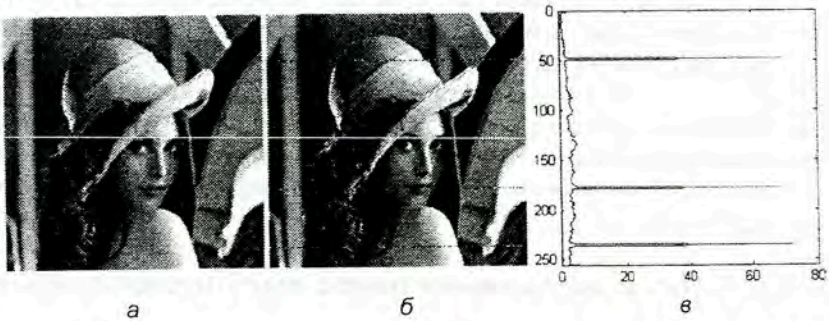


Рис. 9.2. Изображение, восстановленное с помощью медианного фильтра (*а*); искаженное изображение (*б*); вертикальная гистограмма (*в*)

После детектирования полос шума можно приступать к восстановлению искаженных пикселей. Если полоса импульсного шума находится в однородной области изображения, в процессе восстановления достаточно использовать информацию о яркости ближайших пикселей, находящихся на одинаковом расстоянии от этой полосы. Однако если одна или несколько последовательных полос находятся в неоднородной области изображения, то в большинстве случаев после корректировки в этом месте на изображении появляется резкая черта. Для улучшения результатов восстановления предлагается использовать метод интерполяции на основе кубических сплайнов. (Порядок сплайнов определен экспериментально.)

Введем понятие r-окрестности зашумленного пикселя. Под r-окрестностью зашумленного пикселя будем понимать количество зашумленных пикселей, находящихся на одной вертикальной линии длиной в r пикселей, в центре которой находится текущий искаженный пиксель. Если значение 5-окрестности равно 0 или 1, то в процессе интерполяции используем участок вертикальной линии длиной в 5 пикселей с центром в корректируемой точке. Если же значение 5-окрестности больше или равно 2, то в процессе корректировки предлагается учитывать значения 9 пикселей из этой окрестности.

9.3.1. Результаты экспериментов

Эффективность предложенного алгоритма подтверждается экспериментальными результатами, проведенными для стандартных тестовых изображений. При определении качества восстановленного изображения используется критерий отношения амплитуд «сигнал–шум».

Первый эксперимент проведен для тестовых изображений, искусственно искаженных шумом. Позиции искажаемых строк и столбцов изображения выбраны с использованием генератора равномерно распределенных случайных чисел. Пикселям, находящимся в этих позициях, с помощью аналогичного датчика присвоены значения яркости из диапазона [0, 255].

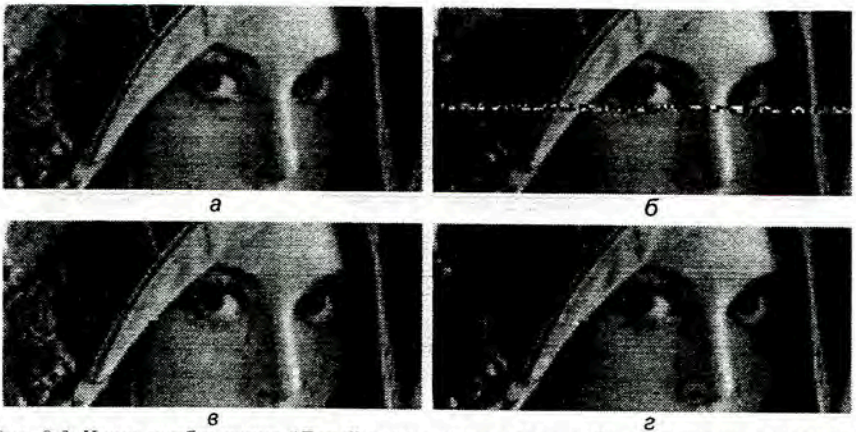


Рис. 9.3. Часть изображения "Лена" с изменением масштаба: *а* – оригинальное изображение; *б* – искаженное изображение; *в* – изображение, восстановленное с помощью метода [124]; *г* – изображение, восстановленное с помощью предложенного метода

Результаты эксперимента по фильтрации шума для тестового изображения «Лена» показаны на рис. 9.3. Как видно из приведенных изображений, в отличие от метода, описанного в [124], в результате применения предложенного подхода в неоднородной части изображения не появляется контрастная линия, т.е. качество фильтрации оказалось выше.

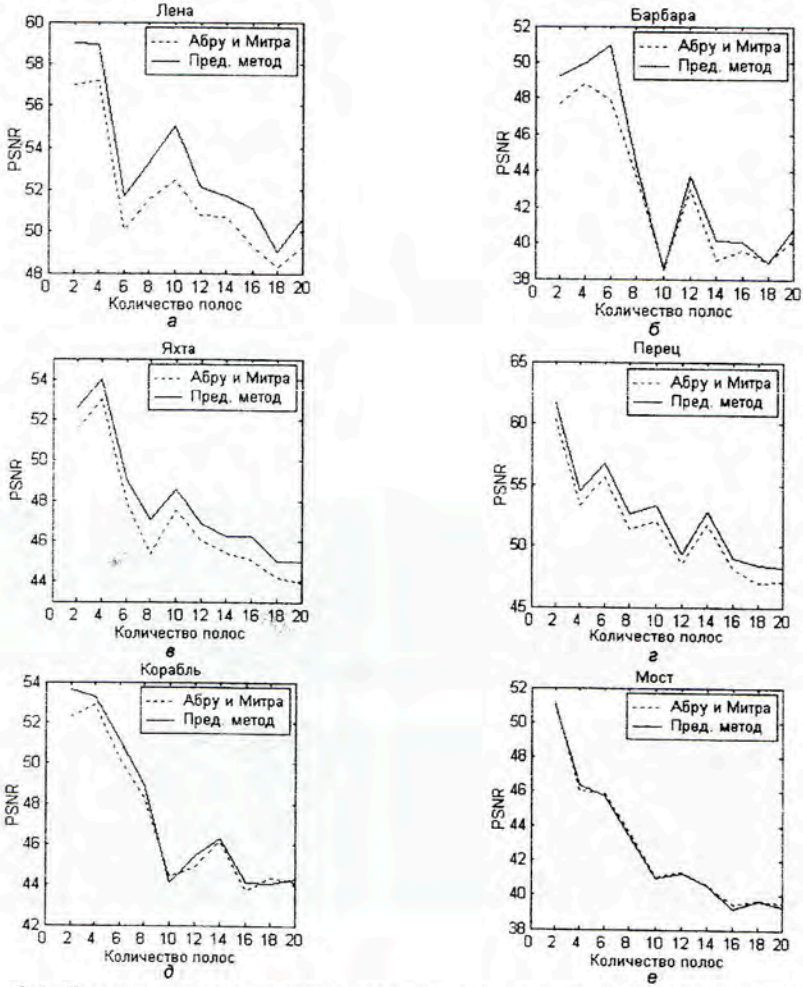
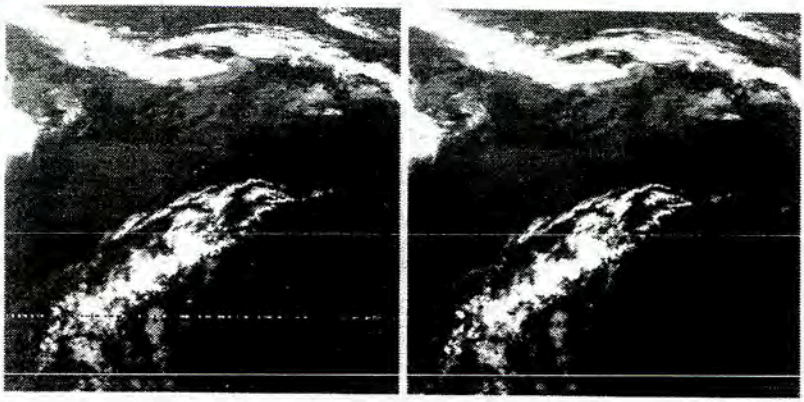


Рис. 9.4. Сравнительные результаты для популярных изображений Лена, Барбара, Корабль, Мост, Перец, Яхта с разным количеством полос импульса

На рис. 9.4 показаны сравнительные результаты применения предлагаемого метода фильтрации и способа, описанного в [124]. Очевидно, что предложенный алгоритм обеспечивает более качественную фильтрацию для всех тестовых изображений при любом количестве полос импульсного шума.



а *б*

Рис. 9.5. Исходное космическое изображение с горизонтальной полосой импульсного шума и равномерно распределенными по изображению отдельными зашумленными пикселями (*а*); изображение, восстановленное с помощью предложенного метода (*б*)

Второй эксперимент проводился для космического снимка, искаженного реальным импульсным шумом (рис. 9.5, *а*). В процессе эксперимента выяснилось, что при наличии полос импульсного шума предложенные в [129] методы детектирования изолированных пикселей, искаженных импульсным шумом, оказываются неэффективными. Поскольку на изображении имеются не только полосы шума, но и зашумленные изолированные пиксели, эксперимент проводился в два этапа: сначала с помощью предложенного метода детектировались и устранялись полосы импульсного шума, а затем изолированные зашумленные пиксели корректировались методом, описанным в [122, 123]. Результаты корректировки, показанные на рис. 9.5, *б*, подтверждают эффективность предложенного метода.

В табл. 9.1 приведены численные результаты сравнения эффективности предложенного метода с известными методами фильтрации

по критерию отношения амплитуд «сигнал/шум» для космического снимка, показанного на рис. 9.5, *а*. Как видно из таблицы, предложенный метод работает лучше, чем медианный фильтр или метод, описанный в [129].

Таблица 9.1. **Сравнение результатов фильтрации для космического изображения**

	Медианный фильтр		Метод [129]	Предложенный метод + метод [122, 123]
	3×1	5×1		
Космическое изображение	42,41	37,11	51,24	53,23

9.4. Обсуждение

Таким образом, рассмотрен простой и эффективный метод обнаружения и устранения полос импульсного шума. Он не только позволяет надежно выявлять полосы импульсного шума, но и, в отличие от описанных в литературе методов, обеспечивает сохранность деталей изображения после корректировки. Эффективность предложенного метода экспериментально подтверждена не только на тестовых изображениях, но и на реальных космических снимках, содержащих как полосы импульсного шума, так и изолированные зашумленные пиксели. Это особенно важно, поскольку при наличии на изображении обоих типов шума существующие методы работают недостаточно эффективно.

Другой важный результат, представленный в данной главе, – формальное описание модели шума общего вида, а также процедуры фильтрации импульсного шума произвольного вида.

Глава 10

ПАРАЛЛЕЛЬНАЯ РЕАЛИЗАЦИЯ АЛГОРИТМОВ ФИЛЬТРАЦИИ КОСМИЧЕСКИХ ИЗОБРАЖЕНИЙ

КА Meteosat представляет собой геостационарный спутник, поставляющий данные для решения гидрометеорологических задач и некоторых других задач наблюдения Земли из космоса. В настоящее время решена важная задача – предварительная обработка изображений, которая заключается в выделении и фильтрации шума. При этом в процессе фильтрации необходимо обеспечить максимальное сохранение деталей изображения. На снимках КА Meteosat шум представляет собой композицию импульсного шума типа «соль и перец» и горизонтальных полос с равномерно распределенным импульсным шумом. Особенность таких снимков заключается в высокой частоте их поступления (каждые полчаса) и большом объеме. Так, один такой снимок, полученный с Meteosat-7 занимает почти 10 Мбайт, а один снимок КА MSG (Meteosat второго поколения) – до 100 Мбайт. Поэтому решение прикладных задач предварительной и тематической обработки информации этого спутника невозможно без привлечения мощных вычислительных ресурсов.

Фильтрация зашумленных пикселей относится к группе низкоуровневых операций обработки изображений [130]. При последовательной обработке каждого пикселя информационного потока время обработки изображений достаточно велико, что неприемлемо в случае проведения вычислений в реальном времени. Эту проблему можно решить путем привлечения высокопроизводительных параллельных вычислений [131].

Рассмотрим задачу распараллеливания вычислений при решении задачи фильтрации космических изображений, а также наиболее эффективный способ разбиения изображения и распределения задач между отдельными процессорами [132]. Эффективность предлагаемых алгоритмов параллельных вычислений, выполняемых при решении задач фильтрации, подтверждается практическими результатами компьютерного моделирования и реализацией параллельных вычислений в локальной сети ИКИ НАНУ–НКАУ. Полученные результаты применимы для обработки широкого спектра графических изображений, в том числе и для фильтрации космических снимков.

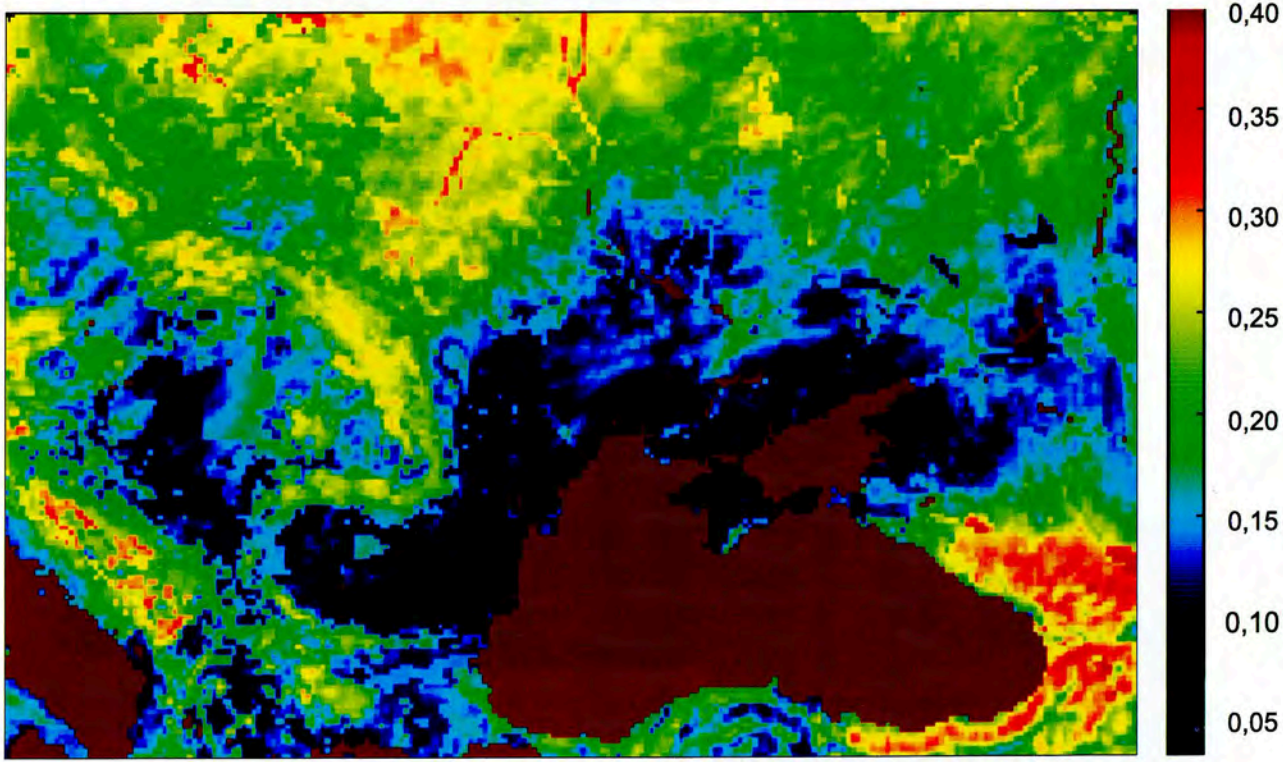


Рис. В.5. Результаты оценки среднемесячной влажности грунта (0-10 см) с использованием модели Noah за июль 2007 г.

10.1. Основные принципы параллельных вычислений

Опишем основные принципы построения параллельных вычислительных систем, модели параллельных вычислений и инструментальные средства, которые поддерживают разработку параллельных программ.

10.1.1. Архитектура параллельных вычислительных систем

Существуют две основные архитектуры систем параллельных вычислений: на базе симметричного мультипроцессора (СМП) и массовых параллельных процессоров (МПП) [133].

Система на основе СМП (рис. 10.1) использует разделяемые ресурсы, например память, подсистему ввода/вывода и т.д. При этом все процессоры имеют доступ к разделяемому ресурсу по принципу симметрии, который заключается в том, что ни один из процессоров не выполняет роль операционного) [133]. СМП-система обеспечивает механизм объединения данных, которые содержатся в локальной сверхоперативной памяти (кэш). Связь между процессорами и разделяемой памятью обеспечивает шина. Такое соединение компьютеров называется параллельным с разделяемой памятью (*shared memory* parallel computers).

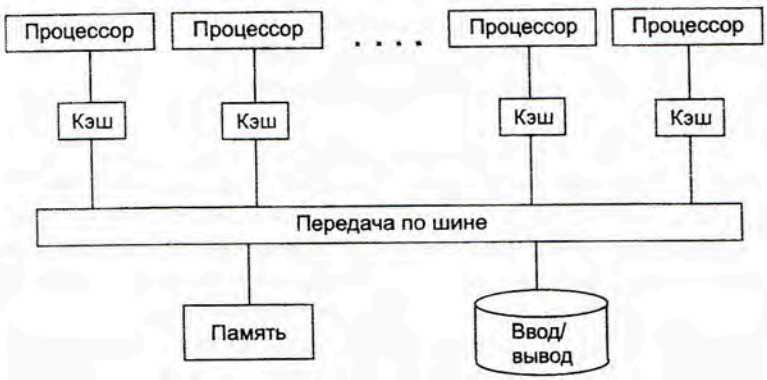


Рис. 10.1. СМП-архитектура

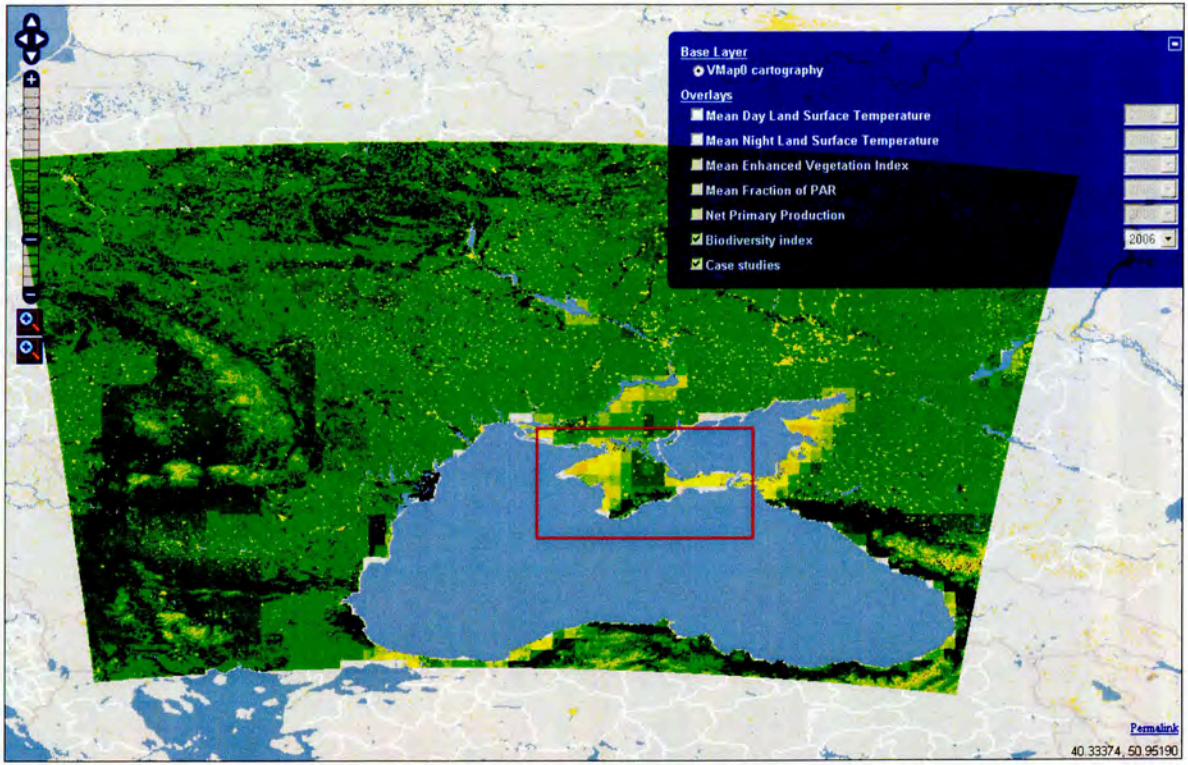


Рис. В.6. Результаты работы сервиса оценки биоразнообразия

Альтернативу СМП-системам составляют архитектуры на основе МПП (рис. 10.2). Такая система состоит из отдельных компьютеров, называемых узлами, которые соединены между собой быстродействующей вычислительной сетью. У каждого узла есть свой процессор, память, подсистемы ввода/вывода. Внутреннее сетевое соединение позволяет осуществлять передачу данных между узлами. Такое соединение компьютеров называется параллельным с распределенной памятью (*distributed memory* parallel computers).

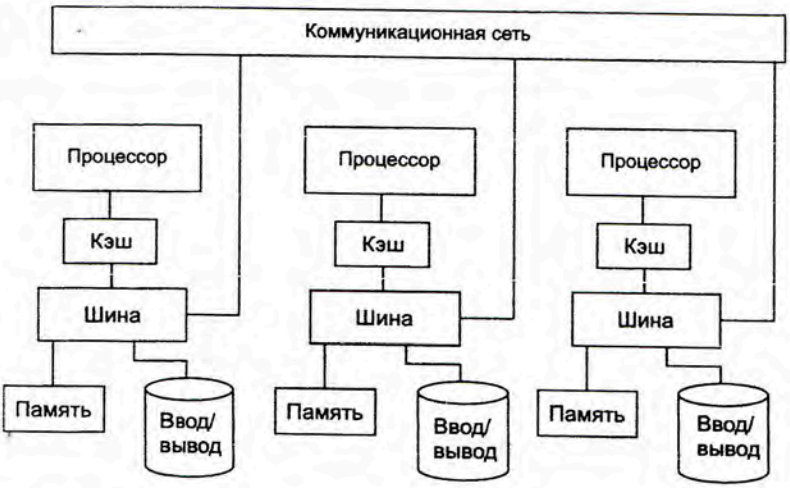


Рис. 10.2. МПП-архитектура

При выполнении параллельных вычислений в МПП-системе активно используются сетевые ресурсы, от которых во многом и зависит общая эффективность вычислений. Именно эта архитектура рассматривается в данной главе.

10.1.2. Модели параллельных вычислений

Существуют две общепринятые модели параллельных вычислений. Их различие состоит в организации доступа к памяти процессора. В модели с общей (разделяемой) памятью каждый из потоков управления имеет доступ ко всей памяти. В модели с распределенной памятью память процессора доступна только для действующего процесса.

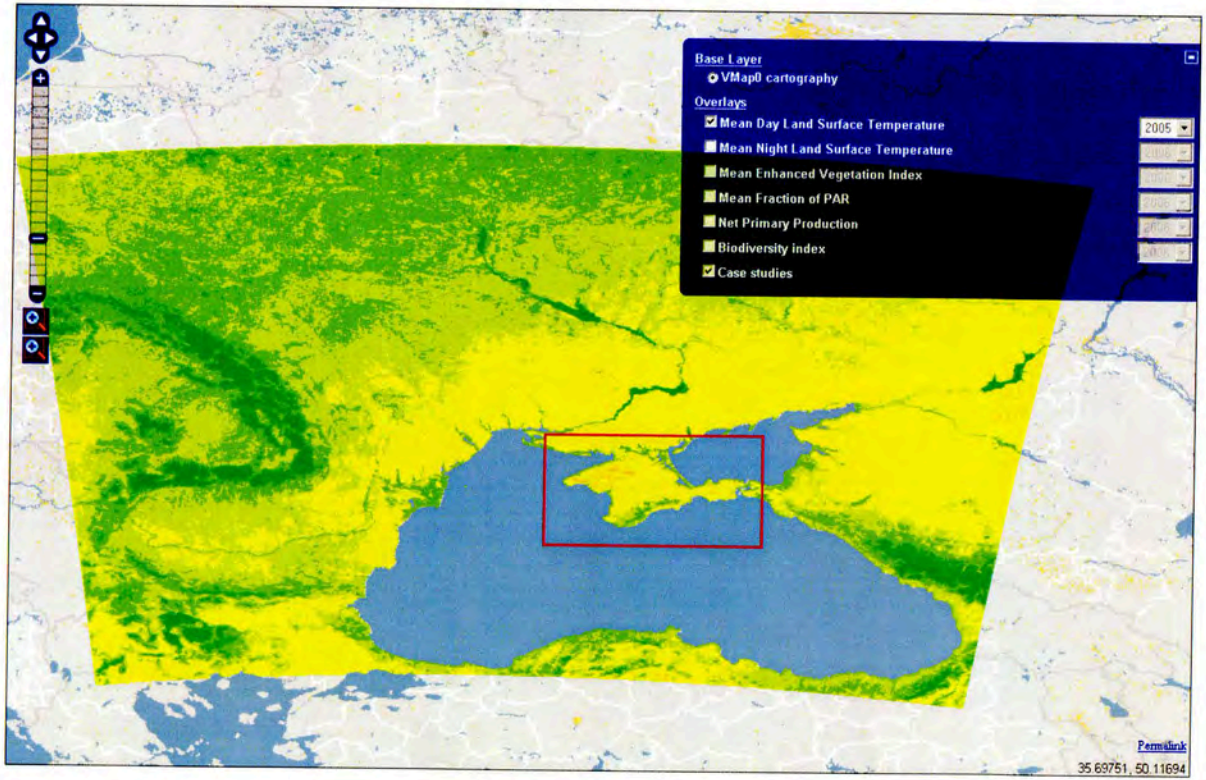


Рис. В.7. Результаты оценки дневной температуры поверхности Земли по спутниковым данным

Примером реализации модели с распределенной памятью служит модель передачи сообщений. Существуют два вида этой модели: единая программа со множеством данных – ЕПМД (рис. 10.3, *а*) (SPMD – Single Program Multiple Data) и множественные программы со множественными данными – МПМД (MPMD – Multiple Programs Multiple Data).

В ЕПМД действует только одна программа и каждый процесс соответствует выполнению кода этой программы на различных множествах данных. В модели МПМД разным процессам соответствуют различные программы, но процессы «сотрудничают» между собой для решения единой проблемы. Типичный пример модели МПМД – архитектура «мастер/работник» (рис. 10.3, *б*): «мастер» отправляет задачи «работнику» и несколько «работников» обслуживают одного «мастера».

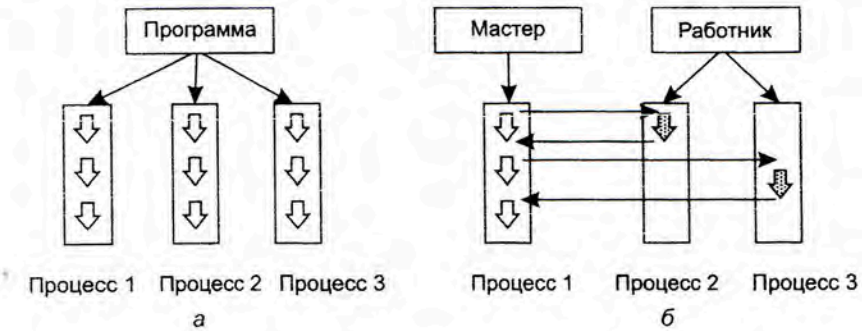


Рис. 10.3. Модели ЕПМД (*а*) и МПМД (*б*)

10.1.3. Интерфейс передачи сообщений MPI

Интерфейс передачи сообщений MPI (Message Passing Interface) представляет собой библиотеку функций и макросов, которые могут быть использованы в программах, написанных на языках программирования C, FORTRAN и C++ [134, 135]. MPI предназначен для программ, основанных на модели передачи сообщений [136]. Приведем три характерные особенности этой библиотеки [137].

- Платформенная независимость, т.е. один и тот же программный код может выполняться на всех аппаратных платформах, на которых поддерживается библиотека MPI.

- Возможность прозрачного выполнения в неоднородной среде. MPI обеспечивает виртуальную вычислительную машину, которая предоставляет архитектурные различия. При необходимости библиотека MPI обеспечивает автоматическое преобразование типов данных и использование требуемого коммуникационного протокола.
- Эффективная реализация на машинах с различными характеристиками. MPI позволяет избежать конкретного описания выполнения операций, заменяя его логическим описанием. Поэтому существует возможность использования преимуществ различных машин.

Далее опишем предлагаемый алгоритм фильтрации импульсного шума и обоснуем его параллельную реализацию на основе модели с распределенной памятью и MPI.

10.2. Последовательный алгоритм фильтрации импульсного шума

Один из наиболее эффективных алгоритмов устранения изолированных пикселей шума (при низкой вероятности искажения изображения) – пороговый булевый фильтр — ПБФ [122] Однако на космических изображениях иногда появляются целые полосы зашумленных пикселей. Тогда для коррекции изображений целесообразно использовать сочетание ПБФ и предложенного в [6] эффективного метода фильтрации полос шума. Подробно рассматривать здесь эти методы не будем, а приведем лишь обобщенный алгоритм на языке псевдокода их последовательной реализации.

```
<Изоб.> = функцияЧтениеФайлаИзображения(<параметры>);
//    Первый   шаг:   поиск   и   удаление   полос
// импульсного шума
if(функцияПоискПолосИмпульса(<Изоб.>,<параметры>)==   TRUE)
{
  функцияУдалениеПолосИмпульса(<Изоб.>, <параметры>);
}
//    Второй   шаг:   поиск   и   удаление   изолированных
// пикселей импульсного шума
for (раз = 0; раз < ЦИКЛ; раз ++) {
  <КартаИмпульса>=функцияПоискИмпульса(<Изоб.>,
                                       <параметры>);
  <Восс.Изоб.>=функцияУдалениеИмпульса(<Изоб.>,
                    <КартаИмпульса>, <параметры>);
  <Изоб.> = <Восс.Изоб.>;
}
функция ЗаписьФайлаИзображения(<Изоб.>, <параметры>);
```

Несложно заметить, что удаление полос импульсного шума всегда выполняется на *первом шаге* алгоритма, а затем результаты выполнения этой операции передаются для обработки на *второй шаг*. На *втором шаге* искаженные пиксели восстанавливаются только после фазы детектирования карты зашумленных позиций. Кроме того, процесс детектирования и удаления происходит в цикле с количеством итераций **ЦИКЛ**, при этом результаты предыдущей итерации служат входными данными для последующей.

Среди популярных парадигм параллельных вычислений наиболее эффективны модели параллелизма данных и параллелизма задачи. Параллелизм данных – это модель программирования, в которой одна программа применяется для всех данных одновременно. Параллелизм задачи позволяет независимым частям одной программы функционировать в качестве различных процессов или несвязанных групп процессов (в режиме параллелизма данных процессы одной группы могут взаимодействовать друг с другом) [138]. Следует отметить, что иногда сочетание параллелизма данных и задачи позволяет повысить быстродействие больших вычислительных систем по сравнению с использованием каждого из подходов в отдельности [139]. Однако для решения поставленной задачи мы ограничимся использованием модели параллелизма данных. Это объясняется следующими причинами.

1. С точки зрения построения алгоритма, *первый* и *второй шаги* (до некоторой степени) могут выполняться независимо, поэтому можно реализовать и модель параллелизма задачи. Но при этом возникают две проблемы.

• Эксперименты показали [132], что предложенный алгоритм максимально эффективен только в том случае, когда сначала выполняется *первый шаг*, а затем полученный результат передается на *второй шаг*.

• При использовании модели параллелизма задачи существенно усложняется процесс балансировки нагрузки (корректного распределения заданий между процессами обработки для увеличения общей производительности [131]).

Большую часть времени обработки на каждом шаге занимает выполнение функций **функцияПоискПолосИмпульса**() и **функцияПоискИмпульса**(), поскольку они обрабатывают все пиксели изображения. Причем функции **функцияУдалениеПолосИмпульса**() и **функцияУдалениеИмпульса**() работают только с незначительным количеством пикселей (меньше 0,5 % всего изображения). Функция **функцияПоискИмпульса**()

выполняется **ЦИКЛ** раз. Поэтому обеспечение равномерного распределения заданий между процессами – непростая задача.

2. С технической точки зрения рассматриваемый алгоритм фильтрации использует две из трех основных «низкоуровневых операций обработки изображения» [139]. Поэтому вполне естественным выглядит подход на основе параллелизма данных, когда много операций применяется к каждому отдельному элементу данных.

И, наконец, следует отметить, что объем обрабатываемых данных в этой задаче не настолько велик, чтобы сочетание параллелизма данных и задачи позволило получить дополнительные преимущества.

10.3. Параллельный алгоритм фильтрации импульсного шума

С учетом проведенного анализа для параллельной реализации алгоритма фильтрации импульсного шума целесообразно использовать модель параллелизма данных. В процессе обработки все изображение сканируется окнами одинакового размера – $n \times n$ пикселей, где n – нечетное число. Обработку пикселей каждого окна можно выполнять параллельно в рамках отдельного процесса. Однако после каждой итерации обработки необходимо обеспечить обмен «краевой» информацией между соседними процессами. Это побочный эффект распараллеливания связанный с необходимостью обмена данными между параллельно работающими процессорами путем передачи сообщений (отправки и получения информации между параллельными процессами). Приведем параллельный алгоритм фильтрации на языке псевдокода.

```
...
функцияОтправкаПолучениеКраевыхДанных(<параметры>);
if(функцияПоискПолосИмпульса(<ЧастьИзоб.>,<параметры>)      ==
TRUE)
{
  функцияУдалениеПолосИмпульса(<ЧастьИзоб.>,<параметры>);
  функцияОтправкаПолучениеКраевыхДанных(<параметры>);
}
for     (раз     =     0;     раз     <     ЦИКЛ;     раз     ++)
{
  <Карта>=функцияПоискИмпульса(<ЧастьИзоб.>,
                               <параметры>);
  <Восс.ЧастьИзоб.>                                          =
                 функцияУдалениеИмпульса(<ЧастьИзоб.>,
                                         <Карта>, <параметры>);
```

```
  <ЧастьИзоб.> = <Восс. ЧастьИзоб.>;
  функцияОтправкаПолучениеКраевыхДанных(<параметры>);
}
...
```

Этот параллельный алгоритм основан на усовершенствованной модели ЕПМД, в которой применяются элементы архитектуры «мастер/работник», соответствующей модели МПМД. Процесс «мастер» распределяет части изображения между процессами «работник». Однако в данном случае процесс «мастер» также играет роль процесса «работник» и получает свою часть изображения. Каждый процесс «работник» обрабатывает свои данные, после чего процесс «мастер» собирает в рамках одного изображения части данных процессов «работник».

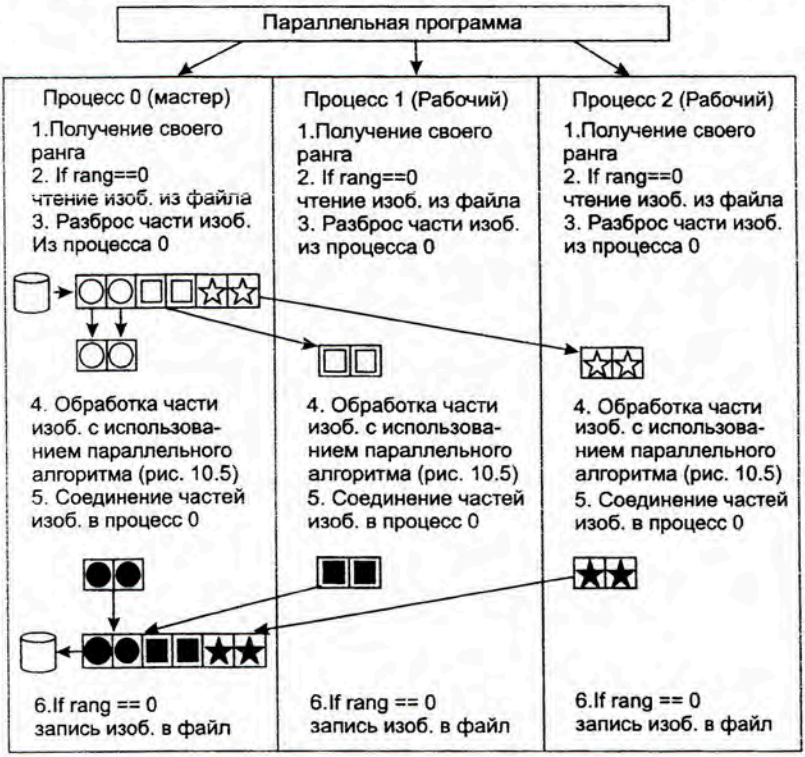


Рис. 10.4. Параллельная реализация алгоритма фильтрации изображения (незакрашенные круги, квадраты и звездочки обозначают исходные значения элементов, а закрашенные – значения после обработки)

Общая схема распараллеливания вычислений показана на рис. 10.4. На первом шаге алгоритма каждому процессу присваивается свой ранг. На втором шаге процесс с рангом 0 (мастер) считывает изображение из файла. На третьем шаге части изображения отправляются всем процессам, включая процесс с рангом 0 (теперь он играет роль работника). На четвертом шаге каждый процесс обрабатывает свои данные, используя приведенный алгоритм. После завершения этого шага ни один из процессов не обладает полными данными, и уже на пятом шаге все части изображения собираются и передаются процессу с рангом 0 (мастер). Этот процесс записывает обрабатываемое изображение в файл (шестой шаг).

При разработке программы с распараллеливанием выполнения задач необходимо придерживаться следующих принципов [133].

- Максимальное увеличение последовательных фрагментов программы, которые можно выполнять параллельно.
- Сбалансированность объемов работ в параллельных процессах.
- Уменьшение времени обмена информацией.

В контексте поставленной задачи выполнение второго принципа зависит от того, существует ли полоса импульсного шума на части изображения, поступающей для обработки в каждый процессор. Однако, как упоминалось, количество составляющих полосу искаженных пикселей незначительно (менее 0,5 %), поэтому время обработки полосы тоже невелико по сравнению с временем детектирования. Иными словами, второй принцип выполняется в том случае, когда размеры частей изображения, отправляемых различным процессорам, одинаковы.

Для уменьшения времени взаимодействия необходимо минимизировать количество передаваемых данных (трафик), а также количество сеансов связи. Доступ к данным будет эффективнее, если они записаны в памяти последовательно, а не фрагментированы по всему носителю информации.

Рассмотрим четыре возможных способа разделения данных изображения.

10.3.1. Разделение изображения по горизонтали

Это самое естественное разбиение (рис. 10.5), поскольку данные в массиве обычно хранятся по строкам.

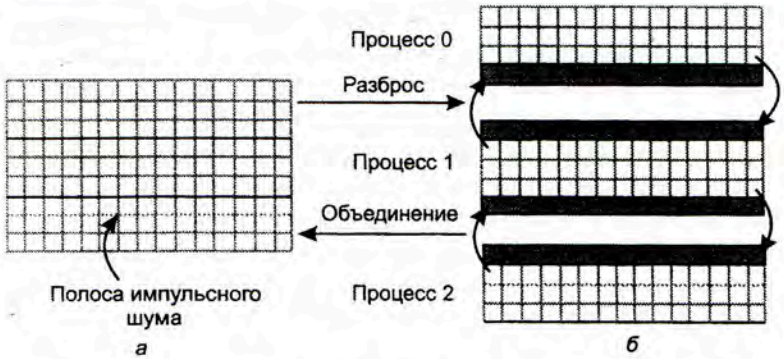


Рис. 10.5. Разделение исходного изображения по горизонтали: исходное изображение (*а*); разделение частей изображения по процессам (*б*)

Серые зоны на рис. 10.5, *б* содержат информацию о границах. Этой информацией обмениваются соседние процессы. Стрелки на рис. 10.5, *б* указывают направление обмена данными (эти обозначения будут использоваться и в дальнейшем).

При использовании такого подхода для поддержки процесса обмена информацией не надо определять какой-либо новый тип данных. Однако существуют и некоторые ограничения. Во-первых, не обеспечивается сбалансированность объемов работ параллельных процессов, а во-вторых, количество передаваемых между процессами данных максимально.

10.3.2. Поворот и горизонтальное разделение изображения

Для устранения перечисленных недостатков до начала обработки изображения повернем его на 90°. При этом соблюдается принцип сбалансированности объемов работ в параллельных процессах, а также уменьшается количество данных, передаваемых между процессами. Следует отметить, что при подобном разбиении для хранения данных по-прежнему можно воспользоваться преимуществом хранения элементов массива по строкам, а также стандартными типами данных языка C (нет необходимости определять новые типы данных) (рис. 10.6).

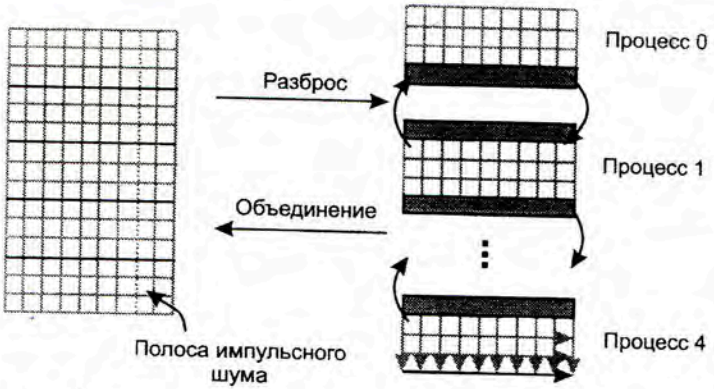


Рис. 10.6. Поворот исходного изображения на 90° и горизонтальное разделение: *а* – повернутое изображение; *б* – части изображения, соответствующие разным процессам

Недостаток этого подхода заключается в дополнительных временных затратах на поворот изображения до и после устранения шума.

10.3.3. Вертикальное разделение изображения

При разделении исходного изображения на вертикальные полосы (рис. 10.7) гарантированно выполняются два из трех указанных принципов: сбалансированность объемов работ в параллельных процессах и уменьшение количества передаваемых данных. Недостаток такого подхода к разбиению изображения – необходимость пересылки фрагментированной информации.

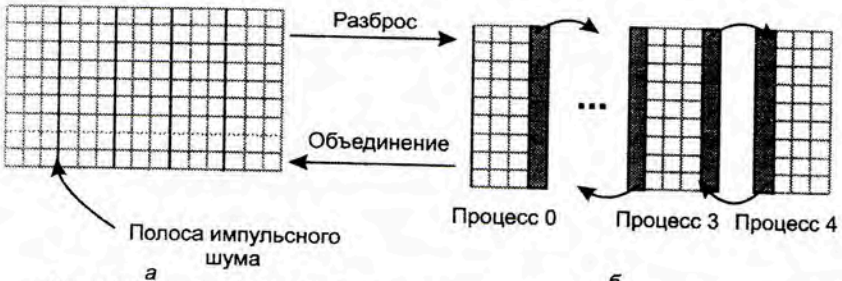


Рис. 10.7. Вертикальное разделение исходного изображения: *а* – исходное изображение; *б* – части изображения, обрабатываемые разными процессами

10.3.4. Разбиение изображения по квадратам

Преимущество предлагаемого подхода к разбиению изображения заключается в том, что при его использовании максимально уменьшается количество информации при обмене «границами» между соседними процессами. Поскольку при равных площадях периметр прямоугольника больше, чем периметр квадрата, принято решение разбить исходное изображение на квадраты. Однако этот подход наиболее трудоемкий в реализации (рис. 10.8).

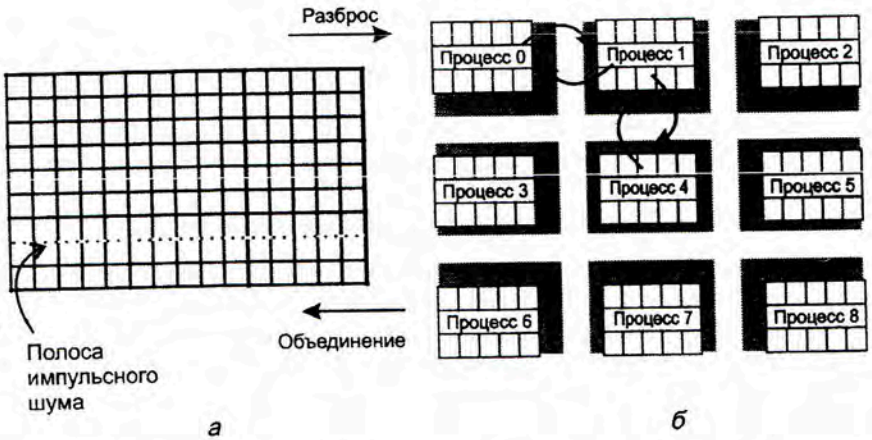


Рис. 10.8. Разбиение исходного изображения на квадраты: *а* – исходное изображение; *б* – части изображения, соответствующие различным процессам

При таком подходе количество операций по передаче информации о границах возрастает и составляет 4 операции обмена «по горизонтали», 4 операции обмена «по вертикали» и 4 операции обмена элементами, расположенными по углам фрагмента изображения, соответствующего одному процессу. Применение подхода, предложенного в [133], дало возможность избежать передачи четырех угловых элементов (рис. 10.9).

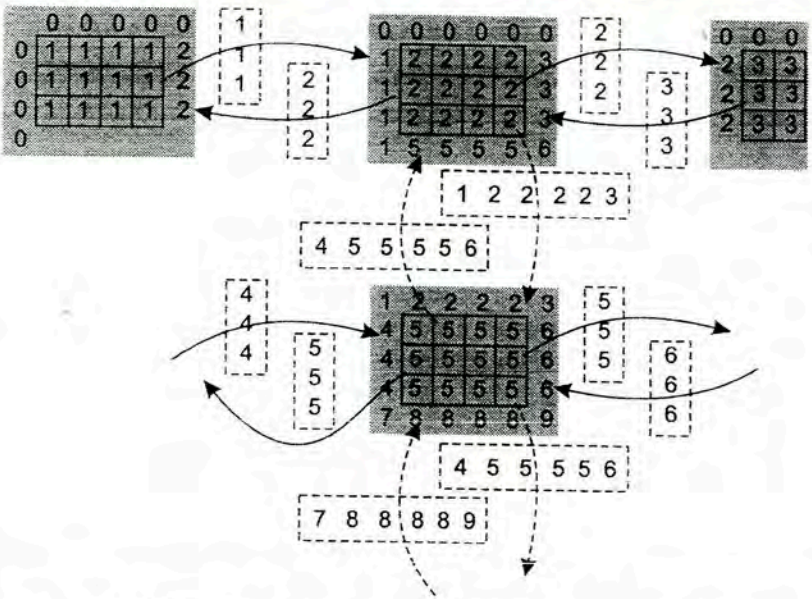


Рис. 10.9. Отправка/получение информации о границах. Сначала осуществляется обмен данными «по горизонтали», а затем «по вертикали»

10.3.5. Результаты экспериментов

Программы для проведения экспериментов были написаны на языке программирования C с использованием функций MPI при поддержке MPICH [140]. MPICH – переносимая реализация полного пакета MPI, в комплект поставки которой входит описание принципов построения различных параллельных и распределяемых вычислительных сред. MPICH содержит не только библиотеку MPI, но и среду разработки MPI-программ.

Эффективность работы алгоритма проверялась в локальной сети ИКИ НАНУ–НКАУ. Компьютеры, задействованные в экспериментах, имели различные конфигурации: мощность процессоров от «AMD Athlon 900 MHz» до «Intel Pentium 4 2,8 GHz», память 256 MB или 512 MB RAM. В экспериментах было задействовано до девяти компьютеров. Максимальное расстояние между «мастером» и «работниками» составляло 80 метров.

В процессе проведения экспериментов часто возникали непредвиденные препятствия, связанные с занятостью шины, запуском программ на некоторых компьютерах и т.д. Для устранения таких «помех» каждый эксперимент повторялся 10–15 раз. Затем результаты сравнивались и выбиралось среднее значение из трех лучших результатов каждого эксперимента.

Полученные результаты проиллюстрированы на рис. 10.10. График на рис. 10.10, *а* отражает время выполнения последовательного алгоритма фильтрации импульсного шума. Этот эксперимент проведен на компьютере с процессором Pentium 4 мощностью 2,4 GHz и оперативной памятью 256 MB. На рис. 10.10, *б* показаны результаты экспериментов при параллельном решении задачи в сети. Разбиение изображения на квадраты использовалось только в экспериментах с четырьмя и девятью процессорами (соответствующими массивам логических процессоров 2×2 и 3×3). Различия между результатами этих двух экспериментов прослеживаются не очень четко по нескольким объективным причинам. Во-первых, эксперименты проводились в гетерогенной среде и обрабатываемое изображение имело недостаточно большой размер (800×1250 пикселей). Кроме того, в процессе экспериментов иногда возникали упомянутые «помехи».



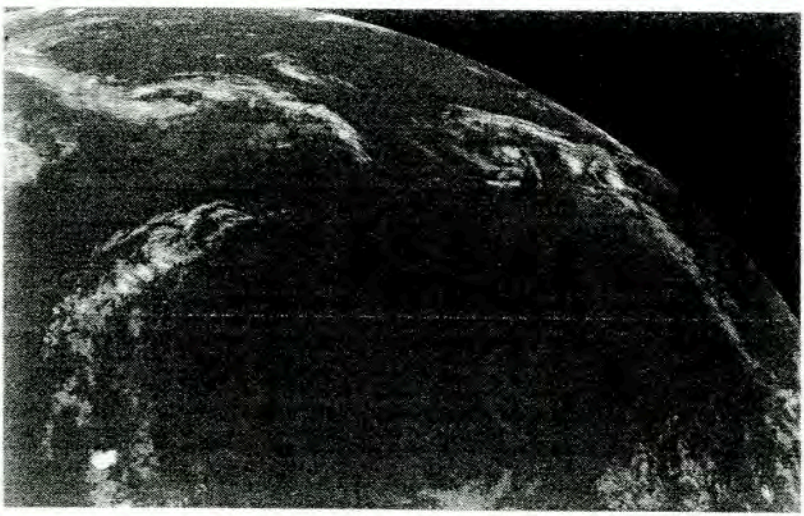
Рис. 10.10. Сравнительные результаты экспериментов: *а* – результат последовательного выполнения алгоритма; *б* – результаты параллельной реализации алгоритма для четырех типов разделения данных

Следует отметить, что при использовании девяти процессоров результаты, полученные при разбиении исходного изображения по горизонтали и повороте с последующим горизонтальным разбиением, свидетельствуют о том, что эти два подхода можно в дальнейших исследованиях не учитывать.

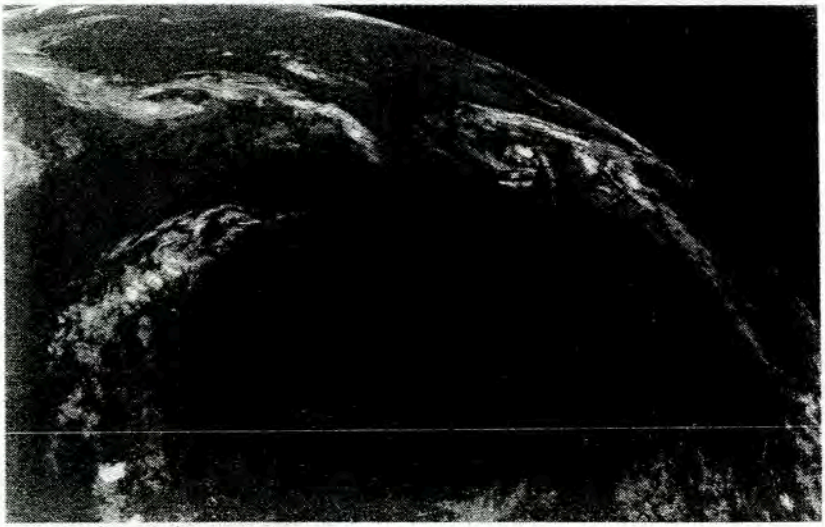
Исходя из полученных практических результатов и проведенного теоретического анализа, сделаем следующие выводы.

- Наилучший и наихудший результаты связаны соответственно с разбиением изображения на квадраты и по горизонтали. Это означает, что количество элементов, которые используются в процессе обмена «краевой» информацией, существенно влияет на общее время обработки изображения.
- Время обработки при использовании остальных двух типов разбиения (поворот с последующим горизонтальным разделением изображения и вертикальное разбиение) приблизительно одинаково. Операция поворота изображения реализуется в оперативной памяти и требует незначительного времени по сравнению с полным процессом фильтрации (около 1 %).

Разработанные процедуры фильтрации импульсного шума используются и для обработки реальных спутниковых изображений. Полученные результаты приведены на рис. 10.11.



а



б

Рис. 10.11. Космический снимок до (*а*) и после (*б*) фильтрации шума

10.4. Обсуждение

Рассмотрены аспекты реализации параллельных алгоритмов фильтрации изображений, искаженных импульсным шумом [132]. Параллельная обработка, основанная на модели параллелизма данных, обладает рядом существенных преимуществ – такими, как простота, естественность и эффективность. Если ставится задача оптимизации процесса решения задачи по времени, то предпочтительнее использовать разбиение изображения на квадраты. Несмотря на то что этот подход несколько сложнее остальных, на его реализацию всегда требуются наименьшие затраты времени. И наоборот, если важна простота на этапе проектирования программы, то следует применять подход, связанный с поворотом и горизонтальным разбиением изображения. Отправку/получение частей изображения между процессами «мастер/работники» можно упростить с помощью пары функций MPI_Scatter и MPI_Gather из библиотеки функций MPI.

Предлагаемый алгоритм можно эффективно применять при обработке мультиспектральных космических изображений большого объема в реальном времени. Описанный алгоритм в дальнейшем планируется использовать в качестве модуля предварительной обработки изображений в системе определения динамики облачности на основе снимков КА Meteosat второго поколения. Кроме того, предложенные подходы к распараллеливанию изображения можно применять и для распараллеливания процесса решения тематических задач, в том числе для построения маски облачности и оптических потоков. Учитывая большой размер изображений (до 100 Мбайт), высокую частоту их поступления (каждые 15 минут), а также сложность алгоритмов определения динамики облачности, параллельную реализацию этих алгоритмов целесообразно выполнять не в локальной сети, а на кластере. Соответствующие компьютерные эксперименты в настоящее время проводятся на кластере, разработанном в Институте кибернетики НАНУ.

Глава 11

СТРУКТУРНАЯ И ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ МОДЕЛЕЙ ОБЪЕКТОВ УПРАВЛЕНИЯ НА ОСНОВЕ ИНТЕЛЛЕКТУАЛЬНЫХ ВЫЧИСЛЕНИЙ

В последние годы задачи идентификации параметров математических моделей или оценивания состояний объектов управления все чаще формулируются в нестохастической постановке, т.е. неопределенность описывается не вероятностными характеристиками, а допустимыми интервалами (множествами) значений или нечеткими множествами. Такой подход наиболее адекватен в том случае, если отсутствуют статистические данные о работе объекта или если неопределенность вообще не имеет вероятностной природы. В условиях нестатистически заданной неопределенности широко применяются методы теоретико-множественного (гарантированного) оценивания [141], в частности метод эллипсоидов [142], или методы теории нечетких множеств, например, изложенные в [143].

Задача оценивания состояний объекта управления на практике зачастую осложняется неопределенностью параметров математической модели. Если точно известен порядок модели, то для одновременного оценивания состояний и коэффициентов модели можно использовать метод расширения пространства (увеличения размерности неизвестного вектора). Подобный подход использовался в [144] для оценивания матрицы параметров математической модели при точно известном векторе состояния.

Однако задача существенно усложняется, если неизвестны не только коэффициенты, но и сама структура (порядок) модели, поскольку традиционные методы оценивания не позволяют решать задачу структурной идентификации математических моделей. Поэтому для решения комплексной задачи структурной и параметрической идентификации математической модели в [145] предлагается использовать эволюционные методы вычислений (относящиеся к так называемым интеллектуальным методам), а именно для идентификации структуры (определения порядка) математической модели применять генетический алгоритм [146]. Он представляет собой метод поиска, основанный

на моделировании процессов развития биологических видов, а в роли критерия качества его оценок можно использовать сходимость метода нечеткого эллипсоидального оценивания состояний объекта управления [147].

11.1. Постановка задачи

Уравнение произвольного объекта управления с одним входом и одним выходом в дискретном времени имеет вид

$$a_n y(k-n)+a_{n-1}y(k-n+1)+\text{K}+a_1 y(n-1)+a_0 y(k)= \\ = b_0 u(k)+b_1 u(k-1)+\text{K}+b_n u(k-n), \qquad (11.1)$$

где $(u(k), y(k))$ – измеряемая входная и выходная информации об объекте в момент времени k; $S=(a_0, a_1, \text{K}, a_n, b_0, b_1, \text{K}, b_n)$ – неизвестный вектор параметров объекта; n – неизвестный (в общем случае) порядок математической модели.

Требуется на основании измерений входной и выходной информации $\{(u(k), y(k)), k=1,2,...\}$ построить адекватную математическую модель объекта, т.е. определить ее структуру (порядок n) и вектор неизвестных коэффициентов S.

11.2. Метод решения

Уравнение объекта (11.1) с одним входом и одним выходом можно представить в терминах переменных состояния:

$$x(k+1)=Ax(k)+Bu(k), \qquad (11.2)$$

$$y(k)=C^T x(k)+du(k), \qquad (11.3)$$

где A, B, C, d – неизвестные параметры объекта управления вида

$$A=\begin{bmatrix} -\frac{a_1}{a_0} & 1 & 0 & \text{L} & 0 \\ -\frac{a_2}{a_0} & 0 & 1 & \text{L} & 0 \\ \text{L} & \text{L} & \text{L} & \text{L} & 1 \\ -\frac{a_n}{a_0} & 0 & 0 & \text{L} & 0 \end{bmatrix}, \quad B=\begin{bmatrix} b_1 & -\frac{a_1}{a_0} & b_0 \\ b_2 & -\frac{a_2}{a_0} & b_0 \\ \text{L} & \text{L} & \text{L} \\ b_n & -\frac{a_n}{a_0} & b_0 \end{bmatrix}, \qquad (11.4)$$

$$C^T = \left[\frac{1}{a_0}, 0, \mathrm{K}, 0\right], \quad d = \frac{b_0}{a_0}. \tag{11.5}$$

Предлагаемый метод идентификации математической модели основывается на следующих рассуждениях. Если все коэффициенты (11.4), (11.5) модели (11.2), (11.3) точно известны, то для наблюдения состояния можно использовать любые методы теоретико-множественного, в частности эллипсоидального, оценивания [144]. При этом множественная оценка неизвестного вектора состояния стягивается в точку. Если же структура (порядок) математической модели или ее параметры не соответствуют реальному объекту, то метод эллипсоидального оценивания состояний системы (2),(3) расходится. Следовательно, сходимость метода наблюдения состояний можно использовать в качестве критерия адекватности математической модели реальному объекту.

При этом структурная идентификация модели сводится к определению неизвестного вектора S, оптимизирующего процесс сходимости алгоритма наблюдения вектора состояния системы (11.2), (11.3).

Поскольку поверхность в пространстве параметров, на которой осуществляется оптимизация, не обладает свойством гладкости и какая-либо дополнительная информация о ее форме отсутствует, для оптимизации математической модели нельзя воспользоваться традиционными методами оптимизации. В такой ситуации целесообразно применить один из методов эволюционных вычислений [148]. Методология эволюционных вычислений базируется на моделировании основных механизмов развития биологических видов, связанных с естественным отбором и генетическим наследованием [149]. Среди моделей выделяют три основные парадигмы: генетические алгоритмы, эволюционные стратегии и эволюционное программирование [150]. Для рассматриваемой постановки задачи целесообразно использовать генетический алгоритм, который представляет собой метод поиска, оперирующий в каждый момент времени не одним приближением, а набором (популяцией) приближений. Каждое из приближений представляет собой бинарную строку, кодирующую неизвестную величину (в данном случае вектор параметров S). В процессе выполнения генетического алгоритма (ГА) на основе моделирования механизмов биологической эволюции

итеративно формируется последовательность популяций, элементы (особи) которых на каждой следующей итерации удовлетворяют критерию качества не хуже своих предшественников.

К основным операциям ГА относят скрещивание, мутации и естественный отбор. Формализация этих операций многократно описана в литературе (например, [146, 150]) и не зависит от решаемой задачи. Предметная область решаемой задачи определяет способ формирования бинарных строк кода неизвестного вектора и вид критерия качества, применяемого для отбора лучших представителей популяции. Таким образом, для рассматриваемой задачи структурной и параметрической идентификации математической модели объекта управления необходимо определить способ кодирования вектора параметров S и критерий качества.

Поскольку рассматриваемая задача не является задачей дискретной оптимизации, а компоненты неизвестного вектора представляют собой вещественные числа, их целесообразно кодировать в соответствии с традиционным компьютерным представлением вещественных чисел в так называемом научном формате в виде 4 байтов.

Если порядок математической модели (11.1) или (11.2), (11.3) неизвестен, то размерность вектора S нужно выбрать достаточно высокой (заведомо большей, чем требует предполагаемый порядок модели). В случае несоответствия предполагаемого порядка модели реальному найденный вектор решения S содержит несколько нулевых компонент ($a_n = b_n = 0$, $a_{n-1} = b_{n-1} = 0$, ..., $a_{n-n^*} = b_{n-n^*} = 0$), где n – предполагаемый, а n^* – реальный порядок математической модели объекта.

В качестве критерия оптимальности найденной математической модели удобно использовать сходимость одного из известных теоретико-множественных алгоритмов наблюдения состояний [147]

$$J = (y(k) - \hat{y}(k))^2, \qquad (11.6)$$

где $y(k)$ – измеренное, $\hat{y}(k)$ – вычисленное по оценке состояния значение выхода объекта управления. Выбор теоретико-множественных или гарантированных алгоритмов наблюдения объясняется тем, что наряду с точечной оценкой вектора состояния они позволяют получить его множественную оценку, а значит, определить качество этой оцен-

ки. Однако для работы классических гарантированных методов оценивания требуется указать замкнутое множество в пространстве состояний, которому заведомо принадлежит начальный вектор состояния. Поскольку в рассматриваемой задаче такое множество неизвестно, то в качестве алгоритма наблюдения естественно выбрать нечеткий алгоритм эллипсоидального оценивания [143], не требующий для своей работы никакой априорной информации об оцениваемом векторе.

11.3. ГА оптимизации математической модели

Для структурной и параметрической идентификации математической модели рассматриваемого объекта, т.е. для оценивания вектора S, удобно применить следующий ГА оптимизации [146].

1. Инициализировать популяцию, т.е. задать набор начальных приближений вектора S. Учитывая достаточно высокую сложность решаемой задачи, размер популяции μ целесообразно выбрать большим, например, равным 100.

2. Выполнить рекомбинацию (скрещивание) с использованием μ родительских особей для получения λ потомков. Как принято в эволюционных вычислениях, количество потомков λ должно в 5–7 раз превышать количество родительских особей.

3. Выполнить мутацию (случайное зашумление) для каждого из λ потомков.

4. Оценить λ или $\mu+\lambda$ представителей популяции согласно выбранному критерию (11.6), т.е. реализовать для каждого из них алгоритм наблюдения состояний. Заметим, что для каждого представителя нового поколения λ необходимо проверять выполнение условия наблюдаемости системы (11.2), (11.3).

5. Выбрать μ лучших представителей для формирования новой популяции.

6. Если требуемая точность оценивания не достигнута, перейти к шагу 2, в противном случае завершить алгоритм.

Взаимодействие генетического алгоритма поиска и нечеткого алгоритма эллипсоидального оценивания параметров модели показано на рис. 11.1.

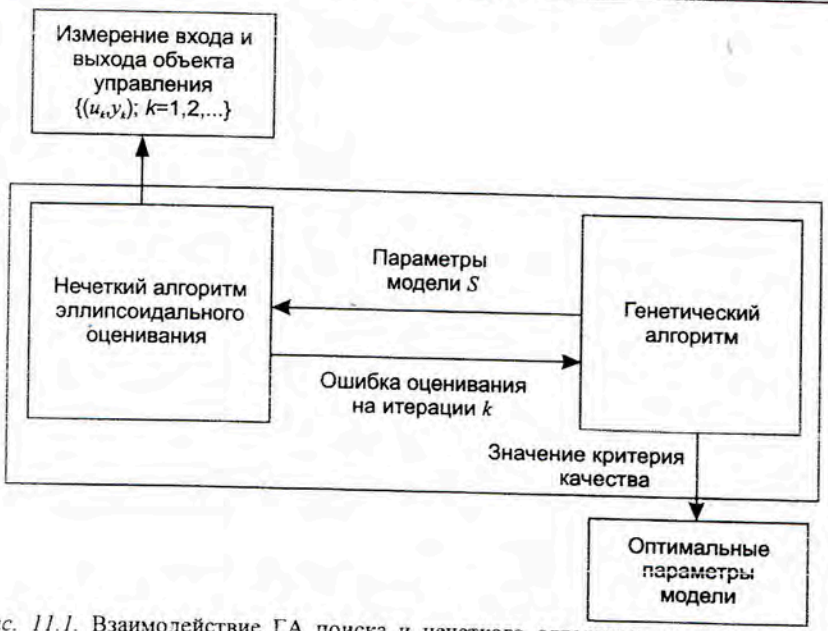


Рис. 11.1. Взаимодействие ГА поиска и нечеткого алгоритма эллипсоидального оценивания параметров модели

11.4. Нечеткий алгоритм эллипсоидального оценивания

Для оценивания каждого из λ представителей нового поколения на шаге 4 описанного алгоритма применим алгоритм нечеткого эллипсоидального оценивания состояний системы (11.2), (11.3), описанный в [143]. Особенность подобных нечетких алгоритмов наблюдения, которая выгодно отличает их от традиционных методов эллипсоидального оценивания, заключается в их работоспособности в условиях отсутствия априорной информации. Основная идея метода нечеткого эллипсоидального оценивания состоит в том, что в каждый момент дискретного времени k состояние объекта (11.2), (11.3) оценивается с использованием семейства концентрических многомерных эллипсоидов (нечеткого эллипсоидального множества) вида

$$E_k(\delta) = \{x \in R^n : (x - \hat{x}_k)^{\mathrm{T}} H_k^{-1} (x - \hat{x}_k) \le \frac{1-\delta}{\delta}\}, \qquad (11.7)$$

где $\hat{x}_k \in R^n$ – точечная оценка неизвестного вектора состояния; H_k – матрица, определяющая конфигурацию нечеткого эллипсоидального множества; $\delta \in (0,1]$ – параметр «размытости» множественной оценки.

Параметры нечеткой эллипсоидальной оценки с учетом каждого нового измерения входа и выхода объекта вычисляются рекуррентно по формулам [143]

$$\hat{x}_{k+1} = \tilde{x}_{k+1} + \tilde{H}_{k+1} C (C^{\mathrm{T}} \tilde{H}_{k+1} C)^{-1} \Delta_{k+1}, \qquad (11.8)$$

$$H_{k+1} = (\tilde{H}_{k+1} - (1-\beta_k^2)\tilde{H}_{k+1} C (C^{\mathrm{T}} \tilde{H}_{k+1} C)^{-1} C^{\mathrm{T}} \tilde{H}_{k+1}) \gamma_k^2, \qquad (11.9)$$

где

$$\tilde{H}_{k+1} = A H_k A^{\mathrm{T}},\ \gamma_k^2 = 1 + \sigma_k^2,\ \Delta_{k+1} = y(k+1) - C^{\mathrm{T}} \tilde{x}_{k+1} - du(k),$$

$$\sigma_k^2 = \Delta_{k+1}^{\mathrm{T}} (C^{\mathrm{T}} \tilde{H}_{k+1} C)^{-1} \Delta_{k+1},\ \tilde{x}_{k+1} = A\hat{x}_k + Bu(k),$$

$\beta_k^2 \in [0,1]$ – коэффициент сжатия пространства, выбор которого обеспечивает сходимость алгоритма наблюдения, если математическая модель адекватно отражает реальный объект.

Таким образом, в уравнении критерия качества (11.6) математической модели (11.1) используется значение выхода

$$\hat{y}_k = C^{\mathrm{T}} \hat{x}_k + du(k),$$

вычисленное на основе оценки вектора состояния согласно формулам (11.8), (11.9).

11.5. Обсуждение

Численное моделирование работы алгоритма показало, что несмотря на достаточно высокую вычислительную сложность предложенного алгоритма его применение в задаче структурной и параметрической идентификации математических моделей дает достаточно хорошие результаты. Так, при решении задачи идентификации математической модели вида (11.1) третьего порядка использовалась математическая модель порядка $n = 5$ (оценивался вектор S размерности 12). Для получения адекватной математической модели потребовалось приблизительно 1100 итераций (поколений). При этом качество каждого приближения (каждой особи поколения) оценивалось при $k = 100$.

Таким образом, результаты численного моделирования подтверждают применимость интеллектуальных методов вычислений в задачах идентификации и управления в условиях неопределенности.

Список литературы

1. *Building* a European information capacity for environment and security. A contribution to the initial period of the GMES Action Plan (2002–2003) // Office for Official Publications of the European Communities (Luxembourg). – 2004. – 238 p.

2. *Global* Earth Observation System of Systems (GEOSS). 10-Year Implementation Plan Reference Document // ESA Publication Division, Netherlands, 2005. – 209 p.

3. *Федоров О.П., Куссуль Н.Н., Шелестов А.Ю.* Задачи и перспективы развития в Украине информационной системы наблюдения Земли из космоса // Проблемы управления и информатики. – 2005. – № 6. – С. 116–120.

4. *Шелестов А.Ю., Кравченко А.Н., Гнибеда Л.С.* Комплексное использование информации из различных источников для дистанционного мониторинга поверхности Земли // Кибернетика и вычисл. техника. – 2005. – Вып. 148. – С.

5. *Довгий С.О. Лялько В.І. Трофимчук О.М. Федоровський О.Д.* Інформатизація аерокосмічного землезнавства. – К.: Наук. думка, 2001. – С. 523–534

6. *Нгуен Т.Ф.* Простой и эффективный метод обнаружения и устранения полос импульсного шума на изображениях // Проблемы управления и информатики. – 2004. – № 5. – С. 125–130.

7. *Шелестов А.Ю., Нгуен Т.Ф., Лавренюк А.Н.* Анализ нелинейных фильтров для восстановления изображений, искаженных импульсным шумом // Кибернетика и вычисл. техника. – 2004. – Вып. 143. – С. 69–91.

8. *Куссуль Н.Н., Шелестов А.Ю., Лобунец А.Г.* Применение методов операционного анализа для оценки производительности GRID-систем // Кибернетика и вычисл. техника. – 2004. – Вып. 144. – С. 3–20.

9. *Kussul N., Lavrenyuk A., Skakun S.* Distance learning system for Meteosat data investigation // Proc. of the 2004 Eumetsat Meteorological Satellite Conference. – Prague: Czech Republic. – 2004. – P. 434–438.

10. *Kussul N., Skakun S., Lobunets A.* GRID system for Meteosat data processing // Сб. тез. докл. Международной научно-практической конференции «Единое информационное пространство». – Днепропетровск: ИПК ИнКомЦентра УГХТУ, 2003. – С. 21–22.

11. *Committee* on Earth Observation satellites disaster management support group: The use of Earth observing satellites for hazard support: Assessments & Scenarios // Final Report; National Oceanic & Atmospheric Administration, Department of Commerce, USA, 2001. – P. –

12. *GEO* Work Plan 2007–2009 – "Toward Convergence".

13. *Haykin S.* Neural Networks: a comprehensive foundation, Upper Saddle River. – New Jersey: Prentice Hall, 1999. – 842 p.

14. *Solheim I., Solbo S., Indregard M., Lauknes I.* User requirements and SAR-Solutions for flood mapping // 4th International Symposium on Retrieval of Bio-and Geophysical Parameters from SAR Data for Land Applications. – Innsbruck, Austria, 2001. – P. –

15. *ESA* Earth Watch. – http://earth.esa.int/ew/floods/.

16. *Yang C., Zhou C., Wan Q.* Deciding the flood extent with RADARSAT SAR data and image fusion // 20th Asian Conference on Remote Sensing, 1999. – P. –

17. *Extracting* the flood extent from satellite SAR image with thesupport of topographic data / Y. Cunjian, W. Yiming, W. Siyuan, Z. Zengxiang, H. Shifeng // Proc. of Intern. Conf. on Information Technology and Information Networks (ICII 2001). – Beijing, China. – **1**. – P. 87–92.

18. *Evaluation* of a remote sensing based regional flood/waterlog and drought monitoring model utilising multi-source satellite data set including envisat data / G. Csornai, Zs. Suba, G. Nádor, I. László, Á. Csekő, Cs. Wirnhardt, L. Tikász, L. Martinovich // Proc. of the 2004 Envisat & ERS Symposium. Salzburg, Austria, 6–10 September 2004 (ESA SP-572, April 2005).

19. *De Chiara G., Bovolin V., P., Migliaccio M.* Remote sensing technique to estimate the water surface of artificial reservoirs Villani – Problems and potential solutions // IEEE GOLD Remote Sensing Conference 2006.

20. *Ferdinand B., Roy D.* Monitoring flood extent and forecasting excess runoff risk with RADARSAT-1 Data // Natural Hazards. – 2005. – **35**. – P. 377–393.

21. *Определение* затопленных территорий на основе интеграции разнородных данных / Н.Н. Куссуль, Е.А. Лупян, А.Ю. Шелестов, С.В. Скакун, Ю.Г. Тищенко, Л. Хлухи // Проблемы управления и информатики. – 2007. – № 6. – С. 117–126.

22. *Нейросетевой* метод мониторинга затопленных территорий с использованием радиолокационных спутниковых данных / Н.Н. Куссуль, Е.А. Лупян, А.Ю. Шелестов, С.В. Скакун, В.П. Саворский, Ю.Г. Тищенко. // Исследование Земли из космоса. – 2007.

23. *ESA* Product Specification for ERS Products within Envisat Format, Ref: PX-SP-50-914.5 // Issue/Revision: 3/1, Date: OCT 3, 2006. – http://earth.esrin.esa.it/pub/ESA_DOC/gen144.pdf.

24. *European* Topic Centre on Terrestrial Environment. – http://terrestrial.eionet.eu.int/CLC2000.

25. *ERS SAR* Calibration. Derivation of the backscattering coefficient in ESA ERS SAR PRI products // ES-TN-RS-PM-HL09 05, November 2004, Issue 2, Rev. 5f.

26. *Gonzalez R.C., Woods R.E.* Digital image processing. – Prentice Hall, Upper Saddle River: New Jersey, 2002. – 793 p.

27. *Xu C.Y.* Hydrological Models: Lecture Book. – Uppsala University, Department of Hydrology, 2006. – 200 p.

28. *An introduction* to the European Hydrological System – Systeme Hydrologique Europeen, "SHE" History and philosophy of a physically-based distributed modelling system / M.B. Abbott, J.C. Bathurst, J.A. Cunge, P.E. O'Connell, J. Rasmussen // J. Hydrol. – 1986. – **87**. – P. 45–59.

29. *Singh V.P.* Computer models of watershed hydrology // Littleton, CO: Water Resources Publications, 1995. – 1144 p.

30. *Problem-solving* environment for flood forecasting / L. Hluchy, O. Habala, B. Simo, J. Astalos, V. D. Tran, M. Dobrucky // Management of Environmental Quality: An International. – 2004. – **15**. – № 3. – P. 268–275.

31. *Grell G.A., Dudhia J., Stauffer D.R.* A description of the Fifth-Generation Penn State/NCAR Mesoscale Model (MM5). – NCAR TECHNICAL NOTE, June 2005.

32. *FESWMS* – Finite Element Surface Water Modeling System. – http://www.bossintl.com/html/feswms.html.

33. *Skamarock W.C.* A description of the advanced research WRF Version 2 – NCAR TECHNICAL NOTE, June 2005. – www.mmm.ucar.edu/wrf/users/docs/arw_v2.pdf.

34. *Rutledge, G.K., Alpert J., Ebisuzaki W.* NOMADS, a climate and weather model archive at the National Oceanic and Atmospheric Administration. // Bulletin of the American Meteorological Society. – 2006. – **87** – № 3. – P. 327–341.

35. *Мониторинг* водных ресурсов на основе интеграции разнородных данных и высокопроизводительных вычислений / А.Н. Кравченко, Н.Н. Куссуль, Е.А. Лупян, В.П. Саворский, Л. Хлухи, А.Ю. Шелестов // Кибернетика и системный анализ – 2007.

36. *Chen, F., Dudhia J.* Coupling an advanced land-surface/hydrology model with the Penn State/NCAR MM5 modeling system. Part I: Model implementation and sensitivity // Mon. Wea. Rev. – 2001. – **129**. – P.569–585.

37. *Lo J. C.-F., Yang Z.-L., Pielke Sr. R.* Assessment of ddynamical climate downscaling methodologies using the weather research and forecasting (WRF) Model // J. Geophys. Res. – 2007 (submitted)

38. *Wan Z.* "MODIS Land-Surface Temperature Algorithm Basis Document (LST ATBD): version 3.3" (April 1999). – http://www.icess.ucsb.edu/modis/atbd-mod-11.pdf.

39. *Global* land cover classification by remote sensing: Present capabilities and future possibilities / J.R.G. Townshend, C. Justice, W. Li, C/ Gurney, J. McManus // Remote Sensing of Environment. – 1991. – **35**. – P. 243–255.

40. *Інформаційний* сервіс оцінювання видового різноманіття рослинного і тваринного світу причорноморського регіону України в контексті розвитку українського сегмента системи GEOSS / Н.Н. Куссуль, М.О. Попов, А.Ю. Шелестов, С.А. Станкевич, М.Б. Корбаков, О.М. Кравченко, А.О. Козлова // Наука та інновації. – 2007. – № 6. – С. 13–25.

41. *NASA* Landsat 7. – http://landsat.gsfc.nasa.gov.

42. *National* Land Cover Data (NLCD). – http://www.epa.gov/mrlc/nlcd.html.

43. *Strahler A.* MODIS Land Cover and Land-Cover Change, Algorithm Theoretical Basis Document (ATBD), Version 5.0, 1999. – 72 p.

44. *Belward A.S., Estes J.E., Kline K.D.* The IGBP-DIS Global 1-km Land-Cover Data Set DISCover: A Project Overview // Photogram. Eng. Remote Sens. – 1999. – **65**. – P. 1013–1020.

45. *Foody G.M., Campbell N.A., Trodd N.M., Wood T.F.* Derivation and applications of probabilistic measures of class membership from maximum likelihood classification // Photogramm. Eng. Remote. Sens. – 1992. – **58**. – № 9. – P. 1335–1341.

46. *Benediktsson J.A., Swain P.H., Ersoy O.K.* Neural Network Approaches versus Statistical Methods in Classification of MultiSource Remote sensing Data. // IEEE Trans. On Geoscience and Remote Sensing. – 1990. – **28**. – № 4. – P. 540–552.

47. *Decatur S.E.* Applications of Neural Networks to Terrain Classification. Proc. of the International Joint Conference on Neural Networks. – 1989. – **1**. – P. 283–288.

48. *Bischof H., Schneider W., Pinz A.J.* Multispectral Classification of Landsat Images Using Neural Networks // IEEE Trans. on Geoscience and Remote Sensing. – 1992. – **30**. – № 3. – P. 482–490.

49. *Dawson M.S., Fung A.K.* Neural Networks and Their Applications to Parameter Retrieval and Classification // IEEE Geoscience and Remote Sensing Society Newsletter. – 1993. – P. 6–14.

50. *Carpenter G.A., Martens S., Ogas O.J.* Self-organizing information fusion and hierarchical knowledge discovery: a new framework using ARTMAP neural network // Neural Networks. – 2005. – **18**. – P. 287–295.

51. *Hwang J.N., Lay S.R., Kiang R.* Robust Construction Neural Networks for Classification of Remotely-Sensed Data // Proc. of World Congress on Neural Networks. – 1993. – **4**. – P. 580–584.

52. *Roli F., Serpico S.B., Vernazza G.* Neural Networks for Classification of Remotely-Sensed Images. // Fuzzy Logic and Neural Networks Handbook. – McGraw-Hills, 1996.

53. *Kussul N., Skakun S., Kussul O.* Comparative Analysis of Neural Networks and Statistical Approaches to Remote Sensing Image Classification // In. Scientific J. of "Computing". – 2006. – **5**, Issue 2. – P. 93–99.

54. *Куссуль Н.Н., Скакун С.В., Куссуль О.М.* Анализ нейросетевых и статистических подходов к классификации изображений спутника Landsat-7 // Інтелектуальні системи прийняття рішень і прикладні аспекти інформаційних технологій: Матеріали науково-практичної конференції. Т. 1. – Херсон: Вид-во Херсонського морського інституту, 2006. – С. 117–120.

55. *Werbos P.J.* The roots of backpropagation: from ordered derivatives to neural networks and political forecasting. – New York: John Wiley & Sons, Inc., 1994. – 319 p.

56. *Minai A.A., Williams R.J.* Back-propagation heuristics: A study of the extended delta-bar-delta algorithm // IEEE International Joint Conference on Neural Networks. – 1990. – **1**. – P. 595–600.

57. *Carpenter G.A., Grossberg S., Reynolds J.H.* ARTMAP: Supervised Real-Time Learning and Classification of Nonstationary Data by a Self-Organizing Neural Network // Neural Networks. – 1991. – **4**. – P. 565–588.

58. *Carpenter G.A., Grossberg S.* ART 2: Stable selforganization of pattern recognition codes for analog input patterns // Applied Optics. – 1987. – **26**. – P. 4919–4930.

59. *Лавренюк А.Н., Яровая Е.В., Скакун С.В.* Нейросетевая классификация спектральных характеристик наземных объектов // Кибернетика и вычисл. техника. – 2005. – Вып. 148. – С. 21–28.

60. *Скакун С.В., Насуро Е.В., Лавренюк А.Н., Куссуль О.М.* Анализ применимости нейронных сетей для классификации спутниковых данных // Проблемы управления и информатики. – 2007. – № 2. – С. 105–117.

61. *Stone M.* Cross-validatory choice and assessment of statistical predictions // J. of the Royal Statistical Society. – 1974. – **B36**. – P. 111–133.

62. *Landsat*-7 Science Data User's Handbook. – http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_toc.html.

63. *Электронный* учебник по статистике StatSoft. – http://www.statsoft.ru.

64. A *Neural* Network Method for Mixture Estimation for Vegetation Mapping / Carpenter G.A., Gopal S., Macomber S., Martens S., Woodcock C.E. // Remote Sens. Environ. – 1999. – **70**. – P. 138–152.

65. *Martens S.* ClasserScript v1.1 User's Guide, Technical Report CAS/CNS-TR-05-009, 2005. – 51 p.

66. *Система* геоінформаційного космічного забезпечення. – www.cosmogis.org.ua.

67. *Dufourmont H., Annoni A., De Groof H.* INSPIRE – Work Programme Preparatory Phase 2005–2006 // ESTAT-JRC-ENV, 2004. – 78 p.

68. *Yatsenko V.A., Kochubey S.M., Pardalos P.M., Zhan L.* Estimation of chlorophyll concentration in vegetation using global optimization approach // Proc. of SPIE Conference "AeroSence: Technologies and Systems for Defence & Security", Orlando, USA. – 21–25 April, 2003. – P. 174–182.

69. *Кочубей С.М.* Система мониторинга основных параметров сельскохозяйственных посевов на основе спектров отражения от растительности // Сб. тез. III Укр. конф. по перспективным космическим исследованиям. – Крым, 2003. – С. 229.

70. *Яценко В.О., Хандріга П.О.* Застосування методу покомпонентного аналізу для визначення вмісту хлорофілу в рослинності // Там же. – С. 230.

71. *Определение* содержания хлорофилла в растениях с помощью модульных нейронных сетей / Н.Н. Куссуль, Дж. Марковски, В.А. Яценко, А.А. Саченко, А.В. Сидоренко, С.В. Скакун // Кибернетика и вычисл. техника. – 2003. – Вып. 141. – С. 49–57.

72. *Kochubey S.M., Pardalos P.M., Yatsenko V.A.* Method and the device for remote sensing of vegetation. // Proc. of SPIE Remote Sens. for Agricul., Ecosyst. and Hydrolog. IV, Manfred Qwe, Guido D'Urso, Leonidas Toulios Eds., Agia Pelagia, Crete, Greece. – September, 22–25, 2002. – P. 243–251.

73. *Kussul M., Galinskaya A.* Comparative study of modular classifiers and its training // Proc. of the X th Intern. Conf. "Knowledge-Dialogue-Solution". – Varna, Bulgaria, June, 16–26, 2003. – P. 168–174.

74. *Kussul N., Kussul M., Sachenko A., Markowsky G., Ganzha S.* Remote Sensing of Vegetation Using Modular Neural Networks // Proc. of III Intern. Conf. on Neural Networks and Artificial Intelligence (ICNNAI'2003). – Minsk, Belarus, November, 12–14, 2003. – P. 232–234.

75. *Багатоспектральні* методи дистанційного зондування Землі в задачах природокористування / За ред. В. І. Лялька та М. О. Попова.– К.: Наук. думка, 2006. – 360 с.

76. *Одум Ю.* Экология: Пер. с англ. – М.: Мир, 1986. – **2**. – 376 с.

77. *Протасов А. А.* Биоразнообразие и его оценка: Концептуальная диверсикология. – К.: Ин-т гидробиологии, 2002. – 108 с.

78. *Киселев А. Н.* Оценка и картографирование биологического разнообразия (на примере Приморья). // Геоботаническое картографирование. – 2000.– **3**.– С. 3–15.

79. *Станкевич С. А., Козлова А.О.* Особливості розрахунку індексу видового різноманіття за результатами статистичної класифікації аерокосмічних знімків //

Уч. зап. Таврического национального ун-та им. В.И. Вернадского. 2006. – **19** – № 58. – С.144–150.

80. *Козлова А. А., Станкевич С. А.* Оценка и картографирование биоразнообразия Северно-Причерноморского региона Украины на основании многоспектральных космоснимков и геоинформационных технологий // Сб. тез. VI Укр. конф. по космическим исследованиям. – Евпатория: ИКИ НАН Украины, 2006.– С.117.

81. *Шелестов А., Насуро Е., Скакун С.* Оценка биоразнообразия с использованием нейронных сетей // Proc. of XIII-th International Conference Knowledge-Dialogue-Solutions. – Varna, Bulgaria, 2007. – P. 49–55.

82. *Snyder J. P.* Map projections – a working manual // U. S. Geological Survey Professional Paper 1395. – Washington: U. S. Government Printing Office, 1987. – P. 98–103.

83. *Кравченко О. М., Шелестов А. Ю.* Застосування реалізацій стандартів OGC для створення розподілених систем візуалізації та надання геопросторових даних // Проблеми програмування. – 2006. – № 2–3. – С. 135–140.

84. *Шелестов А.Ю., Куссуль Н.Н., Скакун С.В.* Grid-технологии в системах мониторинга на основе спутниковых данных // Проблемы управления и информатики. – 2006. – № 1–2. – С. 259–271.

85. *Кравченко О.М.* Анализ динамики облачности по спутниковым снимкам на основе метода оптических потоков // Кибернетика и вычисл. техника. – 2006. – № 151. – С. 16–23.

86. *Lucas B.D., Kanade T.* An iterative image registration technique with an application to stereo vision // Proc. of Imaging Understanding Workshop. Vancouver (Canada). – 1981. – P. 121–130.

87. *Horn B.K., Schunck B.* Determining optical flow // Artificial Intelligence. – 1981. – № 17. –P. 185–203.

88. *Corpetti T., Mémin E., Pérez P* Dense motion analysis in fluid imagery // Lecture Notes In Computer Science. – 2002. – **2350**. – P. 676–691.

89. *Corpetti T., Mémin E., Pérez P.* Dense estimation of fluid flows // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2002. – **24.** – № 3 – P. 365–380.

90. *Shelestov A., Kravchenko O., Korbakov M.* Services for satellite data processing // International Journal on Information Theories and Applications. – 2006. – № 3. – P. 272–276.

91. *Європейська* організація по використанню метеорологічних супутників (EUMETSAT – European Organisation for the Exploitation of Meteorological Satellites). – http://www.eumetsat.int.

92. *Barron J.L., Flee D.J., Beauchemin S.S.* Performance of optical flow techniques // Intern. J. of Computer Vision. – 1994. – **12**. – P. 43–77.

93. *Beauchemin S.S., Barron J.L.* The computation of optical flow // ACM Computing Surveys. – 1995. – **27**. – P. 433–466.

94. *Построение* карты облачности с использованием параллельного алгоритма марковской сегментации / Н.Н. Куссуль, А.Ю. Шелестов, М.Б. Корбаков, А.Н. Кравченко, Т.Ф. Нгуен // Кибернетика и вычисл. техника. – 2005. – № 146. – С. 49–60.

95. *Parallel* markovian approach to the problem of cloud mask extraction / N. Kussul, A. Shelestov, T.P. Nguyen, M. Korbakov, A. Kravchenko // Proc. of the XIth Intern. Conf. "Knowledge-Dialogue-Solution". – Varna, Bulgaria. – 2005. – **2**. – P. 567–569.

96. *Li S.Z.* Markov random field modeling in computer vision. – Springer-Verlag, 1995. – 230 p.

97. *Ширяев А.Н.* Вероятность. – М.: Наука, 1989. – 581 с.

98. *MPI-2* : Extensions to the Message-Passing Interface / Ewing Lusk, S. Huss-Lederman, B. Saphir, M. Snir, B. Gropp – University of Tennessee, 1997. – P.

99. *Воеводин В.В., Воеводин Вл.В.* Параллельные вычисления. – СПб.: «БХВ-Петербург», 2002. – 599 с.

100. *Cole D.G.* Space weather: its effects and predictability // Space Science Reviews. – 2003. – № 107. – С. 295–302.

101. *Blais G., Metsa P.* Operating the Hydro-Québec grid under magnetic storm conditions since the storm of March 13, 1989 // Proc. Solar-Terrestrial Predictions Workshop, Ottawa, May 18–22, 1992 / Ed. By J. Hruska, M.A. Shea, D.F. Smart, G. Heckman. – 1993. – **1**. – P. 108–130.

102. *Doherty P., Coster A.J., Murtagh W.* Space weather effects of October–November 2003 // GPS Solutions. – 2004. – **8**. – P. 267–271.

103. *Dryer M., SmartD.F.* Dynamical models of coronal transients and interplanetary disturbances // Advances in Space Research. – 1984. – **4**. – P. 291–301.

104. *Smart D.F., Shea M.A.* A simplified model for timing the arrival of solarare-initiated shocks // J. Geophys. Res. – 1985. – **90**. – P. 183–190.

105. *Smith Z.K., Dryer M., Ort E., Murtagh W.* Performance of interplanetary shock prediction models // J. Atm. Solar-Terr. Phys. – 2000. – **62**. – P. 1264–1274.

106. *Improvements* to the HAF solar wind model for space weather predictions / C.D. Fry, W. Sun, C.S. Deehr, M. Dryer, Z. Smith, S.-I. Akasofu, M. Tokumaru, M. Kojima // J. Geophys. Res. – 2001. – **106**, A10. – P. 20985–21002.

107. *Riley P., Linker J., Mikic Z., Lionello R.* MHD modeling of the solar corona and inner heliosphere: Comparison with observations // In Space Weather, Geophys. Monogr. Ser. – 2001. – **125**. – 159 p.

108. *Leontaritis I.J., Billings S.A.* Model selection and validation methods for nonlinear systems // Int. J. Control. – 1987. – **45**. – P. 311–341.

109. *Boaghe O.M., BalikhinM.A., Billings S.A., Alleyne H.* Identification of nonlinear processes in the magnetospheric dynamics and forecasting of Dst index // J. Geophys. Lett. – 2001. – **106**. – P. 30047–30066.

110. *Vandegriff J., Wagstaff K., Ho G., Plauger J.* Forecasting space weather: Predicting interplanetary shocks using neural networks // Advances in Space Research. – 2005. – **36**. – P. 2323–2327.

111. *Куссуль Н.М., Шелестов А.Ю., Скакун С.В., Житомирська К.Г.* Автоматична система прогнозування міжпланетних ударних хвиль у сонячному вітрі // Космічна наука і технологія. – 2007.

112. *Куссуль Н.Н., Шелестов А.Ю., Скакун С.В., Карбачевский А.И.* Нейросетевое прогнозирование межпланетных ударных волн в солнечном ветре // Кибернетика и вычисл. техника. – 2007. – Вып. 155.

113. *Перечень* ударных волн за 1997–2006 годы (ИЗМИРАН). – http://helios.izmiran.troitsk.ru/cosray/events.htm.

114. *Данные* первого уровня спутника ACE в режиме реального времени. – http://www.sec.noaa.gov/ftpdir/lists/ace.

115. *Архив* данных первого уровня спутника ACE. – http://sohowww.nascom.nasa.gov/sdb/ace/daily.

116. *Шелестов А.Ю., Житомирская К.Г., Кременецкий И.А., Ильин Н.И.* Автоматическое выявление ударных волн по измерениям спутника ACE // Кибернетика и вычисл. техника. – 2006. – № 151. – С. 3–16.

117. *Классификация* событий космической погоды NOAA. – http://www.sec.noaa.gov/NOAAscales.

118. *Хайкин С.* Нейронные сети: 2-е изд. / Пер. с англ. – М.: Издательский дом «Вильямс», 2006. – 940 с.

119. *Riedmiller M., Braun H.* A direct adaptive method for faster backpropagation learning: The RPROP algorithm. – San Francisco, 1993.

120. *Igel C., Husken M.* Improving the Rprop learning algorithm / Ed be H. Bothe and R. Rojas, itors // Proc. of the Second International Symposium on Neural Computation, NC 2000. – ICSC Academic Press, 2000. – P. 115–121.

121. *Pok G., Liu J. C., Nair A. S.* Selective removal of impulse noise based on homogeneity level information // IEEE Trans. On Image Processing. – 2003. – **12**, № 1. – P. 85–92.

122. *Effective* detection and elimination of impulse noise with a minimal image smoothing / I. Aizenberg, J. Astola, C. Butakoff, K. Egiazarian, D. Paliy // Proc. of IEEE Intern. Conf. on Image Processing. – 2003. – P. 357–360.

123. *Aizenberg I., Butakoff C.* Effective impulse detector based on rank-order criteria // IEEE Signal Processing Letters. – 2004. – **11**, № 3. – P. 363–366.

124. *Abreu E., Mitra S. K.* A simple algorithm for restoration of images corrupted by streaks // IEEE Trans. on Image Processing. – 1996. – P. 730–733.

125. *Lin T. C., Yu P. T.* Adaptive two-pass median filter based on support vector machines for image restoration // Neural Computation. – 2004. – **16**, № 2. – P. 333–354.

126. *Sun T., Neuvo Y.* Detail-preserving median based filters in image processing // Pattern Recognition Letters. – 1994. – **15**. – P. 341–347.

127. *Wang Z., Zhang D.* Progressive switching median filter for the removal of impulse noise from highly corrupted images // IEEE Trans. On Circuits and Systems-II: Analog and Digital Signal Processing. – 1999. – **46**, № 1. – P. 78–80.

128. *Xu X., Miller E. L., Chen D., Sarhadi M.* Adaptive two-pass rank order filter to remove impulse noise in highly corrupted images // IEEE Trans. On Image Processing. – 2004. – **13**, № 2. – P. 238–247.

129. *Chen T., Wu H. R.* Adaptive impulse detection using center-weighted median filters // IEEE Signal Processing Letters. – 2001. – **8**, № 1. – P. 1–3.

130. *Nicolescu C., Jonker P.* Parallel low-level image processing on a distributed-memory system // The Intern. Parallel and Distributed Processing Symposium Conference. – 2000.

131. *Seinstra F. J.* User transparent parallel image processing // PhD Thesis. Intelligent Sensory Information System. – University of Amsterdam, the Netherlands. – 2003.

132. *Нгуен Т.Ф., Шелестов А.Ю.* Параллельная реализация алгоритмов фильтрации космических изображений // Проблемы управления и информатики. – 2005. – № 2. – С. 121–132.

133. *Aoyama Y., Nakano J.* RS/6000 SP: Practical MPI Programming // RS/6000 Technical Support Center, IBM Japan. – 1999.

134. *Message* Passing Interface Forum. MPI: A message-passing interface standard // Technical Report: UT-CS-94-230. – 1994.

135. *Pacheco P. S.* A user's guide to MPI // Technical Report, Department of Mathematics, University of San Fransisco, California. – 1998.

136. *Gropp W. D.* Issues in accurate and reliable use of parallel computing in numerical programs // Preprint ANL/MCS-P1193-0804, Argonne National Laboratory. – 2004.

137. *MPI*: The Complete Reference / M. Snir, S. Otto, S. Huss-Lederman, D. Walker, J. Dongarra // The MIT Press. – 1996.

138. *Fissgus U., Rauber T., Rünger G.* A framework for generating task parallel programs // The 7th Symposium on the Frontiers of Massively Parallel Computation. – 1999.

139. *Nicolescu C., Jonker P.* A data and task parallel image processing environment // Parallel Computing. – 2002. – **28**, Issue 7–8. – P. 945–965.

140. *Gropp W. D., Lusk E., Doss N., Skjellum A.* A high-performance, portable implementation of the MPI message passing interface // Parallel Computing. – 1996. – **22**, Issue 6. – P. 789–828.

141. *Кунцевич В.М.* Управление в условиях неопределенности: гарантированные результаты в задачах управления и идентификации. – К.: Наук. думка, 2006. – 206 с.

142. *Черноусько Ф. Л.* Оценивание фазового состояния динамических систем. Метод эллипсоидов. – М.: Наука, 1988. – 320 с.

143. *Куссуль Н.Н., Шелестов А.Ю.* Оценивание фазового состояния линейных многомерных динамических объектов с использованием размытых эллипсоидальных множеств // Проблемы управления и информатики. – 1995. – № 1. – С. 53–62.

144. *Волосов В.В., Одинцова Е.А., Храмов С.А.* Алгоритмы эллипсоидального оценивания матрицы параметров линейного дискретного динамического объекта управления // Проблемы управления и информатики. – 1995. – № 1. – С. 63–77.

145. *Шелестов А.Ю.* Структурная и параметрическая идентификация моделей объектов управления на основе генетического алгоритма // Управляющие системы и машины. – 2007. – № 5.

146. *Eberhart R., Simpson P., Dobbins R.* Computational intelligence PC tools. – New York: AP Professional, 1996. – 464 p.

147. *Бакан Г.М., Куссуль Н.Н.* Размытый эллипсоидальный алгоритм фильтрации состояний статического объекта // Проблемы управления и информатики. – 1996. – № 5. – С. 77–85.

148. *Fogel D.B.* Evolutionary computation: toward a new philosophy of machine intelligence// IEEE Press, 1995. – 272 p.

149. *Жуков-Бережников Н.* Теория генетической информации. Теоретический и экспериментальный очерк. – М.: Мир, 1966. – 320 с.

150. *Назаров А.В., Лоскутов А.И.* Нейросетевые алгоритмы прогнозирования и оптимизации систем. – СПб.: Наука и техника, 2003. – 384 с.

151. *European* Topic Centre on Terrestrial Environment, http://terrestrial.eionet.eu.int/CLC2000.

152. *National* Land Cover Data (NLCD) [http://www.epa.gov/mrlc/nlcd.html]

153. *Strahler A.*, et al. MODIS Land Cover and Land-Cover Change, Algorithm Theoretical Basis Document (ATBD), Version 5.0, 1999. – 72 p.

154. *Belward A.S., Estes J.E., Kline K.D.* The IGBP-DIS Global 1-km Land-Cover Data Set DISCover: A Project Overview// Photogram. Eng. Remote Sens. – 1999. – 65. – P. 1013–1020.

155. *География* и мониторинг биоразнообразия. – М.: Изд-во науч. и уч.-методического центра, 2002. – 432 с.

156. *Попов М.О., Станкевич С.А., Козлова А.О.* Удосконалена процедура класифікування багатоспектральних аерокосмічних зображень при оцінюванні біорізноманіття Північно-Причорноморського регіону України. // Тез. докл. Международной науч. конф. "Фундаментальные исследования важнейших проблем естественных наук на основе интеграционных процессов в образовании и науке". – Севастополь: НПЦ ЭКОСИ-Гидрофизика, 2006. – С. 82–83.

157. *Попов М.А., Станкевич С.А., Козлова А.А.* Особенности использования многоспектральных аэрокосмических изображений при количественной оценке видового разнообразия растительного покрова // Тез. докл. IV Всероссийской открытой конф. «Современные проблемы дистанционного зондирования Земли из космоса». – М.: ИКИ РАН, 2006. – С.225–226.

158. *Snir M., Otto S., Huss-Lederman S., Walker D., Dongarra J.* MPI: The Complete Reference // The MIT Press. – 1996.

159. *A visual* solution to modular neural network system development / M. Kussul, A. Riznyk, E. Sadovaya, A. Sitchov, T.Q. Chen. // Proc. of the 2002 International Joint Conference on Neural Networks (IJCNN'02), Honolulu, HI, USA. – **1**. – 2002. – P 749–754.

160. *The Worldwide* Reference System (WRS). – http://landsat.gsfc.nasa.gov/documentation/wrs.html.

161. *Derivation* of a tasseled cap transformation based on Landsat-7 at-satellite reflectance / C. Huang, B. Wylie, L. Yang, C. Homer, G. Zylstra // Intern. J. of Remote Sensing. – 2002. – **23**. – № 8. – P. 1741–1748.

162. *I.T. Jolliffe.* Principal Component Analysis. – New York: Springer-Verlag, 1986. – 487 p.

163. http://speclab.cr.usgs.gov.

164. http://speclib.jpl nasa.gov.

165. *Каллан Р.* Основные концепции нейронных сетей. – М.: Издательский дом "Вильямс", 2001.

166. *Global* monitoring for environment and security (GMES): Establishing a GMES capacity by 2008 – (Action Plan (2004–2008)) // Communication from the Commission to the European Parliament and the Council, Brussels, COM (2004) 65 final, 2004. – 23 p.

СОДЕРЖАНИЕ

Предисловие 5

Часть I. ИНТЕЛЛЕКТУАЛЬНЫЕ ВЫЧИСЛЕНИЯ В ПРИКЛАДНЫХ ЗАДАЧАХ СПУТНИКОВОГО МОНИТОРИНГА 9

Глава 1. Комплексирование данных и моделей при решении задач дистанционного мониторинга и прогнозирования 11

1.1. Комплексирование данных в задаче оценки состояния почв 11

1.2. Этапы и методы комплексной оценки и прогнозирования состояния земной поверхности 13

1.2.1. Анализ данных, необходимых для оценки и прогнозирования состояния почв и растительности 13

1.2.2. Фильтрация спутниковых данных 14

1.2.3. Методы оценки состояния почв и растительности 16

1.2.3.1. Построение индексов 16

1.2.3.2. Статистические методы и марковские поля 19

1.2.3.3. Интеллектуальные методы оценки состояния почв и растительности 19

1.2.4. Методы прогнозирования состояния почв и растительности 20

1.2.5. Применение моделей 21

1.2.6. Реализация параллельных алгоритмов обработки данных 21

1.3. Обсуждение 22

Глава 2. Мониторинг затоплений на основе радиолокационных спутниковых данных 23

2.1. Описание существующих подходов 24

2.2. Входные спутниковые данные 26

2.3. Метод определения затопленных наводнениями территорий 28

2.3.1. Предварительная обработка изображений 28

2.3.2. Обработка изображений с использованием нейронных сетей Кохонена 29

2.4. Экспериментальные результаты 31

2.5. Обсуждение 35

Глава 3. Создание каскадов гидрометеорологических моделей для прогнозирования паводков 36

3.1. Гидрологические модели. Основные понятия и классификация 37
3.2. Существующие подходы к прогнозированию паводков 40
3.3. Метод прогнозирования паводков на территории Закарпатья 42
3.4. Валидация моделей 48
3.5. Обсуждение 51

Глава 4. Нейросетевая классификация подстилающей поверхности по спутниковым данным 52
4.1. Обзор существующих подходов к классификации данных ДЗЗ 53
4.2. Выбор данных для обучения НС 54
4.3. Анализ применимости различных нейросетевых парадигм для решения задач классификации спутниковых данных 56
4.3.1. Результаты работы MLP 57
4.3.2. Анализ работы алгоритма обучения MLP Back Propagation 58
4.3.3. Анализ работы метода обучения EDBD (Extended Delta-bar-Delta) 62
4.3.4. Анализ работы алгоритма обучения сопряженных градиентов (Conjugate Gradient) 63
4.3.5 Анализ результатов работы квази-ньютоновского метода обучения второго порядка 63
4.3.6. Применение НС на основе радиальных базисных функций (RBF) 65
4.3.7. Применение НС на основе теории адаптивного резонанса для классификации 68
4.4. Сравнительный анализ результатов нейросетевой классификации 70
4.5. Сравнение результатов нейросетевых и статистических методов классификации спутниковых данных 70
4.6. Обсуждение 73

Глава 5. Оценивание состояния и видового разнообразия растительности 74
5.1. Определение содержания хлорофилла в растениях с помощью модульных НС 75
5.1.1. Постановка задачи и обоснование метода решения 75
5.1.2. Архитектура модульной НС 77
5.1.3. Результаты экспериментов 78
5.1.4. Сравнение эффективности модульной и традиционной нейросетевой архитектуры 82
5.1.5. Обсуждение 84

5.2. Оценка видового разнообразия 84
5.2.1. Методика оценивания видового разнообразия 85
5.2.2. Модификация метода оценки биоразнообразия на основе нейросетевой классификации типов покрывающей поверхности 88
5.2.3. Реализация программной инфраструктуры с сервисом оценки видового многообразия 89
5.2.4. Обсуждение 95
Глава 6. Анализ динамики облачности по спутниковым снимкам на основе метода оптических потоков 96
6.1. Характеристики спутниковых данных 97
6.2. Методы построения оптических потоков 98
6.3. Модификации классических методов 100
6.4. Оценка эффективности работы алгоритмов 101
6.5. Обсуждение 104
Глава 7. Построение карты облачности по данным Meteosat 105
7.1. Описание данных спутника Meteosat 106
7.1.1. Характеристика данных спутника Meteosat-7 106
7.1.2. Meteosat второго поколения 108
7.2. Общее описание марковского подхода к сегментации 111
7.3. Последовательная реализация алгоритма марковской сегментации 113
7.4. Анализ последовательной реализации алгоритма ICM 114
7.5. Параллельная реализация алгоритма марковской сегментации 115
7.5.1. Программная реализация алгоритма 117
7.5.2. Синхронизация границ фрагментов изображения 119
7.5.3. Коэффициент ускорения и его оценки 124
7.6. Результаты экспериментов 125
Глава 8. Прогнозирование межпланетных ударных волн в солнечном ветре 128
8.1. Подходы к прогнозированию УВ 129
8.1.1. Данные ACE/EPAM 131
8.1.2. Модуль прогнозирования УВ 131
8.1.3. Алгоритм идентификации УВ 132
8.1.4. Алгоритм классификации УВ 134
8.1.5. Алгоритм прогноза времени прибытия УВ 136
8.2. Результаты экспериментов 136
8.2.1. Результаты идентификации УВ 136
8.2.2. Результаты классификации УВ 137

8.2.3. Результаты прогнозирования времени прибытия УВ 142
8.3. Обсуждение 143

Часть II. ВСПОМОГАТЕЛЬНЫЕ ЗАДАЧИ, РЕШАЕМЫЕ В РАМКАХ СИСТЕМЫ EOGRID 145

Глава 9. Устранение полос импульсного шума на изображениях..... 147
9.1. Общая модель импульсного шума..... 148
9.1.1. Процедура фильтрации импульсного шума общего вида 149
9.2. Существующий подход к восстановлению искаженных изображений 150
9.3. Способ устранения полос импульсного шума..... 151
9.3.1. Результаты экспериментов..... 153
9.4. Обсуждение 156

Глава 10. Параллельная реализация алгоритмов фильтрации космических изображений 158
10.1. Основные принципы параллельных вычислений..... 158
10.1.1. Архитектура параллельных вычислительных систем..... 158
10.1.2. Модели параллельных вычислений..... 159
10.1.3. Интерфейс передачи сообщений MPI 160
10.2. Последовательный алгоритм фильтрации импульсного шума.....161
10.3. Параллельный алгоритм фильтрации импульсного шума..... 163
10.3.1. Разделение изображения по горизонтали 165
10.3.2. Поворот и горизонтальное разделение изображения 166
10.3.3. Вертикальное разделение изображения..... 167
10.3.4. Разбиение изображения по квадратам 168
10.3.5. Результаты экспериментов..... 169
10.4. Обсуждение 172

Глава 11. Структурная и параметрическая идентификация моделей объектов управления на основе интеллектуальных вычислений..... 174
11.1. Постановка задачи 175
11.2. Метод решения..... 175
11.3. ГА оптимизации математической модели 178
11.4. Нечеткий алгоритм эллипсоидального оценивания..... 179
11.5. Обсуждение 180
Список литературы 181

Наукове видання

Куссуль Наталія Миколаївна
Шелестов Андрій Юрійович
Скакун Сергій Васильович
Кравченко Олексій Миколайович

Інтелектуальні обчислення у задачах обробки даних спостереження Землі

Київ Науково-виробниче підприємство
"Видавництво Наукова думка"
НАН України, 2007
(Російською мовою)

Редактор Т.М. Карпенко
Комп'ютерна верстка О.О. Єрмоленко

Підп. до друку 14.12.2007 р. Формат 60x84 1/16.
Папір офс. № 1. Гарт. офс. друк. Ум. друк. арк. 12.
Обл.- вид. арк. 14,75. Тираж 300 прим. Зам. № 4209

НВП «Наукова думка» НАН України
Свідоцтво про внесення суб'єкта видавничої справи до державного реєстру видавців, виготівників і розповсюджувачів видавничої продукції
Серія ДК № 2440 від 15.03.2004 р.
01601 Київ 4, вул. Терещенківська, 3



Куссуль Наталия Николаевна

(род. в 1965 г.), профессор, доктор технических наук, заведующая отделом информационных технологий и систем Института космических исследований НАН и НКА Украины. Профессор кафедры информационной безопасности НТУУ "КПИ". Член рабочей группы WGISS международного комитета по спутниковым наблюдениям CEOS. Область научных интересов – интеллектуальные вычисления, методы обработки спутниковых данных, информационные технологии. Автор свыше 150 научных публикаций, в том числе двух монографий и двух учебных пособий.



Шелестов Андрей Юрьевич

(род. в 1967 г.), кандидат технических наук, старший научный сотрудник, доцент кафедры информационной безопасности НТУУ "КПИ", докторант Института космических исследований НАН и НКА Украины. Область научных интересов – интеллектуальные вычисления, моделирование и разработка распределенных систем, информационные технологии. Автор свыше 100 научных публикаций, в том числе двух учебных пособий.



Скакун Сергей Васильевич

(род. в 1980 г.), кандидат технических наук, научный сотрудник Института космических исследований НАН и НКА Украины, доцент кафедры информационной безопасности НТУУ "КПИ". Лауреат премии НАН Украины для студентов ВУЗов, удостоен стипендии Президента для молодых ученых. Область научных интересов – интеллектуальные методы обработки данных, информационные технологии. Автор свыше 40 научных публикаций.



Кравченко Алексей Николаевич

(род. в 1983 г.), аспирант, младший научный сотрудник Института космических исследований НАН и НКА Украины, ассистент кафедры информационной безопасности НТУУ "КПИ". Лауреат премии НАН Украины для студентов ВУЗов, призер международной олимпиады по математике. Область научных интересов – методы обработки и ассимиляции спутниковых данных, информационные технологии, ГИС. Автор 17 научных публикаций.