

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«ВОРОНЕЖСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ»
(ФГБОУ ВО «ВГУ»)

На правах рукописи



ФЕДУТИНОВ Константин Александрович

ИНТЕЛЛЕКТУАЛИЗАЦИЯ ПРОЦЕССОВ ПРИНЯТИЯ РЕШЕНИЙ В
ОРГАНИЗАЦИОННЫХ СИСТЕМАХ В УСЛОВИЯХ ОПЕРАТИВНОГО
АНАЛИЗА МОНИТОРИНГОВЫХ ДАННЫХ

Специальность 2.3.4. Управление в организационных системах

ДИССЕРТАЦИЯ

на соискание ученой степени кандидата технических наук

Научный руководитель:

доктор технических наук, доцент

Каширина Ирина Леонидовна

Воронеж – 2023

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
ГЛАВА 1. АНАЛИЗ СОВРЕМЕННЫХ ПОДХОДОВ К ПОВЫШЕНИЮ ЭФФЕКТИВНОСТИ УПРАВЛЕНИЯ В ОРГАНИЗАЦИОННЫХ СИСТЕМАХ НА ОСНОВЕ МОНИТОРИНГОВЫХ ДАННЫХ	12
1.1. Формализация процесса управления в организационных системах на основе мониторинговых данных	12
1.2. Существующие подходы к разработке информационных технологий управления на основе мониторинговых данных.....	17
1.3 Требования к алгоритмическому обеспечению для оперативного анализа мониторинговых данных при управлении организационными системами	25
ВЫВОДЫ ПЕРВОЙ ГЛАВЫ.....	29
ГЛАВА 2 НЕЙРОСЕТЕВОЙ ПОДХОД К ПОВЫШЕНИЮ ЭФФЕКТИВНОСТИ УПРАВЛЕНИЯ В ОРГАНИЗАЦИОННЫХ СИСТЕМАХ НА ОСНОВЕ МОНИТОРИНГОВЫХ ДАННЫХ	31
2.1 Структурно-функциональная модель поддержки принятия управленческих решений на основе мониторинговых показателей	31
2.2. Сети семейства ART как основа для разработки алгоритмов поддержки принятия решений на основе мониторинговых данных	34
2.3. Разработка алгоритма кластеризации для оперативного анализа мониторинговых данных на основе нейро-нечеткой сети FuzzyART	46
2.4. Автоматическая настройка гиперпараметров и распараллеливание процессов сети Fuzzy ARTMAP для повышения эффективности обработки мониторинговых данных	52
2.5. Разработка модифицированного алгоритма обучения сети Fuzzy ARTMAP для структуризации данных мониторинга в условиях пересекающихся классов	62
ВЫВОДЫ ВТОРОЙ ГЛАВЫ.....	71

ГЛАВА 3	РАЗРАБОТКА АЛГОРИТМОВ АВТОМАТИЗИРОВАННОГО ФОРМИРОВАНИЯ УПРАВЛЯЮЩИХ РЕШЕНИЙ НА ОСНОВЕ МОНИТОРИНГОВОЙ ИНФОРМАЦИИ.....	73
3.1	Разработка интерпретируемого алгоритма анализа мониторинговой информации на основе нейронной сети архитектуры Cascade ARTMAP.....	73
3.2.	Построение решающих правил с помощью нейронной сети Cascade ARTMAP	80
	ВЫВОДЫ ТРЕТЬЕЙ ГЛАВЫ.....	86
ГЛАВА 4.	РАЗРАБОТКА СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ УПРАВЛЕНИЯ ОХРАНОЙ ПРИРОДЫ НА ОСНОВЕ ДАННЫХ ЭКОЛОГИЧЕСКОГО МОНИТОРИНГА.....	88
4.1	Использование нейросетевых интерпретируемых алгоритмов анализа мониторинговых данных при управлении природоохранной деятельностью ...	88
4.2	Нейросетевой подход к комплексному экогеологическому районированию территорий Воронежской области на основе мониторинговых данных.....	91
4.3	Разработка алгоритма автоматизированного формирования управляющих принятия решений по управлению охраной природы в регионах	97
4.4	Выявление проблемных территорий Воронежской области на основе данных мониторинга загрязнения окружающей среды.....	100
4.5	Результаты практического использования разработанных алгоритмов.....	104
	ВЫВОДЫ ЧЕТВЕРТОЙ ГЛАВЫ.....	107
	ЗАКЛЮЧЕНИЕ	109
	ЛИТЕРАТУРА	111
	Приложение 1. Свидетельство о регистрации программы для ЭВМ	111
	Приложение 2. Акты о внедрении.....	122

ВВЕДЕНИЕ

Актуальность темы исследования.

Совершенствование процессов управления в организационных системах на современном этапе требует внедрения новых информационных технологий, включающих методы поддержки принятия решений на основе оперативно поступающих мониторинговых данных. Управление, основанное на данных – это новый ключевой тренд, представленный в национальной программе «Цифровая экономика Российской Федерации».

В современном мире мониторинг стал неотъемлемой частью различных сфер деятельности. Например, он активно применяется в экологии, позволяя контролировать загрязнение окружающей среды; в медицине, помогая отслеживать состояние здоровья пациентов; в образовании, содействуя оценке эффективности образовательных организаций.

Использование мониторинговых данных для поддержки принятия управленческих решений в организационных системах имеет ряд преимуществ. Во-первых, мониторинг позволяет получать непрерывную информацию о состоянии объектов и процессов, что дает возможность при принятии управленческих решений оперативно реагировать на возникающие проблемы. Во-вторых, мониторинг способствует более эффективному использованию ресурсов, так как на основе информации об актуальных данных можно оптимизировать процессы и уменьшить потери.

Однако, несмотря на все преимущества, мониторинг также имеет свои ограничения. Существующие методы обработки данных мониторинга, как правило, имеют недостаточную эффективность из-за невозможности оперативно учитывать большие объемы поступающей информации (в том числе зашумленной и содержащей пропущенные значения, собранной из разнородных источников). Неправильная обработка и анализ мониторинговых данных зачастую приводит к принятию неверных решений. В целом, использование мониторинговых данных в управлении требует не только их правильного

анализа, но и понимания, как эти данные должны влиять на изменения в организации.

При этом, появившиеся в последние годы технологии машинного обучения, основанные на нейросетевых и нейро-нечетких подходах, позволяют обрабатывать в системах управления оперативно поступающие реальные данные, в том числе содержащие пропущенные, ошибочные или неточные значения, а также автоматически формировать примеры управляющих решений.

Исследование существующих нейросетевых и нейро-нечетких архитектур выявило целесообразность применения для обработки мониторинговых данных в задачах поддержки принятия решений в организационных системах сетей адаптивного резонанса (ART). Сети ART обладают стабильностью, что означает способность сохранять накопленные знания на протяжении всего времени работы системы. Кроме того, они обеспечивают пластичность за счет использования механизма инкрементного обучения. Инкрементное обучение позволяет учитывать актуальную информацию о состоянии объектов и оперативно реагировать на изменения ситуации. Нейро-нечеткие модели Cascade ARTMAP хорошо справляются с обработкой зашумленных данных и позволяют разработать систему автоматизированного построения решающих правил для поддержки принятия управленческих решений на основе данных мониторинга.

Проблемы разработки методов и механизмов управления на основе мониторинговых данных, рассматривались в работах В.Н. Буркова, Д.А. Новикова, Д.В. Гаскарова, А.В. Щепкина, Я. Е. Львовича, В.А. Ирикова, В.Д. Кондратьева, Г.А. Угольницкого и других. Современные нейросетевые и нейро-нечеткие технологии, используемые при разработке информационного обеспечения управляющих систем освещены в работах К. Бройдена, Д. Гольдфарба, Э. Мамдани, Г.С. Поспелова, С. Хайкина, Д. Шанно, Г. Карпентер, С. Гроссберга, Я. Лекуна, П. Флаха, Я. Гудфеллоу.

Исследования этих специалистов заложили научную и методологическую основу данной диссертации. Однако вопросы внедрения методов управления

на основе оперативно поступающих мониторинговых данных с использованием алгоритмов машинного обучения в практику поддержки принятия решений в организационных системах пока в литературе освящены недостаточно.

В связи с этим *актуальность* тематики диссертационного исследования продиктована необходимостью дальнейшего развития средств интеллектуальной поддержки принятия решений в организационных системах в условиях оперативного мониторинга на основе нейронных сетей адаптивного резонанса.

Целью диссертационной работы является разработка средств алгоритмизации процессов принятия управленческих решений в организационных системах на основе инкрементных нейросетевых методов анализа мониторинговых данных.

Для достижения поставленной цели необходимо решить следующие *задачи*:

1. Провести анализ систем управления на основе мониторинговых данных в организационных системах, выявить проблемы и на этой основе сформулировать актуальные направления развития систем поддержки принятия решений.

2. Разработать структурно-функциональную модель поддержки принятия управленческих решений на основе мониторинговых показателей в целях усовершенствования информационного обеспечения процессов управления в организациях.

3. Разработать модифицированный алгоритм кластеризации мониторинговых данных на основе нейросетевой модели Fuzzy ART, для совершенствования кластерного подхода к управлению с возможностью выбора различных управляющих воздействий для различных кластеров значений мониторинговых показателей в условиях их оперативного анализа.

4. Разработать ансамблевую модель классификации мониторинговых данных на основе сетей Fuzzy ARTMAP, предоставляющую возможность анализировать большие объемы информации за счет параллельного процесса их обработки и имеющую высокую точность в условиях присутствия в исходных мониторинговых данных шумов, пропусков и ошибок.

5. Разработать модифицированный нейросетевой алгоритм

автоматизированного построения решающих правил на основе мониторинговых данных, позволяющий в автоматическом режиме формировать управляющие решения в наглядном и понятном для специалистов в предметной области формате.

6. Разработать программный комплекс для интеллектуальной поддержки принятия управленческих решений на основе мониторинговых данных.

Объектом исследования является процесс управления принятием решений на основе мониторинговых данных, а *предметом исследования* – методы интеллектуализации процессов принятия решений в организационных системах на основе оперативно поступающих мониторинговых данных.

Методы исследования. Для решения поставленных в диссертации задач использовались методы теории системного анализа, принятия решений, машинного обучения, обработки больших данных, нечеткой логики, теории искусственных нейронных сетей, современные методы и средства программирования.

Обоснованность. Корректное использование методов исследования является основой для обоснованности научных выводов, выраженных в данной работе.

Достоверность научных результатов подтверждается проведенным в диссертации сравнительным анализом подходов к обработке оперативно поступающих мониторинговых данных и практической апробацией разработанных методов для решения задач анализа экологической информации.

Тематика работы. Диссертация соответствует п.3 «Разработка методов и алгоритмов решения задач управления в организационных системах»; п.4 «Разработка информационного и программного обеспечения систем управления и механизмов принятия решений в организационных системах»; п.9 «Разработка методов и алгоритмов интеллектуальной поддержки принятия управленческих решений в организационных системах».

Научная новизна. В процессе исследования в диссертации были достигнуты следующие основные результаты, отличающиеся научной новизной:

1. Формализованная модель поддержки принятия управляющих решений на основе мониторинговых показателей, отличающаяся использованием инкрементных нейросетевых алгоритмов интеллектуального анализа данных как средства совершенствования процессов управления в организациях.

2. Модифицированный алгоритм кластеризации данных на основе нейронных сетей архитектуры Fuzzy ART, отличающийся возможностью выявлять скрытые структурные связи между наборами оперативно поступающих мониторинговых показателей, ограничивать число создаваемых кластеров и автоматически настраивать гиперпараметры сети в процессе ее инкрементного обучения.

3. Алгоритм классификации данных на основе ансамбля нейронных сетей семейства Fuzzy ARTMAP, отличающийся возможностью анализировать большие объемы мониторинговых данных с учетом присутствия в них шумов, пропусков и ошибок, оперативно адаптируясь к поступающему потоку информации.

4. Модифицированный алгоритм обработки мониторинговых данных на основе нейро-нечеткой сети архитектуры Cascade ARTMAP, отличающийся возможностью в автоматическом режиме генерировать решающие правила, позволяющие формировать варианты управляющих решений.

5. Структура программного комплекса с механизмами встраивания в системы поддержки принятия решений, отличающегося возможностью в непрерывном режиме обрабатывать мониторинговые данные с использованием методов инкрементного обучения, извлекать из этих данных решающие правила и формировать на основе этих правил управляющие решения.

Теоретическая и практическая значимость работы заключается в том, что разработанные методы и алгоритмы нейросетевого анализа данных позволяют повысить эффективность процессов принятия решений и могут применяться для определения эффективной стратегии оперативного реагирования на поступающую мониторинговую информацию. Предложенные модели и методы могут быть использованы в научно-исследовательских и проектных

организациях, занимающихся разработкой специального программного обеспечения систем экологического мониторинга территорий.

Положения, выносимые на защиту.

1. Структурно-функциональная модель поддержки принятия управляющих решений на основе мониторинговых показателей позволяет усовершенствовать информационное обеспечение процессов управления в организациях, и создает логическую основу для разработки систем поддержки принятия управляющих решений.

2. Модифицированный алгоритм кластеризации мониторинговых данных на основе нейросетевой модели Fuzzy ART позволяет выявлять скрытые структурные связи между наборами мониторинговых показателей для обоснованного выбора управляющих воздействий.

3. Предлагаемая ансамблевая модель на основе сетей Fuzzy ARTMAP для классификации мониторинговых данных, позволяет анализировать и обрабатывать большие объемы оперативно поступающей информации в условиях присутствия в исходных данных шумов, пропусков и ошибок.

4. Использование модифицированного алгоритма, основанного на нейро-нечеткой модели Cascade ARTMAP, позволяет перенести предварительный опыт экспертов в структуру кластеров мониторинговых данных и затем автоматически преобразовать результаты кластеризации в компактный и понятный набор управляющих решений.

5. Программный комплекс для поддержки принятия решений в организационных системах в условиях оперативного анализа мониторинговых данных позволяет в непрерывном режиме демонстрировать текущее состояние системы в интерпретируемой и наглядной форме и дает возможность автоматически формировать управляющие решения.

Внедрение результатов работы. Теоретические и практические результаты исследований, реализованные в виде программного комплекса для поддержки принятия решений по управлению в организационных системах на основе данных экологического мониторинга, получили внедрение в Центре

гигиены и эпидемиологии Воронежской области. Основные результаты диссертации также внедрены в учебный процесс Воронежского государственного университета в рамках дисциплин: «Современные нейросетевые технологии», «Управление в социальных и экономических системах».

Апробация работы. Основные результаты диссертационной работы обсуждались на Всероссийской молодёжной научной школе «Оптимизация и моделирование в автоматизированных системах» (Воронежский государственный технический университет», 13 декабря 2017 г.), Международных научно-технических конференциях "Актуальные проблемы прикладной математики, информатики и механики" (Воронежский государственный университет, 18–20 декабря 2017 г., 17–19 декабря 2018 г. и 11–12 ноября 2022 г.); XVII и XIX международных научно-методических конференциях «Информатика: проблемы, методология, технологии» (Воронежский государственный университет, 9-10 февраля 2017 г. и 14-15 февраля 2019 г.); XVI Всероссийской школе-конференции молодых ученых «Управление большими системами» (Тамбовский государственный технический университет, 10 – 13 сентября 2019 г.); V Всероссийской научно-практической конференции с международным участием «Современные проблемы физико-математических наук» (Орловский государственный университет, 26-29 сентября 2019 г.); научных семинарах и заседаниях кафедры математических методов исследования операций Воронежского государственного университета в 2017-2023 гг.

Публикации. По тематике диссертации опубликовано 19 научных работ, в том числе 8 – в изданиях, рекомендуемых ВАК для опубликования основных научных результатов диссертаций, из них 3 работы проиндексированы в SCOPUS, получено 1 свидетельство на программу для ЭВМ.

Личный вклад автора. В работах, опубликованных в соавторстве, личный вклад соискателя состоит: [1, 3] – предложены алгоритмы и модели, применяемые для обработки потоковой мониторинговой информации; [2, 11] -

осуществлен системный анализ мониторинговых данных с использованием сетей ART и создана модель для принятия управляющих решений на основе показателей мониторинга; [4, 12] – разработана модификация нейросетевого классификатора, основанного на сети Fuzzy ARTMAP; [5, 13] – разработан алгоритм для создания решающих правил с помощью нейронной сети Cascade ARTMAP; [6,14] – предложен алгоритм конфигурирования системы мониторинга; [17,19] – разработаны модули системы поддержки принятия решений для экологического мониторинга.

ГЛАВА 1. АНАЛИЗ СОВРЕМЕННЫХ ПОДХОДОВ К ПОВЫШЕНИЮ ЭФФЕКТИВНОСТИ УПРАВЛЕНИЯ В ОРГАНИЗАЦИОННЫХ СИСТЕМАХ НА ОСНОВЕ МОНИТОРИНГОВЫХ ДАННЫХ

1.1. Формализация процесса управления в организационных системах на основе мониторинговых данных

Управленческий мониторинг является неотъемлемой частью эффективного управления организацией, предоставляя информацию для принятия обоснованных решений и обеспечения устойчивого развития. Основной функцией мониторинга является наблюдение за состоянием организации на основе системы показателей. Мониторинг позволяет оценить, насколько реальные данные о деятельности организации соответствуют запланированным значениям. Кроме того, на основе результатов мониторинга осуществляется определение степени отклонения фактических данных от предусмотренных: анализ отклонений помогает выявить проблемы в управлении и причины их возникновения. Мониторинг дает возможность проводить диагностику состояния организации, заблаговременно получать данные о серьезных нарушениях и формировать основу для разработки стратегий решения проблем. Мониторинг помогает определить необходимые изменения в управлении организацией и адаптироваться к изменяющейся среде. На его основе можно осуществлять регулярную корректировку целей и показателей развития организации. Мониторинг позволяет определить, насколько эффективны действующие стратегии и внести необходимые изменения.

В настоящее время существует множество организаций, которые опираются на мониторинговые данные при управлении. В частности, к ним можно отнести следующие.

1. Финансовые организации. Банки, страховые компании и инвестиционные фонды используют оперативно поступающие мониторинговые данные для управления рисками.

2. Транспортные компании. Авиаперевозчики, железные дороги, автомобильные компании используют мониторинговые данные для управления графиками и временными задержками, контроля безопасности и оптимизации маршрутов.

3. Производственные предприятия. Производственные компании используют мониторинговые данные для контроля качества продукции, оценки эффективности оборудования, планирования производственных процессов и оптимизации использования ресурсов.

4. Медицинские учреждения. Больницы и клиники используют мониторинговые данные для отслеживания состояния пациентов, контроля жизненно важных показателей, определения эффективности лечения и прогнозирования заболеваний.

5. Государственные и муниципальные организации. Государственные учреждения применяют мониторинговые данные для отслеживания социально-экономических показателей, контроля выполнения государственных программ, и принятия управленческих решений.

6. Природоохранные организации. Данные учреждения используют показатели экологического мониторинга для контроля качества окружающей среды.

На рис. 1.1. приведены основные сферы применения управленческого мониторинга.



Рис.1.1. Области применения управленческого мониторинга.

На рис. 1.2 приведена формализация процесса управления в

организационных системах на основе мониторинговых данных с контуром обратной связи.

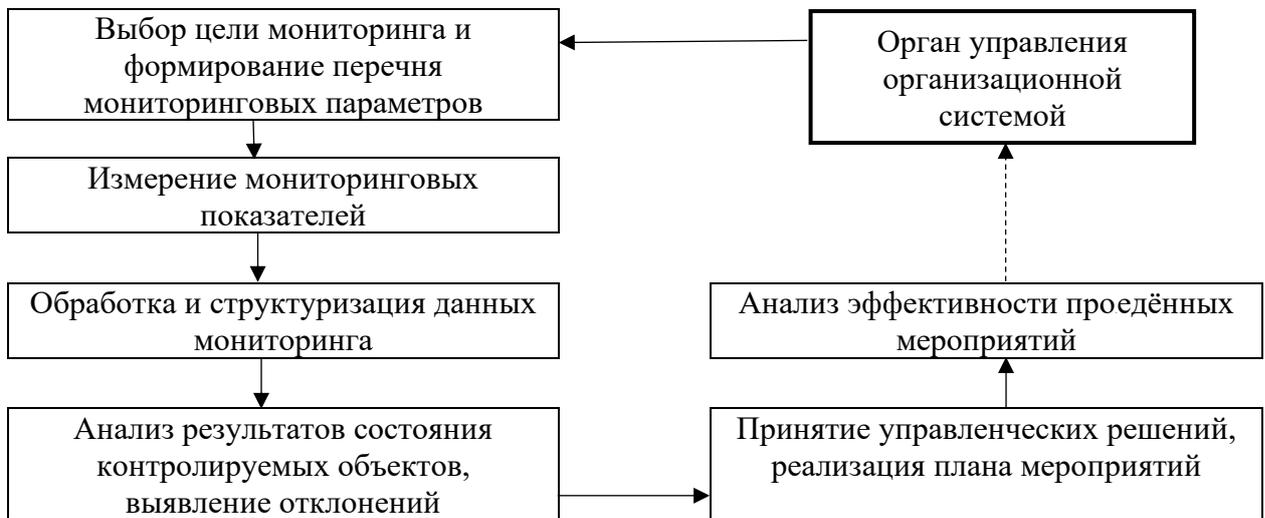


Рис.1.2. Процесс управления организационной системой на основе мониторинговых данных.

Преимущества все более широкого использования мониторинговых данных при управлении в организационных системах можно сформулировать следующим образом.

1. *Объективная оценка производительности.* Мониторинговые данные позволяют получить объективную оценку производительности организационных систем, таких как процессы производства, системы складского хранения, системы учета и др. Это позволяет руководству организации более точно оценить эффективность и определить области, требующие улучшений.

2. *Оптимизация ресурсов.* Мониторинговые данные помогают узнать, какие ресурсы используются эффективно и какие требуют оптимизации. Они могут указывать на избыточное использование ресурсов или, наоборот, на нехватку ресурсов для достижения целей организации. Это позволяет руководству принять соответствующие меры для улучшения использования ресурсов и экономии затрат.

3. *Выявление проблем и их устранение.* Мониторинговые данные помогают выявить проблемные ситуации в организационных системах, такие как

отклонения от стандартов качества, недостаточная производительность процессов, простои, а также критические ситуации, связанные с угрозой дестабилизации нормального состояния объектов. Это позволяет быстро принять меры для устранения проблем и повышения эффективности.

4. *Принятие обоснованных решений.* Мониторинговые данные предоставляют информацию, на основе которой можно принимать обоснованные решения. Они помогают предвидеть результаты различных стратегий и выбрать наилучшую с учетом имеющихся ресурсов и целей организации.

5. *Увеличение прозрачности.* Мониторинговые данные делают работу организации более прозрачной и позволяют контролировать выполнение задач и достижение целей. Это способствует повышению ответственности сотрудников и улучшению коммуникации внутри организации.

6. *Прогнозирование и предотвращение проблем.* Мониторинговые данные позволяют прогнозировать возможные проблемы и принимать меры для их предотвращения до того, как это приведет к серьезным проблемам и убыткам.

В целом, использование мониторинговых данных при управлении организационными системами позволяет повысить эффективность работы, улучшить использование ресурсов, управлять рисками и принимать обоснованные решения на основе фактической информации.

Таким образом, новые технологии сбора данных увеличивают потенциал для получения информации при управлении организационными системами, но также создают ключевые проблемы, связанные с их качественной обработкой. Рассмотрим основные возникающие *проблемы*.

Качество данных. Одной из основных проблем является качество собранных данных. Если данные неполные, неточные или недостаточно актуальные, они могут привести к неправильным выводам и некорректным управленческим решениям.

Отсутствие аналитических навыков. Интерпретация мониторинговых данных требует аналитических навыков и умения видеть связи и тенденции в

данных. Недостаток таких навыков у ЛПР может затруднить правильное использование мониторинговых данных.

Отсутствие четкой стратегии использования. Если нет четко определенной стратегии использования мониторинговых данных, они могут оказаться бесполезными. Необходимо установить цели и задачи, определить, какие показатели и данные используются, и как они будут влиять на управленческие решения.

Недостаточная связь с реальными действиями. Даже если мониторинговые данные доступны и проанализированы, может возникнуть проблема связи между полученными результатами и реальными действиями. Если нет четкого понимания того, как эти данные должны влиять на дальнейшие действия при управлении организацией, результаты мониторинга могут остаться бесполезными.

Слишком много информации. Как правило, мониторинговые данные поступают в непрерывном потоковом режиме. В этом случае проблемой становится избыток информации, когда есть слишком много данных, которые могут затруднить принятие решений, а не упростить его, если в организации отсутствует подсистема оперативного анализа мониторинговых данных.

В целом, использование мониторинговых данных в управлении требует не только доступности качественно измеренных данных, но и их правильного анализа, стратегического планирования и понимания, как эти данные должны влиять на действия и изменения в организации. На рис. 1.3. изображены основные этапы использования мониторинговых данных при управлении в организационных системах.

Таким образом, актуальность разработки интеллектуальных систем поддержки принятия управленческих решений на основе мониторинговых данных, преодолевающих указанные недостатки, не подлежит сомнению.

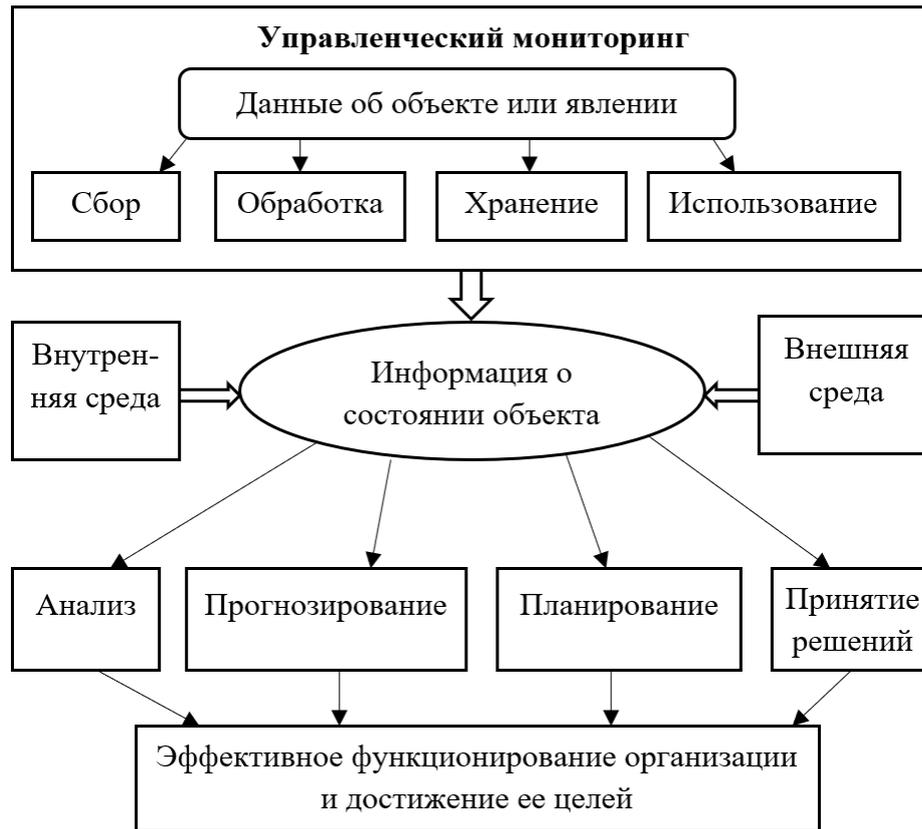


Рис. 1.3. Этапы управления в организационных системах на основе мониторинговых данных.

1.2. Существующие подходы к разработке информационных технологий управления на основе мониторинговых данных

Существует несколько подходов к разработке информационных технологий управления на основе мониторинговых данных. Рассмотрим основные из них.

1. *Анализ данных в реальном времени.* Этот метод предполагает непрерывный мониторинг различных параметров и датчиков для сбора данных в режиме реального времени. Полученные данные анализируются с целью выявления тенденций, закономерностей и аномалий, что позволяет принимать оперативные управленческие решения.

2. *Использование машинного обучения.* Данный подход основан на применении алгоритмов машинного обучения для анализа и обработки данных

мониторинга. Модели машинного обучения могут быть обучены распознавать определенные закономерности или прогнозировать будущие значения параметров на основе исторических данных.

3. *Использование аналитики больших данных.* Этот подход предполагает сбор и анализ больших объемов информации с использованием специализированных инструментов и алгоритмов. Большие данные позволяют выявлять сложные взаимосвязи и тенденции, которые могут быть использованы при принятии управленческих решений.

4. *Использование интернета вещей (IoT).* С развитием технологий IoT возможности мониторинга значительно расширились. IoT-устройства могут собирать и передавать данные от различных объектов и датчиков, что позволяет осуществлять более точный мониторинг и управление.

5. *Автоматизация и оптимизация процессов.* Данный подход предусматривает разработку информационных технологий, позволяющих автоматизировать и оптимизировать различные процессы на основе данных мониторинга. Это может включать автоматическую настройку параметров в режиме реального времени или предложение оптимальных стратегий управления на основе полученных данных.

Окончательный выбор метода разработки информационных технологий управления на основе данных мониторинга зависит от конкретной задачи и требований организации. Однако в настоящее время в качестве основной технологии оперативного анализа мониторинговой информации используются методы машинного обучения. Рассмотрим основные причины этого.

1) Во-первых, алгоритмы машинного обучения могут быстро анализировать и извлекать информацию из потоковых данных, что существенно упрощает работу с большими объемами данных.

2) Во-вторых, методы машинного обучения способны искать и обнаруживать скрытые закономерности и взаимосвязи в мониторинговых данных, которые могут быть незаметными даже для эксперта. Это позволяет выявлять схожие паттерны в наборах мониторинговых показателей и

предсказывать будущие тенденции на основе имеющихся данных, что является ценной информацией при принятии решений.

3) В-третьих, методы машинного обучения позволяют создавать модели, которые учитывают сложные нелинейные взаимодействия и зависимости в данных. Такие модели могут быть более точными и качественными, чем линейные подходы.

4) В-четвертых, методы машинного обучения могут обучаться на новых данных и обновлять параметры моделей, что позволяет им адаптироваться к изменениям и улучшать свою производительность. Это особенно важно для обработки мониторинговых данных, которые могут существенно меняться с течением времени.

5) В-пятых, методы машинного обучения могут использоваться для автоматизированного формирования управленческих воздействий на основе накопленных ранее знаний.

На рис. 1.4 представлена схема процесса поддержки принятия решений на основе методов машинного обучения с использованием мониторинговых данных.

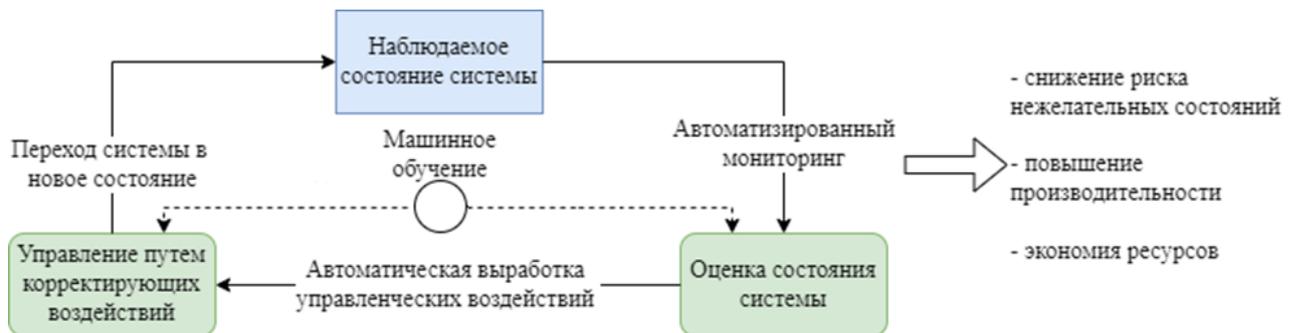


Рис. 1.4. Принятие решений на основе данных мониторинга с использованием методов машинного обучения.

Как правило, методы структуризации мониторинговых данных включают в себя алгоритмы кластеризации и классификации.

Кластеризация относится к фундаментальному способу исследования и обработки показателей, широко используемому для:

- распознавания схожих ситуаций;
- выявления ключевых признаков (характерных особенностей) проблемных ситуаций [12,15];
- интеллектуального анализа, то есть добычи знаний из данных [26,38].

Кластеризация идентифицирует общие структуры, присутствующие в наборе данных на основе некоторой меры сходства.

Алгоритмы классификации используются для систематизации обрабатываемой информации. Классификация может быть бинарной или многоклассовой, давать на выходе пересекающиеся или непересекающиеся классы, выдавать в качестве результата метку класса или вектор вероятностей попадания в каждый из имеющихся классов. В любом случае, алгоритм классификации осуществляет структуризацию исходных данных по некоторому признаку.

Наличие современных возможностей сбора и хранения показателей помогают сформировать огромные объемы информации, для их дальнейшего использования, поиска связей, взаимодействия и закономерностей. Информационные массивы показывают необходимость принятия в комплексные программы мониторинга подпрограмм, которые проводят системный информационный анализ, используя характерные особенности показателей – многомерность и многосвязность. Это способствует появлению трудностей в оценивании и прогнозировании проблемных ситуаций. ЛПР использует оценочные методики, но они не основаны на интеграции, поэтому на практике, часто считаются малоэффективными, и требуют более детальной проработки по всем стратегиям реагирования на присутствующие проблемы и нанесенный ущерб. Особенно стоит уделить внимание некоторым отдельным факторам, влияющим на их комплексное взаимодействие [11]. Например, агрегированию – традиционному способу сбора и анализа сведений по усредненному мониторинговому значению показателей. Проведенные исследования показали, что подходы к имеющимся проблемам несколько нивелируют различия между проблемными ситуациями, о которых могут сигнализировать мониторинговые

показатели [23]. Чтобы повысить точность и оперативность действий по управленческим решениям, нужно использовать в анализе новые интеллектуальные технологии. Такой интеллектуальный подход к анализу позволит работать даже в условиях недостаточного информирования.

Например, в исследованиях [43] и [71] при управлении на основе мониторинговых данных предлагается использовать научно-методический аппарат квалиметрического подхода, основанного на нечетких технологиях. Это поможет построить неаддитивную интегральную оценку, которая будет служить средневзвешенной «квазигеометрической» величиной. Чтобы системный анализ давал ощутимый результат при проблемных ситуациях, строить интегральную оценку на основе мониторинговых данных необходимо путем применения разных подходов, устанавливающих структурные связи мониторинговых показателей системы, так как это позволит избрать наиболее логический и последовательный способ при принятии важных решений.

В целом, методы, базирующиеся на нечеткой логике, хорошо справляются с обработкой качественных и неточных значений показателей, обладая при этом высокой интерпретируемостью. Однако эти методы требуют существенных усилий по настройке их гиперпараметров, с привлечением специалистов предметной области. Если бы такая настройка требовалась разово, то это не было бы важным ограничением, однако даже при небольшом изменении набора анализируемых параметров требуется существенная доработка системы.

Еще одну группу методов, применяемых для обработки мониторинговых показателей, составляют методы эволюционного моделирования. Ключом к использованию генетических алгоритмов (ГА) при обработке мониторинговых данных является постановка проблемы как задачи оптимизации. Многие задачи обработки мониторинговых данных являются задачами оптимизации, например, многочисленные применения обратных моделей (то есть задачи поиска таких значений мониторинговых показателей, которые привели бы к нужному эффекту в управлении). В [16] описывается конкретная проблема оптимизации, в которой ГА оказался полезным — использование данных о концентрации загрязняющих

веществ в сочетании с моделью переноса и рассеивания для обратного расчета управляющих воздействий на основе метеорологической информации. С помощью ГА могут оптимизироваться параметры алгоритмов обработки мониторинговых данных. Но это вспомогательный, а не основной инструментарий.

К основному из направлений в компьютерных технологиях мониторинга на основе искусственного интеллекта, относят использование нейронных сетей, которые существенно облегчают решение задач анализа и прогнозирования проблемных ситуаций. На сегодняшний день именно искусственные нейронные сети являются одним из наиболее передовых и современных методов обработки мониторинговой информации и извлечения знаний из мониторинговых данных. Это не удивительно, ведь нейросетевые алгоритмы обладают высоким потенциалом для решения задач обработки мониторинговых данных, они умеют хорошо обрабатывать зашумленные и неполные данные. Проблема заключается только в том, что, как известно, нейронные сети функционируют в режиме “черного ящика”, то есть не являются понятными и интерпретируемыми методами, что ограничивает возможности их применения во многих предметных областях. В частности, в задачах управления в организационных системах иногда возникают ситуации, требующие экстренных мер вмешательства, когда цена ошибки может оказаться очень высокой. В таких случаях эксперты не могут опираться на результат, предсказанный “черным ящиком”. В подобных предметных областях для того, чтобы применить алгоритм поддержки принятия решений он должен быть не только точным, но и понятным для экспертов (ЛПР), чтобы они имели возможность вносить корректировки в полученное решение. Из-за присущих требований к интерпретируемости экспертам часто приходится использовать на практике узкий круг моделей: деревья классификации, нечеткие базы знаний или метод линейной регрессии, пренебрегая при этом невысокой точностью получаемых результатов.

Предварительные знания проблемной области могут помочь нейронной сети научиться решать проблему недостаточной интерпретируемости. В частности,

ранее существовавшие правила классификации могут быть использованы для инициализации архитектуры нейросетей перед обучением. Использование начальных правил не только повышает эффективность сетевого обучения, но и позволяет получить знания, которые не могут быть получены в результате проведения обучения или которые не могут быть легко усвоены нейронной сетью, и тем самым улучшает прогнозирующую работу системы. Кроме того, неполные или частично корректные знания, сформулированные в виде правил классификации, могут быть усовершенствованы или расширены с помощью алгоритмов нейросетевого обучения. Таким образом, введение и уточнение правил в нейронные сети автоматизирует расширение и восстановление экспертных знаний.

С другой стороны, при наличии высоких требований к точности алгоритмов, эксперты вынуждены прибегать к использованию алгоритмов глубокого обучения [13]. Глубокое обучение использует в своей основе алгоритм обратного распространения ошибки, чтобы научиться предсказывать определенные выходные векторы в ответ на обрабатываемые входные векторы [11]. Однако глубокое обучение может приводить к забыванию информации: на любой стадии обучения часть памяти нейронной сети может разрушиться [15]. Причина этого явления заключается в том, что все входные данные сети обрабатываются алгоритмом обратного распространения ошибки через общий набор настраиваемых весов, при этом внутри алгоритма отсутствует механизм для выборочной буферизации предыдущего обучения, которое является предсказательно полезным. Такое забывание может произойти в любом алгоритме обучения, в котором обновления весовых коэффициентов основаны на использовании градиента ошибки в ответ на текущий входной пакет данных.

Таким образом, одной из основных проблем использования сетей обратного распространения для совершенствования знаний, основанных на правилах, является сохранение накопленных знаний. В процессе настройки весов по алгоритму обратного распространения ошибки исходные правила быстро теряют свои первоначальные значения. На самом деле, в результате такого

обучения могут произойти большие сдвиги в значениях весов скрытых слоев [19]. Еще одним серьезным ограничением метода обратного распространения ошибки является то, что начальная база правил должна быть почти полной, иначе созданная изначально сетевая архитектура может быть недостаточно точной для обработки всей совокупности данных. Поскольку стандартный алгоритм обратного распространения ошибки не способен динамически создавать дополнительные нейроны или соединения между ними во время обучения, сеть, инициализированная небольшим набором правил, может даже иметь меньше шансов в конечном итоге решить задачу классификации. Эта проблема была отмечена и частично решена в [13], где используются виртуальные правила для создания потенциальных связей для обучения. Однако, в целом, трудно заранее определить желаемые решающие правила. В работе [21] используется алгоритм обучения, который позволяет создавать дополнительные нейроны в процессе обучения. Однако, поскольку эта модель представляет собой только правила, непосредственно связывающие входные атрибуты с выходными прогнозами, сеть не является достаточно универсальной для работы на основе правил с использованием промежуточных атрибутов и цепочек правил.

Из всего вышесказанного можно сделать вывод, что эффективный адаптивный алгоритм поддержки принятия решений в организационных системах на основе мониторинговых данных должен быть способен инкрементно обучаться, то есть использовать все вновь поступающие данные для дообучения существующей модели. Как уже отмечалось, особенности задач управления в организациях на основе мониторинговых показателей включают в себя принятие решений с использованием данных, которые содержат шумы и пропущенные значения. Входные данные могут быть частично неверными из-за неисправных датчиков. Однако, во время обучения такие данные не должны “портить” правильно настроенные веса.

Таким образом, особенности задач управления в организационных системах на основе мониторинговых данных диктуют необходимость использования инкрементно обучающихся нейросетевых алгоритмов. При этом получаемые

результаты структуризации данных должны быть интерпретируемыми, то есть они должны индуцировать правила вида ЕСЛИ..ТО, которые объясняют, какие комбинации входных признаков предсказывают именно эти результаты.

1.3 Требования к алгоритмическому обеспечению для оперативного анализа мониторинговых данных при управлении организационными системами

Как отмечено на рис. 1.5, первым этапом обработки поступающих мониторинговых данных часто является кластеризация, с помощью которой осуществляется их предварительная систематизация. Мониторинговая среда с помощью методов машинного обучения позволяет проводить кластерную структуризацию данных по всем совокупным показателям. Полученные результаты определяют выбор самого подходящего альтернативного подхода к структуризации, и дают возможность перейти к этапу математического моделирования.

Одновременно, такие структурирующие методы обработки информации позволяют ориентироваться на конкретные цели.

- Путем формирования кластерной структуры исходных показателей можно понять информацию, содержащуюся в них. Полученная кластеризация позволяет улучшить текущие подходы к принятию управленческих решений и разработке стратегий по реагированию на отклонения в значениях мониторинговых показателей. Каждому кластеру может быть применена специальная методика управления.
- В процессе кластеризации можно определить наличие новых и нетипичных данных путем выявления значений мониторинговых показателей, не относящихся ни к одному из кластеров. Эти данные требуют индивидуального анализа для выявления их особенностей.
- Кластеризация позволяет сократить объем анализируемой информации, позволяя анализировать не каждый набор значений мониторинговых показателей, а лишь их комбинации, типичные для отдельных кластеров.

Стоит отметить особую закономерность, применяемую для совершенствования методики оценивания. Широкое использование систем поддержки принятия решений при управлении на основе мониторинговых данных, позволяет осуществлять сбор информации и ее обработку в том числе, с использованием специальных датчиков, которые располагают на объектах мониторинга. Информация с датчиков нужна для проведения полноценного оценивания и анализа функционирования объектов, наличия техногенных, а также негативных природных явлений. Качество принятых решений по организации дальнейших действий находятся в зависимости от такого ряда факторов:

- своевременного поступления информации обо всех процессах на объектах;
- четкого разграничения результатов обработки по кластерам;
- объективной обработки аналитических данных.

Показатели, полученные с датчиков, считаются разновидностями более объемных показателей, нуждающихся в применении алгоритмов интеллектуального управления и обработки поступающих аналитических потоков.

Таким образом, можно сформулировать характерные *особенности* мониторинговых данных и *требования к алгоритмическому обеспечению* для их обработки.

- 1) Как правило, мониторинговые данные имеют очень большой объем, что требует их автоматической обработки (в том числе, в режиме реального времени) и автоматизированного формирования управляющих решений.
- 2) Данные для обработки могут поступать как в пакетном (при периодическом мониторинге), так и в потоковом режиме (при непрерывном мониторинге). Следовательно, нужны методы поддержки принятия решений, которые могут приспособливаться к изменяющемуся потоку данных и масштабироваться к их объему.
- 3) Для мониторинговых показателей характерны нелинейные взаимодействия, оказывающие влияние на состояние контролируемых

объектов, а так же присуща эмерджентность. Следовательно, для СППР нужны методы, которые учитывают нелинейные связи и при этом формируют структуру, бесконтрольно не разрастающуюся с обработкой большого числа данных.

- 4) Мониторинговые данные, как правило, содержат шумы, пропуски и неточные значения (особенно данные, передаваемые с датчиков). Следовательно, нужны методы, умеющие работать с неполной, нечеткой и зашумленной информацией.
- 5) Мониторинговые данные, применяемые для поддержки управленческих решений, данные требуют интерпретативного анализа. Следовательно, нужны методы, умеющие объяснять получаемые результаты.

Практически всем указанным требованиям к алгоритмам структуризации мониторинговых данных удовлетворяет семейство нейронных сетей АРТ (основанных на теории адаптивного резонанса). Первые сети этого семейства были предложены в работах Карпентера и Гроссберга [4-7] в 1987-1990 гг. Однако эти сети в то время не получили широкого применения, так как на небольших объемах данных уступали в точности традиционным сетям. Кроме того, сети АРТ имеют более сложную архитектуру, чем сети архитектуры многослойный перцептрон или сети Кохонена и Хопфилда (предложенные примерно в те же годы), они труднее в настройке (так как обладают большим числом гиперпараметров). Однако, при решении задач обработки больших данных, особенно поступающих на вход сети в виде непрерывного потока (как, например, мониторинговая информация с датчиков), эти сети обладают неоспоримыми преимуществами перед многими традиционными сетями. Эти преимущества основаны на использовании встроенного механизма инкрементного обучения, ориентированного на решение дилеммы стабильности-пластичности: сети семейства АРТ дообучаются “на ходу”, причем вновь поступающая информация не стирает накопленных знаний.

Таблица 1.1. Достоинства и недостатки существующих методов обработки мониторинговой информации.

Методы	Достоинства	Недостатки
Эмпирико-статистические методы	Хорошо исследованы, давно используются, многие из них интерпретируемы	Не имеют возможности обрабатывать оперативно поступающую информацию (в том числе зашумленную и неполную), опираются только на линейные зависимости
Методы, базирующиеся на нейронных сетях, не относящихся к семейству ART	Существуют мощные алгоритмы обучения, автоматически формирующие признаки на основе входных показателей и позволяющие строить нелинейные зависимости, легко адаптируются к изменениям в структуре входных данных	Не обладают свойством инкрементного обучения, не обладают интерпретируемостью, плохо справляются с шумовыми и качественными данными, требуют настройки гиперпараметров
Эволюционные, генетические алгоритмы	Позволяют в автоматическом режиме настраивать параметры метода	Не обладают свойством интерпретируемости, плохо справляются с шумовыми и качественными данными
Методы, базирующиеся на нечеткой логике	Хорошо обрабатывают данные, содержащие пропуски и ошибочные или неточные значения, а также качественные данные, что важно при обработке мониторинговых данных, которые могут быть частично неверными из-за неисправных датчиков. Обладают свойством интерпретируемости	Сложны в настройке и обучении, требуют существенного вовлечения экспертов в построение методов и полного обновления всей системы при любом изменении набора входных показателей
Нейро-нечеткие сети ANFIS (Adaptive Neuro-Fuzzy Inference System) и TSK (Takagi-Sugeno-Kang)	Обладают способностью адаптации к изменениям в данных. Предоставляют возможность интерпретации результатов. Имеют алгоритмы обучения для настройки параметров моделей, сочетают достоинства нейросетевых и нечеткого подхода.	Обучение требует большого количества данных и вычислительных ресурсов, а также привлечения экспертов для выбора нечетких функций принадлежности. Подвержены к переобучению. Требуют предварительного обучения.
Методы, базирующиеся на нейронных сетях семейства ART	Являются гибридным подходом, сочетающим нейросетевые и нечеткие методы, сохраняют все их достоинства. Обладают свойством стабильности-пластичности: способны к инкрементному запоминанию новой информации без потери старой. Не используют явных методов фаззификации и дефаззификации, что существенно облегчает их настройку.	Не вполне справляются с большими потоками мониторинговых данных, начинают формировать слишком много различных категорий в структуре данных, не справляются с задачей классификации в условиях пересекающихся классов (это требует модификации)

Кроме того, алгоритм обучения сетей ART легко распараллеливается, что делает его пригодным для обработки больших данных. И самое важное-

некоторые подвиды сетей семейства АРТ являются интерпретируемыми моделями- то есть допускают представление результатов обучения в формате правил “если -то”, подобно тому, как это можно сделать в методе деревьев решений.

Сети семейства АРТ могут решать как задачи классификации, так и задачи кластеризации данных, причем даже при решении задачи классификации они в адаптивном режиме самообучения разбивают данные на кластера (кластеры), причем каждому результирующему классу может соответствовать несколько категорий.

Задача актуализации сетей семейства АРТ в алгоритмах структуризации потоковых мониторинговых данных имеет важнейшее значение, так как на сегодняшний день не существует других архитектур, настолько подходящих для решения данной задачи.

В таблице 1.1. приведен сравнительный анализ достоинств и недостатков различных методов обработки мониторинговой информации, включая сети семейства АРТ.

ВЫВОДЫ ПЕРВОЙ ГЛАВЫ

1. Алгоритмы управления в организационных системах на основе оперативной обработки поступающих мониторинговых данных являются современными и актуальными. Они отражают в полной мере соответствуют повсеместно внедряемому в практику тренду управления, основанного на данных. При этом системы мониторинга порождают разнородные, гетерогенные данные. Эти данные необходимо структурировать для последующего анализа и принятия управленческих решений.

2. Математическое и программное обеспечение таких систем изучается и развивается. Однако существующие методы обработки и структуризации данных мониторинга, имеют недостаточную эффективность из-за невозможности оперативно учитывать поступающую информацию (в том числе зашумленную и неполную).

3. Наиболее подходящим аппаратом для обработки мониторинговых данных являются нейронные сети, которые могут учитывать зашумленную и неполную информацию. Однако они имеют ограниченное применение в некоторых областях, так как работают в режиме “черного ящика” и не объясняют полученные результаты. Кроме того, наиболее популярные архитектуры нейронных сетей не способны к инкрементному обучению – то есть к постоянному дообучению сети на новых данных, не стирающего старой памяти, что делает невозможным их применение для обработки непрерывно поступающих данных.

4. Указанных в п.2 недостатков лишены нейронные сети семейства ART (теории адаптивного резонанса) – они допускают инкрементное обучение, решают дилемму стабильности и пластичности при инкрементном обучении и допускают построение интерпретируемых моделей – некоторые сети этого семейства после обучения решению задачи классификации позволяют в автоматическом режиме формировать правила классификации в формате “Если..то..”. Перечисленные характеристики делают сети семейства ART наиболее привлекательным выбором для построения моделей структуризации мониторинговых данных в тех предметных областях, где важна интерпретируемость. Кроме того, сети семейства ART могут масштабироваться в распределенные системы параллельной обработки данных.

5. Однако сети семейства ART также не лишены недостатков: сложности с настройкой многочисленных гиперпараметров, недостаточно высокая точность решения задач классификации; постепенная утеря свойства стабильности при обработке бесконечных потоковых данных, резкий рост числа распознаваемых категорий в условиях частично перекрывающихся классов.

ГЛАВА 2 НЕЙРОСЕТЕВОЙ ПОДХОД К ПОВЫШЕНИЮ ЭФФЕКТИВНОСТИ УПРАВЛЕНИЯ В ОРГАНИЗАЦИОННЫХ СИСТЕМАХ НА ОСНОВЕ МОНИТОРИНГОВЫХ ДАННЫХ

2.1 Структурно-функциональная модель поддержки принятия управленческих решений на основе мониторинговых показателей

Как было отмечено в главе 1, при обработке мониторинговых данных, особенно в условиях их оперативного анализа, на первом этапе проводится их структуризация, то есть кластеризация или классификация. При этом кластеризация позволяет лучше “понять” специфику поступающих данных, выявить в них возможные аномалии, а классификация – отнести текущие измерения показателей к одному из зафиксированных ранее классов состояний контролируемой системы. Следом за этапом структуризации следует этап принятия решений, где на основе оперативно поступившей и уже структурированной информации определяются необходимые в данной ситуации корректирующие воздействия. При этом для автоматизированного формирования управляющих воздействий могут быть использованы нейросетевые модели.

На рис. 2.1. приведена формальная схема процесса поддержки принятия управленческих решений на основе мониторинговых показателей.

Формально такая система может быть описана в виде кортежа:

$$\langle P_t, K_t, R_t, U_t, N_t \rangle, \text{ где}$$

- a) P_t – входной набор значений мониторинговых показателей в момент времени t ;
- b) K_t – набор кластеров, на которые разбивается состояние контролируемых объектов с учетом текущих значений мониторинговых показателей;
- c) R_t – классификация возможных состояний системы в зависимости от получаемых кластеров;

- d) U_t – комплекс возможных управляющих воздействий в зависимости от класса текущего состояния;
- e) N_t – комплекс нейро-нечетких моделей, устанавливающих соответствия:
- $P_t \rightarrow K_t$ (модель кластеризации);
 - $K_t \rightarrow R_t$ (модель классификации);
 - $R_t \rightarrow U_t$ (модель построения решающих правил).

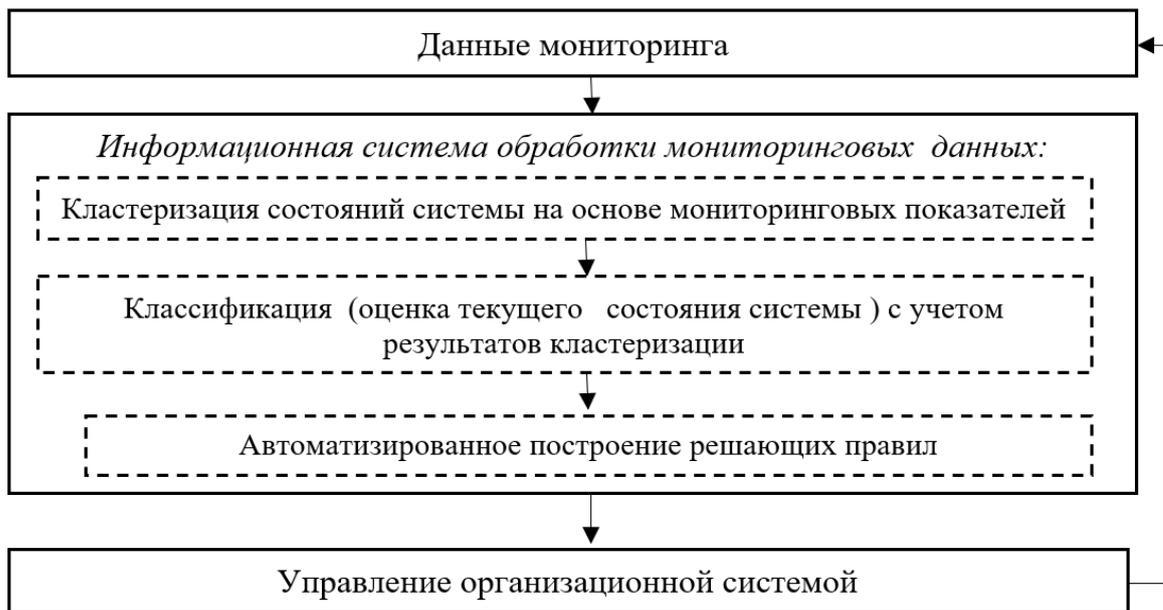


Рис. 2.1. Структурная модель информационного блока в системах управления на основе данных.

В данном исследовании для решения задач, связанных со структуризацией данных на основе кластеризации и классификации, а также для автоматизированного построения решающих правил предлагается использовать нейронные сети ART, которые относятся к семейству Adaptive Resonance Theory.

Представленный вид нейронных сетей создан для устранения проблемы существования взаимноисключающих требований к стабильности и пластичности, которыми должна обладать память нейронной сети [13]. Стабильность считается одним из главных аспектов аналитики. Атрибуция данных на основе стабильности говорит о том, что входной вектор, несколько раз представленный сети, будет постоянно определяться относящимся к одной

и той же кластера. Пластичность указывает на способность системы адаптироваться к новой информации. Оба понятия – стабильность и пластичность находятся в тесном взаимодействии, которые на практике имеют конфликты по алгоритмическим требованиям.

Алгоритмы классической кластеризации в виде EM-алгоритма, алгоритма K-средних и т.д., не способны справиться с дилеммой стабильности-пластичности [11]. Основным подходом, который пытается решить эту проблему, является теория, разработанная Гейл Карпентер и Стивеном Гроссбергом [3-6], детально описывающая семейство нейронных сетей. ART-сети само-организуются и при решении задачи кластеризации формируют устойчивые кластеры в данных, а для решения задачи классификации эти кластеры затем объединяются в классы. Это осуществляется в ответ на входящие образы. Сети ART постоянно занимаются задачей оперативной адаптации, используя принцип стабильности-пластичности, одновременно меняя свою топологию. В процессе своего функционирования сети ART поочередно добавляют или изымают по одному сетевому нейрону. Несмотря на это, изменений архитектуры всей сети не требуется. Замены касаются только конкретного фрагмента, имеющего отношение к данному нейрону. Такой технологичный подход способствует ускорению процесса обучения.

Сети ART способны справиться с большим объемом динамических данных. Они хорошо распознают шаблоны при быстро меняющихся реальных значениях входных показателей. Приложения данной сети работают в разных областях, распознают звуковые сигналы [14], обрабатывают техническую информацию с датчиков [30], выполняют текстовую кластеризацию (группируют содержание документов) [18] и др.

Большинство исследователей отмечают недостатки ART-сетей в обработке, касающийся оперативно поступающей потоковой информации [4,18,31], заметно снижающей эффективность, что характеризуется следующими нюансами:

- недостаточно высокая точность сетей ART при решении задач классификации;

- сложности в настройке многочисленных гиперпараметров;
- постепенная утеря свойства стабильности при обработке оперативно поступающих данных, характерных для задач мониторинга, бесконтрольный рост числа создаваемых кластеров [11].

Данное исследование направлено, в частности, на преодоление этих недостатков.

2.2. Сети семейства ART как основа для разработки алгоритмов поддержки принятия решений на основе мониторинговых данных

Нейронная сеть ART в настоящее время представлена 10 моделями, с принципиальной базой стабильности-пластичности, основными из которых считают:

- ART-1 –эта сеть обрабатывает бинарные входные векторы;
- ART-2 – данная сеть предназначена для кластеризации непрерывных входных векторов (демонстрирует высокое качество работы);
- ART-2a - более быстрая версия ART-2, но уступающая ей по качеству;
- ARTMAP (объединение двух сетей ART-1 или ART-2 в общую совокупность) – решает вопросы с распределением информации по классам, то есть предназначена для задач классификации;
- Fuzzy-ART и Fuzzy- ARTMAP –модифицируют архитектуры сетей ART-2 и ARTMAP за счет использования нечеткой логики в процессе вычислений, что позволяет лучше обрабатывать неполные и зашумленные данные.

Проблема использования нейронной ART-системы заключается в сложности практического использования сети, из-за отсутствия общепринятой авторской формализации. Публикации авторов раскрывают концепции функционирования, но не уделяют внимание обучению структурированных алгоритмов [4,5,6]. Из-за этого исследователи, пользующиеся системой, по-разному описывают структуру ART и обучающие алгоритмы [17,38]. Поэтому можно констатировать факт того, что в научной литературе отсутствует единый стандарт описания семейства ART.

Чтобы решить проблему подхода к описанию системы, нужно сформулировать функциональные принципы сетей ART на общих этапах, а именно следующие.

1. Все виды существующих сетей ART имеют, как минимум, один слой нейронов, которые в процессе работы превращаются в прототипы соответствующих кластеров.

2. Результат кластеризации выражается в определенной реакции “узнавания” нейроном, отвечающим за некоторый кластер, текущего входного вектора.

3. Если поступивший на вход вектор не похож ни на один из сформированных ранее кластеров, то это приводит к созданию нового кластера, соответствующего входному вектору, что, в свою очередь, приводит к добавлению в структуру сети еще одного нейрона, который будет прототипом нового кластера.

4. Прототип кластера способен «обучаться» и изменяться.

5. Прототип кластера не будет модифицироваться в том случае, если входной вектор окажется недостаточно похож на него (что обеспечивает решение проблемы стабильности-пластичности).

6. Входные векторы, не похожие на обрабатываемые ранее данные, могут привести к формированию новых кластеров, но не могут разрушить накопленную память сети и “испортить” ранее сформированные кластеры.

Для рассмотрения общей модели сети семейства ART введем несколько ключевых определений.

Определение 1 (исходная выборка). Пусть $X = \{x^1; x^2; \dots; x^C\}$ - набор данных (векторов признаков или объектов). X – исходная выборка мощности C , каждый элемент которой является вектором в R^n вида $x^k = (x_1; x_2; \dots; x_n)$.

Определение 2 (кластер или кластер). Кластер (кластер) - это подмножество $Z \in X$. Результат кластеризации - это набор кластеров, которые алгоритм кластеризации обнаружил в наборе данных X . “Жесткая” кластеризация - это разделение X на взаимоисключающие кластеры, “мягкая” (или пересекающаяся)

кластеризация позволяет элементу данных принадлежать более чем одному кластеру.

Определение 3 (прототип). Каждый j -й нейрон сети ART ($j=\overline{1, M}$) имеет связанный с ним вектор $w^j = (w_{j1}; w_{j2}; \dots; w_{jn})$, который состоит из весовых коэффициентов w_{ji} на связях нейрона j . Такой вектор w^j называют прототипом кластера, то есть внутренним представлением кластера, описываемой нейроном j .

Функционал сети можно описать при помощи общей модели [62], с помощью которой можно проанализировать результаты обучения различных ART-сетей. Результаты данного анализа можно условно разделить на следующие этапы [44, 45]:

1. Задание начальных параметров сети.

Для того, чтобы сеть ART работала в соответствии с запланированным результатом, необходима предварительная инициализация ее начальных параметров. Любая сеть семейства ART включает, как минимум, один рабочий слой, который содержит прототипы создаваемых категорий (кластеров), обнаруженной сетью во входных данных. Все входы сети связаны с каждым из прототипов посредством матрицы весовых коэффициентов $W=(w_{ij})$, которая на данном этапе обычно заполняется нулями, так как прототипы кластеров пока неизвестны. На начальном этапе должны быть инициализированы все основные параметры сети, к числу которых относятся коэффициент скорости обучения β , параметр, регулирующий сходство векторов из одного кластера ρ , а также предельное число итераций.

2. Подготовка входных векторов (препроцессинг).

В зависимости от характеристик входных данных и типа сети, на этом этапе происходит различная обработка входного вектора. Процедура включает в себя любые его изменения: очищение от шумов, нормирование, удвоение размерности (комплементация) и др., без которых невозможно корректное функционирование сети.

3. Первичный анализ данных (кластеризация).

На этом каждая сеть семейства ART осуществляет первоначальное оценивание вектора входа с помощью некоторой функции выбора, которая предназначена для измерения расстояния между наборами входных признаков на основе какой то из существующих метрик. В сетях Fuzzy-ART и Fuzzy-ARTMAP для измерения этого расстояния используются нечеткие метрики.

4. Детальный анализ соответствия.

На данном этапе активируется конкретный нейрон, входящий в слой прототипов. Его определяют с помощью специальной функции соответствия. Данная функция отвечает за точность и нелинейность проведения анализа в процессе распознавания, касающегося схожести векторов. Тут учитывается важное обстоятельство – если вектор с прототипом пройдут успешную проверку на функциональное соответствие друг другу, то наступит новый этап, в котором веса вектора-прототипа изменятся, то есть пройдут обучение. Если проверка не будет пройдена, то активированный нейрон временно будет деактивирован. Таким образом, с помощью функции выбора определяется ближайший к текущему входному вектору кластер, а с помощью функции соответствия решается вопрос – достаточно ли похож входной вектор на прототип данного кластера?

5. Этап обучения.

На этапе обучения осуществляется изменение весов нейрона, который является прототипом выбранного на прошлом этапе кластера. Если ни один из существующих прототипов не пройдет детальную функциональную проверку на соответствие, то будет создан новый кластер на основе вектора, который сети не удалось распознать. В этом случае получает активацию новый нейрон, характеристики которого определяются координатами нераспознанного вектора. А размер сети при этом увеличивается. То есть сеть ART имеет растущую архитектуру.

6. Постпроцессинг (постобработка результатов).

После того, как процесс обучения был окончен, сетью предусмотрена последующая обработка выходных значений сети. К примеру, если заранее

задано ограничение по количественному составу кластеров, то они объединяются или разъединяются между собой, соблюдая необходимые условия.

Описанные этапы можно представить в виде следующей блок-схемы (рис 2.2.)



Рис. 2.2. Схема функционирования сети семейства ART.

На основании сказанного можно сделать вывод о том, что для решения определенной задачи, касающейся структуризации некоторых входных данных, нужно обязательно определиться с вариантом сетевой модели ART, зависящей от требуемых выходных структурных элементов, и осуществить наполнение этапов, согласно данному алгоритму. Для этого нужно обязательно определиться с

перечнем параметров управления сети, осуществить фиксацию функции выбора, а также функций соответствия и обучения, а также задать два основных алгоритма: пре- и постпроцессинга.

Стоит отметить, что архитектура сети семейства АРТ может включать один или несколько базовых модулей, состоящих их трех блоков: блока обучения, блока сравнения и блока распознавания. На рис 2.3. представлена схема базового модуля сетей семейства АРТ.

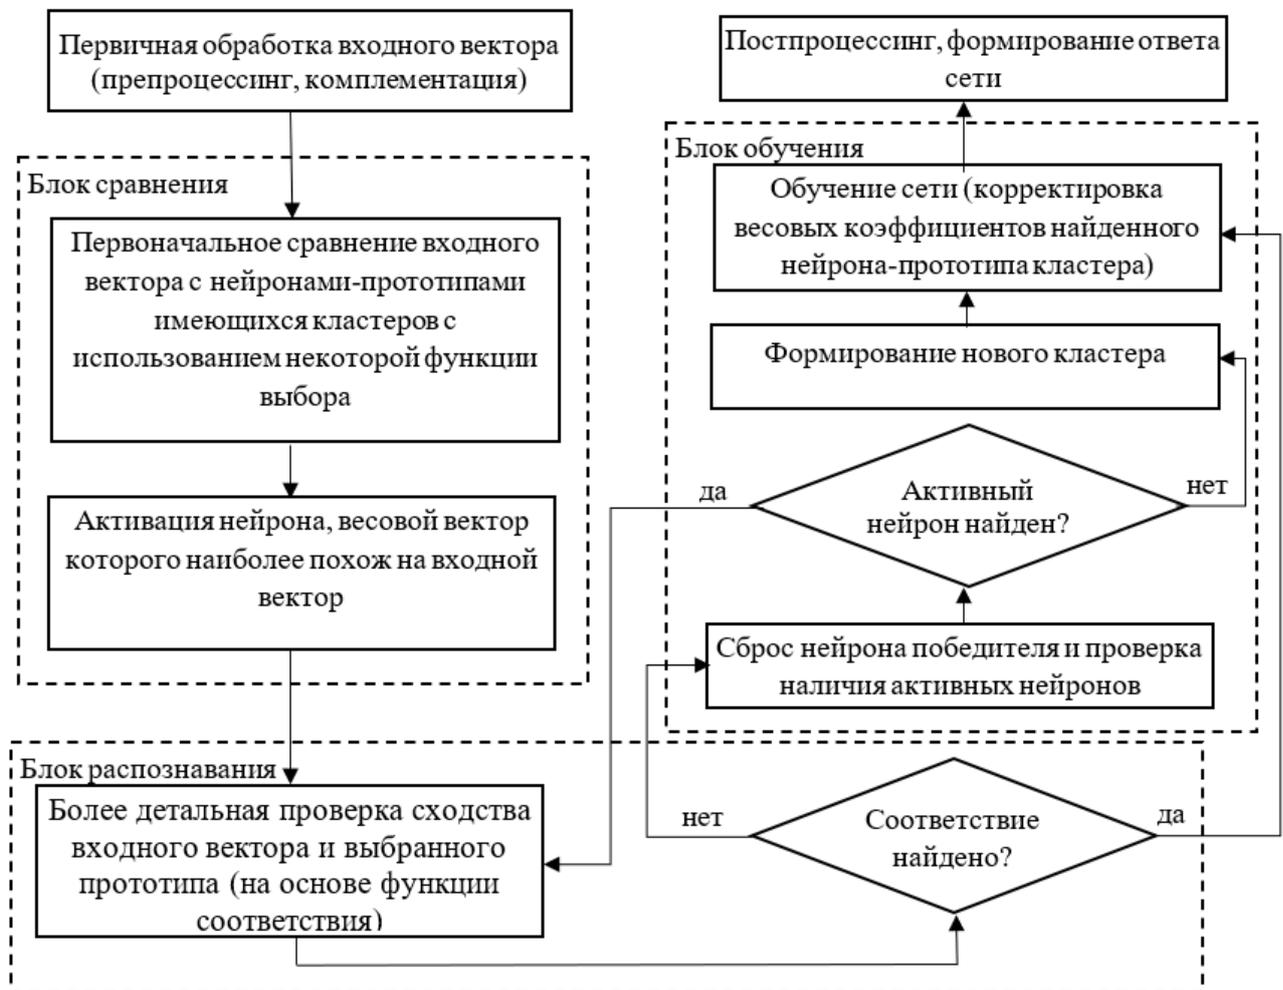


Рис. 2.3. Базовый модуль сетей семейства АРТ.

Сети семейства АРТ могут обучаться как с учителем, так и без. В любом случае, даже если сеть АРТ обучается с учителем, она имеет в своей основе модуль самоорганизации, который разбивает все входные векторы на кластеры, состоящие из схожих образов. Один класс может соответствовать нескольким

кластерам. Обратное в базовом подходе не верно, то есть каждому кластеру может соответствовать только один из выходных классов, что не всегда удобно, так как при обработке реальных данных классы могут пересекаться. Например, один и тот же набор входных мониторинговых показателей может соответствовать сразу нескольким проблемным ситуациям, которые требуют принятия управляющих решений, что, очевидно, подлежит модификации.

Приведенные выше этапы являются общими для всех сетей семейства ART, но их реализация отличается у различных сетей семейства. Рассмотрим наполнение указанных этапов для двух базовых сетей данного семейства, решающих задачу кластеризации: сети ART-2а [13], использующей обычные арифметические операции над вещественными входными данными и ее модификации сети Fuzzy ART [14], использующей при вычислениях операции нечеткой логики (но не требующей фаззификации входов). Использование нечетких операций позволяет сети меньше реагировать на неточные измерения и шумы во входных данных, и именно нейро-нечёткие вариации ART моделей данном исследовании предлагается использовать в качестве основы для разработки систем поддержки принятия решений в организационных системах в условиях оперативного анализа мониторинговых данных. Однако для понимания особенностей функционирования Fuzzy ART необходимо сначала описать логику сети ART-2а, модификацией которой является Fuzzy ART.

В перечень параметров сети ART-2а входит, в частности, скорость обучения, представляющая собой вещественное число $\beta \in [0,1]$, параметр нормализации θ , который берется из отрезка $[0,0.01]$ и граничный критерий сходства ρ , также принадлежащий отрезку $[0,1]$ [13,60]. Сеть ART-2а перед распознаванием требует обязательной нормализации входных векторов до единичной длины:

$$x_{ij}^{нов} = \frac{x_{ij}^{ст}}{\sum_{j=1}^J (x_{ij}^{ст})^2},$$

где через J обозначена размерность очередного подаваемого на вход вектора X^i ,

а через x_{ij} – его j -я компонента.

Затем координаты нормализованных векторов, чье значение стало меньше параметра нормализации θ , обнуляются, после чего процедура нормализации повторяется еще раз. Данная процедура предназначена для подавления небольших случайных шумов в исходных данных, которые могут негативно повлиять на результирующее качество кластеризации.

В сети ART-2а в качестве метрики сходства используется косинусное расстояние между векторами, которое вычисляется как скалярное произведение соответствующих векторов единичной длины.

$$T_k = M_k = (X^i, w^k) = \sum_{j=1}^J x_{ij} w_j^k, \quad (2.1)$$

Здесь через X^i опять обозначен i -й входной вектор, через T_k обозначена функция выбора для k -го кластера, M_k – это величина установленной функции соответствия, вектор w^k – это имеющийся на текущий момент прототип k -го кластера.

Алгоритм работы сети ART-2а заключается в реализации следующих шагов. На первом шаге, применяя косинусную метрику, сеть выбирает кластер с номером s , прототип которого обладает максимальной схожестью с исходным вектором X^i , т.е. $s = \arg \max_k T_k$. На втором шаге для выбранного кластера проверяется условие соответствия $M_s > \rho$, где ρ – значение критерия сходства, задающего верхнюю границу для однородности векторов в кластере. В том случае, если выбранный прототип кластера удовлетворяет условию сходства, исходный вектор определяется в данный кластер. В этом случае необходимо осуществить пересчет координат прототипа кластера так, чтобы его схожесть с входным вектором увеличилась (формула 2.2)

$$w^{k+1} = \frac{(1 - \beta)w^k + \beta \cdot X^i}{\|(1 - \beta)w^k + \beta \cdot X^i\|}, \quad (2.2)$$

где β – скорость обучения.

Измененный по формуле (2.2) вектор весов проходит дальнейшую нормировку. При этом отметим, что на выбор значения параметра скорости β

оказывает влияние требование выявления долговременных закономерностей или отслеживания тенденций изменения данных. В первом случае устанавливаются малые значения параметра, а во втором более адекватными будут наоборот, большие.

Что касается параметра ρ (уровень сходства), то его выбор осуществить намного труднее. Причем как с теоретической, так и с практической точки зрения. Поскольку у исследователя не всегда есть представление о структуре данных, то задача определения наибольшего угла, при котором векторы можно положить схожими, становится трудоемкой. Вышесказанное является причиной серьезного недостатка сети ART-2a. А именно, высокие значения ρ приводят к увеличению числа кластеров, которое трудно контролировать. А малые значения – к образованию одного крупного кластера. Решение этой проблемы может быть получено применением следующей стратегии: уменьшать параметр скорости обучения с отслеживанием числа кластеров, при стабилизации этого числа процесс прекратить.

На несколько другом принципе обработки непрерывных входных данных основана сеть Fuzzy ART [14,17]. Данная сеть использует операции нечеткой логики, но при этом не требует явной фаззификации данных. Для обработки значений мониторинговых показателей с помощью данной сети необходима не единичная нормировка, а масштабирование масштабирование всех компонент входных и выходных векторов в пределах отрезка [0,1]:

$$x_{ij}^{нов} = \frac{x_{ij}^{ст} - x_i^{min}}{x_i^{max} - x_i^{min}},$$

где через x_i^{min} обозначена минимальная координата входного вектора X^i , а через x_i^{max} – его максимальная координата.

Схематически структура данной сети представлена на рис. 2.4.

Сеть Fuzzy ART включает в себя слой F0, представляющий текущий входной вектор; слой F1, который обрабатывает как вход от слоя F0, так и

обратную связь от слоя F2, представляющего распознанную категорию (кластер).

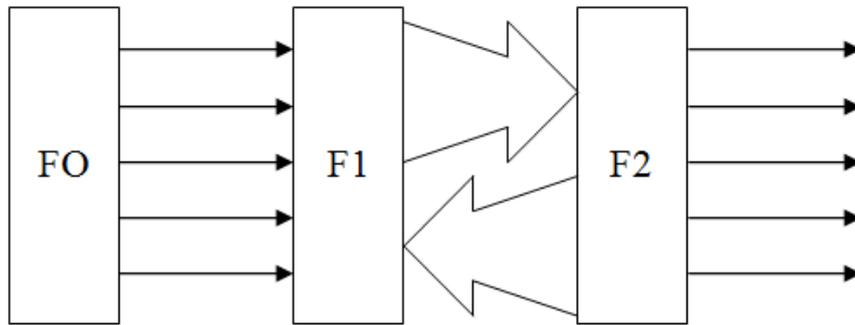


Рис. 2.4 Архитектура сети Fuzzy ART

Выходом слоя F0 является вектор $I = (a_1, \dots, a_M)$, каждая компонента которого принадлежит отрезку $[0,1]$. Слой F1 на выходе генерирует вектор $X = (x_1, \dots, x_M)$, а слой F2 вектор $Y = (y_1, \dots, y_N)$. Матрица весов W связывает между собой слои F1 и F2, причем каждому нейрону j ($j = 1, \dots, N$) слоя F2 соответствует вектор весов $W^j = (w_{j1}, \dots, w_{jM})$.

Первоначально полагается $w_{j1} = \dots = w_{jM} = 1$.

Сеть Fuzzy ART имеет ряд гиперпараметров α , β , ρ , где β и ρ имеют тот же смысл, что и в сети ART-2а, а α – маленькое число (примерно 10^{-6}), отвечающее за невырождение прототипов кластеров. В роли функции выбора может применяться любая из существующих реализаций "нечеткого И", например:

$$T_k = \frac{|X^i \wedge w^k|}{\alpha + |w^k|}, \quad (2.3)$$

где \wedge - нечеткий оператор умножения, который здесь и далее определяется как $(p \wedge q)_j = \min(p_j, q_j)$, $j = \overline{1, J}$, а знаком модуля обозначена нечеткая норма: $|p| = \sum_i p_i$.

Сеть Fuzzy ART, если условие сходства не удовлетворено, применяет механизм временной деактивации кластера. Заметим, что такой механизм не предусмотрен в сети ART-2а. Итак, тогда на этапе определения кластера номер кластера будет определяться по максимальному значению функции (2.3) на всех

активных кластерах, то есть $s = \arg \max_k T_k$, $k \in Q$, где Q – множество номеров активных на данном этапе кластеров. Далее происходит проверка s -го прототипа с входным вектором. Данная проверка осуществляется с использованием следующей функции соответствия:

$$M_s = \frac{|X^i \wedge w^s|}{|X^i|}, \quad (2.4)$$

Входной вектор X принадлежит кластеру s только при условии: $M_s \geq \rho$, где ρ – критерий сходства. Если же данное неравенство не выполняется, найденный кластер s становится временно неактивным, и для выбора нового кластера-претендента снова применяется функция выбора (2.3). Если в процессе работы более не остается кластеров для выбора (то есть все кластеры стали деактивированными), то по входному вектору создается новый кластер. Веса кластера принимаются равными весам входного вектора: $w = X^i$. После процедуры выбора кластера применяется функция обучения, и веса выбранного кластера (его прототипа) пересчитываются по формуле

$$w^{t+1} = (1 - \beta)w^t + \beta(X^i \wedge w^t) \quad (2.5)$$

В сети Fuzzy ART весовые векторы не нормализуются к единичной длине, поэтому использование данной функции обучения порождает проблему вырожденности. Используемый оператор \wedge , вычисляемый как покомпонатный минимум, способствует постепенному снижению координат весовых векторов. Их уменьшение постепенно приведет к вырождению прототипов кластеров, когда они позабудут изученную ранее информацию. С целью преодаления указанной проблемы на этапе предобработки входных векторов к ним применяется комплементарное кодирование, благодаря которому размерность входного вектора удваивается за счет дополнения его компонентами: $x_{i(j+j)} = 1 - x_{ij}$, что препятствует возможности всем компонентам весового вектора w вырождаться до нулевых значений.

Основные этапы общей схемы решения задач кластеризации данных с помощью двух рассмотренных сетей семейства ART имеет вид, описанный

ниже.

Основные этапы общей схемы решения задач кластеризации данных с помощью двух рассмотренных сетей семейства ART.

Этап 1. Выбор алгоритма предобработки. На этом этапе реализуется препроцессинг входных данных с использованием ряда методов.

1.1. Ранжирование входных переменных.

Если заранее известна информация о важности входных переменных, их можно проранжировать, после чего провести процедуру масштабирования входов соответственно выставленным рангам (например, наиболее важная переменная масштабируется в отрезок $[0;1]$, следующая по важности – в меньший отрезок $[0; 0.9]$ и т. д.) Это существенно изменит результат кластеризации, так как более значимые переменные будут вносить больший вклад.

1.2. Нормализация. В сетях ART-2а и Fuzzy ART необходимо использовать нормированные входными векторами. Для сетей Fuzzy ART перед нормализацией проводится комплементация (см далее 1.4).

1.3. Очистка от шумов. Устранение шумов во входных данных может быть осуществлено путем ввода параметров валидации, которые устанавливают верхние и нижние границы возможных значений для каждого из входных параметров. Если значение выходит за эти границы, то оно будет отсечено или отброшено в соответствии с данными границами, чтобы удалить ошибочные значения.

1.4. Комплементация. Данный метод увеличивает размерность входного вектора путем удвоения его размера. В результате вместо входного вектора \bar{a} рассматривается вектор $I^a = [\bar{a} \ \bar{a}^c] = [a_1, \dots, a_n, a_1^c, \dots, a_n^c]$, где $a_i^c = 1 - a_i$.

Этап 2. Задание функции выбора, функции соответствия и функции обучения.

После проведения предобработки необходимо задать конкретный вид функций выбора, соответствия и обучения. Обобщенная структура сети

семейства ART, описанная ранее, дает возможность изменять эти функции на любом этапе функционирования сети, поскольку архитектура и общая логика работы сети не зависит от их конкретного вида. Однако результаты кластеризации и характеристики получаемых кластеров сильно зависят от выбранных функций, поэтому они должны соответствовать решаемой задаче.

Этап 3. Выбор алгоритма постпроцессинга.

Данный этап позволяет после завершения обучения компенсировать недостатки использованной модели семейства ART. Например, один из основных недостатков сетей этого семейства заключается в сложности вычислений при выборе параметра сходства ρ или его аналога, предлагаемого в данном исследовании - интегральной оценки схожести входных векторов. Неправильный выбор параметра ρ может привести к объединению всех имеющихся данных в один большой кластер или, наоборот, неконтрольному росту количества кластеров.

Для формирования алгоритма кластеризации нужно выбрать схемы препроцессинга (предобработки) и постпроцессинга (постобработки).

Проблема выбора метода постпроцессинга является более сложной, так как если сеть ART будет использоваться для кластеризации потоковых непрерывно поступающих данных, то количество кластеров, генерируемых сетью, со временем будет постоянно расти, что затрудняет анализ поступающих данных и принятие на их основе управленческих решений.

2.3. Разработка алгоритма кластеризации для оперативного анализа мониторинговых данных на основе нейро-нечеткой сети FuzzyART

Для решения задачи управления в организационных системах на основе мониторинговых данных требуется усовершенствование информационного обеспечения в части возможности обработки большого объема непрерывно поступающих данных. Первый этап обработки – это структуризация на основе их

кластерного анализа.

Алгоритмы кластерной структуризации потоковых данных постоянно обрабатывают поступающие входные векторы, в том числе в режиме онлайн. Однако не все алгоритмы кластеризации могут использоваться для решения данной задачи. Как уже ранее было отмечено, чтобы результаты были достоверными, такие алгоритмы должны соответствовать определенным условиям:

- показывать готовый результат в реальном времени;
- моментально адаптироваться к меняющимся показателям;
- масштабироваться для произвольного числа объектов;
- создавать незначительно разрастающуюся структуру по мере обработки большего количества объектов;
- определять присутствие выбросов в данных.

На основе данного исследования проводился вычислительный эксперимент для сети FuzzyART, который касался обработки постоянно поступающего потока входных данных. Поток моделировался с помощью библиотеки `scikit-learn`, предназначенной для реализации алгоритмов машинного обучения. Эта библиотека содержит генераторы случайных выборок, данные которых можно использовать для искусственного создания информации контролируемого размера и сложности [19]. Используемая при этом процедура `make_blobs` помогает в создании многоклассовых наборов данных, каждому из которых соответствует один или более кластеров. На основе библиотечной процедуры для проведения анализа возможности использования сетей семейства ART для обработки потоковых данных был сгенерирован поток 10-мерных данных, состоящих из трех равных по размеру кластеров. Один из них был легко отделяемым, а два других – близко расположенными. Иллюстрация такого расположения (для двумерных входных векторов) приведена на рис. 2.6.

При проведении вычислительного эксперимента были получены конкретные результаты (таблица 2.1). Ошибками в работе рассматриваемых сетей считают несовпадение полученного результата и модельной

классификации первоначальных данных (процент неправильной кластеризации).

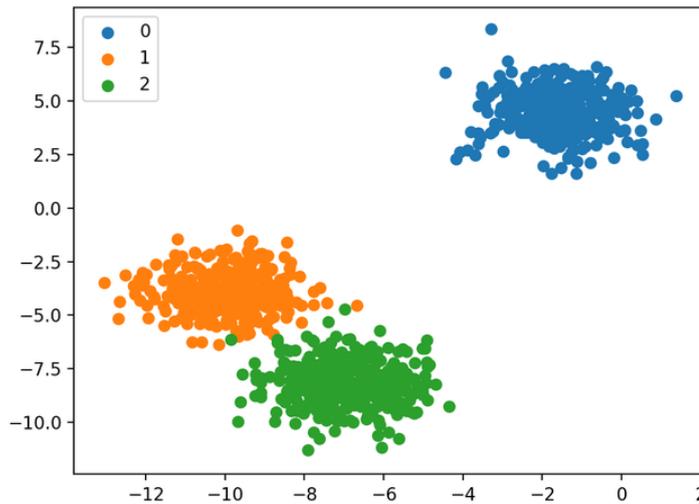


Рис. 2.6. Иллюстрация взаимного расположения сгенерированных кластеров

Таблица 2.1. Зависимость работы сети Fuzzy ART от параметров.

0 <math>\rho < 0,68</math>					
β	0,1	0,3	0,5	0,7	0,9
Ошибки, (%)	64%	60%	65%	66%	63%
Кол-во кластеров	1	1	1	1	1
0,68 $\leq \rho < 0,85$					
β	0,1	0,3	0,5	0,7	0,9
Ошибки, (%)	33%	33%	6,6%	12%	12%
Кол-во кластеров	2	2	3	4	4
0,85 $\leq \rho \leq 0,9$					
β	0,1	0,3	0,5	0,7	0,9
Ошибки, (%)	12%	12%	9,2%	6,6%	6,6%
Кол-во кластеров	4	4	4	3	3

По результатам данного эксперимента сделаны следующие выводы, характеризующие возможность применения сети Fuzzy ART для потоковой кластеризации мониторинговых данных.

1. До получения значения $\rho=0,68$ сеть соединила входящие векторы в общий кластер.

2. Значение $0,68 < \rho < 0,85$ указывает на то, что сеть занимается разделением множества на 2 кластера, один из которых легко отделяемый, а второй – состоит из оставшихся элементов.

3. Разделение на 3 кластера происходит при условии значения $0,85 \leq \rho \leq 0,9$.

4. Когда происходит дальнейшее увеличение $\rho > 0,9$, сеть начинает создавать все большее количество кластеров, то есть исходная выборка разделяется на множество небольших групп.

Стоит заметить, что Fuzzy ART имеет ряд положительных функциональных характеристик, к которым относят стабильность, быструю сходимость и понятную зависимость от выбранной скорости обучения.

Однако по ходу проводившегося эксперимента выяснилось, что функции, которые были использованы Fuzzy ART в качестве выбора, обучения и соответствия, способны привести к возникновению высокой чувствительности по отношению к порядку предоставляемых показателей. Отмечено, что если данные имеют подаются на вход в случайном порядке (перемешаны) в начале функционирования, то распределение по кластерам будет проходить намного качественнее.

Для решения проблемы неконтролируемого роста числа кластеров в данном исследовании предлагается использовать метод постпроцессинга (постобработки), позволяющий ограничивать количество кластеров заданным значением. Но каким числом стоит ограничить количество создаваемых кластеров заранее может быть неизвестно. Поэтому в данном исследовании для пересчета параметра сходства ρ (а именно он отвечает за число кластеров) предлагается специальный метод. Согласно этому методу предлагается на начальном этапе алгоритма задавать максимальное предельно допустимое число кластеров K , а параметр сходства ρ задавать очень близким к 1.

Если в процессе выполнения очередного этапа вектор не соответствует ни одному из существующих кластеров и достигнуто максимально возможное количество кластеров K , то создавать новый кластер нельзя, поэтому в данной ситуации предлагается выполнить шаги алгоритма, представленного на рис. 2.5. Таким образом, новый кластер будет создан, но общее число кластеров не изменится.

Предлагаемый подход к ограничению количества кластеров обладает

достаточной универсальностью и может быть легко применен для внесения модификаций в обучение произвольной сети семейства ART.

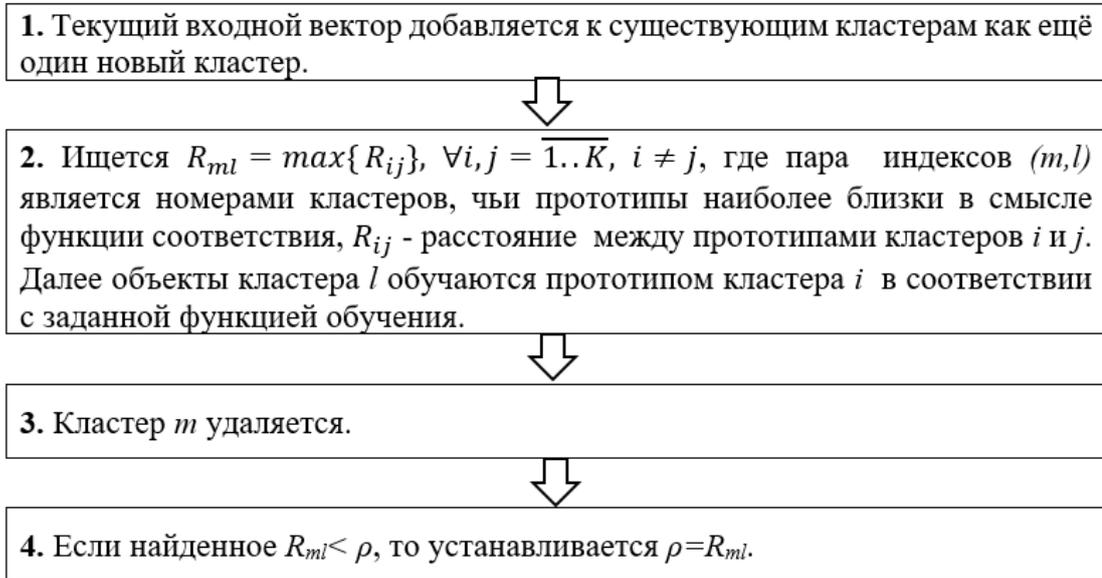


Рис. 2.5. Предлагаемый алгоритм постпроцессинга, ограничивающий количество кластеров сети

Приведем теперь общие рекомендации, получившиеся в виде практических результатов по ходу вычислительного эксперимента, касающихся сети FuzzyART, занимавшейся обработкой постоянного потока данных.

1. В каждом конкретном случае выбирать сеть нужно по типу показателей и рабочего режима, в котором происходит ее функционирование. Сеть Fuzzy ART очень чувствительна к порядку организации входных данных, на основании которого она способна генерировать и получать разные итоги процесса кластеризации. Поэтому на начальном этапе рекомендуется выполнение нескольких итераций в пакетном режиме подачи данных (не онлайн).

2. Выбирать или задавать параметры обучающей скорости β нужно исходя из типа задачи, которая выполняется в процессе. Здесь заданная небольшая начальная скорость обучения позволяет определять общие закономерности полученных результатов, а высокая – оперативно ловить и подстраиваться под существующие тенденции.

3. Применять стратегию настройки параметра сходства ρ . А именно, в начале работы алгоритма задать максимальное число кластеров K , и задать $\rho=1$.

Если в процессе работы алгоритма необходимо создать $(K+1)$ -й кластер (т.е. алгоритм не может классифицировать входной вектор в существующие кластеры), необходимо уменьшить параметр ρ и повторить процедуру снова. Параметр будет уменьшаться до тех пор, пока входной вектор не будет отнесен к одному из уже существующих кластеров.

При этом если в процессе уменьшения ρ прототипы каких либо двух из существующих кластеров становятся похожи в смысле текущего значения критерия сходства, то должно проводиться объединение этих двух кластеров в один общий.

4. Когда сеть при низких показателях β функционирует медленно, и в ней отмечается длительная миграция кластеров, Fuzzy-ART используют только для данных, поступающих объемным, но дискретным потоком (например, несколько раз в сутки считываются значения показателей датчиков). В таком случае данные могут обрабатываться в пакетном режиме.

5. В варианте, когда в потоке показателей будут происходить шумовые всплески, с появлением векторов входа нетипичного вида, запоминающихся новыми кластерами, может произойти превышение лимита количества кластеров. Поэтому, при анализе результатов эксперт будет либо изучать появившиеся малые кластеры (если одной из целей анализа является поиск аномалий в полученных данных), либо удалять их (чтобы не создавали ненужный шум), либо уменьшать требования к количеству кластеров. Последний подход, при условии хаотичного порядка поступления входных данных, будет приводить к поглощению маленьких кластеров основными кластерами.

В качестве метрики качества в задачах кластеризации чаще всего используется среднее внутрикластерное расстояние, которое необходимо минимизировать, или среднее межкластерное расстояние, которое максимизируется. Метрика коэффициент силуэта [12] в некотором смысле объединяет оба эти подхода, поэтому именно ее предлагается использовать для оценки качества кластеризации.

Коэффициент силуэта используется для оценки различия между объектами внутри кластеров и объектами в других кластерах. Значение коэффициента силуэта может находиться в диапазоне от -1 до 1. Чем больше значение коэффициента силуэта, тем лучше качество проведенной кластеризации. Отрицательные значения указывают на плохую или неправильную кластеризацию, значения около нуля говорят о перекрытии и наложении кластеров, а значения, близкие к 1, указывают на плотно сгруппированные кластеры. В дальнейшем качество разработанных алгоритмов оценивается с использованием именно этой метрики.

2.4. Автоматическая настройка гиперпараметров и распараллеливание процессов сети Fuzzy ARTMAP для повышения эффективности обработки мониторинговых данных

В данном разделе рассматривается сеть Fuzzy ARTMAP, которая использует основные принципы и архитектуру сети Fuzzy ART, но с одной важной разницей: Fuzzy ARTMAP обучается с учителем и применяется для решения задач классификации, а не кластеризации данных. Включающая два блока Fuzzy ART – ART_a и ART_b, сеть Fuzzy ARTMAP объединяет эти модули с применением механизма ассоциативной памяти, что изображено на рисунке 2.6. Одной из особенностей Fuzzy ARTMAP является наличие дополнительного модуля F^{ab} , который позволяет сети функционировать автономно в реальном времени. Модуль F^{ab} в Fuzzy ARTMAP реализует встроенный механизм самоорганизации, предназначенный для максимального обобщения входных и выходных данных и уменьшения ошибки сети. Размер слоя F_1^a соответствует числу выходов сети, в то время как количество нейронов в слое F_2^a соответствует сформированным к данному моменту кластерам, число которых растет в процессе инкрементного обучения.

То есть сеть Fuzzy ARTMAP также, как и Fuzzy ART, относится к классу

растущих сетей. Слои нейронов F_1^a и F_2^a соединены между собой весовой матрицей $W^a = (w_{ij}^a)$, при этом каждый весовой вектор w_j^a , $j = 1..l$, представляет собой прототип соответствующего кластера с номером j .

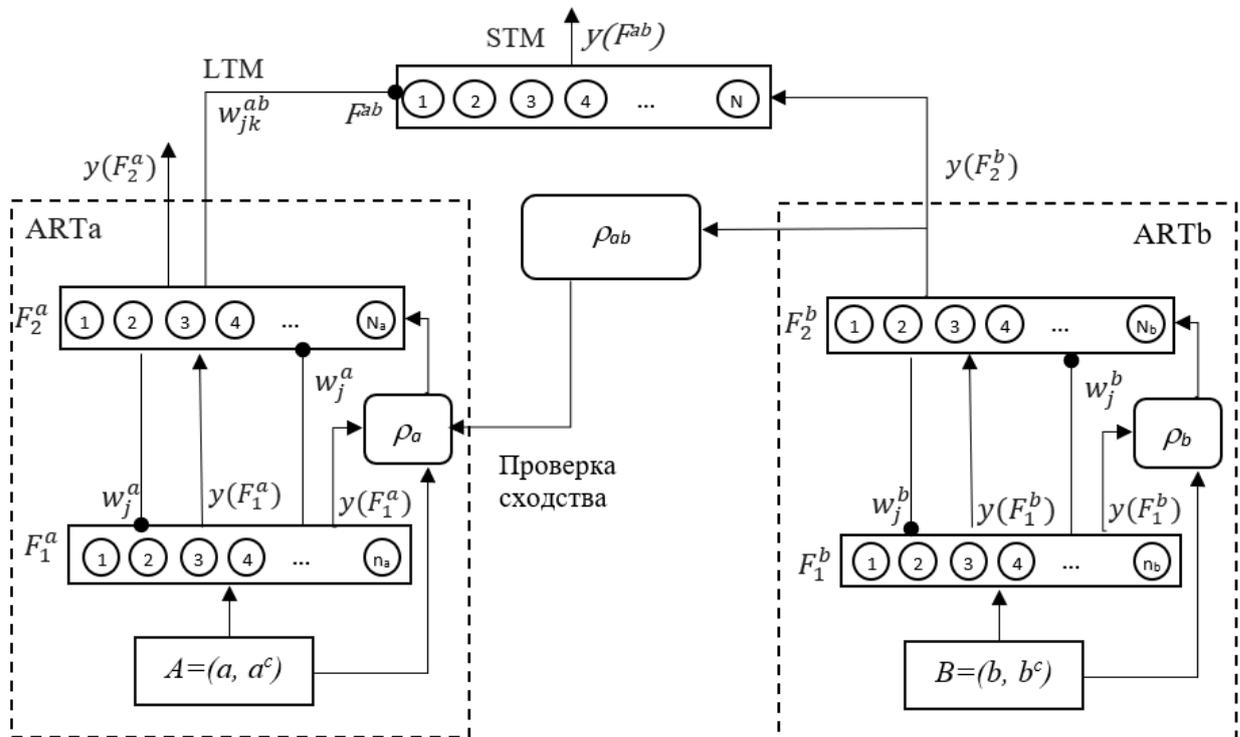


Рис. 2.6. Архитектура сети Fuzzy ARTMAP.

Слои F_1^b и F_2^b имеют похожий смысл, но при этом они используются для кластеризации выходных векторов, а не входных. Слой F_2^a соединен с модулем F^{ab} весовой матрицей $W^{ab} = (w_{jk}^{ab}), j = 1..l; k = 1..n$, содержащей только бинарные элементы. Здесь через l обозначено число входных, а через n – количество выходных кластеров на которые сеть разбивает, соответственно, входные и выходные данные. Вес $w_{jk}^{ab} = 1$, если вектор, на входе отнесенный к кластеру j , на выходе попал в выходной кластер k . В сети Fuzzy ARTMAP может быть несколько кластеров выходных показателей, связанных с одним и тем же кластером входных показателей и наоборот. Цель такого подхода заключается в том, чтобы сеть могла хранить в памяти несколько типичных представителей входных и выходных кластеров для одного класса, что

существенно увеличивает возможность сети к обобщению. То есть выходом данной сети может являться не просто метка класса, а несколько наиболее типичных представителей данного класса. Кратко функционирование сети Fuzzy ARTMAP можно представить следующим образом: в процессе инкрементного обучения сеть разбивает на кластеры не только входные, но и выходные показатели. При этом происходит обучение с учителем, но в процессе такого обучения аппроксимируется зависимость не только между входами и выходами сети, но и между целыми кластерами входных и выходных векторов. В результате, хотя сети Fuzzy ARTMAP используют подход обучения с учителем, они успешно преодолевают проблему стабильности-пластичности. Они обладают уникальной способностью сохранять накопленные знания и одновременно гибко корректировать их в процессе обучения, эффективно объединяя экспертный опыт в заданной предметной области для формирования кластеров.

Рассмотрим основные этапы обучения сети Fuzzy ARTMAP.

Этап 1. Входные векторы подсети ARTa имеют вид $a = [a_1, \dots, a_{Ma}]$, а подсети ARTb: $b = [b_1, \dots, b_{Mb}]$, где $a_i, b_j \in [0,1]$. В то же время имеется семь ключевых гиперпараметров, которые влияют на эффективность сети Fuzzy ARTMAP: [34].

- параметры выбора ($\alpha_a, \alpha_b > 0$): влияют на выбор кластера и препятствуют вырождению прототипов кластеров.

- параметры скорости обучения ($\beta_a, \beta_b \in [0, 1]$) Значения β_a, β_b , близкие к 1 позволяют системе быстрее адаптироваться к новым данным, а β_a, β_b , близкие к 0 используются, как правило, при необходимости выявления долговременных тенденций в данных.

- параметры сходства ($\rho_a, \rho_b, \rho_{ab} \in [0, 1]$): управляют сетевым резонансом. Параметры сходства играют решающую роль в формировании кластеров и определяют степень однородности векторов в них. Если параметр сходства установлен слишком высоко, это приведет к образованию большого количества

кластеров и хорошей классификации на обучающей выборке, но ограничит способность сети к обобщению и может привести к переобучению. С другой стороны, если параметр сходства слишком низок, количество сформированных кластеров уменьшится, что увеличит возможности обобщения, но может увеличить вероятность ошибок классификации на обучающей выборке. [17].

Этап 2. С той же целью, как это было описано в сети Fuzzy ART, входные и выходные образы в сети Fuzzy ARTMAP подвергаются комплиментарному кодированию: $I^a = [\bar{a} \bar{a}^c] = [a_1, \dots, a_{M_a}, a_1^c, \dots, a_{M_a}^c]$, где $a_i^c = 1 - a_i$, а M_a длина исходного входного вектора; $I^b = [\bar{b} \bar{b}^c] = [b_1, \dots, b_{M_b}, b_1^c, \dots, b_{M_b}^c]$.

Этап 3. Сеть ARTMAP выполняет одновременную обработку двух сетей Fuzzy ART: ARTa и ARTb. В качестве функции выбора, как и ранее, можно применять любой из существующих вариантов операции “нечеткого И”, например:

$$T_j = \max_j T_j = \frac{|I^a \wedge w_j^a|}{\alpha_a + |w_j^a|}; \quad S_k = \max_k S_k = \frac{|I^b \wedge w_k^b|}{\alpha_b + |w_k^b|}, \quad (2.6)$$

После подтверждения резонанса найденный кластер J является активным кластером для сети ARTa, а найденный кластер K является активным кластером для сети ARTb.

Этап 4. На данном шаге алгоритма осуществляется контроль сходства между активным кластером ARTa и требуемым вектором выхода, представленным в модуле ARTb. Функция соответствия сети вычисляется с использованием следующей формулы:

$$M_{ab} = \frac{|y^b \wedge w_{JK}^{ab}|}{|y^b|} \quad (2.7)$$

Соответствие между кластерами устанавливается только при выполнении условия $M_{ab} \geq \rho_{ab}$, где ρ_{ab} – параметр сходства. В случае нарушения неравенства кластер помечается как неактивный и выбирается другой кластер. Данный процесс повторяется до достижения соответствия активного кластера требуемому результату. В случае, если все активные кластеры исчерпались,

создается новый кластер с весами, равными текущему входному вектору.

Этап 5. Весовые коэффициенты входного вектора подвергаются обучению (адаптации) после достижения резонанса между входом и выходом. Для модификации весовых коэффициентов прототипов модулей ARTa и ARTb, которые успешно прошли проверку на сходство, используются формулы:

$$w_j^a \leftarrow \beta_a (I^a \wedge w_j^a) + (1 - \beta_a) w_j^a \quad (2.8)$$

$$w_K^b \leftarrow \beta_b (I^b \wedge w_K^b) + (1 - \beta_b) w_K^b \quad (2.9)$$

Адаптация весов для модуля F^{ab} выполняется следующим образом:

$$w_{jK}^{ab} = 1, w_{jk}^{ab} = 0 \text{ для } k \neq K. \quad (2.10)$$

Этап 6. Одним из распространенных недостатков ART-сетей является сложность выбора гиперпараметров. Для сети ARTMAP подход на основе постобработки с обширным вычислительным экспериментом неэффективен, так как случайный выбор лучшего набора из семи гиперпараметров невозможен. В данном исследовании предлагается подход на основе разработки генетического алгоритма для оптимизации параметров. Генетический алгоритм обладает высокой степенью робастности в отношении шума и выбросов в данных. Это позволяет эффективно настраивать параметры нейронной сети, даже при наличии шумов в данных. Кроме того, генетический алгоритм не зависит от специфики задачи и может быть применен для настройки параметров нейронной сети в различных областях. Наконец, генетический алгоритм проводит направленный поиск в пространстве параметров, что дает существенный выигрыш во времени по сравнению методом перебора по сетке, то есть ненаправленного поиска.

Общая схема генетического алгоритма описана в работе [69]. Предлагаемый ниже алгоритм соответствует ее основным этапам.

Будем использовать следующую функцию приспособленности для оценки набора параметров в популяции: $E = M/N$, где M - количество обучающих примеров, правильно идентифицированных сетью Fuzzy ARTMAP для заданного набора параметров, а N - общее количество примеров в обучающей выборке.

Для оператора кроссинговера использовался арифметический кроссовер представленный в работе [69], так как он показал лучшую стабильность при создании новых решений в вычислительных экспериментах.

Для оператора мутации использовалась неравномерная мутация Михалевича, также описанная в работе [69], поскольку она обеспечивала более быструю сходимость и большую точность, по сравнению с другими существующими операторами мутации.

Процесс выбора параметров с помощью ГА представлен на рисунке 2.6.

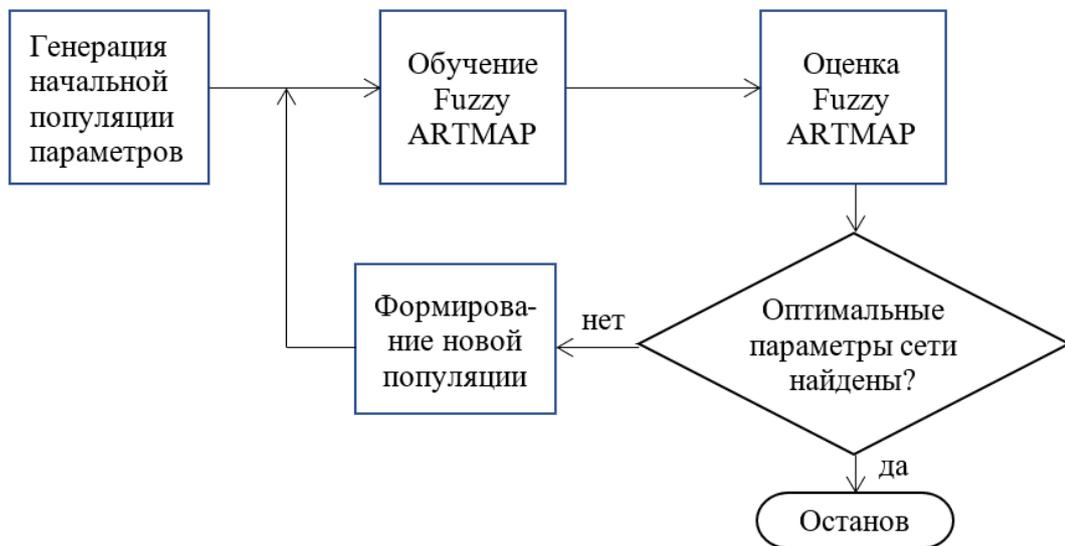


Рис. 2.6 Предлагаемый генетический алгоритм для автоматического выбора параметров сети.

Процесс построения подсистемы анализа данных для системы структуризации мониторинговых данных включает четыре основные фазы: предварительная обработка данных и отбор значимых признаков классификации, отыскание оптимальных гиперпараметров сети Fuzzy ARTMAP с использованием ГА, классификация с помощью Fuzzy ARTMAP и тестирование системы. На рисунке 2.7 показана блок-схема построения подсистемы анализа для модуля классификации мониторинговых данных.

На этапе предварительной обработки данных (препроцессинга) проводится очистка от шумов, а также комплементация входных и выходных векторов. Отбор наиболее значимых признаков проводится с помощью хорошо

зарекомендовавшего себя в нескольких задачах алгоритма поиска с возвратом [45], алгоритмическая схема которого описана ниже.

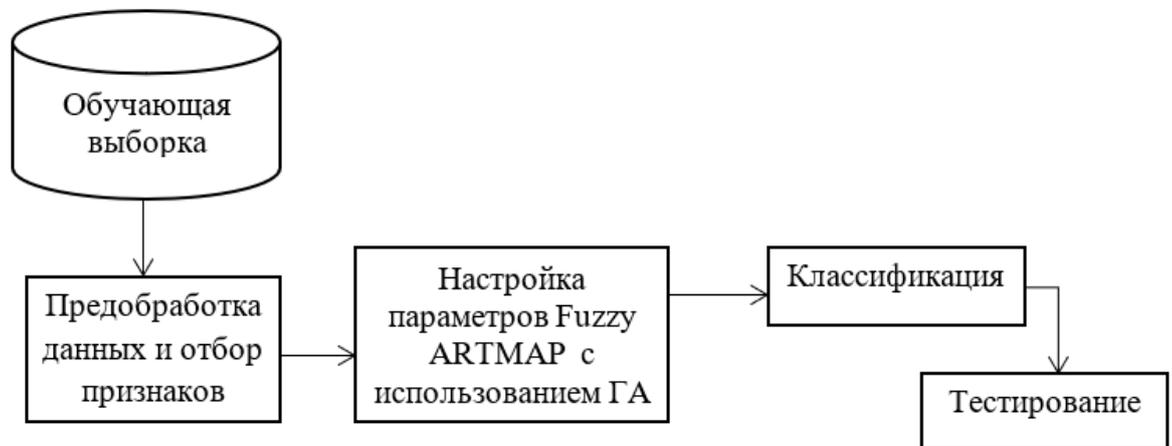


Рис. 2.7 Построение модуля классификации мониторинговых данных

Шаг 1. *Инициализация.* Задается верхняя граница количества признаков k . Обозначим через *accuracy* (S) точность (долю правильных ответов) алгоритма классификации при условии использования множества признаков S .

Шаг 2. *Исключение.* Алгоритм определяет наименее значимые показатели из исходного набора признаков S и удаляет их, продолжая этот процесс до тех пор, пока количество признаков не станет равным заранее заданному значению k . При этом наименее значимым для текущего подмножества признаков S_w считается такой признак f_x , что

$$accuracy(S_w - f_x) > accuracy(S_w - f_i), \quad (f_i \in S_w, f_i \neq f_x)$$

Шаг 3. *Включение.* Ищется наиболее значимый признак среди исключенных показателей, и добавляется к имеющемуся набору признаков. Наиболее значимым для заданного набора признаков S_w называют такой показатель $f_x \in S_u$, где $S_u = S - S_w$, и при этом

$$accuracy(S_w + f_x) > accuracy(S_w + f_i), \quad (f_i \in S_u, f_i \neq f_x)$$

Процедура включения повторяется до тех пор, пока с добавлением очередного показателя точность алгоритма монотонно увеличивается.

Шаг 4: *Отображение.* Если число входных показателей в текущем наборе

превышает k , возврат к шагу 2; иначе требуемый набор признаков найден.

После отыскания набора значимых признаков эти признаки используются для обучения Fuzzy ARTMAP.

В частности, с помощью предложенного алгоритма на этапе отбора признаков в задаче оценки состояния окружающей среды региона (описанной подробно в главе 4) было отобрано 12 (из 41) наиболее важных признаков. На рисунке 2.8 график показывает точность метода классификации основанного на нечеткой сети Fuzzy ARTMAP по мере увеличения количества признаков. Можно сделать вывод, что точность ближе всего приближается к единице при использовании 12 признаков, поэтому этот числовой показатель был выбран в качестве оптимальной размерности входного вектора.

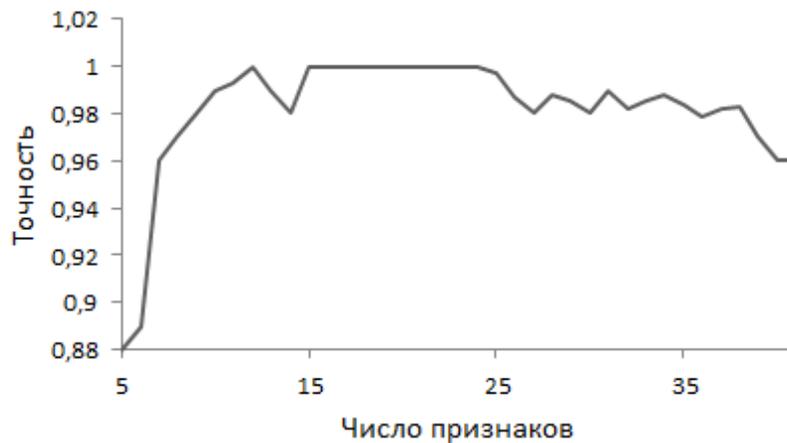


Рис. 2.8 Зависимость доли правильных ответов алгоритма от числа входных признаков.

При работе с одним и тем же компьютером Fuzzy ARTMAP с использованием 12 признаков требует всего около 58% времени, затрачиваемого на обучение сетей с полным набором признаков. Этот факт имеет огромное значение для обработки данных, поступающих в режиме реального времени. Общая точность классификации системы на тестовой выборке, используемой для настройки параметров алгоритма, составила 98,79%.

В настоящее время для обработки непрерывно поступающих потоковых данных используются различные алгоритмы распараллеливания процессов. В

последние годы появилось несколько современных фреймворков для организации потоковой обработки данных, такие как Apache. Поскольку технология параллельных и высокопроизводительных вычислений развивается и вычислительные ресурсы становятся все более доступными, появляются новые возможности для распараллеливания моделей нейронных сетей, с точки зрения лучшей обработки вычислений и повышения интенсивности обработки данных.

Рассмотрим возможный подход к распараллеливанию моделей нейронных сетей Fuzzy ARTMAP. Как уже отмечалось, Fuzzy ARTMAP- это инкрементно обучающаяся система, которой не требуется отдельный этап обучения и которая выдает классифицирующие решения с первых шагов алгоритма. При этом очевидно, что на первых шагах точность классифицирующего алгоритма будет невысока. Чтобы ускорить процесс первичной настройки алгоритма на исходных данных, предлагается использовать ансамбль нейронных сетей. В предлагаемый ансамбль входит K сетей архитектуры Fuzzy ARTMAP, каждая из которых будет обучаться независимо от других на некотором подмножестве исходных данных. Таким образом, может быть применена параллельная парадигма, позволяющая моделям Fuzzy ARTMAP работать одновременно на различных узлах компьютерной сети. Как известно, перекрестная проверка (cross validation) эффективно повышает точность ансамблей нейронных сетей за счет формирования различных обучающих наборов для каждой модели и полного использования всего набора данных [36]. В данном случае предлагается использовать аналогичную стратегию. На этапе обучения имеющийся в текущий момент набор данных делится на K частей (фолдов) для параллельного обучения K сетей. На этапе тестирования $K-1$ сеть объединяется в ансамбль, который тестируется на оставшейся части. Этот процесс повторяется K раз, чтобы протестировать ансамбль на каждой части набора данных.

Поскольку каждая модель Fuzzy ARTMAP работает на одном многоядерном вычислительном узле, применяется подход параллельных вычислений с общей памятью для генерации нескольких потоков, обращающихся к общему набору данных в глобальной памяти, и параллельного запуска модели (рис. 2.9).

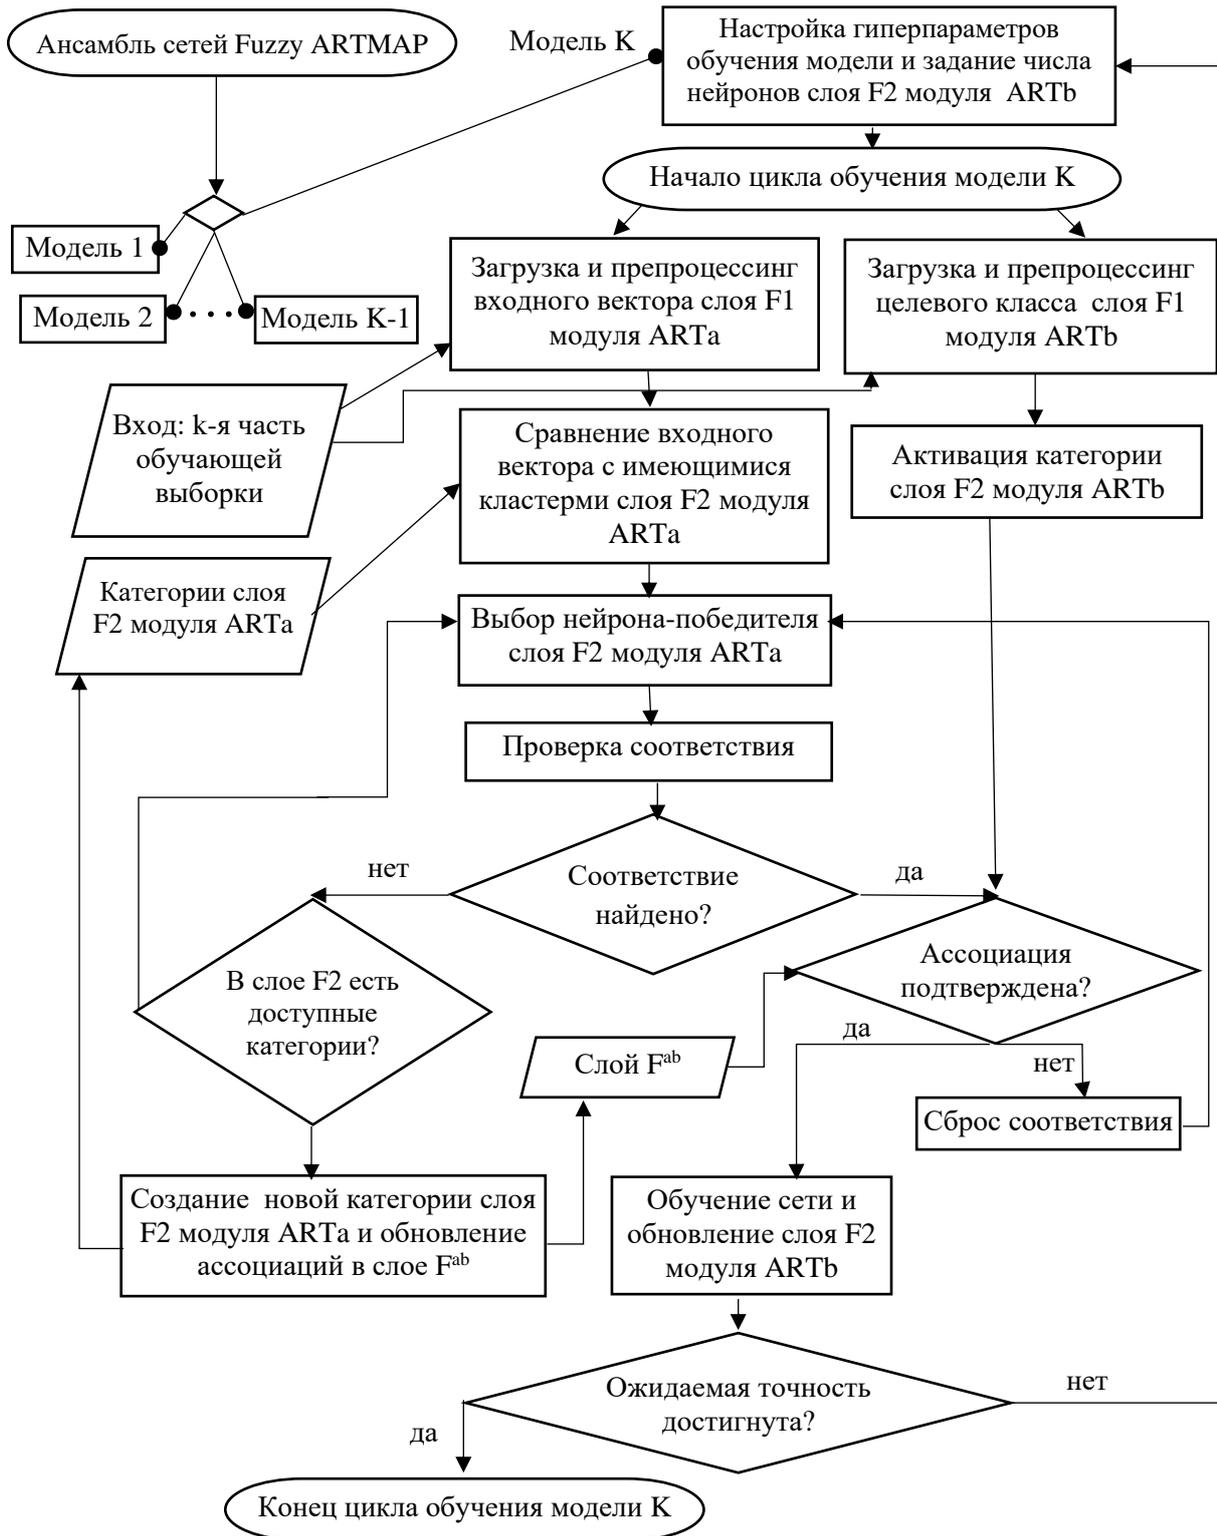


Рис. 2.9. Обучение ансамбля сетей Fuzzy ARTMAP.

Это позволяет распараллелить решение задачи на нескольких уровнях, чтобы использовать параллелизм с точки зрения параллелизма как данных, так и задач. Параллелизм данных представляет собой форму распараллеливания, при которой один набор операций выполняется с разными подмножествами данных.

Например, на этапе “Выбор нейрона-победителя слоя F2 модуля ARTa” (представленного на рис. 2.3. ранее), задача поиска глобального максимума функции выбора может быть разделена на подзадачи для каждого потока для поиска своего локального максимума, а затем объединена для генерации глобального максимума с помощью функции редукции. Этот пример процесса параллелизма данных.

Параллелизм задач относится к форме распараллеливания, при которой набор функционально независимых задач работает с собственными данными. Например, операции в модулях ARTa и ARTb полностью независимы до тех пор, пока не наступит этап подтверждения ассоциации в слое F^{ab} , что позволяет выполнять две параллельные задачи. На рисунке 2.9 показаны все распараллеленные компоненты или шаги в алгоритме обучения и типы данных (например, входные данные и сети), хранящиеся в общей памяти.

2.5. Разработка модифицированного алгоритма обучения сети Fuzzy ARTMAP для структуризации данных мониторинга в условиях пересекающихся классов

Классификация – это процесс присвоения набору входных данных метки одного из нескольких предварительно определенных классов. Если пространство входных данных не может быть подразделено на области с отдельными метками классов, говорят, что базовые классы распределения пересекаются. Эта ситуация часто встречается в реальных задачах из-за шума, неопределенности классификации и ошибок, использования неоптимальных входных характеристик, потери контекста и так далее. Существует ряд методов, способных проводить нелинейные границы между классами, как на рисунке 2.10, но такие границы, как правило, приводят к проблеме переобучения и большому числу ошибок на тестовой выборке.

Классификация точек из пересекающихся распределений классов – это

более сложная проблема, чем классификация точек из разделимых распределений. Невозможно однозначно классифицировать точку, лежащую в области перекрытия классов. Лучшее, что может сделать классификатор – это оценить вероятность того, что такая точка принадлежит определенному классу или определить нечеткое значение принадлежности точки к данному классу [17]. Если вывод классификатора ограничен одной меткой, то наиболее общий подход заключается в выборе одного класса, из которого точка, скорее всего, была взята.

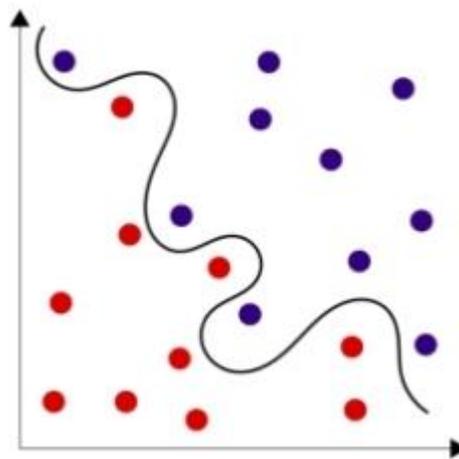


Рис. 2.10. Иллюстрация нелинейно разделимых классов.

Нечеткая сеть ARTMAP [21] обычно используется для построения классификатора в режиме обучения с учителем. В этом случае она состоит из одного модуля Fuzzy ART и модуля контролируемой классификации MAP. Во время обучения на вход сети подаются обучающие векторы, размеченные в соответствии с классами, к которым они принадлежат. Модуль Fuzzy ART назначает текущему входному вектору определенный кластер (как правило, каждому классу соответствует несколько кластеров близких в смысле некоторого критерия сходства векторов). Поле MAP связывает каждый кластер с определенным классом. Если метка класса обучающего вектора отличается от класса, связанного с выбранным кластером, поле MAP повторно вызывает поиск модуля Fuzzy ART, на этот раз с ограничением внимания на оставшиеся кластеры. Если эта процедура, называемая отслеживанием совпадений, успешно

присваивает входному вектору кластер с правильной меткой класса, веса, определяющие этот кластер, обновляются, что повышает вероятность повторного отнесения этого обучающего вектора к данному кластеру в будущем. Если кластер с правильной меткой класса не найден, для данного входного вектора создается новый кластер.

Когда распределения данных, связанных с несколькими классами, перекрываются, Fuzzy ARTMAP имеет тенденцию создавать отдельный кластер для каждого набора данных из пересечения классов. Это явление называется распространением кластеров. Это является прямым результатом того факта, что классы не являются разделяемыми. Хотя это приводит к правильной классификации обучающих векторов, производительность на тестовых данных (то есть обобщение) такой сети часто хуже, чем сети с меньшим числом кластеров. Кроме того, время, необходимое для поиска Fuzzy ARTMAP, и память, необходимая для хранения весовых коэффициентов, пропорциональны количеству кластеров, что обеспечивает дополнительные стимулы для ограничения количества создаваемых кластеров.

Рассмотрим несколько возможных вариантов модификации сети Fuzzy ARTMAP.

1. *Обрезка.* Если кластеры, которые содержат наименьшее количество обучающих векторов, периодически удалять, число используемых кластеров приблизится к стационарному значению. Оставшиеся кластеры будут увеличиваться, чтобы захватить обучающие векторы, которые были ранее отнесены к удаленным кластерам. Если периодически удаляются кластеры, захватывающие менее N_1 обучающих векторов, то верхней оценкой общего числа кластеров является N_2 / N_1 , где N_2 – размер обучающей выборки. На практике количество образованных кластеров обычно значительно меньше этого. Простой способ отслеживать, сколько обучающих векторов принадлежит к каждому кластеру, заключается в незначительном изменении веса этого кластера w_{jk}^{ab} в поле MAP. Вместо установки значения веса равным 1.0 при формировании

нового кластера, вес увеличивается на некоторую постоянную величину, δ , каждый раз, когда очередной обучающий вектор относится к этому кластеру. Тогда величина веса поля MAP будет показывать, сколько обучающих векторов зафиксировано в соответствующем кластере. Для того, чтобы веса полей MAP не превышали допустимые пределы, все веса поля MAP делятся на 2 через каждое определенное число итераций.

2. *Ограничение на создание новых кластеров.* Скорость создания новых кластеров может быть ограничена. Например, если один и тот же набор данных предъявляется многократно во время обучения, количество кластеров, создаваемых во время каждой эпохи обучения, может быть ограничено некоторым значением, например, общим количеством классов. Это приводит к максимально возможному росту существующих кластеров, что в целом сокращает общее количество сформированных кластеров.

3. *Двухнаправленное движение веса.* Правило обучения сети Fuzzy ARTMAP гарантирует, что сформированные кластеры со временем только растут и никогда не уменьшаются [12]. Следовательно, после достаточного числа итераций, каждая точка обучающей выборки будет лежать либо внутри, либо на границе кластера, который ее захватывает. Причем, в силу использования нечетких операций (2.6)-(2.9), геометрически сформированный кластер сети Fuzzy ARTMAP представляет собой многомерный параллелепипед в пространстве признаков, то есть в процессе классификации пространство входных векторов покрывается n -мерными «параллелепипедами» выделенных кластеров [34]. Весовой вектор хранит «прототип» каждого кластера. В качестве модификации предлагается обновлять только те компоненты весового вектора, для которых соответствующие компоненты входного вектора попали в границы распознанного кластера. В формуле (2.11) W – матрица весов, w_{ji} – i -я компонента весового вектора-прототипа J -той кластера w^J , I – входной вектор. При этом учитывается что входы, как требует сеть Fuzzy ARTMAP, закодированы с помощью комплементарного кодирования: $I_{i+M}=1-I_i$.

$$w_{ji}^{new} = \begin{cases} w_{ji}^{old}, & w_{Jcomp} \geq I_{comp} \\ w_{ji}^{old} - \beta(w_{ji}^{old} - I_i), & w_{Jcomp} < I_{comp} \end{cases}, \text{ где} \quad (2.11)$$

$$w_{Jcomp} = w_{J(i-M)} \text{ и } I_{comp} = I_{i+M}, \text{ если } i \leq M, \text{ и}$$

$$w_{Jcomp} = w_{J(i-M)} \text{ и } I_{comp} = I_{i-M}, \text{ если } i > M.$$

При использовании такого способа пересчета весовых коэффициентов кластер растёт вдоль размерностей, в которых компонент входного вектора лежит за границами параллелепипеда, соответствующего распознанному кластеру, и сжимается вдоль размерностей, в которых компонент входного вектора лежит внутри существующего параллелепипеда. Это приводит к уменьшению размеров кластеров, и позволяет лучше приближать формы оптимальных границ принятия решений между пересекающимися распределениями классов. Однако без сокращения или ограничения создания новых кластеров двунаправленное движение веса часто приводит к появлению большого количества кластеров. Таким образом, для того, чтобы двунаправленные движения веса были полезными, следует использовать описанный ранее способ ограничения количества кластеров.

4. *Перемаркировка кластеров.* Если функция соответствия $S_J(I)$ близка к единице (то есть расстояние от входного вектора I до весового вектора кластера J не превосходит некоторого порогового значения ρ_J), и все же классы, связанные с кластером J и обучающим вектором I , отличаются, стандартная Fuzzy ARTMAP создает новый кластер, что приводит к росту числа кластеров. Вместо этого можно разрешить такому кластеру быть связанным с несколькими классами, то есть метка класса для такого кластера будет иметь тип запись, состоящую из нескольких полей. Когда тестовый вектор попадает в такой кластер, можно назначить ему нечеткое членство в каждом из классов или вывести одну метку класса на основе относительных величин соответствия каждому из классов. При этом необходимо уменьшить вероятность того, что кластер, связанный с несколькими классами, захватит точку, которая может быть однозначно отнесена к одному классу (п.5).

5. *Функция выбора, предпочитающая большие кластеры.* При использовании исходной функции выбора для сети Fuzzy ARTMAP, если входной вектор данных попадает в оба из перекрывающихся весовых параллелепипедов кластеров, побеждает меньший параллелепипед [21]. Это гарантирует, что кластер, созданный в ответ на некоторый входной вектор, захватит этот вектор, если он будет когда-либо заново предъявлен на вход сети. Кроме того, если точка данных находится посередине между двумя имеющимися параллелепипедами кластеров, побеждает меньший. Второе свойство имеет нежелательные последствия. Интуитивно понятно, что маленький весовой параллелепипед получается из очень локализованного набора уже близких векторов, тогда как большой весовой параллелепипед получается из разбросанного набора точек. Если новая точка находится на одинаковом расстоянии от двух параллелепипедов, она удалена на большее число стандартных отклонений от меньшего параллелепипеда, чем от большего, и поэтому должна быть назначена большему. В исходной функции выбора для сети Fuzzy ARTMAP это условие не соблюдается. Поэтому предлагается модифицированная функция выбора (2.12) обеспечивающая подобную классификацию:

$$T_j(I) = |w^j| \left(1 + \frac{|I \wedge w^j| - |w^j|}{\alpha} \right) \quad (2.12)$$

Здесь обозначения \wedge , $|\cdot|$ имеют тот же смысл, что и ранее:

$$(p \wedge q)_j = \min(p_j, q_j), j = \overline{1, J}; \quad |p| = \sum_i p_i.$$

Как и в функции выбора сети Fuzzy ARTMAP [2], α является малой константой, но в данном случае α определяет диапазон, в котором параллелепипед большего размера предпочтительнее меньшего.

Величина $T_j(I)$ может быть меньше 0. При этом значение $|w^j|$ будет вычисляться только при обновлении весов кластера J .

Можно показать, что предлагаемая функция (2.12) удовлетворяет трем требованиям к функции выбора, сформулированным в работе [4] (в которой предлагается базовый алгоритм обучения сети Fuzzy ARTMAP):

- 1) Уменьшение вектора весов w^j в ответ на входной вектор I

увеличивает $T_j(I)$.

Действительно, рассмотрим входной вектор I , который лежит вне весового параллелепипеда R_j . Это подразумевает, что некоторая составляющая входного вектора, i , меньше соответствующего веса: $I_i < w_{ij}$.

Используя формулы (3) и (4) вычислим производную:

$$\frac{\partial T_j(I)}{\partial w_{ij}} = \frac{\partial \left(|w^j| \left(1 + \frac{|I \wedge w^j| - |w^j|}{\alpha} \right) \right)}{\partial w_{ij}} = 1 - \frac{|w^j|}{\alpha} + \frac{|I \wedge w^j| - |w^j|}{\alpha}$$

Из определения операции \wedge следует, что $|I \wedge w^j| < |w^j|$. Кроме того, критерий соответствия гарантирует, что $|w^j| \geq \rho M$. Если выбрать $\rho \geq \alpha M$, то это гарантирует, что $|w^j|/\alpha \geq 1$. Поскольку число α обычно очень мало, это требование не налагает серьезных ограничений на выбор ρ . Если α и ρ подчиняются этой взаимосвязи, производная будет отрицательна, а уменьшение w_{ji} , т.е. перемещение веса в сторону обучающего вектора, увеличивает $T_j(I)$.

2) Если входной вектор находится внутри двух перекрывающихся кластеров (то есть в пересечении их весовых параллелепипедов), меньший параллелепипед соответствует большему значению функции выбора, то есть вектор будет отнесен к меньшему кластеру.

Действительно, если входной вектор лежит внутри некоторого параллелепипеда R_j , то $T_j(I) = |w_j|$. Так как меньший параллелепипед имеет больший $|w|$, он захватывает входной вектор.

3) Значение функции выбора монотонно уменьшается с увеличением расстояния от входного вектора до весового параллелепипеда кластера.

Для доказательства рассмотрим входной вектор I , который лежит за пределами некоторого параллелепипеда R_j , определяемого диапазоном изменения весовых коэффициентов j -го кластера. Это означает, что некоторая составляющая этого входного вектора меньше соответствующего веса: $I_i < w_{ij}$. Вычислим производную

$$\frac{\partial T_J(I)}{\partial I_i} = \frac{\partial \left(|w^J| \left(1 + \frac{|I \wedge w^J| - |w^J|}{\alpha} \right) \right)}{\partial I_i} = \frac{|w^J|}{\alpha}$$

Так как производная положительна, то уменьшение I_i , т.е. удаление входного вектора от весового параллелепипеда уменьшает $T_J(I)$.

Действительно, рассмотрим некоторый входной вектор I , который лежит за пределами параллелепипедов, соответствующих кластерам R_j и R_k . Обозначим:

$$\delta_j = |w^j| - |I \wedge w^j|, \quad \delta_k = |w^k| - |I \wedge w^k|$$

Это расстояния от вектора I до параллелепипедов, отвечающих кластерам с номерами j и k , соответственно. Если $T_J(I) = T_K(I)$, то

$$\begin{aligned} |w^j| \left(1 - \frac{\delta_j}{\alpha} \right) &= |w^k| \left(1 - \frac{\delta_k}{\alpha} \right) \Rightarrow \\ \delta_j &= \frac{|w^k|}{|w^j|} \delta_k + \alpha \left(1 - \frac{|w^k|}{|w^j|} \right) = C \delta_k + D \end{aligned}$$

Таким образом, диапазон, δ_j при котором функция выбора кластера j равна функции выбора кластера k , является линейной функцией расстояния δ_k от I до R_k . Наклон C и смещение D этой линии являются функциями размеров весовых параллелепипедов. Если R_j меньше R_k , то $|w^j| > |w^k|$, то есть $C < 1$, и $D > 0$. Проанализируем, когда δ_j будет меньше δ_k . Очевидно, что при достаточно больших δ_k определяющее значение имеет первое слагаемое, то есть $C \delta_k + D \approx C \delta_k$, так как D — достаточно малая величина. В этом случае $\delta_j \approx C \delta_k < \delta_k$. Второе слагаемое D доминирует только тогда, когда I очень близок к двум параллелепипедам веса ($\delta_k \approx 0$). В этом случае $\delta_j \approx D > \delta_k$ и предпочтение отдается небольшим параллелепипедам. Таким образом, если I равноудалён от двух весовых параллелепипедов, соответствующих двум различным кластерам, то он будет захвачен более крупным, если он не находится на маленьком расстоянии как от R_j , так и от R_k .

6. Использование неоднородного масштабирования исходной выборки.

Общей проблемой алгоритмов обучения нейронных сетей является выбор метода предварительного масштабирования компонентов входного вектора. Если большая вариация одного компонента не влияет на классификацию исходных данных, а незначительная вариация другого компонента изменяет классификацию, результирующие показатели классификации могут даже ухудшиться после масштабирования. Неоднородное масштабирование входных данных может существенно изменить точность классификации. Предлагаемая функция неоднородного выбора придает большее значение изменениям в тех кластерах, в которых наблюдалось меньше внутриклассовых изменений, о чем свидетельствуют длины сторон весовых параллелепипедов. Весовые коэффициенты Fuzzy ART однозначно дают дополнительную информацию о размере каждого кластера. Эти знания используются функцией выбора в пользу наименьшего кластера, когда входной вектор попадает в несколько весовых параллелепипедов. Они также используются для ограничения максимального количества кластеров (через критерий сходства), и являются полезными для механизма контролируемого обучения Fuzzy ARTMAP, который ограничивает внимание к меньшим кластерам после того, как сеть связала входные данные с неправильным классом. В то время как знания о размере весовых параллелепипедов используются в модели Fuzzy ART, знания об их форме (соотношении сторон) никак не учитываются (хотя они и доступны). Предлагаемая ниже функция выбора использует эту информацию для обеспечения локального автоматического масштабирования:

$$T_j(I) = \begin{cases} |w^j|, & \text{если } I \text{ лежит внутри } R_j \\ -\sum_i \frac{\delta_{ij}}{\alpha + R_{ij}}, & \text{иначе} \end{cases}$$

Здесь, α - небольшая константа. δ_{ji} - это расстояние от входного вектора до весового параллелепипеда R_j в измерении i . R_{ji} - это длина грани параллелепипеда R_j в измерении i . В каждом измерении вклад расстояния от I до R_j масштабируется на α плюс длина стороны параллелепипеда. Константа α необходима для предотвращения деления на ноль. Кроме того, увеличение α

уменьшает долю случаев, когда при выборе между двумя кластерами малые размеры весового параллелепипеда выбраковываются по сравнению с большими.

В процессе численного эксперимента (проведенного в главе 4 при решении конкретной практической задачи) отмечено увеличение производительности модифицированного алгоритма по сравнению с базовой сетью Fuzzy ARTMAP в тестах с наборами данных различной размерности и различной степени перекрытия между распределениями классов.

ВЫВОДЫ ВТОРОЙ ГЛАВЫ

1. Для разработки методов и алгоритмов интеллектуальной поддержки принятия управленческих решений при обработке мониторинговой информации лучше всего подходят нейронные сети семейства ART, так как они отличаются стабильной и быстрой атрибуцией данных, и вместе с тем пластичностью для запоминания новой информации.
2. На основе использования сетей семейства ART предложен общий подход к решению задач кластеризации мониторинговых данных. Так как общеизвестным недостатком сетей семейства ART является зависимость от начальной инициализации гиперпараметров, исследован вид и характер данной зависимости в задачах кластеризации мониторинговых данных.
3. Предложен генетический алгоритм для автоматической настройки гиперпараметров сети Fuzzy ARTMAP, с целью преодоления указанного недостатка. Такой алгоритм позволяет совершенствовать методы получения и обработки информации для задач управления организационными системами.
4. Так как мониторинговая информация может порождать потоки данных большого объема, предложен алгоритм использования ансамбля сетей Fuzzy ARTMAP для параллельной обработки и структуризации потоковых данных. Технология параллельных и высокопроизводительных вычислений развивается и вычислительные ресурсы становятся все более доступными, появляются новые возможности для распараллеливания моделей нейронных сетей, с точки зрения

лучшей обработки вычислений и повышения интенсивности обработки данных, а, следовательно и повышения скорости принятия управленческих решений на основе оперативно поступающих данных, что особенно важно в задачах управления в организационных системах.

5. Разработан алгоритм обучения сети Fuzzy ARTMAP для решения задачи классификации в условиях пересекающихся классов. Такая задача часто возникает при анализе мониторинговой информации в системах поддержки принятия управленческих решений, так как при сборе оперативных данных часто встречаются шумы и ошибки, что размывает границы между классами, на которые разбиваются значения входных мониторинговых показателей. Для этого алгоритма предложена модифицированная функция выбора обеспечивающая подобную классификацию, математически обоснованы ее свойства.

ГЛАВА 3 РАЗРАБОТКА АЛГОРИТМОВ АВТОМАТИЗИРОВАННОГО ФОРМИРОВАНИЯ УПРАВЛЯЮЩИХ РЕШЕНИЙ НА ОСНОВЕ МОНИТОРИНГОВОЙ ИНФОРМАЦИИ

3.1 Разработка интерпретируемого алгоритма анализа мониторинговой информации на основе нейронной сети архитектуры Cascade ARTMAP

В системах поддержки принятия решений при управлении организациями на практике часто применяются простые и понятные модели, как, например, правила принятия решений на основе известных методов нечеткой логики, линейная или логистическая регрессия, метод деревьев классификации и регрессии. Ценность и практическая значимость подобных алгоритмов заключается в важной способности этих алгоритмов понимать и разъяснять их внутреннюю логику принятия решения, но недостатком является их невысокая точность. Более точные нейросетевые алгоритмы, как правило, не обладают свойством интерпретируемости. Однако предлагаемый в данном исследовании алгоритм сочетает в себе достаточно высокую точность при анализе мониторинговой информации и, вместе с тем, он хорошо объясняет получаемые решения.

В данной главе рассматривается нейросетевая архитектура Cascade ARTMAP, основанная на архитектуре Fuzzy ARTMAP, и предназначенная для решения задач классификации (то есть обучающаяся с учителем). Как было отмечено в главе 2, кластеры, формируемые сетью Fuzzy ARTMAP, представляют собой n -мерные параллелепипеды в пространстве признаков, что позволяет описать их в виде правил вида “ЕСЛИ значения признака₁ находятся в диапазоне $[p_3, p_4]$, а значения признака₂ находятся в диапазоне $[p_1, p_2]$, ТО...”. То есть сеть Cascade ARTMAP позволяет получать систему знаний, основанную на правилах [11], при этом каждый сформированный кластер схожих входных значений мониторинговых показателей будет порождать некоторое управляющее правило. При обучении данной сети новые кластеры распознавания создаются

динамическим образом, что позволяет эффективно дополнять сформировавшийся набор правил. Обучение в сети Cascade ARTMAP не стирает накопившиеся знания благодаря свойству стабильности-пластичности [13]. Использование метода обобщения и извлечения правил в отношении выходных значений сети Cascade ARTMAP, позволяет получить совокупность решающих правил. Такой подход способствует возможности проведения сравнений получаемых правил с экспертными знаниями. Каждому правилу, формируемому сетью, может быть сопоставлен коэффициент достоверности, указывающий значимость или полезность этого правила. Таким образом происходит ранжирование и оценивание формируемых правил. Поэтому алгоритмы построения, корректировки и оценки правильности правил в сети Cascade ARTMAP представляют собой определенную нейросетевую парадигму, которая осуществляет формирование правил принятия решений (Рис. 3.1.) [65].

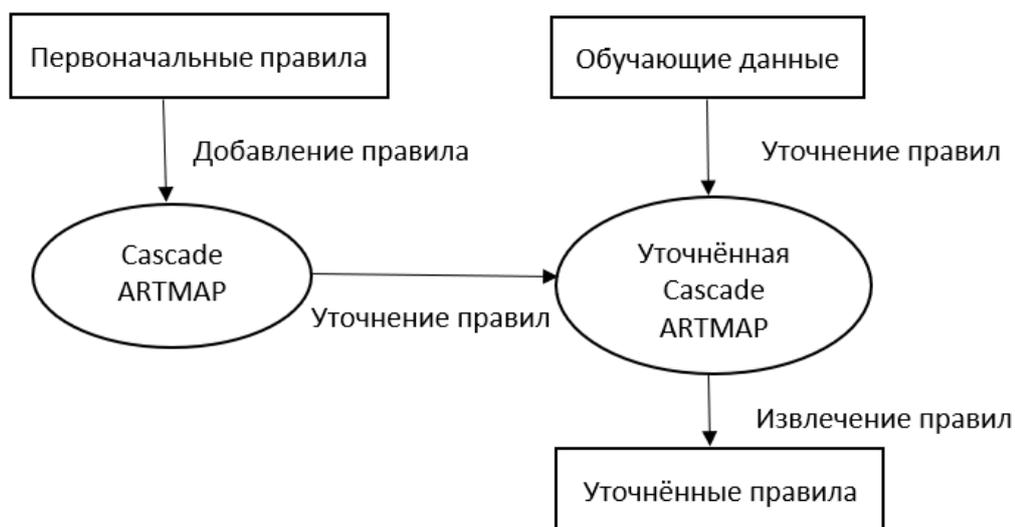


Рис. 3.1. Cascade ARTMAP для построения решающих правил.

Перейдем к описанию сети Cascade ARTMAP, являющейся логическим обобщением сети Fuzzy ARTMAP, описанной в главе 2. Архитектура этой сети приведена на рис. 2.6, и она останется без изменений, поменяется только интерпретация обрабатываемых значений и немного алгоритм обучения.

Введем несколько важных понятий, касающихся формирования решающих правил.

Входные атрибуты – это атрибуты, которые служат только в качестве посылки для применения какого-либо правила. Выходные атрибуты – это атрибуты, которые возникают только в результате применения правил. Промежуточные атрибуты – это атрибуты, которые имеют две роли: для каких-то правил они выступают в качестве посылки, а для каких-то в качестве следствия. Каскад правил – это набор правил, где одно из выводов правила также используется в качестве посылки для другого правила. С учетом введенной терминологии будем считать, что слой F_1^a сети Fuzzy ARTMAP является слоем, обрабатывающим входные атрибуты, а слой F_1^b – выходные атрибуты.

Сеть Cascade ARTMAP, объединяет указанные слои в том смысле, что и F_1^a и F_1^b будут обрабатывать входные, выходные и промежуточные атрибуты. Рассмотрим два правила, которые образуют простой двухуровневый каскад правил:

Правило 1: IF A and B THEN C,

Правило 2: IF C and D THEN E,

где A, B и D - входные атрибуты; C - промежуточные атрибуты; и E - выходные атрибуты. Все атрибуты (A, B, C, D и E) представлены как в F_1^a , так и в F_1^b (рис. 3.2.).

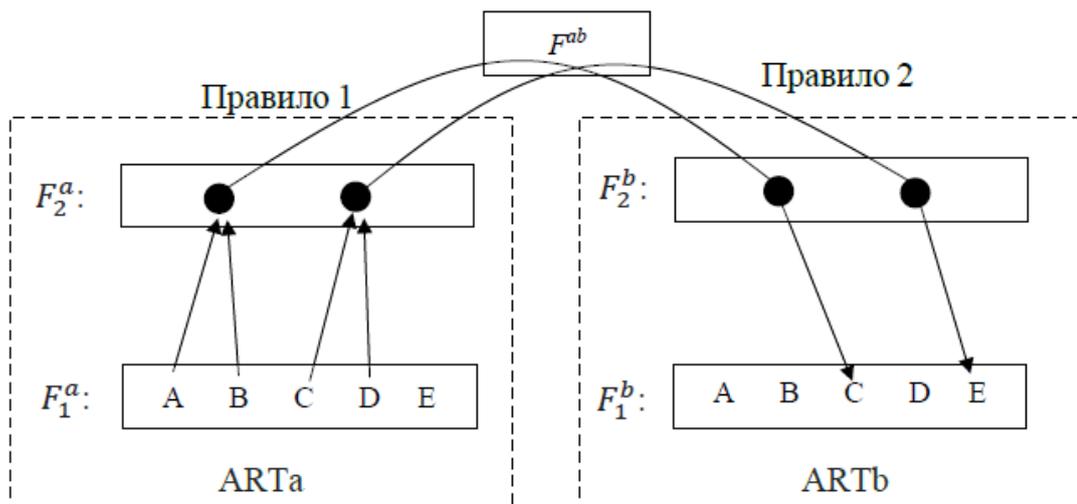


Рис 3.2. Представление каскада простых правил в сети Cascade ARTMAP.

Для правила 1 кластер слоя F_2^a используется для запоминания A и B, при

этом она связана с кластером слоя F_2^b , предсказывающей C. Аналогично для правила 2, кластер слоя F_2^a используется для запоминания C и D, и при этом она связана с кластером слоя F_2^b , предсказывающий E. Рассмотрим реализацию этапов обучения сети Cascade ARTMAP. На рис. 3.3 представлена блок-схема этапа инициализации.

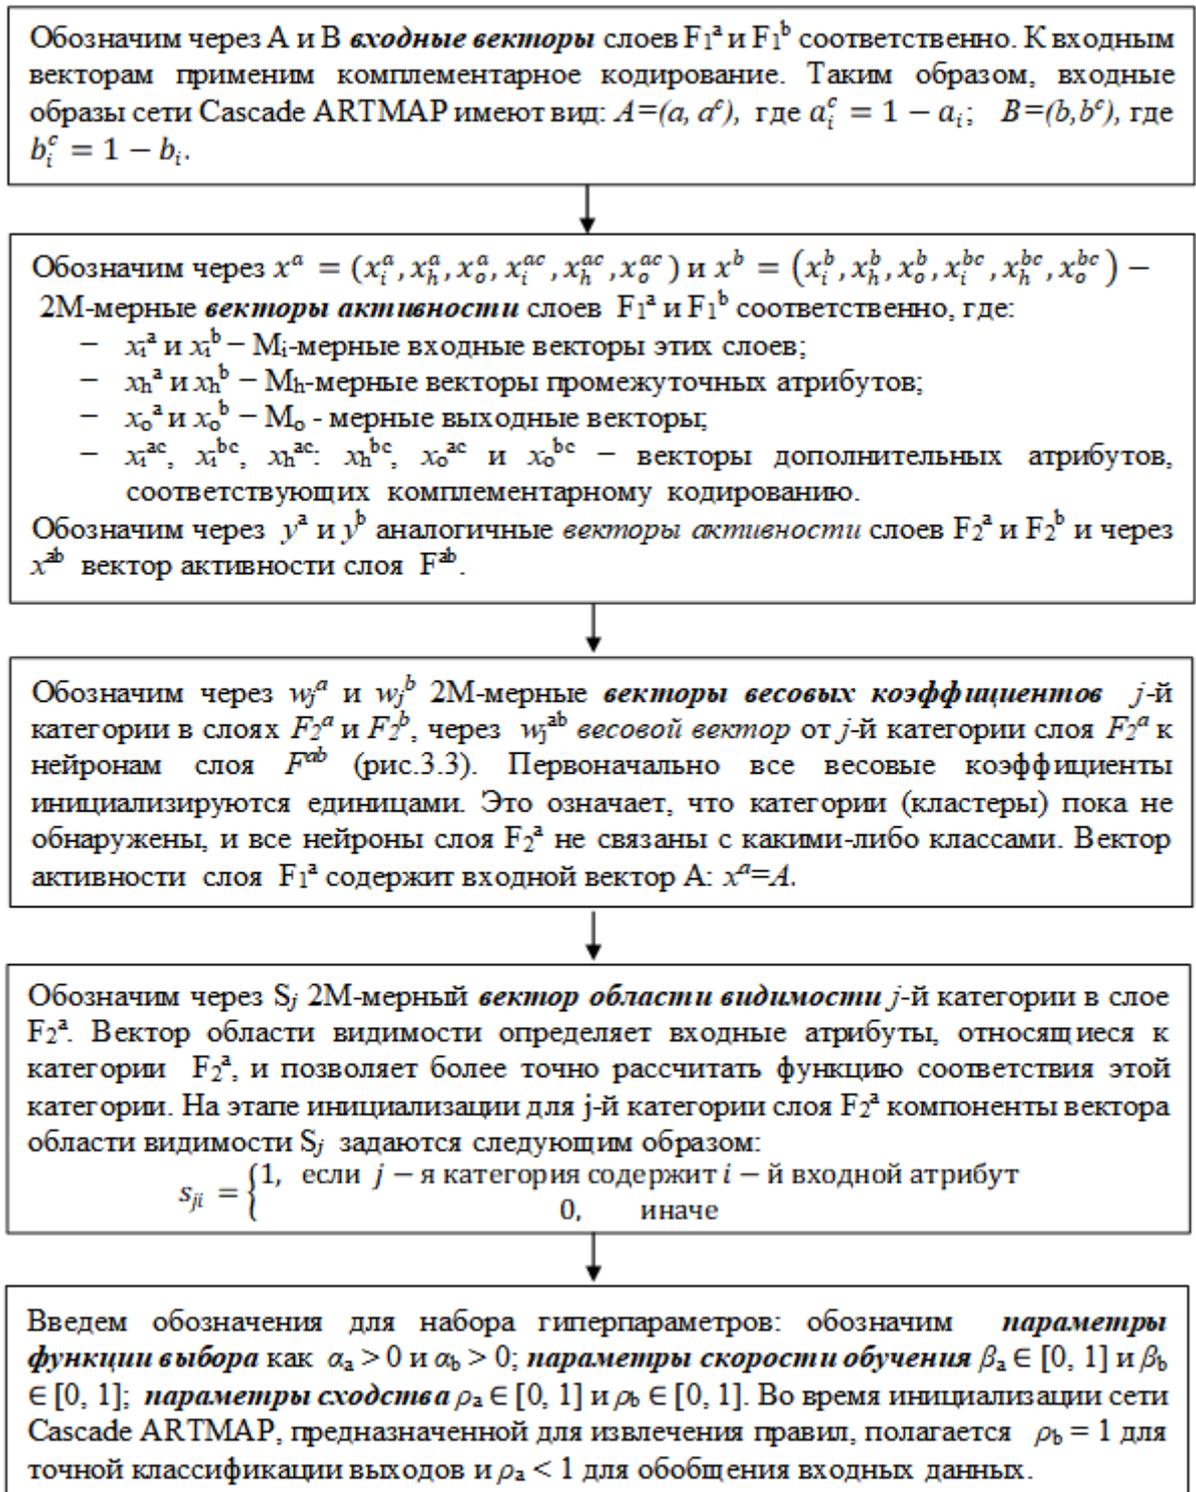


Рис. 3.3. Правила инициализации всех основных элементов сети.

Остальные этапы реализации алгоритма обучения модулей ARTa и ARTb рассмотрим отдельно (под буквами а и b соответственно).

1(a). Функция выбора T_j^a для каждого нейрона j слоя F_2^a определяется по следующему принципу:

$$T_j^a = \frac{|x^a \wedge w_j^a|}{\alpha_a + |w_j^a|}, \quad (3.1)$$

Будем считать, что система выполнила выбор кластера, если найден такой кластер J , при котором выполняется следующее условие.

$$T_J^a = \max_j T_j^a. \quad (3.2)$$

Если максимальное значение достигается на нескольких кластерах, будет выбран кластер с наименьшим индексом. При выборе j -го кластера будет установлено:

$$y_j^a = 1, \text{ и } y_j^a = 0 \text{ для } j \neq J.$$

2(a). Если функция соответствия выбранного нейрона m_j^a удовлетворяет критерию соответствия, то возникает резонанс.

$$m_j^a = \frac{|x^a \wedge w_j^a \wedge S_j|}{|x^a \wedge S_j|} \geq \rho_a, \quad (3.3)$$

Если условие не выполнено, то осуществляется сброс соответствия, после чего величина функции выбора T_j^a остается равной 0 в течение всего процесса анализа входного вектора A , чтобы избежать последующего выбора того же самого кластера. После этого шаг 1a повторяется и происходит выбор нового индекса J .

3(a). Если вектор A , который является текущим входом, отличается от всех имеющихся кластеров, то для него формируется новый кластер. В этом случае происходят изменения в весах нейрона J в слое F_2^a .

$$w_j^a \leftarrow \beta_a (x^a \wedge w_j^a) + (1 - \beta_a) w_j^a \quad (3.4)$$

1(b). При выборе кластера для входного вектора B в слое F_2^b применяется аналогичный подход. Нейрон K , выбранный в слое F_2^b , сохраняет шаблон слоя F_1^b с использованием следующей формулы:

$$w_K^b \leftarrow \beta_b (x^b \wedge w_K^b) + (1 - \beta_b) w_K^b \quad (3.5)$$

После этого кластер J в слое F_2^a устанавливает связь с кластером K в слое F_2^b через настройку весов слоя F^{ab} .

$$w_{JK}^{ab} = 1, w_{Jk}^{ab} = 0 \text{ для } k \neq K. \quad (3.7)$$

Если нейрон, выбранный в слое F_2^a , является частью уже существующего кластера J , то выходной вектор слоя F^{ab} будет равным его весовым коэффициентам. Следовательно, выход x^{ab} будет иметь вид:

$$x_J^{ab} = w_J^{ab} \quad (3.8)$$

2(b). Функция выбора T_k^b для каждого нейрона с номером k в слое F_2^b имеет вид:

$$T_k^b = x_k^{ab}$$

Система повторно выбирает определенный кластер с номером K , где:

$$T_K^b = \max_k T_k^b.$$

Когда выбран K -й кластер, полагается $y_K^b = 1$ и $y_k^b = 0$ для $k \neq K$. Выходы активированного нейрона слоя F_1^b полагаются равными весовым коэффициентам слоя F_2^b :

$$x^b = w_K^b \quad (3.9)$$

Если нейрон слоя F_1^b активирован выбором кластера в F_2^b , условие завершения вывода проверяется вычислением выходного сигнала g :

$$g = \sum_{i=1}^{M_0} (x_{oi}^b + x_{oi}^{bc}) \quad (3.10)$$

Вывод делается всякий раз, когда для данного входа определен какой-либо выходной атрибут, в этом случае $g > 0$. Если вывод не сделан, т.е. $g = 0$, вектор активности x^a обновляется с учетом вектора x^b по формуле:

$$x^a \leftarrow x^a \vee x^b, \quad (3.11)$$

где нечеткая операция \vee определяется как $(p \vee q)_j = \max(p_j, q_j)$.

Этап 3б. Если вывод сделан, то есть $g > 0$, функция соответствия m_K^b прогноза x^b и входного вектора B слоя F_1^b вычисляется следующим образом:

$$m_K^b = \frac{|x^b \wedge B|}{|B|} \quad (3.12)$$

Если полученное значение m_K^b удовлетворяет критерию соответствия модуля ART_b ($m_K^b \geq \rho_b$), возникает резонанс. Активированные нейроны слоев F_2^a и F_2^b обучаются по формулам, аналогичным выше. Несовпадение прогнозов активирует процесс проверки сходства. С помощью процедуры поиска минимальных совпадений определяется нейрон j , который имеет минимальное значение функции соответствия. Функция выбора T_j^a нейрона j устанавливается равной нулю. Величина параметра ρ_a в модуле ART_a повышается до чуть более высокого значения, чем соответствие, достигнутое нейроном j :

$$\rho_a \leftarrow \max\{\rho_a, \min_j m_j^a + \epsilon\}. \quad (3.13)$$

Идеальное соответствие возникает, когда система пытается увеличить ρ_a до значения, равного единице. Идеальное соответствие в ART_a в сочетании с несоответствием в ART_b указывает на существование противоречивых знаний, где идентичные входные наборы связаны с разными результатами классификации.

После проверки сходства новый цикл работы сети повторяется.

Более кратко указанные этапы можно описать в виде следующего **алгоритма**.

Шаг 1. Задание гиперпараметров сети:

- параметров выбора ($\alpha_a, \alpha_b > 0$): влияют на выбор кластера;
- параметры скорости обучения ($\beta_a, \beta_b \in [0, 1]$);
- параметры сходства ($\rho_a, \rho_b \in [0, 1]$);
- параметр точности ϵ .

Инициализация областей видимости категорий: для j -й кластера слоя F_2^a компоненты вектора области видимости S_j задаются следующим образом:

$$S_{ji} = \begin{cases} 1, & \text{если } j - \text{й кластер содержит } i - \text{й входной атрибут} \\ 0, & \text{иначе.} \end{cases}$$

Инициализация матрицы весовых коэффициентов W .

Шаг 2. Подача на вход входного, а на выход - выходного вектора из обучающей пары (A, B) .

Шаг 3. Вычисление функций выбора для входного и выходного вектора:

$$T_j = \max_j T_j = T_j^a = \frac{|x^a \wedge w_j^a|}{\alpha_a + |w_j^a|}.$$

Шаг 4. Вычисление функции соответствия входного вектора и выбранного входного кластера с помощью

$$M_a = \frac{|x^a \wedge w_j^a \wedge S_j|}{|x^a \wedge S_j|}, \quad M_b = \frac{|x^b \wedge B|}{|B|}$$

Соответствие между кластерами устанавливается при выполнении условия $M_a \geq \rho_a$, $M_b \geq \rho_b$

Шаг 5. Вычисление выходного сигнала g : $g = \sum_{i=1}^M (x_i^b + x_i^{ab})$.

Если вывод не сделан, т.е. $g = 0$, вектор активности x^a обновляется с учетом вектора x^b по формуле: $x^a \leftarrow x^a \vee x^b$,

Шаг 6. Обучение весовых коэффициентов по формулам:

$$w_j^a \leftarrow \beta_a (x^a \wedge w_j^a) + (1 - \beta_a) w_j^a; \quad w_K^b \leftarrow \beta_b (x^b \wedge w_K^b) + (1 - \beta_b) w_K^b$$

Адаптация весов для модуля F^{ab} выполняется следующим образом:

$$w_{jK}^{ab} = 1, w_{jk}^{ab} = 0 \text{ для } k \neq K.$$

Обновление параметра резонанса

$$\rho_a \leftarrow \max\{\rho_a, \min_j m_j^a + \epsilon\}.$$

Шаг 7. Вычисление функции ошибки сети (доля правильно предсказанных кластеров) и возврат на этап 2.

3.2. Построение решающих правил с помощью нейронной сети Cascade

ARTMAP

Характеристические особенности сетей ART предоставляют возможность для быстрого обучения, основанного на подходе, при котором входные данные

постоянно применяются в качестве дополнения к существующим знаниям в рамках имеющейся модели. Здесь имеет значение совместимость знаний и правил, вместе составляющих вычислительную парадигму, основанную на принципах, отличающих сети ART от других систем машинного обучения. Такой подход и алгоритмы могут применяться в качестве обработки поточных сведений, непрерывно поступающих показателей, позволяя на ходу, без длительного предварительного обучения, получать из данных нужные знания, преобразовывая их в понятные правила принятия решений. В процессе приема новой информации обработки данные правила корректируются и уточняются.

Как уже отмечалось, сеть Cascade ARTMAP функционирует схожим образом с формированием знаний в экспертных системах, где правила на основе нечеткого логического вывода преобразуются в четкие системы распознавания. Cascade ARTMAP иницируется правилами нечеткого логического вывода, что формирует начальную структуру сети нейронов, способствуя ускорению обучающего процесса и повышению точности прогноза, так как образует кластеры, к данному моменту не представленные исходными данными.

Процесс формирования начального множества правил выполняют в 2 этапа:

1. Из имеющихся правил извлекают атрибуты z_i и формируют полный список (словарь) атрибутов $Z=(z_1, z_2, \dots z_M)$.
2. На основе полученных данных каждое правило преобразуют в входные и выходные векторы (соответственно A и B), использующиеся на входе для модулей ARTa и ARTb.

Таким образом, правилу “IF $x_1, x_2, \dots x_M$ THEN $y_1, y_2, \dots y_M$ ” с учетом комплементарного кодирования будет соответствовать бинарный входной вектор $A=(a_1, a_2, \dots a_M, a_1^c, a_2^c, \dots a_M^c)$ и бинарный выходной вектор $B=(b_1, b_2, \dots b_M, b_1^c, b_2^c, \dots b_M^c)$, где

- $a_i = 1, a_i^c = 0$, если $x_i = z_i$;
- $a_i = 0, a_i^c = 1$, если $x_i = \bar{z}_i$;
- $a_i = 0, a_i^c = 0$, если i -й атрибут не представлен в посылке правила.

Аналогично:

- $b_i = 1, b_i^c = 0$, если $y_i = z_i$;
- $b_i = 0, b_i^c = 1$, если $y_i = \bar{z}_i$ и
- $b_i = 0, b_i^c = 0$, если i -й атрибут не представлен в выводе правила.

Векторные пары, полученные из правил, затем используются в качестве тренировочных образцов для инициализации сети Cascade ARTMAP. Каждый отдельный вектор А соотносится с некоторым кластером в модуле ART_a, а также каждый отдельный вектор В попадает в некоторый кластер в ART_b. Учитывая, что пара векторов А и В происходит от одного правила, их соответствующие кластеры распознавания связаны через поле F^{ab}.

Для обучения сети Cascade ARTMAP используется алгоритм обратного отслеживания, который идентифицирует все правила (кластеры слоев F_2^a и F_2^b), которые ответственны за получение текущего выходного значения. То есть, если, например, текущий входной вектор активировал j -й кластер из слоя F_2^a , алгоритм идентифицирует предшествующее множество кластеров $\Psi(j)$, которые привели к выбору кластера j . Обратное отслеживание в этом случае происходит в направлении $F_2^a \rightarrow F_1^a \rightarrow F_1^b \rightarrow F_2^b \rightarrow F^{ab} \rightarrow F_2^a$. Например, на рисунке 3.2 алгоритм отследит кластер j_2 слоя F_2^a до его предшественников С и D в слое F_1^a . Затем он проверит, что С является промежуточным атрибутом, активируемым в F_1^b и, наконец, отследит кластер j_1 в слое F_2^a . Отслеживание останавливается на j_1 , поскольку все предшественники этого кластера являются входными атрибутами. То есть предшественником кластера j_2 слоя F_2^a является кластер j_1 , поэтому алгоритм обучения будет корректировать не только веса нейрона j_2 , но и весовые коэффициенты нейрона j_1 .

Если прогноз, сделанный нейроном J , верен, то для каждого нейрона j слоя F_2^a в предшествующем множестве $\Psi(j)$, весовой вектор w_j^a уменьшается в сторону его нечеткого пересечения с вектором активности A слоя F_1^a . Таким образом, срабатывающее правило учится игнорировать те особенности, которые

отсутствуют в текущем входе. Это приводит к обобщению, уменьшая количество признаков, на которые ссылается правило.

Более сложная ситуация возникает при возникновении ошибки классификации. При длинной цепочке срабатывания правил, изменение весов может быть затруднено, так как неясно, какое правило в ходе логического вывода приводит к ошибке. Чтобы справиться с предсказанным несоответствием, процесс отслеживания минимального соответствия повышает параметр сходства ρ_a модуля ART_a на чуть большее значение, чем минимальное соответствие, достигнутое по имеющимся правилам. В этом случае предлагается проводить отслеживание соответствия эквивалентно параллельному механизму, используемому в сети Fusion ARTMAP, описанной в работе [11]. Этот метод блокирует работу узла F_2^a с минимальным соответствием для текущих входных данных. Предполагается, что правило с наихудшим соответствием, скорее всего, является правилом, которое вызывает ошибку классификации. Затем система проходит еще один цикл поиска в памяти и процесс логического вывода с повышенным параметром сходства до тех пор, пока не будет достигнут резонанс.

Процесс извлечения правил из сети Cascade ARTMAP достаточно прост. Как уже отмечалось, каждый нейрон в слое F_2^a представляет собой кластер распознавания входных шаблонов модуля ART_a. Через промежуточный слой F^{ab} каждый такой нейрон связан с кластером модуля ART_b в слое F_2^b , который, в свою очередь, кодирует результат классификации. Обученные весовые векторы слоя F_2^a , запоминают набор правил, связывающих входные данные с результатами. Итоговое количество правил равно количеству нейронов слоя F_2^a , которые сформировались во время обучения. Формально система производства правил состоит из трех основных компонент: компоненты рабочей памяти, компоненты формирования правила и внешнего механизма вывода или обработки правил. Обработчик правил многократно выполняет трехфазный цикл, состоящий из фазы совпадения, фазы выбора и фазы выполнения (рис. 3.4.).

В фазе совпадения обработчик сравнивает предыдущий набор атрибутов

каждого правила с содержимым рабочей памяти. В конфликтный набор включаются правила с полностью совпадающими атрибутами. В фазе выбора одно правило выбирается из конфликтного набора с помощью некоторых стратегий. Если конфликтный набор пуст, цикл прекращается. В противном случае, в фазе выполнения интерпретатор добавляет в рабочую память цепочку атрибутов выбранного правила.

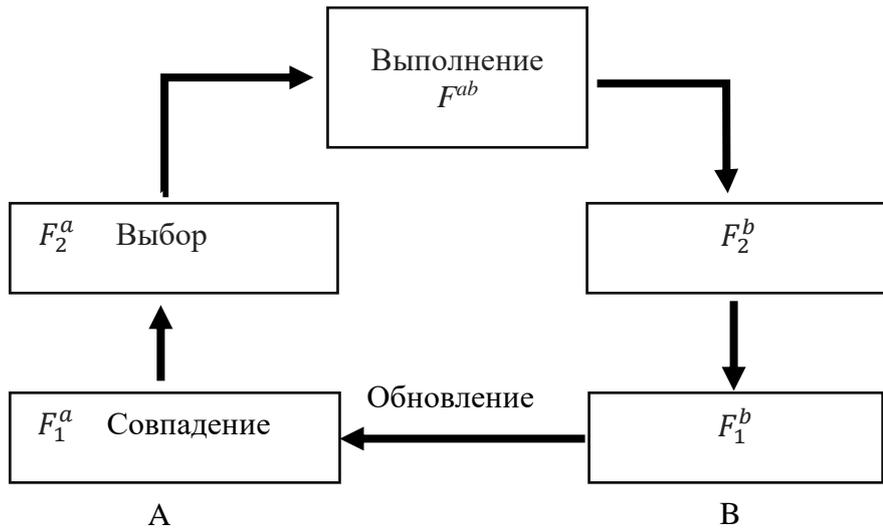


Рис 3.4 Формирование правил в сети Cascade ARTMAP.

В Cascade ARTMAP атрибуты полей F_1^a и F_1^b могут быть определены как компоненты рабочей памяти. F_1^a поддерживает текущее состояние памяти A и обеспечивает соответствие условий и запуска правила. F_1^b сохраняет следующее состояние памяти B , полученное согласно правилу. Компонент формирования правила реализуется двумя полями категорий F_2^a и F_2^b , полем карты F^{ab} и их взаимосвязями. Согласование, выбор и выполнение трехфазного цикла выполняется без привлечения внешнего обработчика правил.

На фазе сопоставления вычисляется функция выбора T_j^a для каждого кластера (правила) F_2^a на основании состояния памяти A . При параллельной реализации фаза согласования может быть выполнена за один процесс активации. Этап выбора реализуется путем взаимодействия "победитель получает все" между всеми нейронами F_2^a , в котором будет идентифицирован нейрон F_2^a с наибольшей функцией выбора T_j^a . Если выбранный нейрон (правило) не удовлетворяет критерию сходства ART_a , система проходит еще

один этап цикла поиска в памяти, чтобы выбрать другой нейрон слоя F_2^a , который будет удовлетворять критерию сходства ART_a . Если такого нейрона не существует, цикл останавливается. В противном случае, в фазе выполнения, цепочка атрибутов выбранного правила будет считана в F_1^b . Для применения правила не требуется точного совпадения, пока оно удовлетворяет критерию сходства ART_a . В конце цикла новое состояние памяти B используется для обновления A в слое F_1^a для подготовки к следующему циклу логического вывода. В приведенном ранее примере каскада правил (рисунок 3.2. в п. 3.1) набор входных атрибутов $\{A, B, D\}$ активирует нейрон J_1 в слое F_2^a , который определяет результат C . В процессе обновления памяти C возвращается из F_1^b в F_1^a . Состояние памяти B , которое содержит $\{A, B, C, D\}$, активирует нейрон J_2 в следующем цикле вычисления, который выведет результат E .

Как правило, большие наборы данных заставляют Cascade ARTMAP генерировать слишком много правил для их практического применения. Задача извлечения правил состоит в том, чтобы выбрать небольшой набор правил для хорошо прогнозируемых категорий и описать их в понятной форме.

С этой целью с каждым принятым правилом можно связать коэффициент достоверности, раскрывающий актуальность правила в данный временной промежуток и определяющий его точность.

Удаление категорий распознавания с низкой степенью достоверности, созданных на нетипичных примерах, приводит к созданию сетей меньшего размера. Коэффициент достоверности рассчитывается для каждого кластера слоя F_2^a с точки зрения частоты встречаемости этого кластера в обучающей выборке и точности классификации объектов, относящихся к данному кластеру. Для оценки коэффициента достоверности, для каждого j -го кластера слоя F_2^a вычисляются два показателя: доля μ_j соотнесенных кластеру j обучающих векторов и доля π_j объектов, правильно классифицированных кластером j (относительно количества всех объектов, относящихся к данному кластеру). Коэффициент достоверности правила j вычисляется следующим образом: $k_j = \Delta\mu_j + (1 - \Delta)\pi_j$, где $\Delta \in [0, 1]$

— это коэффициент, настраиваемый в процессе обучения.

Не менее важной проблемой является не сокращение количества самих правил, а сокращение количества посылок в правилах, то есть отыскание набора наиболее компактных правил. При извлечении правила ненулевой вес каждого нейрона слоя F_2^a преобразуется в посылку соответствующего правила. Аналогичным образом можно рассчитать коэффициент достоверности для каждой посылки в каждом правиле, основываясь на точности этого правила на обучающих и тестовых наборах. Когда правило j совершает ошибку классификации, каждая посылка этого правила, изменяется пропорционально коэффициенту достоверности правила. Так как одни и те же посылки могут входить в разные правила, коэффициенты достоверности посылок и правил будут со временем различаться. После определения коэффициента достоверности для каждой посылки локальная стратегия отсекающая может устранять излишние посылки.

ВЫВОДЫ ТРЕТЬЕЙ ГЛАВЫ

1. Интерпретация результатов, получаемых при использовании методов и алгоритмов интеллектуальной поддержки принятия управленческих решений важна в задачах управления организациями. Лицу, принимающему решение, нужно не просто указать на неблагополучные мониторинговые показатели или предоставить наиболее подходящую стратегию реагирования на изменение показателей, но и объяснить, на основании чего такое решение принято. Многие алгоритмы машинного обучения работают в режиме “черного ящика”, что затрудняет получение таких объяснений. Однако в структуре сетей Cascade ARTMAP заложен внутренний механизм преобразования результатов кластеризации мониторинговых данных в набор понятных правил формата “если-то”.

2. Для обучения сети Cascade ARTMAP необходима ее инициализация некоторым начальным обучающим набором правил (сформированных

экспертами или извлеченных из регламентов к показателям мониторинга), а затем сеть инкрементно обучается с использованием описанного в данной главе механизма обратного отслеживания, пополняя существующий набор правил и адаптивно реагируя на оперативно поступающую мониторинговую информацию.

3.2. С целью разработки специального математического и программного обеспечения систем управления и механизмов принятия управленческих решений в данной главе предлагается модифицированный алгоритм построения решающих правил с помощью нейронной сети Cascade ARTMAP. В качестве модификации уже существующего в литературе подхода к построению правил на основе сети Cascade ARTMAP для оценки каждого правила вводится в рассмотрение коэффициент достоверности, основанный на точности этого правила на тестовых данных. Такие правила позволяют экспертам увидеть, изменения каких мониторируемых показателей повлияли на текущую ситуацию и понять, что можно сделать для ее исправления.

ГЛАВА 4. РАЗРАБОТКА СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ УПРАВЛЕНИЯ ОХРАНОЙ ПРИРОДЫ НА ОСНОВЕ ДАННЫХ ЭКОЛОГИЧЕСКОГО МОНИТОРИНГА

4.1 Использование нейросетевых интерпретируемых алгоритмов анализа мониторинговых данных при управлении природоохранной деятельностью

Разработанные в данном исследовании алгоритмы прошли практическую апробацию в составе модулей системы поддержки принятия решений при управлении природоохранной деятельностью на уровне региона (мезоуровне). Разработанный программный комплекс был внедрен в состав системы поддержки принятия решений по в «Центре гигиены и эпидемиологии в Воронежской области». Данная организация осуществляет деятельность территориального управления Роспотребнадзора в Воронежской области по проведению социально-гигиенического мониторинга. Она также формулирует предложения для органов исполнительной власти относительно необходимых мер для устранения выявленных вредных воздействий на окружающую среду, которые могут негативно влиять на условия обитания людей.

Применительно к задаче управления охраной окружающей среды разработанная система может быть описана в виде кортежа:

$$\langle P_t, K_t, R_t, V_t, U_t, N_t \rangle, \text{ где}$$

- P_t - входной набор мониторинговых показателей о состоянии окружающей среды в момент времени t ;
- K_t –набор кластеров, на которые разбивается территория региона с учетом мониторинговых показателей в момент времени t ;
- R_t -стратификация уровней экологического риска для получаемых кластеров;
- V_t - визуальное представление полученной структуры классов или кластеров на гугл-карте региона;
- U_t - комплекс управляющих воздействий в зависимости от стратификации уровня риска;

– N_t -комплекс нейросетевых моделей, устанавливающих соответствия :

- 1) $P_t \rightarrow K_t$ (модель Fuzzy ART для кластеризации, то есть выделения территорий с примерно одинаковым уровнем риска),
- 2) $P_t \rightarrow R_t$ (модель Fuzzy ARTMAP для классификации, то есть стратификация территорий по уровню риска),
- 3) $P_t \rightarrow U_t$ (модель Cascade ARTMAP построения решающих правил при автоматизированной выработке управленческих решений).

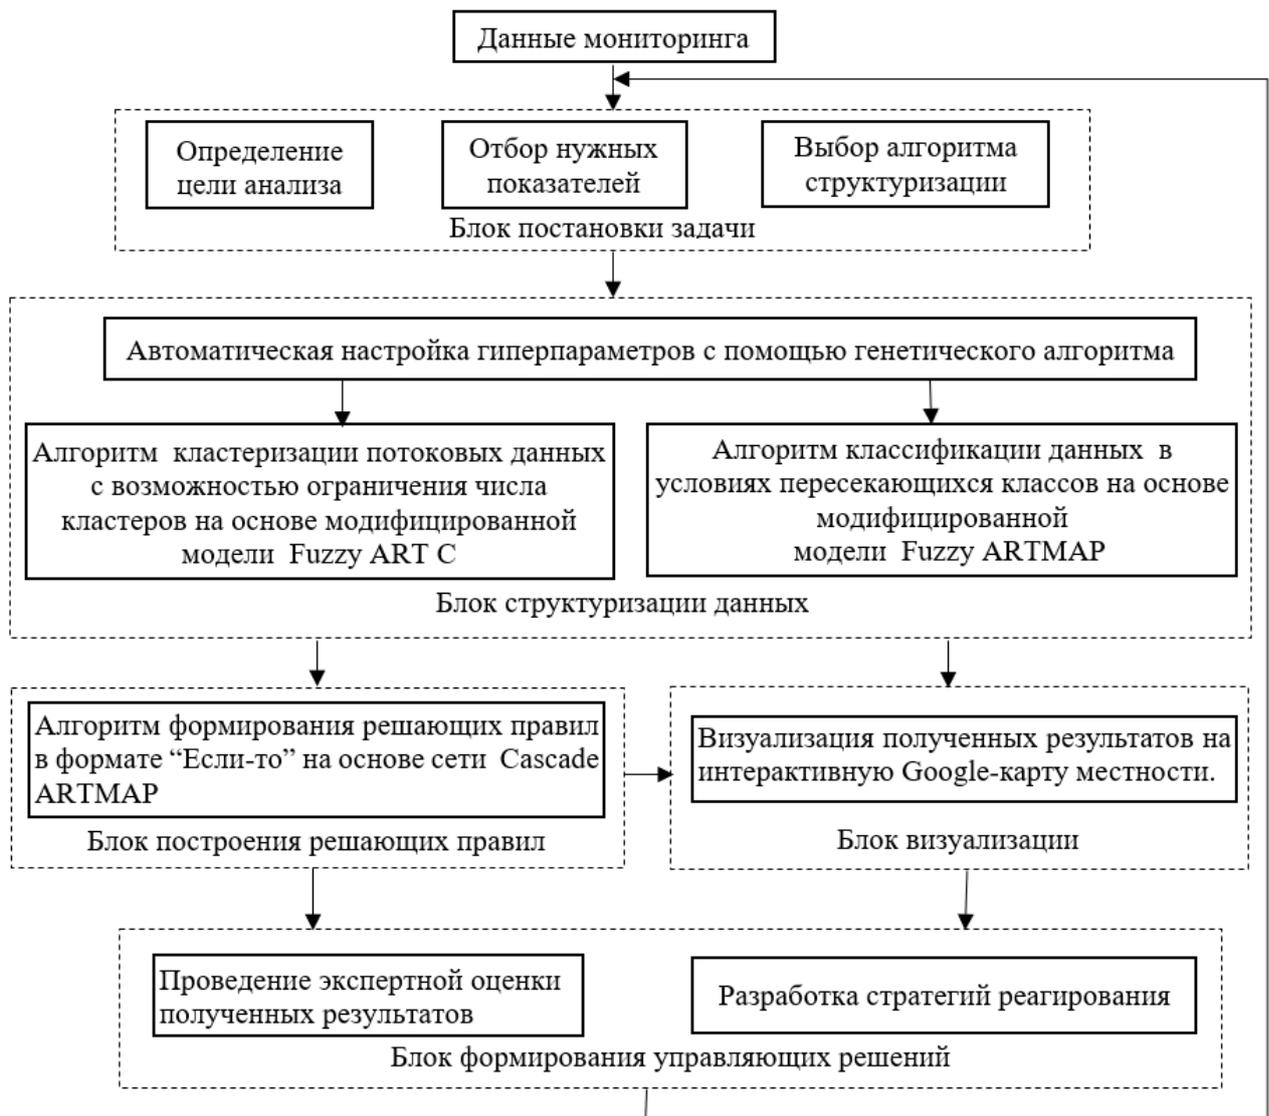


Рис. 4.1. Структурно-функциональная организация системы поддержки управления охраной природы на основе мониторинговых данных.

На рис. 4.1 представлена структурно-функциональная организация разработанной системы поддержки принятия решений при управлении

охраной природы на основе мониторинговых данных с использованием сетей семейства ART.

На рис 4.2. представлена структура разработанных в данном исследовании модулей системы поддержки принятия решений по управлению охраной окружающей среды. СППР состоит из трех основных модулей: модуль для решения задач кластеризации, модуль для решения задач классификации и модуль для построения решающих правил. Каждый из модулей реализован с использованием одной из сетей семейства ART, модифицированных для случая обработки мониторинговых данных. Для визуализации данных использовалась библиотека Folium.

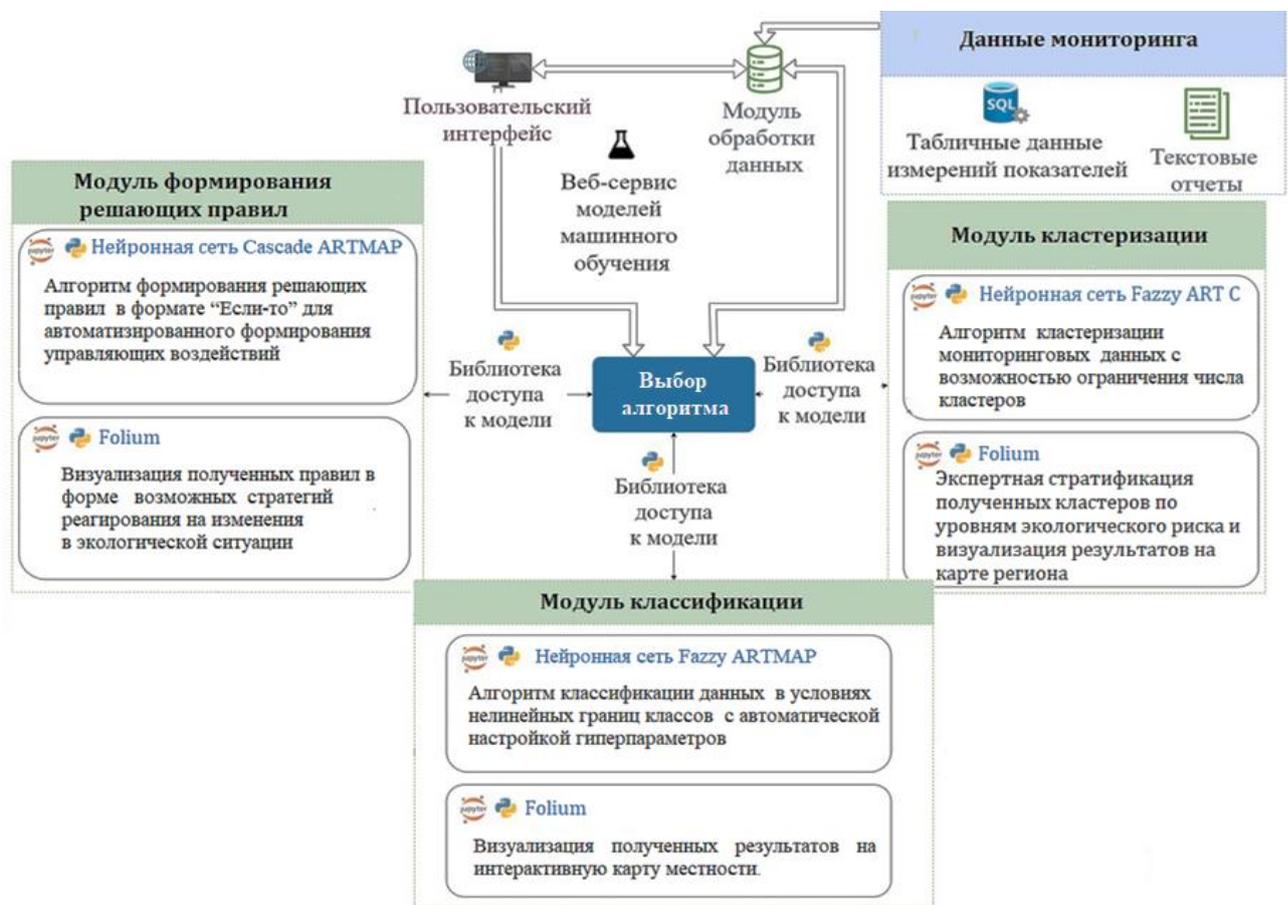


Рис. 4.2. Структура модулей системы поддержки принятия решений по управлению охраной окружающей среды.

Далее рассмотрим примеры двух практических задач, решенных с помощью разработанной системы: задачи комплексного районирования

территорий Воронежской области на основе мониторинговых данных по совокупности из 17 показателей, характеризующих общее экогеологическое состояние территории, и отдельно задачи оценки загрязнения окружающей среды на основе показателей состояния воды, воздуха и почвы. Результатами решения этих задач будет автоматизированная выработка предлагаемых управляющих воздействий, максимально соответствующих текущей наблюдаемой ситуации.

4.2 Нейросетевой подход к комплексному экогеологическому районированию территорий Воронежской области на основе мониторинговых данных

Исходные данные первой задачи оценки состояния экологии региона представляют собой ряд мониторинговых показателей, снятых в Воронежской области с разрешением 500х500 метров.

Список используемых показателей включает 4 экзогенных показателя, связанных с эрозиями, оползнями и заболачиванием; три показателя по гидросфере; два показателя состояния почвы; количество выбросов вредных веществ в атмосферу, интегральный критерий климатической комфортности, интегральный показатель здоровья населения, степень изменения морфологических признаков высших растений. Набор обрабатываемых данных составил 206 тысяч 676 значений для каждого из исходных показателей. Значение каждого показателя измеряется в целочисленной шкале. Общее число показателей – 17 (включая географические координаты точки сбора значений показателя). Данные предоставлены территориальным управлением Роспотребнадзора, где накоплен большой фактический материал для анализа природно-техногенных показателей Воронежской области.

Для решения задачи кластерной структуризации данной мониторинговой информации разработан программный комплекс, реализующий модификацию сети Fuzzy ART, позволяющую ограничивать максимальное число создаваемых

кластеров.

Таблица 4.1. Фрагмент перечня исходных показателей экологического мониторинга

1	Районирование территории по степени опасности развития процессов овражной эрозии		
	Градации	Класс	Балл
	Территории с почти полным отсутствием процессов овражной эрозии. 1-я категория опасности.	1	1
	Территории весьма слабо подверженные развитию процессов овражной эрозии. 2-я категория опасности.	2	2
	Территории слабо подверженные развитию процессов овражной эрозии. 3-я категория опасности.	3	4
	Территории подверженные развитию процессов овражной эрозии. Водоразделы в пределах Среднерусской антеклизы. 4-я категория опасности.	4	6
	Территории средне подверженные развитию процессов овражной эрозии. 5-я категория опасности.	5	8
	Территории сильно подверженные развитию процессов овражной эрозии. 6-я категория опасности.	6	10
2	Районирование территории по степени опасности развития оползней		
	Территории, где вероятность развития оползней низкая.	1	1
	Территории, где возможно развитие мелких оползней течения.	2	4
	Территории, где возможно развитие средних оползней выдавливания и мелких оползней течения.	3	6
	Территории, где вероятно развитие средних и мелких оползней выдавливания и течения.	4	8
	Территории, где вероятно развитие крупных оползней.	5	10

8	Количество выбросов вредных веществ в атмосферу от стационарных источников (по данным Росгидромета)		
	0 – 1 тыс. тонн	1	1
	1 – 2 тыс. тонн	2	2
	2 – 4 тыс. тонн	3	5
	4 – 10 тыс. тонн	4	8
	10 – 16 тыс. тонн	5	10
9	Степень изменения морфологии спор высших растений		
	10-30%	1	1
	30-50%	2	4
	50-70%	3	7
	70-90%	4	10
10	Естественная защищенность от загрязнения основных эксплуатационных горизонтов подземных вод		
	Защищенные	1	1
	Условно защищенные	2	5
	Незащищенные	3	10
11	Районирование территории по степени опасности развития процессов заболачивания		
	Территории не подверженные процессам заболачивания.	1	1
	Территории, где возможно локальное заболачивание.	2	2
	Территории, местами подверженные заболачиванию – формирование верховых болот.	3	4

Разработанный комплекс дает возможность осуществлять в процессе интерактивной работы с пользователем выбор любого набора из имеющегося списка 17-ти показателей и оценку на их основе состояния окружающей природной среды. Особо следует отметить, что сеть Fuzzy ART очень подходит для решения данной задачи, т.к. обеспечивает быстроту обработки больших массивов данных и стабильность получаемой кластерной структуризации, но при этом в данном случае не требуется тонкая настройка гиперпараметров алгоритма под конкретный набор данных. Разработанные экспертами стратегии корректировки экологического состояния среды будут применяться к значительным областям, а не к отдельным точкам, поэтому небольшое «гуляние» границ кластеров в зависимости от значений гиперпараметров вполне допустимо, важно выделение общих классов.

Таким образом, работа с программным модулем Fuzzy ART не требует вмешательства специалиста в области нейронных сетей для настройки гиперпараметров. Примеры получающихся кластеров можно видеть на рис. 4.3. и 4.4.

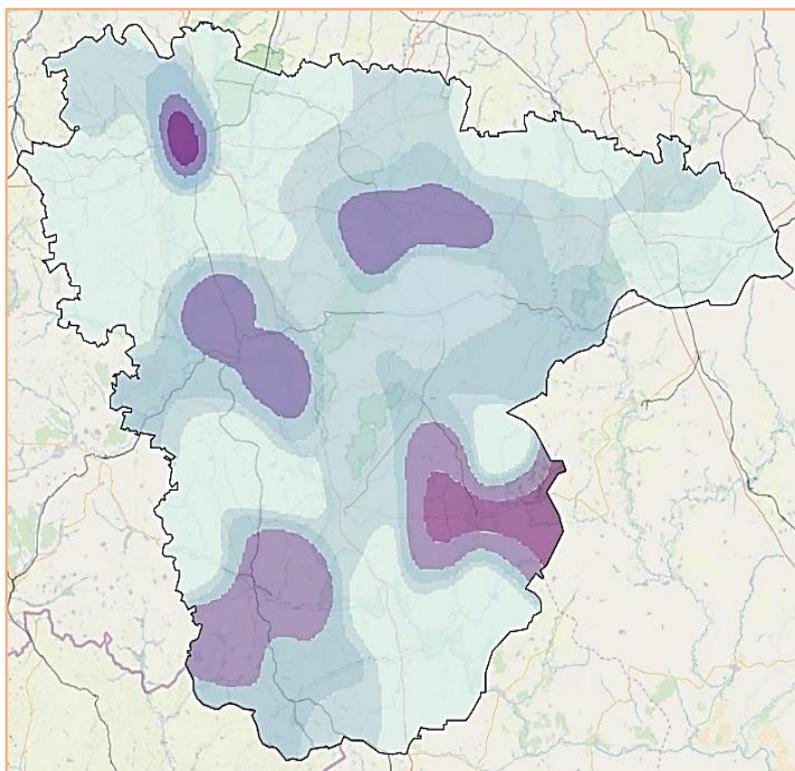


Рис. 4.3 Кластеризация по техногенным факторам.

Значения коэффициента силуэта для результатов кластеризации, приведенных на рис. 4.3. равно $s=0.91$, а для кластеризации на рис 4.4. $s=0.83$ (что неудивительно, так как на рис. 4.4. кластеры плотнее сгруппированы). Однако оба эти значения говорят о том, что с помощью сети Fuzzy ART в данных найдены достаточно плотные и разделимые кластеры.

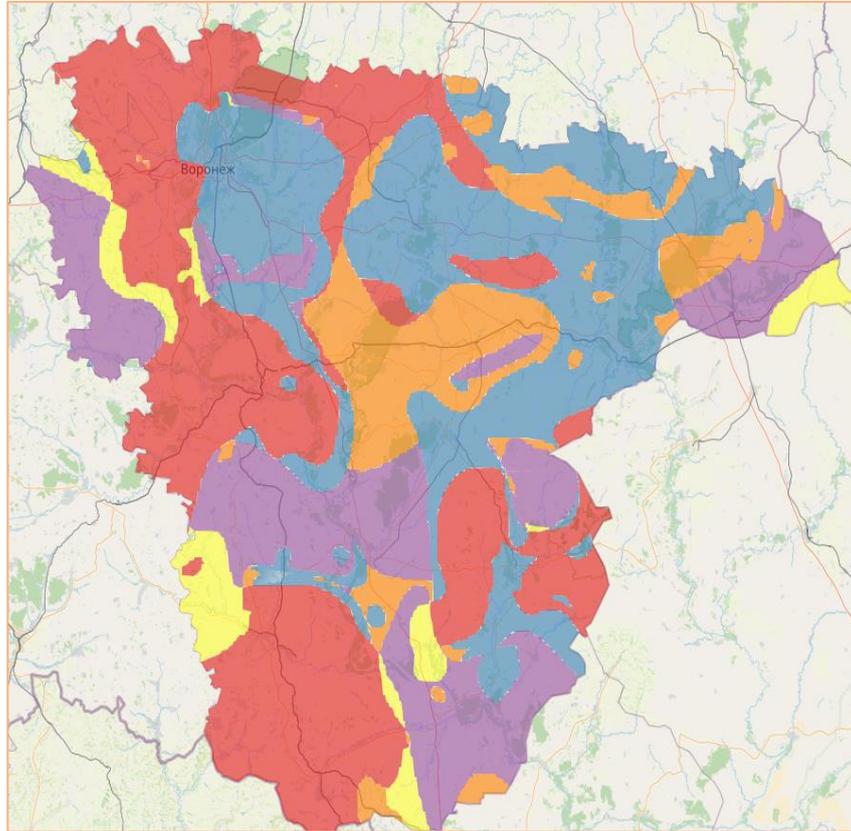


Рис. 4.4 Кластеризация по климатическим факторам и интегральному показателю здоровья населения

Для интеграции разработанных методов в полноценную ГИС -систему была использована библиотека Folium. Это Python-библиотека для визуализации географических данных, которая содержит всю необходимую картографическую информацию. Folium позволяет визуализировать данные, которые были обработаны в Python, на интерактивной карте местности. Это позволяет осуществлять привязку данных к карте для визуализации, выделение областей на карте, передачу произвольных изображений в качестве маркеров.

Интерактивные карты, построенные с помощью библиотеки Folium, допускают

увеличение или уменьшение масштаба до необходимой степени детализации с целью наглядного просмотра границ кластеров, выделения буферных зон (рис. 4.5).

Рассмотрим основные этапы использования разработанного модуля для экогеологического районирования территорий Воронежской области на основе мониторинговых данных.

1. Определение цели анализа экологического состояния и отбор нужных критериев.

2. Проведение с помощью ПО кластеризации массива данных по выбранным компонентам. Первичная визуализация результатов в проекции на модель местности.

3. Корректировка искомого числа кластеров и повторение пункта 2.

4. Проведение экспертной оценки полученных прототипов кластеров и разработка стратегий действий для каждого из них.

5. Возможное дообучение сети при поступлении новых данных и повторение пункта 4.

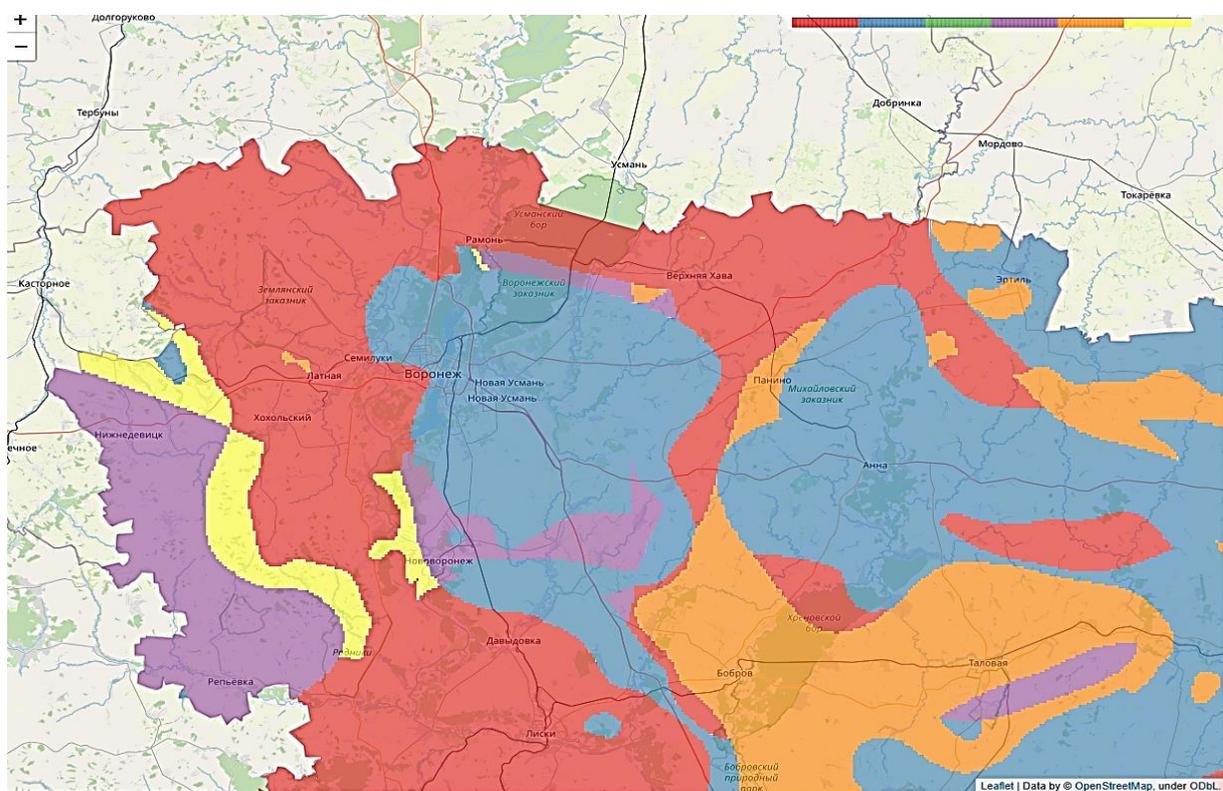


Рис. 4.5 Фрагмент полученной кластеризации.

Отметим, что хотя данные могут быть сгруппированы по географическому признаку (Левый и правый берега Дона, Окско-Донская и Калачская низменности), или по своему происхождению (группа экзогенных показателей, группа гидрологических показателей, группа техногенно-социальных показателей), с помощью разработанного комплекса возможно проведение кластеризации без объединения исходных показателей и дополнительного этапа формирования и отбора значимых признаков, т.к. сети типа ART изначально спроектированы для обработки слабо структурированных данных, и позволяют кластеризовать данные с зависимыми друг от друга входными параметрами.

Отметим, что сеть Fuzzy ART выделяет на карте региона области с схожим в смысле выбранных показателей экогеологическим состоянием. И если эксперты обнаружили отклонение от нормы на некотором участке территории региона, полученная раскраска карты позволит определить, в каких еще районах области возможна схожая проблемная ситуация и применить в них аналогичные управляющие решения.

Полученная модель оценки экологического состояния региона может быть применена и в долгосрочной перспективе. При этом сразу можно выделить два возможных направления анализа. Первый заключается в применении сети для первичной кластеризации и построении схемы стратегий управления экологической ситуацией в регионе, а второй – в отслеживании тенденций изменений состояния экологической ситуации.

Проанализировав один раз глобальное состояние региона, модель позволяет использовать поступающие новые данные для дообучения сети, а её пластичность обеспечит возможность отследить тенденции. Модель также позволяет увидеть миграцию прототипов и вовремя скорректировать схемы стратегий реагирования на состояние окружающей среды региона. Возможность ограничения числа кластеров позволяет провести ещё один тип анализа – последовательное разбиение на 2, 3,...,N кластеров. Анализ расщеплений соответствующих прототипов может позволить эксперту сделать более точные выводы о характере отдельных кластеров и сопутствующим им характеристикам

реальной экологии окружающей среды, что приведет к более эффективным стратегиям по управлению.

4.3 Разработка алгоритма автоматизированного формирования управляющих принятия решений по управлению охраной окружающей среды в регионах

Для исследования возможности применения сети Cascade ARTMAP для автоматической выработки управленческих решений на основе показателей экологического мониторинга разработано программное обеспечение на языке Python, с помощью которого была реализована модифицированная модель Cascade ARTMAP.

В качестве исходных данных использовались те же, что и в п. 4.2. мониторинговые экологические показатели, снятые в Воронежской области с разрешением 500x500 метров [16].

Таблица 4.2. Результаты классификации сети Cascade ARTMAP.

Нейронная сеть Cascade ARTMAP	Размер обучающей выборки (%) для первоначальной настройки сети	Сформировано правил при обучении (в среднем)	Точность классификации (процент правильных ответов) (%)
Без начальной инициализации правилами	25%	18,6	89,9
	50%	22,3	98,1
С начальной инициализацией 6-ю правилами	0%	6,4	49,1
	25%	20,1	97,8
	50%	23,2	98,9
С начальной инициализацией 12-ю правилами	0%	12,5	64,2
	25%	20,1	97,2
	50%	25,3	99,5
С начальной инициализацией 18-ю правилами	0%	18,2	76,7
	25%	20,3	97,6
	50%	25,4	100

Для проверки работоспособности сети Cascade ARTMAP экспертами было сформулировано 18 правил для оценки геоэкологического состояния территории в каждой точке мониторинга на основе значений показателей по 4 полученным ранее классам экологического риска: «низкий риск», «средний риск»,

«повышенный риск», «высокий риск». Результаты представлены в таблице 4.2. После обучения сети на некотором подмножестве входных векторов (0%, 10% или 50% исходных данных) запускалась процедура тестирования. Размер обучающей выборки в 0 % означает, что сеть инициализировалась указанным набором правил, а далее запускался режим инкрементного обучения Cascade ARTMAP, при этом оценка точности в таблице приводится для всего набора исходных данных. Если размер обучающей выборки равен, например, 10%, это означает, что на основе 10% исходных данных была сформирована начальная структура сети и определены начальные значения весовых коэффициентов, а оценка точности в таблице приведена для оставшихся 90% исходных данных.

Вначале качество классификации с помощью сети Cascade ARTMAP проверялось без использования начальной базы классификационных правил. Далее сеть инициализировалась подмножеством правил из начальной базы знаний, а затем проводилось обучение и тестирование такие же, как и в предыдущем эксперименте. Из табл. 4.2 следует, что Cascade ARTMAP достаточно точно извлекает скрытые закономерности из набора данных. В среднем (в зависимости от настройки гиперпараметров сети, в частности, порогового значения для коэффициента достоверности правил) в процессе функционирования создается 15-25 правил. Как видно, начальная инициализация априорно известными экспертам правилами существенно повышает точность алгоритма. При инициализации Cascade ARTMAP полным предоставленным экспертами набором из 18 правил даже без этапа предварительного обучения сеть правильно классифицировала 76,7% исходных данных, а после обучения на 50% данных оставшиеся 50% сеть классифицировала безошибочно.

На рис. 4.6 приведен пример классификации Воронежской области по отдельно выбранным мониторинговым факторам, связанным только с показателями гидросферы с результатом автоматизированного формирования управляющих воздействий. Указано, что в связи с загрязнением

эксплуатационных горизонтов подземных вод в выделенном пункте требуются санитарно-технические мероприятия.

В результате проведённого исследования разработано и апробировано на примере Воронежской области программное обеспечение, позволяющее использовать адаптивные классификаторы на базе нейросетевой архитектуры Cascade ARTMAP в составе систем экологического мониторинга. Разработанный подход позволяет исследовать пространственное взаимодействие элементов системы, выявлять ведущие факторы, воздействующие на экологическое состояние и в автоматическом режиме формировать правила классификации в наглядном и понятном для специалистов в предметной области формате. Разработанные алгоритмы могут найти применение для обработки потоковых мониторинговых экологических данных или больших данных, позволяя, без длительной предварительной процедуры обучения, извлекать из этих данных знания и формировать на основе этих знаний управляющие решения.

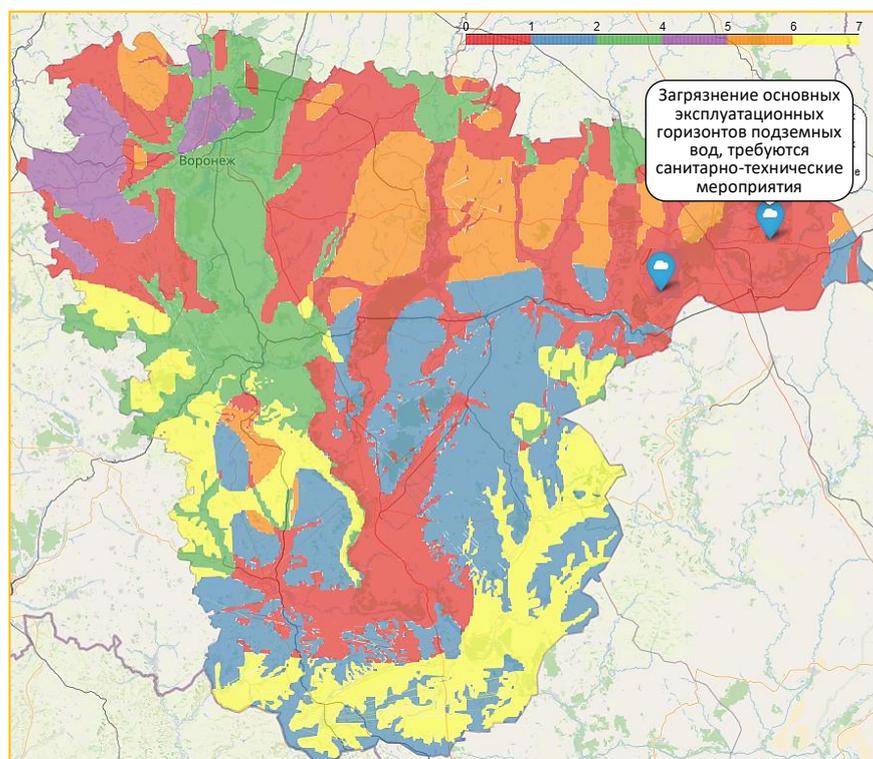


Рис. 4.6. Пример формирования управляющего решения

4.4 Выявление проблемных территорий Воронежской области на основе данных мониторинга загрязнения окружающей среды

Исходные данные второй задачи выявления проблемных территорий Воронежской области региона представляют собой временные ряды из мониторинговых показателей, используемых для оценки риска химического загрязнения окружающей среды. Данные об актуальных значениях этих показателей в контрольных точках, расположенных в 32 муниципальных районах Воронежской области были предоставлены «Центром гигиены и эпидемиологии в Воронежской области». На рисунке 4.7 представлены примеры основных показателей, использованных для анализа экологической ситуации.



Рис. 4.7. Показатели оценки экологической ситуации в регионе

В таблицах 4.3-4.5 приведены примеры измеренных значений показателей.

Для программной реализации решения данной задачи также использовалась библиотека Folium.

Результат кластеризации можно наглядно посмотреть на рисунке 4.8, где отображены данные Folium о химической загрязненности почвы, воздуха и воды в Воронежской области в соответствии с показателями зонирования области.

Таблица 4.3. Результаты лабораторных исследований состояния почвы по мониторинговым точкам за 2021 год

Район	№ точки (код)	Перечень ингредиентов	Измерения						
			1	2	3	4	5	6	7
с. Бродовое, ул. Школьная, 4, детский сад	496	кадмий	0,1	0,1	0,1	0,1	0,1	0,1	0,1
		марганец	50	50	50	50	50	50	50
		медь	1	1	1	1	1	1	1
		мышьяк	0,1	0,1	0,1	0,1	0,1	0,1	0,1
		никель	0,2	0,2	0,2	0,2	0,2	0,2	0,2
		ртуть	0,1	0,1	0,1	0,1	0,1	0,1	0,1
		свинец	0,5	0,5	0,5	0,5	0,5	0,5	0,5
		цинк	1	1	1	1	1	1	1
		индекс БГКП	3	5	7	6	6	4	7
		индекс энтерококков	3	5	6	6	6	4	7
		патогенные бактерии	0	0	0	0	0	0	0
		яйца гельминтов	0	0	0	0	0	0	0
цисты патогенных	0	0	0	0	0	0	0		

Таблица 4.4. Результаты лабораторных исследований состояния атмосферного воздуха по мониторинговым точкам за 2020 год

Район	№ точки (код)	Перечень ингредиентов	Измерения						
			1	2	3	4	5	6	7
п.г.т. Анна, пересечение улиц Ватутина и Красноармейская	483	азота диоксид	0,02	0,02	0,02	0,02	0,02	0,02	0,02
		взвешенные в-ва	0,056	0,056	0,056	0,056	0,056	0,056	0,056
		серы диоксид	0,03	0,03	0,03	0,03	0,03	0,03	0,03
		углерода оксид	1,4	1,4	1,4	1,4	1,4	1,4	1,4
		фенол	0,004	0,004	0,004	0,004	0,004	0,004	0,004
		формальдегид	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Таблица 4.5. Результаты лабораторных исследований качества питьевой воды по мониторинговым точкам за 2020 год

Район	№ точки (код)	Перечень ингредиентов	Измерения						
			1	2	3	4	5	6	7
п.г.т. Анна, ул.Садовая, 20, водоразборная колонка	485	бор	0,1	0,1	0,1	0,1	0,1	0,1	0,1
		железо	0,05	0,14	0,11	0,05	0,05	0,07	0,05
		жёсткость	6,7	7,3	7,3	6,7	6,7	5,3	6,8
		марганец	0,01	0,01	0,01	0,01	0,01	0,04	0,01
		нитраты	4,2	5	5,2	7,8	7	1	3
		ОКБ	0	0	0	0	0	0	0
		ТКБ	0	0	0	0	0	0	0
ОМЧ	21	23	22	26	16	24	27		

Данные результаты полностью соответствуют показателям риска химического загрязнения, определяемого по шкале Харрингтона (вербально-числовой шкале). Относительно химического регионального загрязнения данная шкала включает в себя 5 уровней риска:

- 1 – крайне низкий;
- 2 – низкий;
- 3 – средний;
- 4 – высокий;
- 5 – очень высокий.

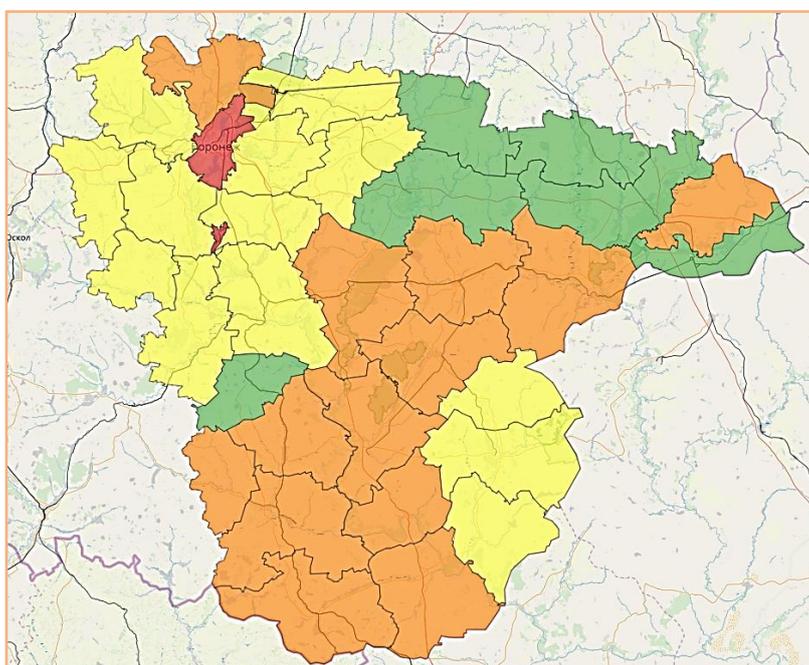


Рис. 4.8 Кластеризация муниципальных районов Воронежской области по показателям химического загрязнения окружающей среды с использованием сети Fuzzy ART (коэффициент силуэта $s=0.81$)

При этом, как правило, при оценке муниципальных районов используются только 4 оценки (крайне низкий, низкий, высокий и самый высокий). На рисунке 4.8 наглядно видно состояние отдельных районов. Территории, выделенные красным цветом, получили оценку 5 – они характеризуются большим риском загрязнений. Оценка 1 получили желтые области, эти районы являются наиболее благоприятными.

Рисунок 4.9 показывает результаты по районам Воронежской области, опираясь на данные химического загрязнения с использованием метода К-средних. Судя по результатам, можно отметить значительные отличия от работы [6], где зеленым цветом отмечены самые благополучные районы. Здесь стоит обратить внимание на получившиеся результаты на рис. 4.7. Они хорошо согласуются с показателями, представленными на сайте ФГУЗ «Центр гигиены и эпидемиологии в Воронежской области» [7].

Однако метрики качества кластеризации показывают, что сеть Fuzzy ART лучше выделила кластеры.

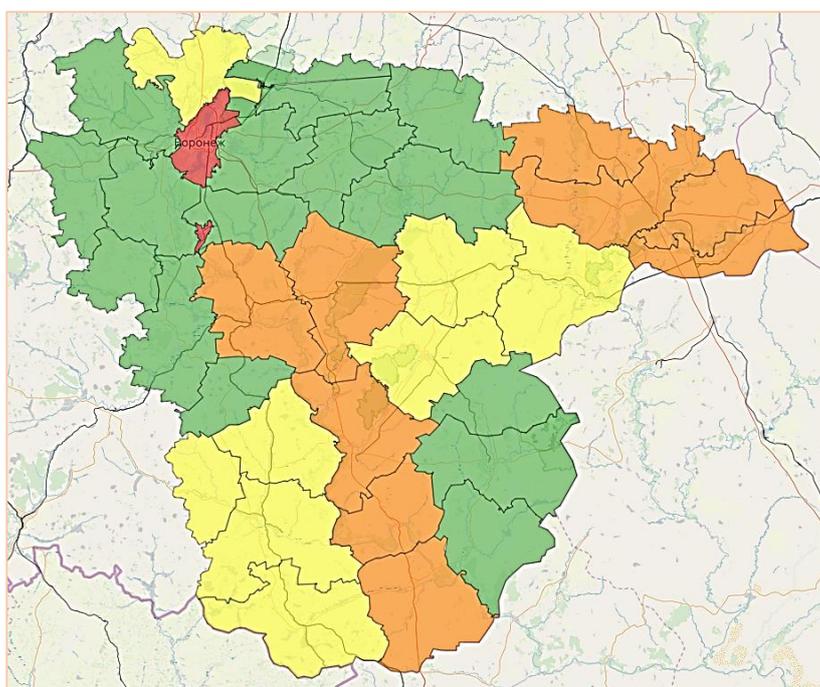


Рис. 4.9 Кластеризация муниципальных районов Воронежской области по показателям химического загрязнения окружающей среды с использованием К-Means (коэффициент силуэта $s=0.75$)

Интерактивные карты, построенные с помощью библиотеки Folium, допускают увеличение или уменьшение масштаба до необходимой степени детализации с целью наглядного просмотра границ кластеров, выделения буферных зон. На рисунке 4.10. представлен увеличенный фрагмент карты, изображенной на рисунке 5 в районе западной границы г. Воронежа, выезда из города на курскую трассу Р-298.

4.5 Результаты практического использования разработанных алгоритмов

Все разработанные в данном исследовании алгоритмы получили внедрение в качестве модулей системы поддержки принятия решений (СППР) в Центрально-Черноземном межрегиональном управлении федеральной службы по надзору в сфере природопользования.

На рис. 4.11 с приведены задачи, решение которых в данный момент реализовано в СППР, информация для лица принимающего решения, формируемая в разработанной системе, и примеры принимаемых решений.

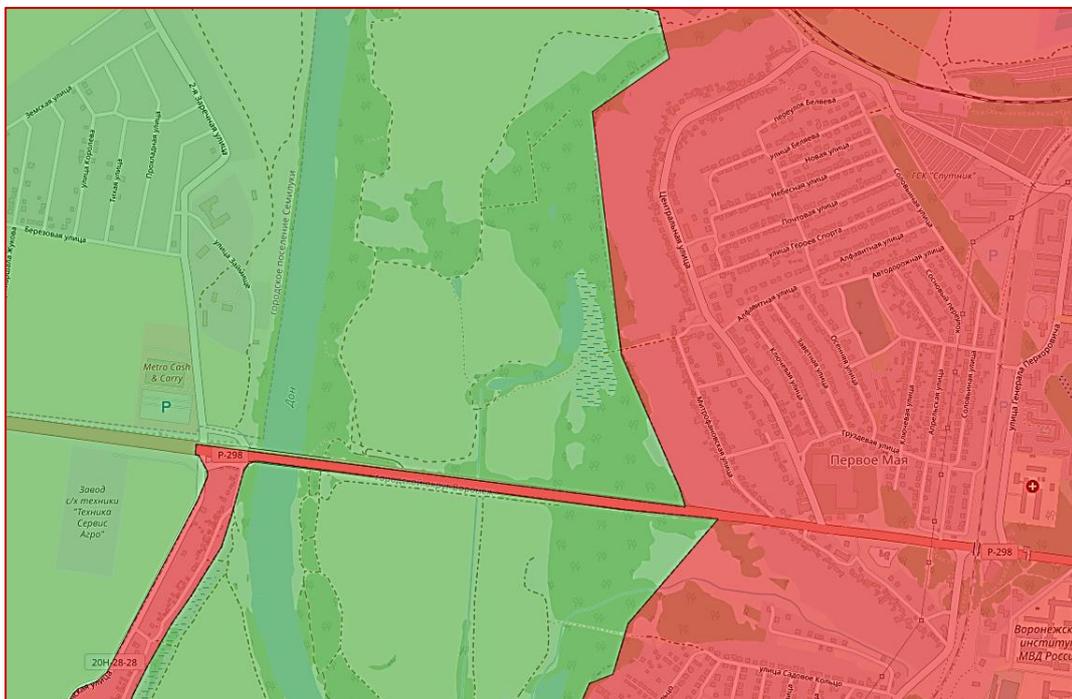


Рисунок 4.10 Фрагмент кластеризации муниципальных районов Воронежской области по показателям химического загрязнения окружающей среды с использованием Fuzzy ART.

С использованием разработанной СППР в Центрально-Черноземном межрегиональном управлении федеральной службы по надзору в сфере природопользования удалось точнее выявить проблемные территории, принять и реализовать на них в приоритетном порядке управленческие решения по охране окружающей среды и первичной профилактике заболеваемости населения, обусловленной воздействием техногенных факторов (загрязнения

атмосферного воздуха, неудовлетворительного качества питьевой воды, загрязнения почвы).

С использованием модели анализа риска загрязнений окружающей среды получены следующие результаты.



Рис. 4.11. Примеры решений, вырабатываемых с помощью СПДР.

В области защиты населения от воздействия загрязнителей атмосферного воздуха в 2021 г. проверено соблюдение режима санитарно-защитных зон для промышленных предприятий Воронежской области. В области защиты населения от воздействия загрязнителей атмосферного воздуха выявлены новые неблагоприятные зоны. В целях улучшения экологической ситуации утверждены новые санитарно-защитные зоны 256 объектов. В связи с принятыми мерами по уменьшению вредного воздействия выбросов промышленных предприятий, для 1329 человек условия проживания были доведены до гигиенических нормативов.

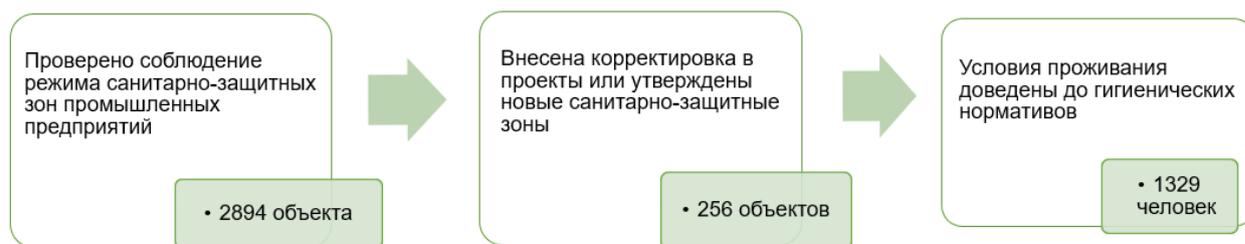


Рис. 4.12 Результаты применения разработанных моделей и алгоритмов в задачах оценки загрязнения атмосферного воздуха

В области обеспечения населения доброкачественной питьевой водой:

1) Результаты исследования послужили основанием для принятия решения о включении в 2021 году выявленных населённых пунктов с низким качеством питьевой воды в региональную государственную программу «Обеспечение качественными жилищно-коммунальными услугами населения Воронежской области» (мероприятие 1.3. «Чистая вода»).

2) За счет реализации мероприятий программы за 2020-2022 г. снизилась доля населения, обеспеченного питьевой водой, не отвечающей гигиеническим нормативам с 11,8% до 7,2%; на 6,7 тыс. человек снижен популяционный риск, связанный с повышенной концентрацией нитратов в питьевой воде, за счёт проведенных санитарно-технических мероприятий.

В области рекреационного водопользования:

По результатам анализа данных действующей системы мониторинга качества воды на территории Воронежской области определены зоны рекреации (пляжи), соответствующие нормативам качества воды.

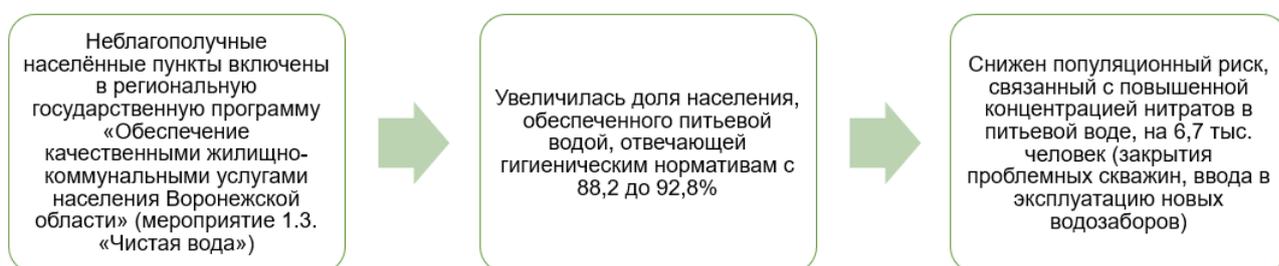


Рис. 4.13 Результаты применения разработанных моделей и алгоритмов в задачах оценки загрязнения питьевой воды

В области охраны почвы от загрязнения и снижения воздействия отходов производства и потребления:

Разработана территориальная схема обращения с отходами. Согласно данным регионального кадастра отходов, наблюдается тенденция к уменьшению количества крупных несанкционированных свалок: с 24-х в 2017 году до 6-ти в 2022 году.



Рис. 4.14 Результаты применения разработанных моделей и алгоритмов в задачах оценки загрязнения почвы

Повторный анализ риска загрязнений территории Воронежской области по данным 2022 г. подтвердил эффективность принимаемых решений (снизилась площадь проблемных зон).

ВЫВОДЫ ЧЕТВЕРТОЙ ГЛАВЫ

1. Нейросетевые алгоритмы оперативного анализа данных экологического мониторинга могут являться основой для разработки новых модулей в составе систем поддержки принятия решений в задачах управления охраной природы.

2. Программный комплекс, основанный на нейросетевом подходе к комплексному экогеологическому районированию территорий Воронежской области позволяет осуществлять в процессе интерактивной работы с пользователем выбор любого набора из имеющегося списка 17-ти мониторинговых показателей и оценку на их основе состояния окружающей природной среды в любой точке Воронежской области. Результаты полученной оценки визуализируются на интерактивной карте местности.

3. На основе интерпретируемого алгоритма оценивания состояния

окружающей среды разработано программное обеспечение, позволяющее обеспечивать интеллектуальную поддержку принятия решений по управлению охраной природы в регионах. Разработанный подход позволяет выявлять ведущие факторы, воздействующие на экологическое состояние и в автоматическом режиме формировать управляющие решения в наглядном и понятном для лица принимающего решения формате.

4. С использованием разработанного ПО проведен нейросетевой анализ риска загрязнения окружающей среды в районах Воронежской области. Разработана и апробирована схема структурно-функциональной организации системы поддержки управления охраной природы на основе мониторинговых данных.

ЗАКЛЮЧЕНИЕ

Проведенное диссертационное исследование позволило усовершенствовать процесс поддержки принятия решений по управлению организационными системами на основе разработки инкрементных нейросетевых методов анализа мониторинговых экологических данных. Обобщим его результаты:

1. Предложена структурно-функциональная модель поддержки принятия управляющих решений на основе мониторинговых показателей, позволяющая усовершенствовать информационное обеспечение процессов управления в организациях, и создающая логическую основу для разработки систем поддержки принятия управляющих решений на основе мониторинговых данных.

2. Разработаны алгоритмы структуризации мониторинговых данных на основе модифицированных нейросетевых моделей Fuzzy ART и Fuzzy ARTMAP позволяющие выявлять скрытые структурные связи между наборами мониторинговых показателей, анализировать и обрабатывать большие объемы информации, в том числе непрерывно поступающей в режиме реального времени, для последующего оперативного выбора управляющих воздействий, в условиях присутствия в исходных мониторинговых данных шумов, пропусков и ошибок.

3. Разработан алгоритм обработки мониторинговой информации на основе модифицированной нейросетевой модели Cascade ARTMAP, позволяющий отображать априорный опыт экспертов в области управления в структуру кластеров и, наоборот, в автоматическом режиме трансформировать результаты кластеризации в наглядный и содержательный набор решающих правил, обеспечивающих простую и понятную интерпретацию экспертами.

4. Разработан программный комплекс для поддержки принятия решений, который обеспечивает оперативный анализ мониторинговых данных с использованием методов инкрементного обучения, способных адаптивно

запоминать поступающую информацию. С помощью этой системы можно извлекать решающие правила из данных и автоматически формировать управляющие решения на основе этих правил.

Предложенные модели и методы могут быть использованы в научно-исследовательских и проектных организациях, занимающихся разработкой специального программного обеспечения систем экологического мониторинга территорий.

Проведенные в диссертации исследования целесообразно продолжить и использовать для формирования цифровой среды управления в других классах организационных систем, опирающихся при принятии решений на реальные данные, поступающие в оперативном режиме. В частности, к таким относятся финансовые организации, транспортные компании, медицинские организации, телекоммуникационные компании, организации государственного и муниципального управления и др. Интересными представляются результаты апробации, которые могут быть получены для этих классов систем.

ЛИТЕРАТУРА

1. Amis G. P. Self-supervised ARTMAP / G. P. Amis, G. A. Carpenter // *Neural Networks*. – 2010. – № 23. – P. 265–282.
2. Apache Spark - Lightning-Fast Cluster Computing [Электронный ресурс]. / Режим доступа: <https://spark.apache.org>. – Дата доступа: 12.01.2021.
3. Brito da Silva L. E. Dual vigilance fuzzy adaptive resonance theory / L. E. Brito da Silva, I. Elnabarawy, D. C. Wunsch 2nd // *Neural Networks*. – 2019. – № 109. – P. 1–5.
4. Carpenter G. A. Fuzzy ARTMAP: An adaptive resonance architecture for incremental learning of analog maps / G.A. Carpenter, S. Grossberg, N. Markuzon, J.H. Reynolds, D.B. Rosen // *Proc. of the Int. Joint Conf. on Neural Network*. – Boston, 1992.
5. Carpenter G. A. Adaptive Resonance Theory / G.A. Carpenter, S. Grossberg // *The Handbook of Brain Theory and Neural Networks. Second Edition*. – 2003. – P. 87–90.
6. Carpenter G.A. ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network / G.A. Carpenter, S. Grossberg, J.H. Reynolds // *Neural Networks*. – 1991. – V. 4. – P. 565–588.
7. Carpenter G.A. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system / G.A. Carpenter, S. Grossberg, D.B. Rosen // *Neural Networks*. – 1991. – № 4. – P. 759–771.
8. Chu K. L. Probabilistic ensemble Fuzzy ARTMAP optimization using hierarchical parallel genetic algorithms. / K. L. Chu, W. Liew, M. Seera, E. Lim // *Neural Computing and Applications*. – 2014. – № 26. – P. 263-276.
9. Brito Da Silva L. E. A survey of adaptive resonance theory neural network models for engineering applications. / L. E. Brito da Silva, I. Elnabarawy, D. C. Wunsch 2nd // *Neural Networks*. – 2019. – № 120. – P. 167–203.
10. Denning D. E. An Intrusion Detection Model. / D. E. Denning // *Proceedings of the Seventh IEEE Symposium on Security and Privacy*. – 1986. – P. 119—131.
11. French R. M. Catastrophic forgetting in connectionist networks. / R. M. French //

- Trends Cogn. Sci. – 1999. – № 3, – P. 128–135.
12. Ghosh J. Cluster ensembles. / J. Ghosh, A. Acharya // Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery. – 2011. – V. 1(4). – P. 305–315.
 13. Grossberg S. Adaptive Resonance Theory: how a brain learns to consciously attend, learn, and recognize a changing world / S. Grossberg // Neural Networks. – 2013. – № 37. – P. 1–47.
 14. Grossberg S. The resonant brain: how attentive conscious seeing regulates action sequences that interact with attentive cognitive learning, recognition, and prediction. / S. Grossberg // Atten. Percep. Psychophys. – 2019. – № 81, – P. 2237–2264.
 15. Grossberg S. A Path Toward Explainable AI and Autonomous Adaptive Intelligence: Deep Learning, Adaptive Resonance, and Models of Perception, Emotion, and Action. / S. Grossberg // Front. Neurobot. – 2020. – V. 14.
 16. Haupt S.E. Environmental Optimization: Applications of Genetic Algorithms. / S.E. Haupt, A. Pasini, C. Marzban // Artificial Intelligence Methods in the Environmental Sciences. – 2009. – P. 379–395.
 17. Keskin G. A. An Alternative Evaluation of FMEA: Fuzzy ART Algorithm / G. A. Keskin, C. Ozkan // Quality and reliability engineering international. – 2009. – V. 25(6). – P. 647–661.
 18. Kirkpatrick J. Overcoming catastrophic forgetting in neural networks. / J. Kirkpatrick, R. Pancanu, N. Rabinowitz, J. Veness, G. Desjardins, A. A. Rusu et al. // Proc. Natl. Acad. Sci. U.S.A. – 2017. – № 114, – P. 3521–3526.
 19. Kuncheva L. I. Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy. / L. I. Kuncheva, C. J. Whitaker // Machine Learning. – 2003. – № 51, – P. 181–207.
 20. Le Cun Y. Deep learning. / Y. Le Cun, Y. Bengio, G. Hinton // Nature. – 2015. – № 521, – P. 436–444.
 21. Massey L. Real-world text clustering with adaptive resonance theory neural networks. / L. Massey // Proceedings of 2005 international joint conference on neural network. – Montreal, Canada, July 31–August 4, 2005.

22. Martinez-Zarzuela M. Fuzzy ART Neural Network Parallel Computing on the GPU. / M. Martinez-Zarzuela, F. J. Diaz Pernas, J. F. Diez Higuera, M. A. Rodriguez // *Computational and Ambient Intelligence*. – 2007. – P. 463–470.
23. Meng L. Vigilance adaptation in adaptive resonance theory. / L. Meng, A.-H. Tan, D. C. Wunsch // *In Proc. IEEE International Joint Conference on Neural Networks (IJCNN)*. – 2013. – P. 1-7.
24. Molnar C. *Interpretable Machine Learning [Электронный ресурс]* / C. Molnar // Perfect-bound Paperback. – 2019. – P. 318. – Режим доступа: <https://christophm.github.io/interpretable-ml-book/>. – Дата доступа: 08.09.2019.
25. Oong T. H. Feature-Based Ordering Algorithm for Data Presentation of Fuzzy ARTMAP Ensembles. / T. H. Oong, N. A. M. Isa // *IEEE Transactions on Neural Networks and Learning Systems*. – 2014. – № 25 . – P. 812- 819.
26. Rosenberg A. Detecting pitch accent using pitch-corrected energy-based predictors. / A. Rosenberg, J. Hirschberg // *In interspeech*. – 2007. – P. 2777–2780.
27. Rousseeuw P. Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis / P. Rousseeuw // *Computational and Applied Mathematics*. – 1987. – № 20. – P. 53–65.
28. Rumelhart D. E. Learning representations by back-propagating errors. / D. E. Rumelhart, G. E. Hinton, R. J. Williams // *Nature*. – 1986. – № 323. – P. 533–536.
29. Pedregosa F. *Scikit-learn: Machine Learning in Python* / F. Pedregosa et al. // *Journal of Machine Learning Research*. – 2011. – № 12. – P. 2825–2830.
30. Seto K. Comparing ARTMAP neural network with the maximum-likelihood classifier for detecting urban change. / K. Seto, W. Liu // *Photogrammetric Engineering & Remote Sensing*. – 2003. – № 69(9). – P.981-990.
31. Solyanik S.A. Development of distributed management complexes for territorial information systems data flows. / S.A. Solyanik, O.JA. Kravets. // Science Book Publishing House LLC. – Yelm, WA, USA. – 2020.
32. Skovajsova L. Soft clustering algorithms based on neural networks / L. Skovajsova, M. Rojcek // *IEEE 12th International Symposium on Computational Intelligence and Informatics, Budapest*. – 2011. – P. 439–442.

33. Tan A.-H. Cascade ARTMAP: Integrating Neural Computation and Symbolic Knowledge Processing / A.-H. Tan // IEEE Trans. on Neural Networks. – 1997. – № 8(2). – P. 237–250.
34. Wasserman P.D. Neural Computing: Theory and Practice. / P.D. Wasserman // Van Nostrand Reinhold Co. – 1989. – P. 230.
35. Versace M. Adaptive Resonance Theory Design in Mixed Memristive-Fuzzy Hardware. / M. Versace, R. T. Kozma, D. C. Wunsch // Advances in Neuromorphic Memristor Science and Applications. – 2012. – P. 133 -153.
36. Xu R. Survey of Clustering Algorithms. / R. Xu, D. C. Wunsch 2nd // IEEE transactions on neural networks. – 2005. – Vol. 16. – № 3. – P. 645–678.
37. Yazikov E.G. Geocological environmental monitoring: coursebook / E.G. Yazikov, A.V. Talovskaya, L.V. Nadeina // Tomsk Polytechnic University. – Tomsk: TPU Publishing House. – 2013. – P. 131.
38. Ашихмина Т.Л. Экологический мониторинг / Т.Л. Ашихмана // Академический Проект; Альма Матер. – 2009. – С. 416.
39. Бериков В.Б. Классификация данных с применением коллектива алгоритмов кластерного анализа / В.Б. Бериков // Труды V Всероссийской конференции “Знания-Онтологии-Теории” (ЗОНТ-2015). – 2015. – С. 29-38.
40. Бурков В.Н. Механизмы управления эколого-экономическими системами / В.Н. Бурков, Д.А. Новиков, А.В. Щепкин // М.: Изд-во ФИЗМАТЛИТ. – 2008. – С. 244.
41. Бурковский В.Л. Модель формирования планов развития городских территорий / В.Л. Бурковский, С.А. Баркалов, П.Н. Курочка, М.А. Пинаева // Моделирование, оптимизация и информационные технологии. – 2019. – Т. 7. – № 1 (24). – С. 245-253.
42. Бурков В.Н. Модели и механизмы управления безопасностью / В.Н. Бурков [и др.] // М.: СИНТЕГ. – 2001. – С. 160.
43. Воронина В.В. Теория и практика машинного обучения: учебное пособие / В.В. Воронина [и др.] // Ульяновск: УлГТУ. – 2017. – С. 290.
44. Вестра Э. Разработка геоприложений на языке Python / Э. Вестра // Перевод с

- англ. А. В. Логунова. М: ДМК Пресс. – 2017. – С. 446.
45. Ганеева Ж.Г. Определение понятия «мониторинг» в различных сферах его применения / Ж.Г. Ганеева // Вестник Челябинского государственного университета. – 2005. – Вып. 8. – № 1. – С. 30-33.
46. Гаскаров Д.В. Введение в геофизическую кибернетику и экологический мониторинг / Д.В. Гаскаров [и др.] // СПб.: СПГУВК. – 1998. – С. 165.
47. Грачев А.В. Информационные технологии в экологии и природопользовании / А.В. Грачев, В.Ю. Орлов // Ярославль: ЯрГУ. – 2013. – С. 108.
48. Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль // М.: ДМК Пресс. – 2018. – С. 652.
49. Дейтел П. Python: Искусственный интеллект, большие данные и облачные вычисления / П. Дейтел, Х. Дейтел // СПб.: Питер, – 2020. – С. 864.
50. Ермолаев О.П. Автоматизированное построение ландшафтных карт с использованием нейронных сетей / О.П. Ермолаев [и др.] // Современные аспекты экологии и экологического образования. Материалы Всероссийской научной конференции, Казань, 19–23 сентября 2005 г. Казань: Издательство Казанского университета. – 2005. – С. 346-347.
51. Ермолаев О.П. Подходы к районированию рельефа на основе его морфометрических показателей с использованием искусственных нейронных сетей / О.П. Ермолаев [и др.] // Труды XII съезда Русского географического общества, Кронштадт. – 2005. – Т. 4. – С. 348-356.
52. Мандель И.Д. Кластерный анализ / И.Д. Мандель // М.: Финансы и статистика. – 1988. – С. 176.
53. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем / О. Жерон // СПб.: ООО "Альфа-книга". – 2018. – С. 688.
54. Журкин И.Г. Геоинформационные системы / И.Г. Журкин, С.В. Шайтура // М.: КУДИЦ ПРЕСС. – 2019. – С. 272.
55. Зибров Г.В. Оценка состояния окружающей среды природно-антропогенных

- объектов в кластерах экологической безопасности и риска / Г.В. Зибров [и др.] // Технологии техносферной безопасности. – 2015. – № 2 (60). – С. 252-262.
56. Иванов Д. Взаимодействие компонентов природной среды на территории Воронежской области / Д. Иванов // ArcReview. – 2005. – № 3 (34). – С. 1–3.
57. Ириков В.А., Тренёв В.Н. Распределённые системы принятия решений / А.В. Ириков, В.Н. Тренёв // Теория и приложения. – М.: Наука: Физматлит. – 1999. – С. 285.
58. Капралов Е.Г. Геоинформатика / Е.Г. Капралов, А.В. Кошкарев, В.С. Тикуннов // М.: Издательский центр «Академия». – 2015. – С. 480.
59. Карлин Л.Н. Управление энвиронментальными и экологическими рисками / Л.Н. Карлин, В.М. Абрамов // СПб.: Изд-во РГГМУ. – 2006. – С. 332.
60. Каширина И.Л. Интегральное оценивание эффективности сетевых систем с кластерной структурой / И.Л. Каширина, Я.Е. Львович, С.О. Сорокин // Экономика и менеджмент систем управления. – 2015. – Т. 15. – № 1.3. – С. 330-337.
61. Каширина И.Л. Кластеризация непрерывного потока данных на основе обобщенной модели нейронной сети семейства ART / И.Л. Каширина, К.А. Федутин // Системы управления и информационные технологии. – 2018. – Т. 71. – № 1. – С. 33-39
62. Каширина И.Л. Модели и численные методы оптимизации формирования эффективной сетевой системы с кластерной структурой / И.Л. Каширина, Я.Е. Львович, С.О. Сорокин // Информационные технологии. – 2015. – Т. 21. – № 9. – С. 657-662.
63. Каширина И.Л. Нейросетевое моделирование формирования кластерной структуры на основе сетей ART / И.Л. Каширина, Я.Е. Львович, С.О. Сорокин // Информационные технологии. – 2017. – Т. 23. – № 3. – С. 228-232.
64. Каширина И.Л. Оптимизационное моделирование редукции сетевых систем с кластерной структурой / И.Л. Каширина, Я.Е. Львович, С.О. Сорокин // Вестник Воронежского государственного университета. Серия: Системный

- анализ и информационные технологии. – 2015. – № 3. – С. 62-67.
65. Каширина И.Л. Построение решающих правил с помощью нейронной сети ARTMAP / И.Л. Каширина, К.А. Федутинов // Моделирование, оптимизация и информационные технологии. – 2018. – Т. 7. – № 3. – С. 106-116.
66. Каширина И.Л. Применение сети FUZZY ARTMAP в интеллектуальных системах обнаружения вторжений / И.Л. Каширина, К.А. Федутинов // Моделирование, оптимизация и информационные технологии. – 2018. – Т. 6. – № 3 (22). – С. 243-257.
67. Каширина И.Л. Системный анализ мониторинговой экологической информации с помощью нейронной сети FUZZY ART / И.Л. Каширина, К.А. Федутинов // Актуальные проблемы прикладной математики, информатики и механики: сборник трудов Международной научной конференции, Воронеж, 17-18 декабря 2018 г. Воронеж. – 2019. – С. 1565-1571.
68. Кравец О.Я. Параллельные и распределенные вычисления / О.Я. Кравец, Д.И. Мутин, Е.И. Мутина // Yelm, WA, USA. – 2020.
69. Каширина И.Л. Эволюционное моделирование: учебное пособие / И. Л. Каширина // Воронеж: ИПЦ ВГУ. – 2011. – С. 60.
70. Леденева Т.М. Методологические основы построения неаддитивных квалиметрических моделей интегральной оценки экологического состояния природно-хозяйственных геосистем / Т.М. Леденева, В.М. Умывакин, А.В. Швец // Вестник факультета прикладной математики, информатики и механики. – Воронеж : Издательский дом ВГУ. – 2016. – Вып. 13. – С. 150-165.
71. Леденева Т.М. Методологические основы построения неаддитивных квалиметрических моделей интегральной оценки экологического состояния природно-хозяйственных геосистем / Т.М. Леденева, В.М. Умывакин, А.В. Швец // Вопросы науки. – 2016. – Т. 1. – С. 58-73.
72. Лекун Я. Как учиться машина: Революция в области нейронных сетей и глубокого обучения / Я Лекун. – Москва: Интеллектуальная Литература, 2020. – 351 с.

73. Михеев А.В. Анализ работы нейронной сети типа SFAM в задаче классификации двумерных образов / А.В. Михеев, С.К. Киселев // Вестник УлГТУ. – 2017. – №1 (77). – С. 71–78.
74. Михайлов В.В. Мониторинг качества окружающей среды на основе интегральной оценки экологической опасности территорий природно-хозяйственных геообъектов / В.В. Михайлов, В.М. Умывакин, А.В. Швец // Информатика: проблемы, методология, технологии: материалы XV международной научно-методической конференции, Воронеж, 12–13 февраля 2015 г. Воронеж: ИПЦ Воронежского государственного университета. – 2015. – Т.3. – С. 51-56.
75. Нестерук Ф.Г. Инструментальные средства создания нейросетевых компонент интеллектуальных систем защиты информации / Ф.Г. Нестерук, И.В. Котенко // Труды СПИИРАН. – 2013. – № 3(26). – С. 7-25.
76. Нестерук Г.Ф. Информационная безопасность и интеллектуальные средства защиты информационных ресурсов / Г.Ф. Нестерук, Л.Г. Осовецкий, А.Ф. Харченко. – СПб. : Издательство СПбГУЭФ, – 2003. – 324 с.
77. Нестерук Ф.Г. Исследование адаптивных классификаторов в составе интеллектуальных средств защиты информации / Ф.Г. Нестерук, А.Ю. Татарин, Г.Ф. Нестерук // Оптико-электронные информационно-энергетические технологии. – 2010. – № 2. – С. 110-118.
78. Николенко С. Глубокое обучение / С. Николенко, А. Кадурын, Е. Архангельская. – СПб. : Питер, – 2018. – 480 с.
79. Перелет Р.А. Квалиметрическое моделирование интегральной оценки экологической опасности территорий природно-хозяйственных геосистем / Р.А. Перелет, В.М. Умывакин, А.В. Шевчук // Труды Института системного анализа Российской академии наук. – 2014. – Т. 64. – № 4. – С. 59-63.
80. Плас Дж. В. Python для сложных задач: наука о данных и машинное обучение / Дж. В. Плас. – СПб.: Питер, 2018. – 576 с.
81. Полищук Ю.М. Региональные экологические информационно-моделирующие системы / Ю.М. Полищук [и др.]. – Новосибирск : Наука,

1993. – 133 с.
82. Рашка С. Python и машинное обучение / С. Рашка. – Москва: ДМК Пресс, 2017. – 418 с.
83. Рюмина Е.В. Анализ эколого-экономических взаимодействий / Е.В. Рюмина. – Москва: Наука, 2000. – 158 с.
84. Рычихина Э.Н. Мониторинг как общая функция управления / Э.Н. Рычихина. – Ухта: УГТУ, 2008. – 140 с.
85. Рычихина Э.Н. Показатели эффективности управленческого мониторинга муниципального образования / Э. Н. Рычихина // Вопросы государственного и муниципального управления. – 2009. – № 1. – С. 33-47.
86. Угольницкий Г.А. Управление эколого-экономическими системами / Г.А. Угольницкий. – Москва: Вузовская книга, 2004. – 132 с.
87. Угольницкий Г.А. Информационно-аналитическая система управления эколого-экономическими объектами / Г.А. Угольницкий, А.Б. Усов // Известия РАН. Теория и системы управления. – 2007. – № 6. – С. 230-237.
88. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. – Москва: ДМК Пресс, 2015. – 400 с.
89. Целых А.Н., Оценка экологической обстановки окружающей среды на основе анализа знаний экспертов / А.Н. Целых, Р.П. Тимошенко // Известия ТРТУ. Тематический выпуск «Управление в социальных и экономических системах». – 1998. – №1. – С. 219-222.
90. Целых А.Н. Построение карт аномальных экологических зон на основе нечетких правил / А.Н. Целых, Э.В. Дзюба // Известия ТРТУ. Тематический выпуск «Управление в социальных и экономических системах». – 1998. – №1(7). – С. 222-226.
91. Чигбу Э.Э. Прогнозирование динамики потенциально опасных процессов на основе нейросетевого моделирования / Э.Э. Чигбу, К.Ю. Гусев, В.Л. Бурковский // Вестник Воронежского государственного технического университета. – 2016. – Т. 12. – № 5. – С. 49-53.

92. Шолле Ф. Глубокое обучение на Python / Ф. Шолле. – СПб. : Питер, 2018. – 400 с.
93. Folium [Электронный ресурс] URL : <https://python-visualization.github.io/folium/>. (дата обращения: 22.11.2019).
94. KDD Cup 1999 Data [Электронный ресурс] URL : <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>. (дата обращения: 10.08.2018).
95. RSNNS: Neural Networks using the Stuttgart Neural Network Simulator (SNNS): [Электронный ресурс]. URL : <https://rdrr.io/cran/RSNNS/>. (дата обращения: 15.10.2019).
96. Положение о государственном экологическом мониторинге (государственном мониторинге окружающей среды) и государственном фонде данных государственного экологического мониторинга (государственного мониторинга окружающей среды) (утверждено постановлением Правительства Российской Федерации от 9 августа 2013 года N 681).
97. Федеральное бюджетное учреждение здравоохранения «Центр гигиены и эпидемиологии в Воронежской области» [Электронный ресурс] URL : <https://36grosпотреbnadzorfuz.ru/>
98. Федеральный закон от 10 января 2002 г. № 7-ФЗ «Об охране окружающей среды» (Редакция от 09.03.2021)
99. ГОСТ Р 22.1.02-95. Безопасность в чрезвычайных ситуациях. Мониторинг и прогнозирование. Термины и определения. Введ. 1997-01-01. М. : Издательство стандартов, 1996. 6 с.

Приложение 1. Свидетельство о регистрации программы для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2019613816

«Анализ экологической информации на основе кластерной
структуризации данных»

Правообладатель: *федеральное государственное бюджетное
образовательное учреждение высшего образования «Воронежский
государственный университет» (ФГБОУ ВО «ВГУ») (RU)*

Авторы: *Федутинов Константин Александрович (RU),
Каширина Ирина Леонидовна (RU)*

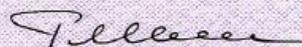
Заявка № 2019612217

Дата поступления 06 марта 2019 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 22 марта 2019 г.

Руководитель Федеральной службы
по интеллектуальной собственности

 Г.П. Ивлиев



Приложение 2. Акты о внедрении

УТВЕРЖДАЮ

И.о. главного врача
ФБУЗ «Центр гигиены и
эпидемиологии в Воронежской области»



А.В. Платунин
_____ 2023 г.

АКТ

**о внедрении результатов диссертационной работы
Федутинова Константина Александровича**

Комиссия в составе: председателя комиссии – заведующего отделением организации работ по информированию населения по вопросам санитарно-эпидемиологического благополучия организационно-методического отдела, д.м.н., профессора Н.П. Мамчика и членов комиссии - к.м.н. И.В. Колнет, д.б.н., профессора О.В. Клепикова составила настоящий Акт о том, что результаты диссертационного исследования Федутинова К.А. по теме «Интеллектуализация процессов принятия решений в организационных системах в условиях оперативного анализа мониторинговых данных» внедрены и используются в деятельности Центра гигиены и эпидемиологии в Воронежской области. В частности, программный комплекс алгоритмов анализа мониторинговой экологической информации с применением геоинформационных технологий используется как инструмент поддержки принятия управленческих решений по реализации мероприятий в системе социально-гигиенического мониторинга Воронежской области.

Председатель комиссии:

Заведующий отделением организации работ по информированию населения по вопросам санитарно-эпидемиологического благополучия организационно-методического отдела, д.м.н., профессор

Н.П. Мамчик

Члены комиссии:

Заведующая отделением социально-гигиенического мониторинга, к.м.н.

И.В. Колнет

Программист отделения статистики организационно-методического отдела, д.б.н., профессор

О.В. Клепиков

УТВЕРЖАЮ

Проректор по науке, инновациям и
цифровизации ФГБОУ ВО«Воронежский государственный
университет», доктор
физико-математических

наук, доцент

Д.В. Костин

«28» сентября 2023 г.



АКТ

о внедрении результатов диссертационного исследования
Федутинова Константина Александровича

Комиссия в составе: председателя комиссии – декана факультета прикладной математики, информатики и механики, кандидата физико-математических наук, доцента Медведева С.Н. и членов комиссии: профессора кафедры математических методов исследования операций, доктора технических наук, доцента Бондаренко Ю.В.; заведующего кафедрой математических методов исследования операций, доктора технических наук, профессора Азарновой Т.В. составила настоящий Акт о том, что результаты диссертационного исследования Федутинова К.А. по теме «Интеллектуализация процессов принятия решений в организационных системах в условиях оперативного анализа мониторинговых данных» внедрены в учебный процесс факультета прикладной математики, информатики и механики в программах следующих учебных дисциплин:

- Современные нейросетевые технологии (направление магистратуры 01.04.02 – Прикладная математика и информатика);
- Управление в социальных и экономических системах (направление магистратуры 38.04.05 Бизнес-информатика)

Председатель комиссии:

С.Н. Медведев

Члены комиссии:

Ю.В. Бондаренко

Т.В. Азарнова