

МОСКОВСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ
ИМЕНИ Н.Э. БАУМАНА
(национальный исследовательский университет)

На правах рукописи



СКРЫННИКОВ Сергей Владимирович

**КОМПЛЕКСНЫЙ КОНТРОЛЬ КОЛЬЦЕВЫХ СВАРНЫХ
СОЕДИНЕНИЙ МАГИСТРАЛЬНЫХ ГАЗОПРОВОДОВ**

2.5.9. Методы и приборы контроля и диагностики материалов, изделий, веществ
и природной среды

ДИССЕРТАЦИЯ

на соискание ученой степени
кандидата технических наук

Научный руководитель:
кандидат технических наук
Н.В. Крысько

Москва - 2024

ОГЛАВЛЕНИЕ

ПЕРЕЧЕНЬ СОКРАЩЕНИЙ.....	5
ВВЕДЕНИЕ.....	6
ГЛАВА 1 СОВРЕМЕННОЕ СОСТОЯНИЕ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ И ОЦЕНКИ КАЧЕСТВА СВАРНЫХ СОЕДИНЕНИЙ МАГИСТРАЛЬНЫХ ГАЗОПРОВОДОВ.....	13
1.1 Существующие технологии и оборудование неразрушающего контроля сварных швов магистральных газопроводов.....	13
1.1.1 Визуальный и измерительный метод НК	13
1.1.2 Радиационный метод НК.....	16
1.1.3 Ультразвуковой метод НК	19
1.2 Оценка качества магистральных газопроводов с применением сочетания данных неразрушающего контроля	26
1.3 Существующие технологии и алгоритмы совместной обработки данных ...	34
1.3.1 Байесовский вывод.....	35
1.3.2 Теория Демпстера-Шафера.....	36
1.3.3 Дерево решений	38
1.3.4 Случайный лес	41
1.3.5 Градиентный бустинг.....	43
1.3.10 Полносвязная нейронная сеть.....	44
1.4 Заключение.....	48
ГЛАВА 2 НАУЧНОЕ ОБОСНОВАНИЕ ВЫБОРА СИСТЕМЫ ИНФОРМАЦИОННЫХ ПРИЗНАКОВ ДЕФЕКТОВ	50
2.1 Изготовление экспериментальных образцов.....	50
2.2 Проведение неразрушающего контроля экспериментальных образцов.....	57
2.3 Формирование исследуемого массива данных.....	62
2.4 Результаты и выводы второй главы	66

ГЛАВА 3 НАУЧНОЕ ОБОСНОВАНИЕ ВОЗМОЖНОСТИ СОЧЕТАНИЯ ДАННЫХ ДЛЯ ПОЛУЧЕННОЙ СИСТЕМЫ ИНФОРМАЦИОННЫХ ПРИЗНАКОВ ДЕФЕКТОВ.....	68
3.1 Проведение визуализации полученного набора данных с применением технологий снижения размерностей	68
3.2 Проведение анализа каждого параметра системы по отдельности с целью идентификации определенного типа дефекта	71
3.3 Установление зависимостей между параметрами системы НК	77
3.4 Обоснование степени влияния параметров систем НК на определение типа и параметров дефектов сварных швов	82
3.5 Результаты и выводы третьей главы.....	86
ГЛАВА 4 ПОСТРОЕНИЕ И НАУЧНОЕ ОБОСНОВАНИЕ ВЫБОРА ОПТИМАЛЬНЫХ МОДЕЛЕЙ СОЧЕТАНИЯ ДАННЫХ, ПРОГНОЗИРУЮЩИХ ТИП И ПАРАМЕТРЫ ДЕФЕКТОВ.....	87
4.1 Определение оптимальных гиперпараметров моделей классификации	87
4.2 Разработка и научное обоснование выбора оптимальной модели классификации.....	91
4.3 Определение оптимальных гиперпараметров моделей регрессии	103
4.4 Разработка и научное обоснование выбора оптимальных моделей регрессии	106
4.5 Результаты и выводы четвертой главы	112
ГЛАВА 5 РАЗРАБОТКА МЕТОДИКИ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ С ВЫПОЛНЕНИЕМ СОВМЕСТНОГО АНАЛИЗА ДАННЫХ НА ОСНОВЕ ПРОВЕДЕННЫХ ИССЛЕДОВАНИЙ	113
5.1 Разработка методики НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК.....	113
5.2 Разработка схемы НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК и ее валидация	130
5.3 Результаты и выводы пятой главы	133
ЗАКЛЮЧЕНИЕ	134

СПИСОК РАБОТ, ОПУБЛИКОВАННЫХ АВТОРОМ ПО ТЕМЕ ДИССЕРТАЦИИ	136
СПИСОК ЛИТЕРАТУРЫ	139

ПЕРЕЧЕНЬ СОКРАЩЕНИЙ

- ВИК – визуальный и измерительный контроль
ДВМ – дифракционно-временной метод
МГ – магистральный газопровод
НД – нормативный документ
НК – неразрушающий контроль
ПАО – публичное акционерное общество
ПВЭ – полная высота экрана
ПО – программное обеспечение
ПЭП – пьезоэлектрический преобразователь
РНК – радиационный неразрушающий контроль
РЭ – руководство по эксплуатации
УЗК – ультразвуковой контроль
ФАР – фазированная антенная решетка

ВВЕДЕНИЕ

Актуальность темы исследования. Сегодня в России существует и продолжает развиваться большая сеть магистральных газопроводов (МГ). Общая протяженность газотранспортной системы на территории России составляет 182,5 тыс. км. С 2005 года было построено более 35 тыс. км. газопроводов и сегодня темп их строительства растет. При строительстве газопровода необходимо производить сварку в сжатые сроки большого количества кольцевых сварных соединений, качество которых оценивается путем проведения визуального и измерительного контроля (ВИК), радиационного контроля (РНК) и ультразвукового контроля (УЗК) в объеме 100% [1], причем УЗК, как правило, проводится двумя методами: эхо-импульсным или эхо-зеркальным в зависимости от типа разделки кромок, а также дифракционно-временным методом (ДВМ) [2].

Для оценки качества сварных соединений МГ сегодня, как правило, используются инженерные критерии [3, 4]. Для применения инженерных критериев оценки качества необходимо прогнозировать размеры дефектов, а также знать величину ошибки данного прогноза. Если не удастся точно прогнозировать размеры дефекта, то необходимо производить отбраковку соединения из соображений безопасности. При отсутствии информации о типе дефекта в прочностные расчеты закладывается самый опасный случай – трещина, выходящая на поверхность, растущая в неблагоприятном направлении для нагрузки сварного шва [5, 6].

Отсутствие информации о типе дефекта и неточная оценка его размеров при неразрушающем контроле (НК) приводит к применению жестких норм, следовательно, к увеличению перебраковки, что в итоге приводит к сильному уменьшению темпа строительства, связанного с частыми ремонтами. Поэтому необходима методика, позволяющая максимально достоверно и точно прогнозировать типы и параметры дефектов сварных швов, опираясь на данные НК.

Подобная методика может быть реализована следующим образом: собираются данные всех применяемых методов НК, далее они подаются в некую модель сочетания данных, которая на основе результатов НК прогнозирует тип и параметры выявленных дефектов, после чего по этой информации происходит оценка качества всего кольцевого сварного соединения. Сочетание данных является процессом объединения различных данных для получения более качественной информации, чем информация от одного источника [7]. Модели сочетания данных, как правило, основываются на алгоритмах математической статистики, теории нечетких множеств, машинном/глубоком обучении и т.д. и активно применяются в таких областях, как оборонная промышленность, медицина и т.д. Анализ показывает, что применение сочетания данных в НК сварных швов исследовано только для РНК и УЗК эхо-импульсным методом и опробовано на ограниченном количестве дефектов [8, 9]. На сегодняшний день не существует модели сочетания данных ВИК, РНК, а также УЗК эхо-импульсным и ДВМ, которая позволит достоверно прогнозировать тип и параметры дефектов сварных швов МГ.

Степень разработанности темы исследования.

Сочетание данных от различных источников широко используется в военной промышленности и робототехнике, а в последнее время также находит применение в НК объектов промышленности. Цифровые технологии сочетания данных впервые были использованы в НК в работе [10], и в настоящее время их использование быстро расширяется. Одной из ключевых задач объединения данных при контроле сварных швов, выполненных дуговой сваркой, является увеличение информативности о геометрических характеристиках дефектов. Поэтому в работе [8] применяли модели сочетания данных, основанные на статистических алгоритмах, для совместного анализа каждого пикселя изображений РНК и эхо-импульсного метода УЗК с целью реконструкции трехмерного изображения дефектов на небольшом количестве образцов. В работе [9] также использовались модели сочетания данных, основанные на статистических алгоритмах и теории нечетких множеств для совместного

анализа каждого пикселя изображений РНК и эхо-импульсного метода УЗК с целью уменьшения неоднозначности при интерпретации плоскостных и объемных дефектов.

Сегодня кольцевые стыковые сварные швы МГ контролируются ВИК, РНК, УЗК эхо-импульсным или эхо-зеркальным в зависимости от типа разделки кромок, а также ДВМ. Причем в большинстве случаев контроль проводится как в ручном, так и в автоматизированном режиме.

Для проведения диссертационного исследования был создан набор данных в виде результатов контроля всеми вышеперечисленными методами образцов в виде сварных швов, содержащих различные дефекты. Также разработана система параметров методов НК для совместного анализа. На основе теории вероятностей и математической статистики на исследуемом наборе данных установлено, что данная система не имеет параметров, зависящих друг от друга, что говорит о ее пригодности в качестве входных параметров для построения моделей сочетания данных.

Построены модели сочетания данных, позволяющие прогнозировать тип и параметры дефектов сварных швов МГ, также показана их работоспособность.

Цель заключалась в повышении темпов строительства МГ путем уменьшения количества ремонтов, вызванных перебраковкой кольцевых сварных соединений, путем оценки качества по типу и параметрам дефектов, определенных по методике НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК.

Для достижения поставленной цели в работе решались следующие задачи:

1. Исследовать информационные признаки дефектов на изображениях, полученных по результатам НК кольцевых сварных швов МГ с последующим формированием системы входных параметров для моделей сочетания данных.

2. Научно обосновать возможность определения типа дефекта каждым параметром системы по отдельности, а также установить наличие корреляционных зависимостей между непрерывными параметрами и связи между категориальными параметрами системы.

3. Исследовать степень влияния входных параметров моделей сочетания данных на возможность прогноза типа и параметров дефектов сварных швов.

4. Разработать и научно обосновать выбор оптимальных моделей сочетания данных, которые позволят производить прогноз типа и размеров дефектов, используя в качестве входных параметров информационные признаки дефектов на изображениях, полученных по результатам НК кольцевых сварных швов МГ. Также оценить работоспособность данных моделей.

5. Разработать методику НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК на основе проведенных исследований.

Научная новизна исследования заключается в следующем:

1. Показано, что только металлические включения надежно идентифицируются по разнице градаций серого при РНК, а для всех остальных типов дефектов присутствует существенная неоднозначность при идентификации, что говорит о необходимости сочетания данных методов НК. В связи с этим предложена система из двадцати трех параметров для совместного анализа результатов РНК и УЗК эхо-импульсного и ДВМ.

2. На основе статистического анализа установлено, что параметры системы используемых методов контроля, являются независимыми друг от друга, что подтверждается критериями Спирмена и V Крамера (не более 0,67 и 0,63 соответственно). Данный факт позволяет эффективно использовать рассматриваемую систему параметров для совместного анализа.

3. Установлена степень влияния параметров системы на возможность классификации дефектов сварных швов по типам согласно критериям «совместной информации» и «экстра деревьев». Количественно обоснована необходимость использования всех двадцати трех предложенных параметров для совместного анализа. Наиболее значимыми параметрами являются: разница градаций серого, протяженность и ширина при РНК, протяженность при УЗК ДВМ, положение в разделке при УЗК эхо-импульсным методом.

Теоретическая и практическая значимость работы. Разработаны модели сочетания данных РНК, УЗК эхо-импульсного на базе фазированных антенных решеток (ФАР) и ДВМ на основе таких алгоритмов машинного обучения, как «байесовский вывод», «дерево решений», «случайный лес», «градиентный бустинг», «полносвязная нейронная сеть», которые позволяют прогнозировать тип дефектов сварных швов. Согласно метрике «макро усредненная F1-мера» определена оптимальная модель, основанная на алгоритме «градиентный бустинг», со значением 0,94. Помимо этого, разработаны модели прогнозирования высоты и длины дефекта на основе таких алгоритмов машинного обучения, как «полносвязная нейронная сеть» и «ridge регрессия».

Разработана методика НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК, позволяющая производить прогноз типа и параметров дефектов сварных швов МГ без необходимости определения типа дефекта по РНК. Данная методика реализована в Р Газпром «Сварка и неразрушающий контроль сварных соединений. Методика неразрушающего контроля сварных соединений трубопроводов с выполнением совместного анализа данных визуального и измерительного, радиографического и ультразвукового методов», которые разработаны авторским коллективом в следующем составе: С.В. Скрынников, Н.А. Щипаков, Д.М. Козлов, Н.В. Крысько, А.Г. Кусый, Е.М. Вышемирский, М.Ю. Тульский, Т.В. Артеменко, Ю.А. Соловьев, А.А. Цыба. Также разработана программа «CoWld», выполняющая все сложные вычисления для данной методики.

Методология и методы исследования. Результаты проделанной работы были получены за счет экспериментальных исследований, статистических методов обработки экспериментальных данных, построения моделей анализа данных и оценки их работоспособности. Экспериментальные данные получены с использованием ультразвуковых дефектоскопов Omniscan MX, iSonic 2009, рентген аппарата РАП220-5 и плоскопанельного детектора ПРОДИС.МАРК. Экспериментальные образцы получены путем имитации естественных дефектов дуговой сварки путем локального изменения режима и техники ручной дуговой,

а также механизированной сварки плавящимся электродом в защитных газах. Статистическая обработка и построение моделей анализа экспериментальных данных проводилась путем написания программ на языке Python 3.0 с применением общедоступных библиотек numpy, scipy, pandas, sikitlearn, tensorflow, keras.

Основные положения, выносимые на защиту:

1. Только дефекты типа металлические включения надежно идентифицируются по разнице градаций серого при РНК, а для всех остальных типов дефектов присутствует существенная неоднозначность при идентификации, что говорит о необходимости сочетания данных методов НК.

2. Наиболее значимыми параметрами НК для классификации дефектов по типам являются: разница градаций серого, протяженность и ширина при РНК, протяженность при УЗК ДВМ, положение в разделке при УЗК эхо-импульсным методом.

3. Из полученных моделей сочетания данных, позволяющих спрогнозировать тип дефекта, на основе таких алгоритмов, как «байесовский вывод», «дерево решений», «случайный лес», «градиентный бустинг», «полносвязная нейронная сеть» оптимальной является «градиентный бустинг» со значением «макро усредненной F1-меры», равным 0,94.

Личный вклад автора. Содержание диссертации и основные положения, выносимые на защиту, отражают персональный вклад автора в опубликованные работы. Постановка задач исследования проводилась автором совместно с научным руководителем. Автором самостоятельно получены основные экспериментальные данные по НК сварных соединений с дефектами. Так же автор самостоятельно производил их статистическую обработку и анализ результатов. В соавторстве с научным руководителем Крысько Н.В. предложена система из двадцати трех параметров для совместного анализа результатов РНК и УЗК эхо-импульсного и ДВМ. Также в соавторстве научным руководителем Крысько Н.В. произведена разработка моделей совместного анализа результатов НК, позволяющих прогнозировать тип и параметры дефектов. Результаты

выполненных исследований автор докладывал на международных и всероссийских конференциях. Вместе с руководителем и соавторами автор диссертационной работы принимал участие в написании научных статей в рецензируемые журналы.

Степень достоверности. Воспроизводимость полученных в работе результатов обосновывает их достоверность. Также достоверность подтверждается использованием поверенного экспериментального оборудования, использованием методов статистической обработки данных, а также применением апробированных библиотек на языке Python 3.

Апробация результатов. Основные результаты проведенной работы были доложены на VIII и IX отраслевых совещаниях «Состояние и основные направления развития неразрушающего контроля качества сварных соединений объектов ПАО Газпром» (г. Санкт-Петербург 2021 г. и 2023 г.), научных семинарах кафедры «Сварка, диагностика и специальная робототехника» МГТУ им. Н.Э. Баумана (г. Москва, 2024).

Публикации. По теме исследования опубликовано 8 научных статей: 6 статей в рецензируемых научных журналах, определенных перечнем ВАК РФ [A1-A6], из которых 5 в журналах, индексируемых в базах данных Web of Science и Scopus [A1-A5], а также 2 статьи в сборнике трудов конференции [A7, A8].

Соответствие диссертации паспорту научной специальности. Содержание диссертации соответствует пункту 6 «Применение новых физических и цифровых методов (нейросети, искусственный интеллект) для целей неразрушающего контроля и диагностики» паспорта специальности 2.5.9. Методы и приборы контроля и диагностики материалов, изделий, веществ и природной среды.

Структура и объем диссертации. Работа состоит из введения, 5 разделов, заключения и списка литературы. Работа изложена на 155 страницах, включая 58 рисунков и 19 таблиц. Библиографический список цитируемой литературы содержит 136 наименований.

ГЛАВА 1 СОВРЕМЕННОЕ СОСТОЯНИЕ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ И ОЦЕНКИ КАЧЕСТВА СВАРНЫХ СОЕДИНЕНИЙ МАГИСТРАЛЬНЫХ ГАЗОПРОВОДОВ

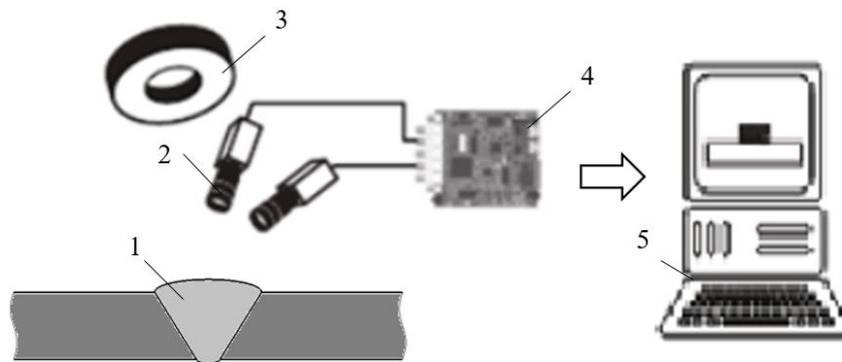
Согласно действующей нормативной документации (НД) ПАО «Газпром», регламентирующей проведение НК кольцевых стыковых сварных соединений МГ, а именно СТО Газпром 15-1.3-004-2023, сварные соединения подвергаются ВИК, РНК и УЗК в объеме 100% [1]. Причем в большинстве случаев контроль проводится как в ручном, так и в автоматизированном режиме. Каждый метод НК кольцевых сварных соединений МГ имеет свои особенности с точки зрения технологии настройки, проведения, а также анализа данных.

1.1 Существующие технологии и оборудование неразрушающего контроля сварных швов магистральных газопроводов

1.1.1 Визуальный и измерительный метод НК

ВИК является наиболее часто применяемым методом НК. ВИК в ручном режиме осуществляется органами зрения, при угле не менее 30° к контролируемой поверхности. Для улучшения обзора поверхности сварных швов применяются такие устройства, как ручные линзы, просмотровые и измерительные лупы, а также микроскопы. Недопустимые согласно НД выходящие на поверхность дефекты сварных швов такие, как поверхностные поры и неметаллические включения, свищи, кратеры, трещины и т.д. отбраковываются по визуальному признаку. Дефекты, имеющие согласно НД границы допустимости, такие как подрезы, смещение кромок, ширина и высота валика усиления шва подлежат измерительному контролю. При проведении ВИК во время измерительного контроля используют различные измерительные приборы, такие как линейки, микрометры наружного диаметра, штангенциркули, глубиномеры, измерительные шаблоны и т.д. [11].

ВИК обычно проводится квалифицированным дефектоскопистом. Однако долгая и утомительная работа часто приводит к тому, что в связи с усталостью дефектоскописта достоверность контроля ухудшается. В связи с этим сегодня все чаще появляются системы, реализующие автоматизированный ВИК. Для автоматизации ВИК используются телевизионные камеры и лазерные триангуляционные датчики. Схема телевизионного контроля сварных швов представлена на рисунке 1.1. При телевизионном контроле сварной шов 1 снимают одна или несколько камер 2 как правило с осветительным устройством 3. Цифровые изображения формируются на устройстве захвата кадров 4 и передаются на персональный компьютер 5.



1 – сварной шов, 2 – камеры, 3 - осветительное устройство, 4 – устройство захвата кадров, 5 – персональный компьютер

Рисунок 1.1 – Схема телевизионного контроля сварных швов

Результатами телевизионного контроля являются изображения сварных швов, где каждый пиксель содержит три значения цвета как правило в цветовом пространстве RGB. Пример изображения сварного шва, полученного по результатам телевизионного контроля, показан на рисунке 1.2. Просмотр множества кадров, содержащих изображения поверхности сварного шва, является трудоемким и утомительным процессом в большинстве случаев занимающий большее количество времени, чем проведение ВИК невооруженным глазом. Для увеличения производительности анализа изображений, полученных с телевизионной камеры, используются как традиционные методы компьютерного зрения, включая пороговую фильтрацию,

обнаружение границ, преобразование Хафа, так и современные технологии глубокого обучения, такие как сверточные нейронные сети, детекторы объектов, модели сегментации и т.д. [12].



Рисунок 1.2 – Пример результатов контроля передаваемых с телевизионной камеры

Лазерный триангуляционный датчик позволяет осуществлять сканирование профиля поверхности сварного шва. Основными элементами измерительной системы триангуляционного типа являются лазерный осветитель и видеокамера (рисунок 1.3 - а). Отражённое от объекта измерения излучение собирается объективом камеры на фотоприёмник (ПЗС матрицу). С использованием специализированных методов обработки изображения выполняется расчёт геометрических параметров объекта измерения [13, 14]. В качестве результатов сканирования лазерным триангуляционным датчиком предоставляется массив координат с записанными значениями геометрических параметров профиля сварного соединения. Пример профиля сварного соединения, построенного по записанным координатам, представлен на рисунке (рисунок 1.3 - б).

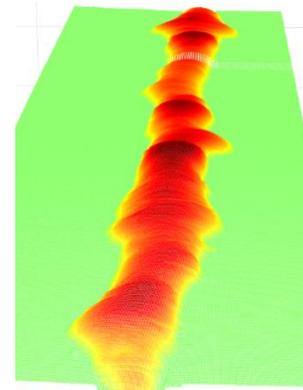
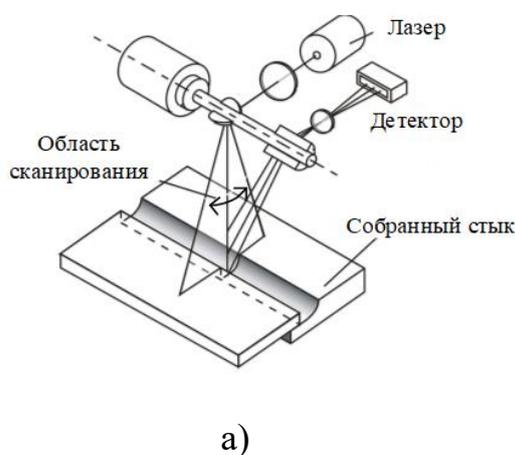


Рисунок 1.3 – Сканирование сварных швов лазерным триангуляционным датчиком. Схема (а), пример результатов (б)

Сегодня существует ряд систем, реализующих автоматизированный ВИК как дополнительный модуль систем автоматизированного РНК и УЗК. Фото существующих систем автоматизированного ВИК представлено на рисунке 1.4.

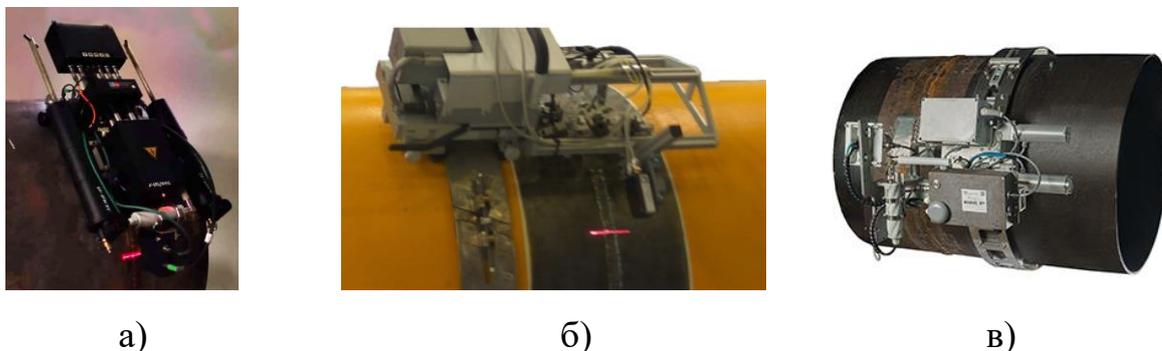
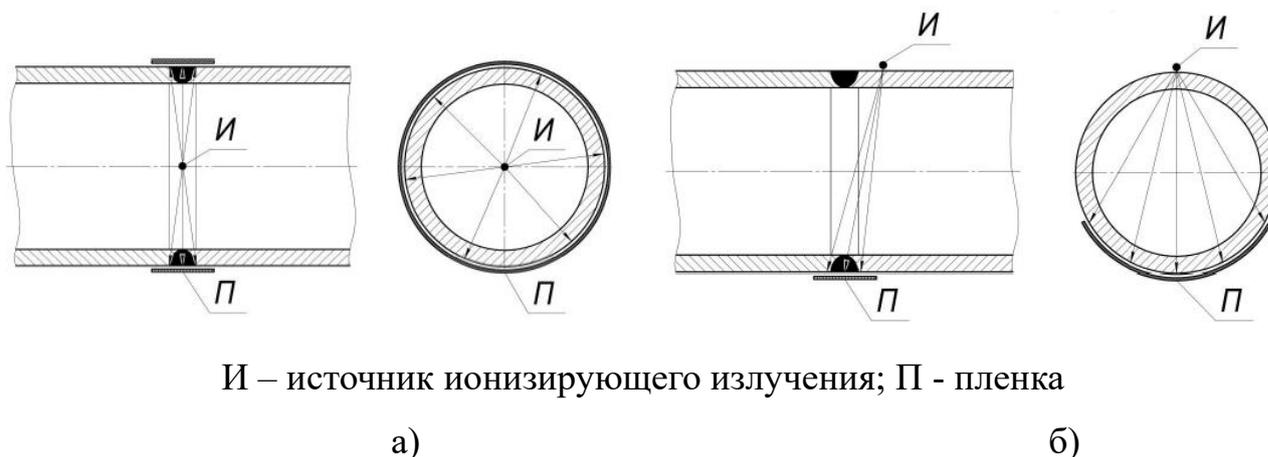


Рисунок 1.4 – Системы автоматизированного ВИК. «Автокон» [15] (а), «Авгур» [16] (б), «Визио» [17] (в)

Как говорилось ранее, ВИК позволяет обнаруживать поверхностные дефекты сварного соединения, а также оценивать отклонения его геометрических параметров профиля сварного соединения. Однако данный метод, не позволяет выявлять дефекты, преимущественно плоскостные, с очень маленьким раскрытием, также он не позволяет выявлять внутренние дефекты.

1.1.2 Радиационный метод НК

РНК является одним из базовых методов НК, который позволяет выявлять несплошности, расположенные внутри объекта контроля не разрушая его. В процессе выполнения РНК производится облучение объекта контроля рентгеновским излучением, генерируемым специализированными источниками, и фиксация прошедшего через объект излучения специальными регистраторами. Согласно НД ПАО «Газпром» просвечивание кольцевых стыковых сварных соединений МГ выполняется по следующим схемам: в случае наличия свободного доступа изнутри – применяется панорамное просвечивание (рисунок 1.5 - а), в случае отсутствия доступа – через две стенки (рисунок 1.5 - б) [18]. В качестве источников рентгеновского излучения используются рентгеновские трубки, а также радиоактивные изотопы. Для регистрации радиографического изображения используются радиографические пленки и цифровые детекторы.



И – источник ионизирующего излучения; П - пленка

а)

б)

Рисунок 1.5 – Схемы просвечивания кольцевых сварных соединений магистральных газопроводов: панорамное (а), через две стенки (б)

Радиографические пленки являются традиционным средством для регистрации рентгеновского излучения. Промышленная рентгеновская плёнка состоит из эмульсии и полиэфирной пластиковой основы голубоватого оттенка толщиной 175 мкм. Эмульсия нанесена на обе стороны основы и защищена внешними слоями с каждой стороны. Эмульсия включает в себя галогениды серебра, как фоточувствительный компонент, а также присадки и желатин. Изображение формируется галогенидами серебра под влиянием рентгеновского или гамма-излучения, вторичных электронов либо флуоресцентного света. В стандартной фотоплёнке светочувствительная эмульсия находится только на одной стороне основы, тогда как в промышленных рентгеновских плёнках она нанесена с обеих сторон. Нанесение двойного слоя эмульсии усиливает поглощение рентгеновского или гамма-излучения, проникающего вглубь, благодаря чему светочувствительные соединения серебра более эффективно улавливают излучение и электроны. Также два слоя эмульсии способствуют повышению контрастности и плотности изображения на рентгеновских снимках [19].

В отличие от радиографических плёнок, средства цифровой радиографии преобразуют рентгеновское излучение напрямую в цифровые изображения, облегчая процесс анализа и хранения информации. Сегодня существуют средства цифровой и компьютерной радиографии.

Цифровые детекторы, преобразовывают рентгеновское излучение напрямую в цифровые изображения, что облегчает процесс их анализа и хранения. Плоскопанельные детекторы применяют аморфный кремний или селен для непосредственного преобразования рентгеновских лучей в электрический сигнал. Данные детекторы характеризуются высокой разрешающей способностью и более коротким временем экспонирования по сравнению с плёночными системами.

В системах на основе компьютерной радиографии используются специальные фосфорные пластины, которые экспонируются под воздействием рентгеновских лучей и затем сканируются лазером для получения цифрового изображения. Системы на основе компьютерной радиографии позволяют использовать традиционные радиографические методы с возможностью последующего получения цифрового изображения, соответствующего рентген-снимку [20].

По результатам проведения РНК с применением цифрового детектора для расшифровки передается цифровое изображение в градациях серого (рисунок 1.6), при этом значения цвета для каждого пикселя может изменяться в пределах до 65 535 градаций серого (16 бит). Обязательными элементами радиографических снимков являются проволочный и канавочный эталоны, которые позволяют оценить чувствительность контроля.

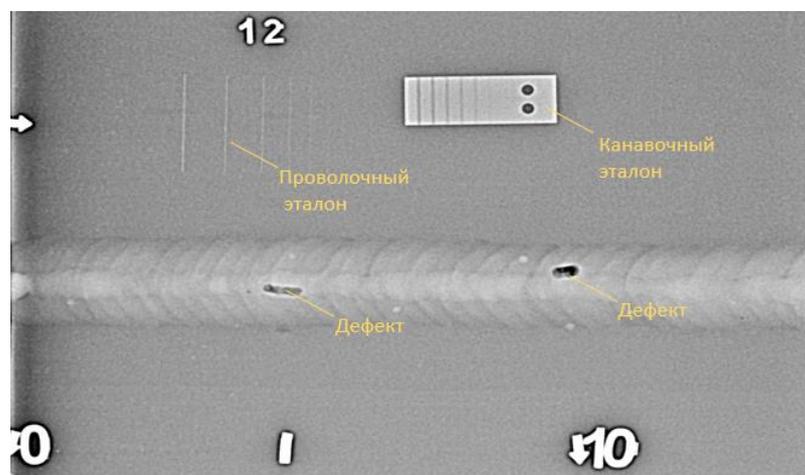


Рисунок 1.6 – Пример результатов РНК с применением цифрового детектора

Сегодня существует ряд систем, реализующих автоматизированный РНК кольцевых стыковых соединений МГ, их фото представлено на рисунке 1.7.



а)



б)

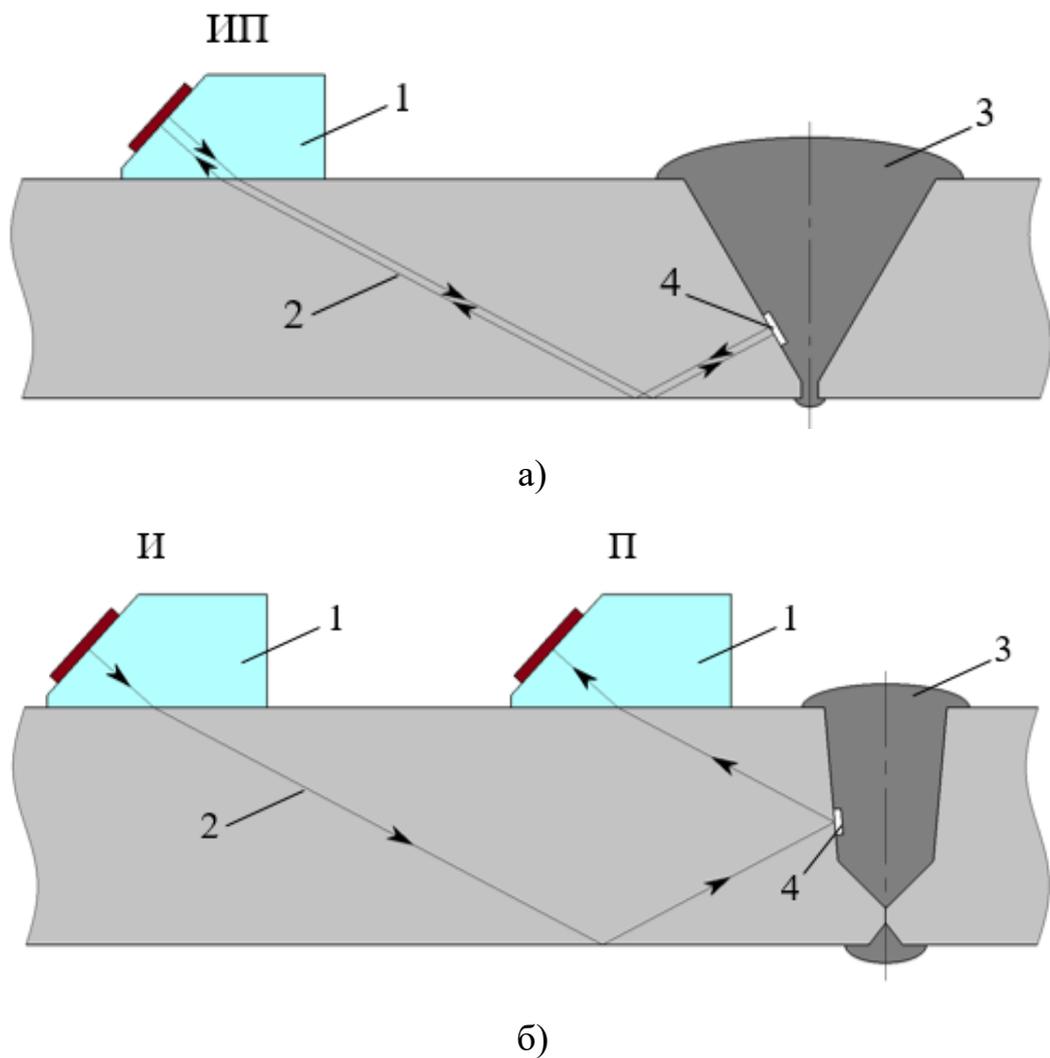
Рисунок 1.7 – Системы автоматизированного РНК. «Цифракон» [21] (а), «RTD Rayscan» [22] (б)

РНК имеет высокий процент выявляемости объемных дефектов и позволяет определить тип выявленного дефекта. В качестве недостатков данного метода можно выделить относительно низкую выявляемость плоскостных дефектов, отсутствие информации о глубине дефекта, а также наличие субъективного фактора при расшифровке результатов контроля, во многом обусловленного квалификацией специалиста, осуществляющего расшифровку.

1.1.3 Ультразвуковой метод НК

УЗК, как и РНК, позволяет выявлять внешние и внутренние дефекты кольцевых сварных соединений МГ. При УЗК производится ввод ультразвуковых колебаний в объект контроля, которые генерируются излучателем. Отраженные или прошедшие через объект колебания фиксируются приемником. При контроле сварных швов в основном для генерации и приема ультразвуковых волн используются пьезоэлектрические преобразователи (ПЭП), принцип работы которых основан на пьезоэлектрическом эффекте. ПЭП обычно устанавливаются на специальную призму, в результате чего прозвучивание сварного шва

производится на поперечных волнах. В основном для контроля сварных швов применяют эхо-импульсный метод и эхо-зеркальный метод (тандем) в зависимости от разделки кромок [23]. Эхо-импульсный метод обычно используется для контроля сварных швов, выполненных ручной дуговой сваркой с V-образной разделкой и углом скоса кромки 30° (рисунок 1.8 – а). Эхо-зеркальный метод (тандем) применяется для контроля сварных швов, сваренных автоматической сваркой с применением оборудования CRC-Evans [24], Saturnax [25] и т.д. с углом скоса кромки, составляющем около 5° (рисунок 1.8 – б).

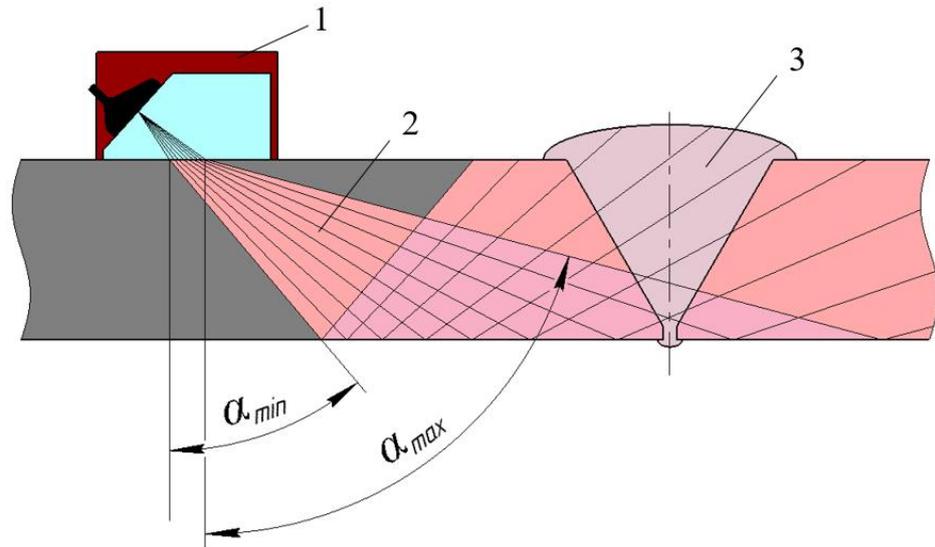


И – излучатель; П - приемник

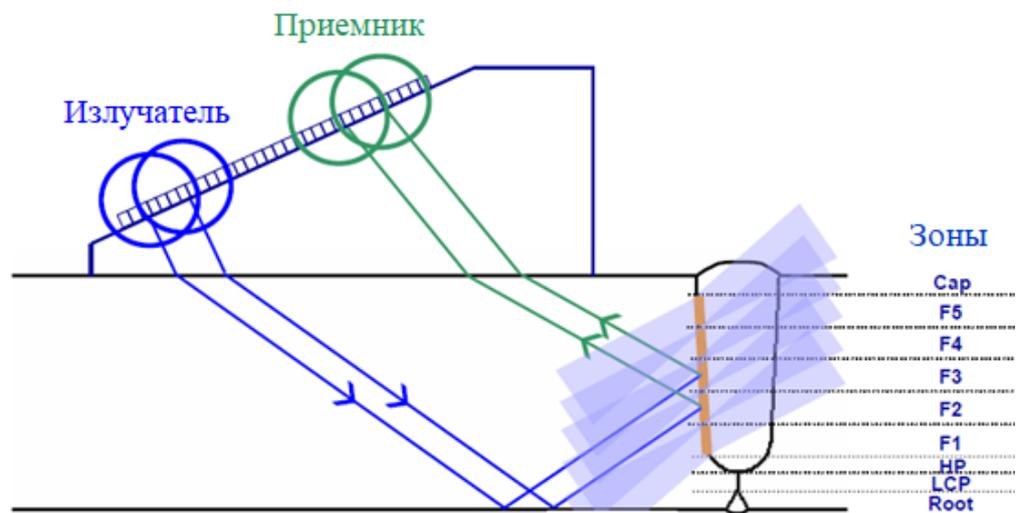
1 – ПЭП, 2 – направление распространения ультразвуковых волн, 3 -
сварной шов, 4 – дефект

Рисунок 1.8 – Схемы УЗК сварных швов МГ. Эхо-импульсный метод – (а),
эхо-зеркальный метод (б)

С целью автоматизации и получения результатов контроля в виде файла с данными, которые можно визуализировать, ультразвуковой эхо-импульсный и эхо-зеркальных методы проводятся на базе ФАР [А7]. С применением ФАР эхо-импульсный метод обычно реализуется в виде секторного сканирования [26], а эхо-зеркальный метод – с применением технологии зонального разбиения [27].



а)



б)

И – излучатель; П - приемник

1 – ФАР, 2 – диапазон секторного сканирования ультразвуковыми волнами, 3 - сварной шов

Рисунок 1.9 – УЗК с ФАР. Секторное сканирование– (а), технология зонального разбиения (б)

При секторном сканировании происходит последовательное прозвучивание сварного шва под разными углами в диапазоне от α_{min} до α_{max} (обычно от 40° до 70° на поперечных волнах) с заранее установленным шагом (рисунок 1.9 - а). При секторном сканировании происходит прозвучивание всего сварного соединения за одну постановку, в результате чего нет необходимости в поперечно-продольном перемещении ФАР, как при одноэлементных ПЭП. При работе с применением технологии зонального разбиения сварной шов условно делят на зоны, обычно высота каждой зоны составляет 2-3 мм, такие как корень, горячий проход, заполнение, облицовка (Root, LCP, HP, F1, F2, F3, F4, F5, C (рисунок 1.9 - б). Для каждой зоны подбирается часть апертуры ФАР, которая работает как излучатель, и другая часть, которая работает, как приемник. В результате каждая зона прозвучивается своей парой излучатель-приемник эхо-зеркальным (тандем) методом с фокусировкой в области кромки.

При секторном сканировании собирается большое количество А-сканов, из которых с целью упрощения их анализа, формируются изображения, называемые В-, С- и S-сканами. При этом, для формирования В-, С- и S-сканов уровень сигнала на А-скане преобразуется в цветное значение в соответствии с выбранной палитрой и каждому пикселю соответствуют три значения цвета в цветовом пространстве RGB. Расшифровка производится непосредственно по цветовым изображениям сигналов. Пример представления данных с применением секторного сканирования представлен на рисунке 1.10.

При применении технологии зонального разбиения амплитуды сигналов «тандем пар» отображаются относительно координаты вдоль направления сканирования. Такое отображение называют «стрипчартами». В случае превышения браковочного уровня сигнал закрашивается красным, в случае превышения уровня фиксации – зеленым для увеличения скорости анализа результатов контроля. Пример представления данных с применением технологии зонального разбиения представлен на рисунке 1.11.

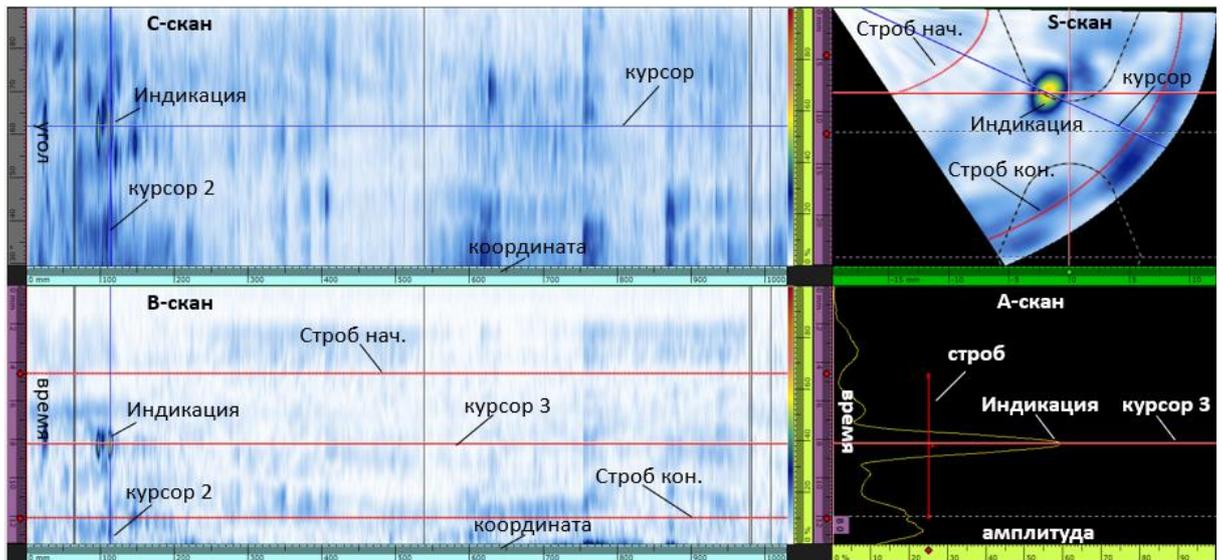


Рисунок 1.10 – Пример результатов УЗК на ФАР с применением секторного сканирования

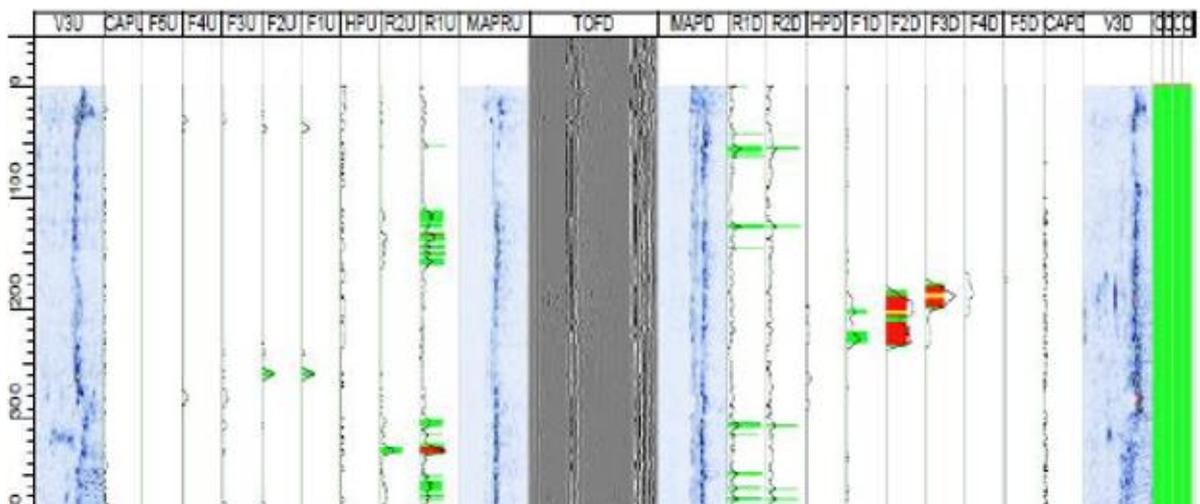
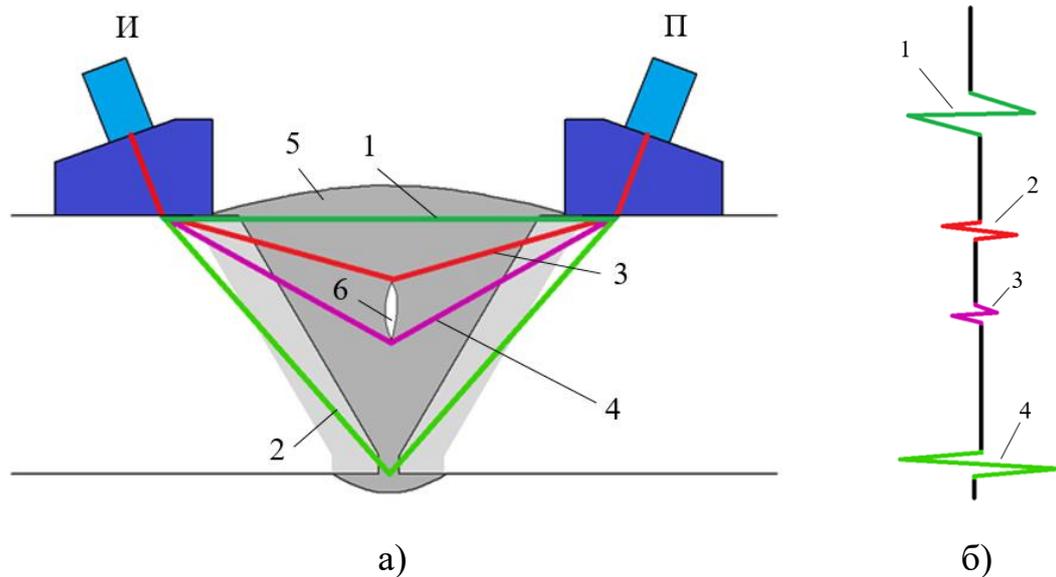


Рисунок 1.11 – Пример результатов УЗК на ФАР с применением технологии зонального разбиения

Эхо-импульсный и эхо-зеркальный (тандем) методы УЗК имеют высокую выявляемость плоскостных дефектов, а также относительно просты в расшифровке. Основным недостатком данных методов является низкая выявляемость объемных дефектов и сильная зависимость выявляемости дефекта от его ориентации. Идеальную выявляемость имеют несплавления с кромкой, которые ориентированы перпендикулярно к направлению распространения ультразвуковых колебаний. В случае отклонения ориентации дефекта от перпендикулярности приблизительно на 10° его выявляемость резко падает.

Помимо эхо-импульсного и эхо-зеркального (тандем) методов УЗК при контроле сварных швов МГ применяется ДВМ (TOFD). ДВМ основан на регистрации времени прихода сигналов, дифрагированных на верхнем и нижнем концах дефекта продольных и поперечных волн, причем ориентация дефекта в данном случае не играет существенной роли [28]. ДВМ выполняется двумя наклонными ПЭП, которые работают в раздельном режиме. Призмы данных ПЭП позволяют вводить ультразвуковые колебания в металл на угле меньше первого критического, тем самым вводя продольную и поперечную волну в сталь. ПЭП располагают симметрично относительно центральной оси сварного шва на строго определенном расстоянии (рисунок 1.12).



И – излучатель; П - приемник

1 – головная волна, 2 – донный сигнал, 3 – сигнал от верхнего края несплошности, 4 – сигнал от нижнего края несплошности, 5 – сварной шов, 6 – несплошность

Рисунок 1.12 – ДВМ. Схема установки ПЭП– (а), схема сигналов на экране дефектоскопа (б)

При такой постановке ПЭП первой в приемник приходит головная волна 1, которая проходит путь от излучателя к приемнику. Далее на бездефектном участке приходит донный сигнал 2. В случае наличия несплошности внутри сварного соединения, между сигналом головной волны и донным сигналом

появляются сигналы от волн, дифрагированных на верхнем и нижнем краю несплошности. По данным сигналам судят о наличии несплошности внутри сварного шва.

Результаты УЗК ДВМ представляются в виде набора А- и В-сканов (рисунок 1.13), при этом для формирования В-скана уровень сигнала на А-скане преобразуется в цветное значение в градациях серого и каждому пикселю соответствует значение в пределах 256 оттенков серого.

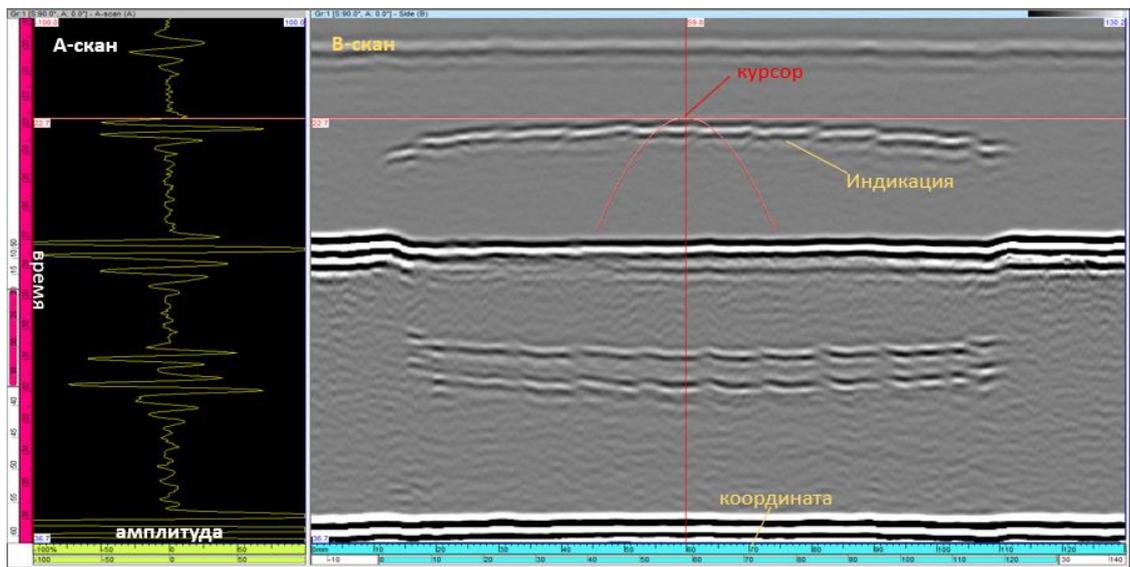


Рисунок 1.13 – Пример результатов УЗК ДВМ

ДВМ имеет высокую выявляемость как плоскостных, так и объемных дефектов, не зависимо от их ориентации, а также позволяет оценивать их высоты. К недостаткам ДВМ можно отнести относительно низкую выявляемость дефектов, расположенных близко к внешней или внутренней поверхностям сварного соединения, из-за наличия мертвых зон, а также наличие субъективного фактора при расшифровке результатов контроля, обусловленного квалификацией специалиста, осуществляющего расшифровку.

Сегодня существует ряд систем, реализующих автоматизированный УЗК вышеуказанными методами кольцевых стыковых соединений МГ, их фото представлено на Рисунке 1.14.

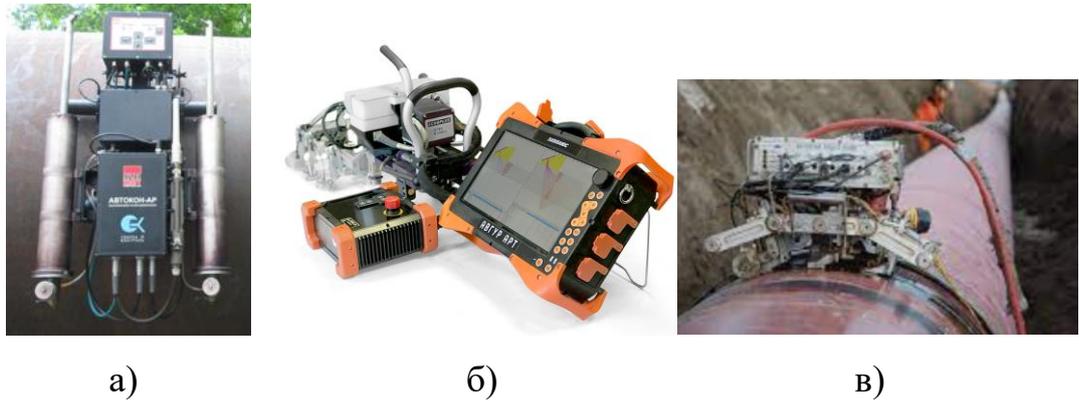


Рисунок 1.14 – Системы автоматизированного УЗК. Автокон-АР [15] (а), Авгур-АРТ [30] (б), Rotoscan [31] (в)

1.2 Оценка качества магистральных газопроводов с применением сочетания данных неразрушающего контроля

Как видно из вышесказанного, каждый метод НК кольцевых сварных соединений МГ имеет свои преимущества и недостатки, проводится в автоматизированном режиме, и, в результате проведения НК, формируются данные в виде изображений различного характера, которые несут в себе значительный объем информации о выявленных несплошностях сварных швов. Согласно существующей НД ПАО «Газпром» [1] результаты всех применяемых методов НК анализируются по отдельности, а принятие решения о качестве кольцевого сварного соединения производится по наихудшему варианту. При этом, в случае выявления РНК и автоматизированным/механизированным УЗК несплошностей типа «несплавления», допускается их оценка по нормам для автоматизированного/механизированного УЗК с целью уменьшения перебраковки по РНК. Схема оценки качества кольцевых сварных соединений по существующей НД ПАО «Газпром» представлена на рисунке 1.15.

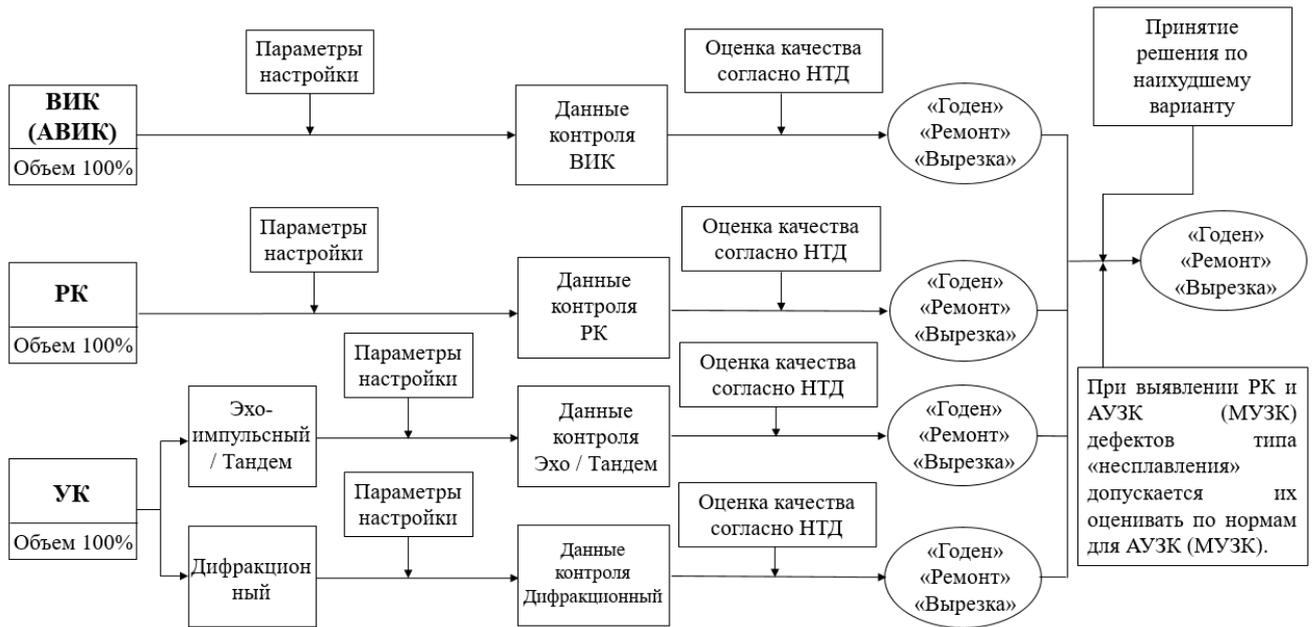


Рисунок 1.15 – Схема оценки качества сварных швов согласно действующей НД ПАО «Газпром»

Для прочностных расчетов ресурса трубопровода требуется информация о типе и параметрах несплошностей сварных швов. Из-за ограниченной информации о несплошности, получаемой по результатам одного метода НК критерии оценки качества для каждого метода по отдельности выбираются более жесткими. В итоге анализ данных контроля методов НК сварных швов МГ по отдельности, и принятие решения о качестве кольцевого сварного соединения по наилучшему варианту приводит к применению жестких норм оценки качества, следовательно, к увеличению перебраковки, в результате чего темп строительства МГ сильно уменьшается из-за частых ремонтов. Поэтому необходима оценки качества МГ, позволяющая максимально достоверно и точно прогнозировать тип и параметры дефектов сварных швов, опираясь на максимально возможную информацию, получаемую из данных НК.

В связи с выше сказанным, предлагаемая схема оценки качества кольцевых сварных соединений МГ заключается в следующем: собираются данные всех методов НК, далее они подаются в некую модель сочетания данных, которая на основе результатов НК прогнозирует тип и параметры дефекта, после чего по этой информации происходит оценка качества всего кольцевого сварного

соединения по существующим или вновь разрабатываемым критериям оценки качества (рисунок 1.16).

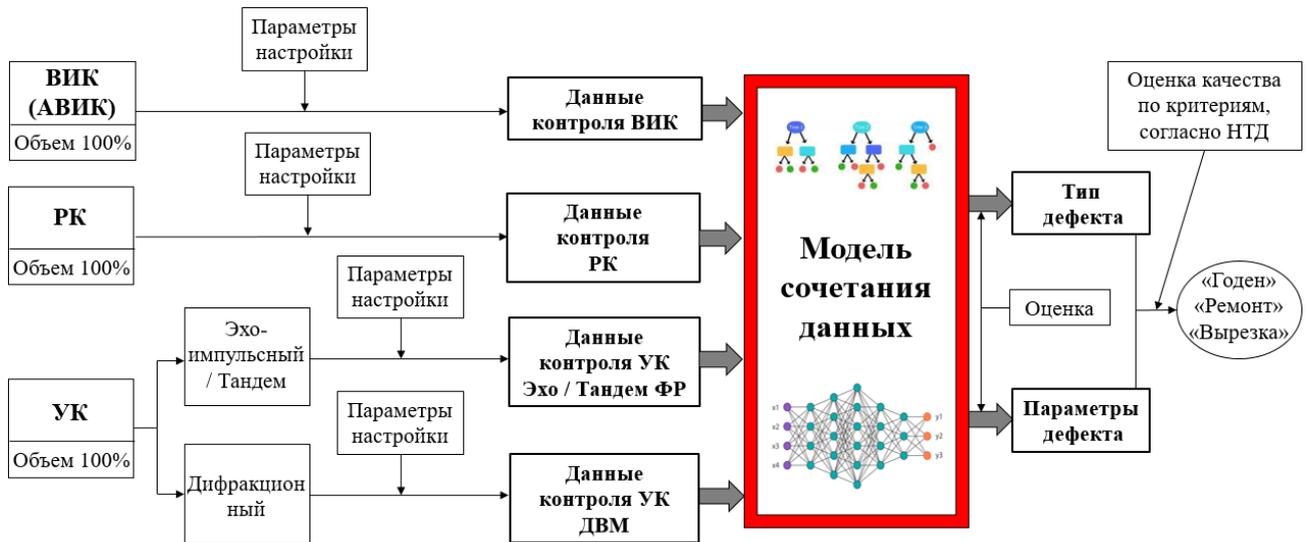


Рисунок 1.16 – Схема оценки качества кольцевого сварного соединения с применением сочетания данных

Сочетание данных является процессом объединения источников данных для получения более согласующейся, точной и полезной информации, чем информация от одного отдельного источника. Модели сочетания данных основываются на статистических алгоритмах, теории нечетких множеств, машинном обучении и т.д., а также активно применяются в оборонной промышленности, медицине и других областях [7]. Впервые цифровые технологии сочетания данных были применены для НК в [10], и в настоящее время их применение стремительно растет. Основными исследователями, занимавшимися сочетанием данных в НК являются: X. E. Gros, J. Bousigue, K. Takahashi, Z. Liu, K. Tsukada, K. Hanasaki, D. Horn, W.R. Mao, A. Dromigny, Н.П. Алешин, Н.В. Крайний, О.Н. Будадин, Т.Е. Троицкий-Марков, М.В. Овечкин, А.Е. Шубочкин, В.В. Атрощенко, М.П. Савичев, Р.Е. Артемьев.

Сочетание данных в НК применялось с целью мониторинга состояния опасных производственных объектов, реконструкции трехмерных изображений дефекта, оценки состояния электронных компонентов, а также оценки качества сварных швов и основного металла. В литературе отмечено применение сочетания данных в аэрокосмической и нефтегазовой промышленности, а также

в гражданском строительстве [32, 33]. В [34] применяли модели сочетания данных, основанные на Байесовском выводе и теории Демпстера-Шафера для совместного анализа результатов вихретокового контроля и инфракрасной термографии при контроле композиционных материалов с целью получения более точной информации о повреждениях. Авторы работы [35] также применяли модели сочетания данных, основанные на Байесовском выводе и теории Демпстера-Шафера, для совместного анализа результатов вихретокового и ультразвукового методов НК при контроле труб теплообменников с целью увеличения достоверности контроля. В [36] авторы использовали байесовский вывод для комплексирования двух рентгеновских изображений, что позволило улучшить динамический диапазон итогового изображения.

Для оценки качества сварных швов с применением сочетания данных различных методов НК в литературе присутствуют следующие работы. В [8] авторы применяли модели сочетания данных, основанные на теории Демпстера-Шафера для совместного анализа каждого пикселя изображений РНК и УЗК эхо-импульсным методом с целью реконструкции трехмерных изображений дефектов. Исследуемый набор данных был небольшим и состоял из 2х образцов. Пример результата сочетания данных из [8] представлен на рисунке – 1.17

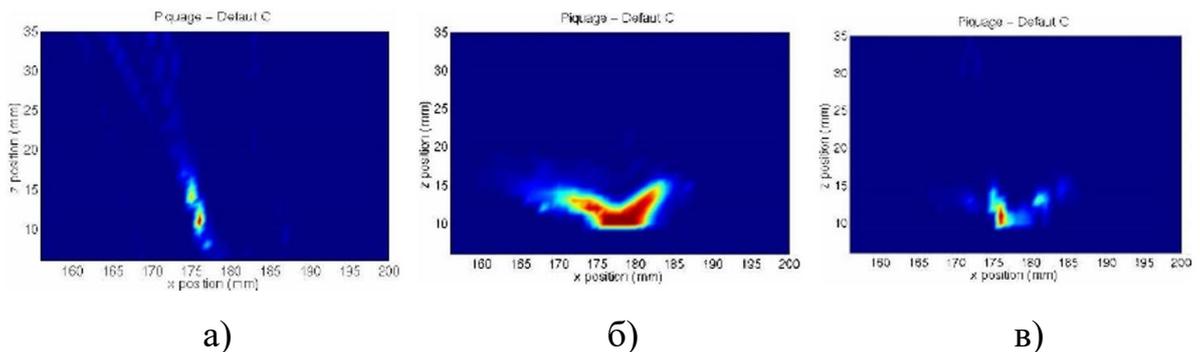


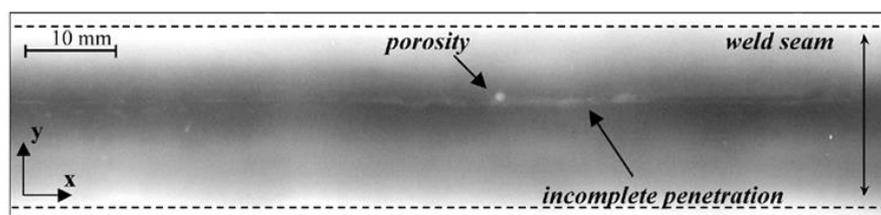
Рисунок 1.17 – Пример результата сочетания данных из [8]. Данные РНК (а), данные УЗК (б), сочетание данных РНК и УЗК

В таблице 1.1 представлены результаты определения параметров дефектов из работы [8]. Значения длины и глубины дефекта, полученные по результатам сочетания данных РНК и УЗК, ближе к паспортным значениям, чем результаты РНК и УЗК по отдельности.

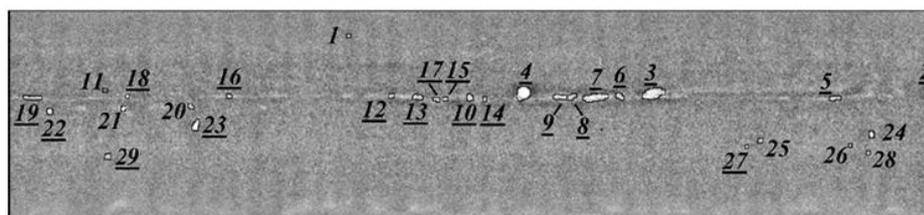
Таблица 1.1 – Определение параметров дефекта из [8]

Параметр дефекта	Паспортное значение, мм	Значение по УЗК, мм	Значение по РНК, мм	Значение по сочетанию РНК и УЗК, мм
Длина	15	>20	14	14,5
Глубина	3	6	14	3

Другим опытом применения сочетания данных УЗК и РНК при контроле сварных швов является работа [9]. В данной работе производили обработку изображений, полученных по результатам РНК с применением фильтрации по пороговым значениям градации серого. Пример обработки изображения РНК представлен на рисунке – 1.18. После подобной сегментации появлялся ряд ложных индикаций (к примеру поз. 1,24, 28, рисунок 1.18 - б). С целью увеличения выявляемости дефектов, исключения ложных индикаций и облегчения интерпретации результатов, данные РНК комбинировали с данными УЗК. Результаты контроля того же шва, совмещенные от разных ПЭП, представлены на рисунке – 1.19.



а)



б)

Рисунок 1.18 – Пример обработки изображения РНК [9]. Исходное изображение РНК (а), обработанное изображение РНК (б)

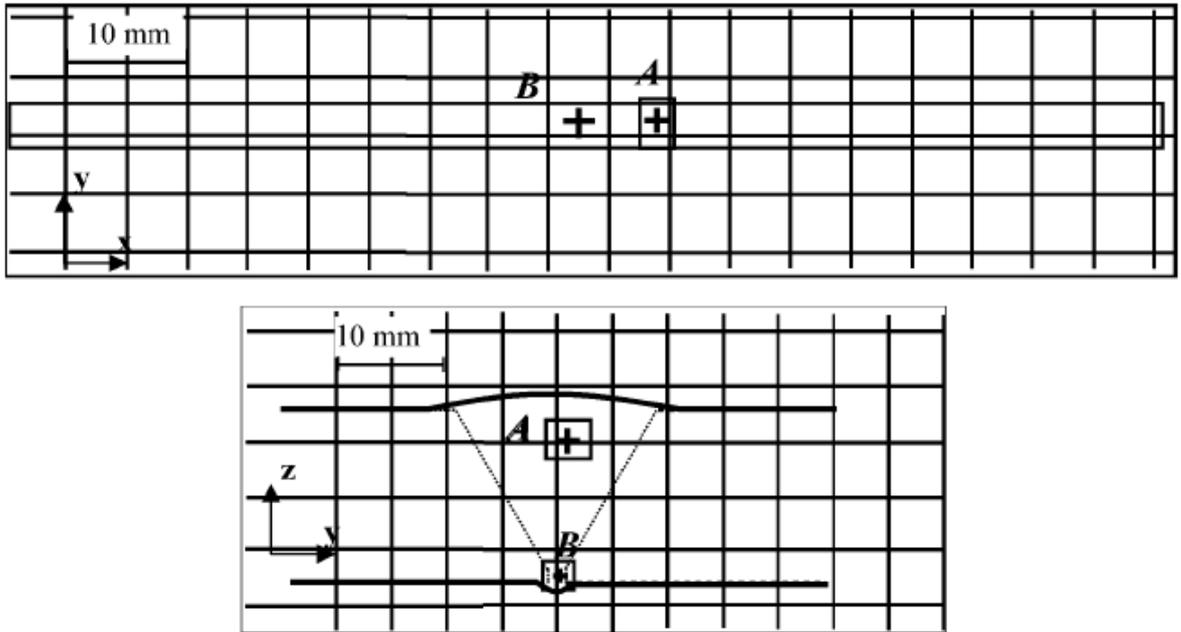


Рисунок 1.19 – Пример результатов УЗК из [9]

Далее были определены функции принадлежности гипотезам, согласно теории нечетких множеств [37]. На основе определенных функций принадлежности были присвоены массовые вероятности теории Демпстера-Шафера [38, 39]. После комбинирования данных по правилу комбинации Демпстера был построен совместный скан (рисунок 1.20).

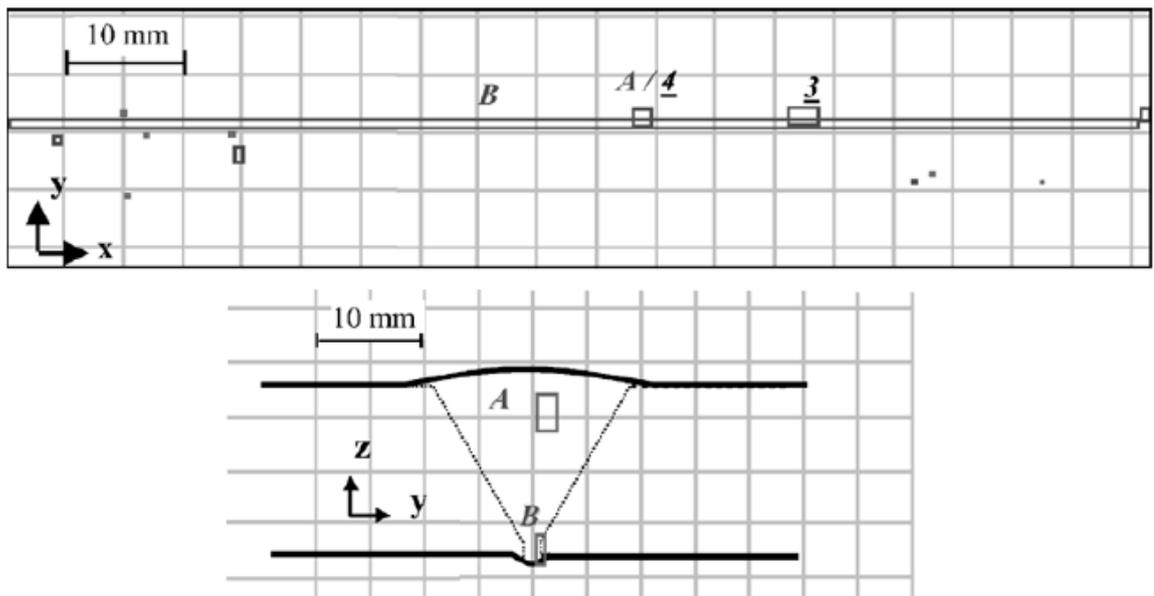


Рисунок 1.20 – Пример совместного скана РНК и УЗК из [9]

Таблица 1.2 представляет результаты совместного анализа для двух основных типов дефектов, при выявлении которых УЗК и РНК достаточно

хорошо дополняют друг друга. Видно, что УЗК и РНК способны обнаружить одно и то же скопление пор минимальной площади, хотя площадь скопления пор, обнаруженного только УЗК, намного меньше, т.к. она зависит от местоположения. Как правило РНК обнаруживает объемные дефекты лучше, чем УЗК. Однако благодаря сочетанию данных даже самые небольшие области скопления пор могут быть обнаружены с соответствующим порогом функции доверия.

Результат сочетания данных можно оценить, сравнив значения функции доверия до и после сочетания (рисунок – 1.21). На объемных дефектах УЗК и РНК показывают среднее значение функции доверия немного ниже 0,7, тогда как сочетание данных показывает существенно большее значение функции доверия - 0,9. Таким образом, при пороге принятия решения, равного 0,7, данные объемные дефекты были бы пропущены при анализе данных методами НК по отдельности.

Таблица 1.2 – Определение параметров дефекта из [9]

Параметр	РНК	УЗК	Сочетание РНК и УЗК, мм
Количество обнаруженной пористости	10	1	12
Минимальная площадь пористости	0,4 мм ²	0,4 мм ²	0,1 мм ²
Количество обнаруженных несплавлений	3 в 12 частях	9	10
Размер несплавлений	Протяженность недооценена, ширина определена корректно	Протяженность определена корректно, ширина переоценена	Протяженность и ширина определены корректно

Плоскостные дефекты обычно обнаруживаются методом РНК как набор фрагментов. Данные типы дефектов имеют особо низкую контрастность. Из-за этого они трудно обнаруживаются РНК и, следовательно, значение функции доверия в данном случае имеет низкое значение. С другой стороны, известно, что УЗК лучше выявляет плоскостные дефекты, и, таким образом, функция доверия для УЗК выше. По результатам сочетания данных не только значение функции доверия выше, чем только при анализе РНК, но в итоге получается корректное количество дефектов вместо нескольких фрагментов. Кроме того, РНК позволяет получить более точные размеры в поперечном сечении благодаря небольшому размеру пикселя.

Плоские дефекты обычно выявляются РНК и УЗК. В результате значение функции доверия довольно высокое для обоих методов, и еще выше после сочетания данных. Среди всех объединенных дефектов 11 из 24 были бы пропущены в случае анализа РНК по отдельности (потому что значение их массовой вероятности было ниже порогового значения), в то время как два дефекта 2 из 9 были бы пропущены случае анализа УЗК по отдельности. Более того, еще 9 дефектов обнаружены только РНК и 5 — УЗК. В связи с этим видно, что сочетание данных увеличивает общее количество обнаруженных дефектов и повышает значение их функции доверия, тем самым позволяя принимать более надежные решения.

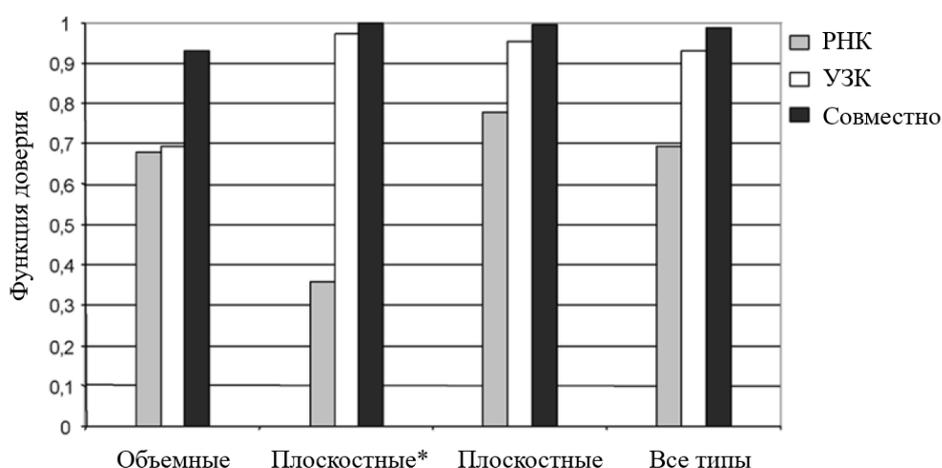


Рисунок 1.21 – Сравнение значений функции доверия для РНК и УЗК и совместного рассмотрения РНК и УЗК для разных типов дефектов из [9]

В работах [135, 136] представлена методика совместного анализа ВИК, РНК и УЗК эхо-импульсным методом, которая с применением логических выражений, позволяет оценить суммарную протяженность, исключить ложные срабатывания по УЗК в месте превышения проплава и смещения кромок.

В большинстве описанных работах для сочетания данных в основном применялись следующие подходы, такие как Байесовский вывод, теория Демпстера-Шафера и теория нечетких множеств. Данные подходы требуют определения априорных и массовых вероятностей, а также функции принадлежности соответственно. Для этого не требуются больших обучающих выборок (либо они могут вообще отсутствовать и априорные вероятности присваиваются на основе ранее накопленного опыта). Сегодня существуют подходы на основе машинного и глубокого обучения, которые по своей работоспособности значительно обходят указанные подходы, но требуют наличия более крупных обучающих выборок.

1.3 Существующие технологии и алгоритмы совместной обработки данных

В настоящее время вопросами комплексной оценки информации, с использованием объединения данных, получаемых от разных источников, занимаются в различных технологических и научных сферах. Среди них можно выделить такие направления как распознавание образов [40-52], обработка изображений [46, 53-62], отслеживание целей [63-78], робототехника [44, 47, 52, 56, 79-85], и контроль качества [10, 86-92]. Некоторые из подходов, которые применяются в этих направлениях, можно использовать для совместного анализа результатов контроля кольцевых сварных швов МГ ВИК, РНК и УЗК.

При контроле сварных швов МГ необходимо решать две подзадачи: первая – определять тип дефектов, вторая – определять их параметры. Таким образом модели совместного анализа должны позволять выполнять классификацию и производить определение параметров. В работах [А1-А4] подобная задача решалась для классификации и определения параметров дефектов основного

металла МГ по результатам совместного анализа визуального и измерительного, вихретокового и ультразвукового методов НК.

Далее будут рассмотрены алгоритмы, которые могут быть применены для поставленных задач.

1.3.1 Байесовский вывод

Байесовский вывод является методом статистического анализа, который основывается на теореме Байеса и позволяет обновлять вероятность гипотезы по мере получения новых данных. Центральным элементом этого подхода является апостериорная вероятность, которая рассчитывается на основе априорной вероятности гипотезы и правдоподобия данных. Байесовский вывод отличается от частотных методов тем, что рассматривает параметры как случайные величины и даёт возможность учитывать предшествующую информацию в виде априорного распределения [39]. В основе байесовского вывода лежит теорема Байеса, которая выражается следующим образом:

$$P(H|D) = \frac{P(D|H)P(H)}{P(D)}, \quad (1.1)$$

где $P(H|D)$ – апостериорная вероятность гипотезы H при результатах D ; $P(H)$ — априорная вероятность гипотезы H , $P(D|H)$ — правдоподобие, которое описывает вероятность данных при условии, что гипотеза верна, и $P(D)$ — нормализующий множитель, обеспечивающий корректность апостериорного распределения.

В случае наличия системы имеющих множество различных датчиков, получающей разнородную информацию применяется комбинированное правило Байесовского вывода, которое выглядит следующим образом:

$$P(H|D_1 \dots D_k) = \frac{P(H) \prod_{k=1}^K P(D_k|H)}{\sum_{i=1}^N P(H) \prod_{k=1}^K P(D_k|H)}, \quad (1.2)$$

где $P(H|D_1 \dots D_k)$ – апостериорная вероятность гипотезы H при получении данных от всех k датчиков; $\prod_{k=1}^K P(D_k|H)$ – правдоподобие, которое описывает вероятность данных от всех датчиков при условии, что гипотеза верна; $P(H)$ –

априорная вероятность гипотезы H ; $\sum_{i=1}^N P(H) \prod_{k=1}^K P(D_k|H)$ – полная вероятность регистрации всех данных.

Байесовский вывод активно используется в области сочетания данных. К примеру, в работах [67, 81, 82] рассматривается совместная обработка данных с использованием децентрализованной архитектуры, так же байесовский вывод используется для получения характеристик состояний окружающей среды при ее сканировании различными датчиками. При комбинировании данных НК байесовский вывод применялся для оценки дефектных и бездефектных изображений, полученных по результатам вихретокового и термографического контроля [34, 93]. Также он применялся для комплексирования двух рентгеновских изображений, что позволило улучшить динамический диапазон итогового изображения [36]. В работе [94] было реализовано выявление трещин на металлических конструкциях атомных электростанций по изображениям с видеокамер. Помимо этого, производилось сочетание данных вихретокового и ультразвукового контроля при сканировании труб на атомных электростанциях [35].

При использовании байесовского вывода на результаты прогноза сильно влияет выбор априорных вероятностей. Помимо этого, байесовский вывод требует наличие взаимоисключающих и исчерпывающих гипотез и не позволяет учитывать неоднозначность одной или нескольких гипотез.

1.3.2 Теория Демпстера-Шафера

Теория Демпстера-Шафера является обобщением байесовского вывода, которая позволяет учитывать неоднозначность между гипотезами [38, 39]. Она использует массовые вероятности, которые присваиваются каждому подмножеству из множества гипотез. Массовая вероятность показывает степень уверенности, о принятии гипотезы, и сумма массовых вероятностей по всем подмножествам равняется единице.

Также в теории Демпстера-Шаффера используются функции доверия и правдоподобия. Функция доверия определяется для конкретного множества и суммирует массовые вероятности всех подмножеств, которые входят в него, тем самым обеспечивая минимальную уверенность в том, что истинный результат находится в этом подмножестве. Функция доверия описывается следующей формулой:

$$Bel(A) = \sum_{B \in A} m(B), \quad (1.3)$$

где $Bel(A)$ – функция доверия для подмножества A ; $m(B)$ – массы подмножеств B , входящих в подмножество A .

Функция правдоподобия показывает максимально возможную уверенность в том, что истинный результат пересекается с рассматриваемым подмножеством. Она рассчитывается как сумма масс всех подмножеств, которые пересекаются с интересующим подмножеством и описывается следующей формулой:

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B), \quad (1.4)$$

где $Pl(A)$ – функция правдоподобия для подмножества A ; $m(B)$ – массы подмножеств B , пересекающихся с подмножеством A .

Основной особенностью теории Демпстера-Шаффера является правило комбинирования Демпстера, которое позволяет объединять массы гипотез, полученных из независимых источников, и сформировать результирующую массовую функцию. Правило комбинации Демпстера описывается следующей формулой:

$$m_{12}(A) = \frac{\sum_{B \cap C = A} m_1(B)m_2(C)}{1 - \sum_{B \cap C = \emptyset} m_1(B)m_2(C)}, \quad (1.5)$$

где $m_{12}(A)$ – результирующая массовая функция; $m_1(B)$ и $m_2(C)$ – массы для данных, полученных из источников B и C , соответственно.

Теория Демпстера-Шаффера, как алгоритм сочетания данных, нашла свое применение при определении степени достоверности в задачах идентификации целей [66, 71, 74]. Так же она использовалась при комбинировании изображений,

полученных по результатам вихретокового контроля и инфракрасной термографии [34]. В [35] теория Демпстера-Шафера применялась для сочетания данных вихретокового и ультразвукового контроля, и показала неплохие результаты. В работе [8] производилось сочетание данных УЗК и РНК сварных соединений. Также теория Демпстера-Шафера применялась для совместного анализа данных ультразвукового и вихретокового контроля с целью улучшения точности определения глубины дефектов [95].

Теория Демпстера-Шафера в отличие от байесовского вывода позволяет осуществлять более полную идентификацию типов дефектов, т.к. имеет возможность учитывать такие классы как отсутствие дефектов, или дефекты, которые невозможно отнести ни к одному из определенных классов. Точность результатов, полученных с помощью теории Демпстера-Шафера, в большой мере зависит от корректности определения массовых вероятностей, причем присутствует возможность получения нелогичных результатов при объединении противоречивых данных.

1.3.3 Дерево решений

«Дерево решений» (Decision Tree) является часто используемым алгоритмом машинного обучения, который применяется как для задач классификации, так и для регрессии. В результате обучения согласно данного алгоритма создается модель в виде древовидной структуры, где каждый узел соответствует атрибуту или признаку данных, ветви представляют возможные значения этого признака, а листья — итоговые классы или значения. Алгоритм разделяет данные на подмножества по определенным условиям, что позволяет последовательно выбирать признаки, наиболее полезные для классификации или регрессии.

Дерево решений состоит из следующих компонентов (рисунок 1.22):

- Корневой узел: представляет весь набор данных. На этом уровне выбирается первый атрибут, по которому происходит первое разбиение данных.

- Внутренние узлы: узлы, которые не являются листьями и представляют собой атрибуты, по которым продолжается разбиение.
- Листовые узлы: конечные узлы дерева, которые представляют решение, то есть конечный класс или спрогнозированное значение.
- Ветви: соединяют узлы и показывают путь, по которому движется процесс принятия решений.

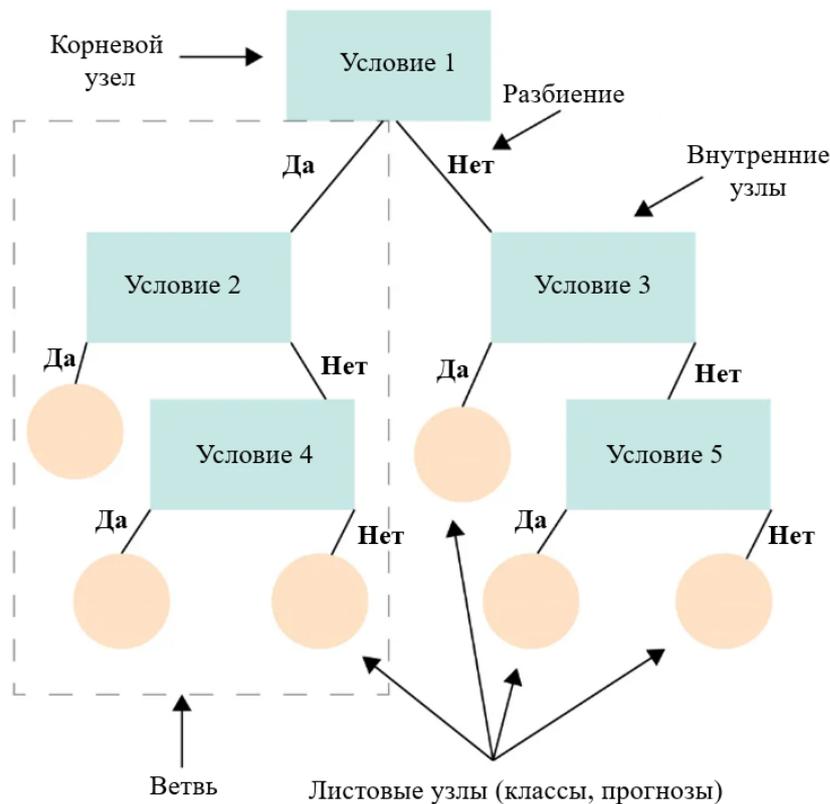


Рисунок 1.22 – Схематическое изображение алгоритма «дерево решений»

Модель дерева решений строится следующим образом. Изначально происходит выбор признака для разделений, при этом алгоритм на каждом шаге выбирает признак, который лучше всего делит данные на подмножества. Оценка "качества" деления может основываться на таких мерах, как критерий информации, индекс Джини и т.д.

Критерий информации базируется на понятии энтропии. Энтропия для множества S , состоящего из n классов, определяется как:

$$H(S) = - \sum_{i=1}^n p_i \log_2 p_i, \quad (1.6)$$

где p_i – вероятность появления класса i в данных S .

Информационный прирост рассчитывается как разница между энтропией исходного набора и средневзвешенной энтропией разбиения:

$$IG(S, A) = H(S) - \sum_{v \in \text{Values}(A)} \frac{|S_v|}{|S|} H(S_v), \quad (1.7)$$

где A - атрибут, по которому происходит разбиение, а S_v подмножество данных, соответствующее значению v атрибута A .

Индекс Джини, как правило, используется для измерения чистоты подмножеств. Индекс Джини для набора S вычисляется как:

$$Gini(S) = 1 - \sum_{i=1}^n p_i^2, \quad (1.8)$$

где p_i - доля объектов класса i в наборе данных S . При выборе атрибута для разделения выбирается тот атрибут, который минимизирует индекс Джини.

Далее происходит разбиение данных, где данные делятся на подмножества по выбранному признаку, после чего процесс повторяется для каждого подмножества. Процесс разбиения продолжается до тех пор, пока не будет выполнено одно из условий: данные разделены идеально (в каждом подмножестве содержится только один класс) или дерево достигло заданной глубины или разбиение больше не улучшает точность прогноза.

«Дерево решений» использовали для классификации дефектов в аэрокосмических конструкциях по результатам вихретокового контроля [96]. В [97] «дерево решений» точнее всех прогнозировало размеры дефектов в композиционных материалах по результатам термографического контроля. В [98] «дерево решений» применялось для определения влияния различных факторов на качество точечной сварки.

Основным преимуществом «деревьев решений» является возможность их интерпретации для понимания логики их прогнозов. Данный алгоритм работает как с категориальными, так и с непрерывными данными, без нормализации. Однако глубокие деревья склонны к переобучению, причем даже небольшие изменения могут приводить к большим различиям в получаемых моделях деревьев.

1.3.4 Случайный лес

«Случайный лес» (Random Forest) является алгоритмом машинного обучения и принадлежит к методам ансамблевого обучения. «Случайный лес» объединяет множество деревьев решений для повышения точности и устойчивости модели. Суть алгоритма заключается в построении множества «деревьев решений», каждое из которых обучается на случайно выбранном подмножестве данных и с использованием случайного набора признаков. Прогнозирование осуществляется путём усреднения результатов всех деревьев для регрессии или голосования большинства для классификации (рисунок 1.23).

Модель на основе алгоритма случайный лес строится следующим образом. Изначально для каждого дерева создается случайная подвыборка из исходного набора данных с возвращением, то есть одно и то же наблюдение может быть выбрано несколько раз, а некоторые данные могут не попасть в подвыборку. Далее для каждого узла в дереве решений выбирается случайное подмножество признаков для разделения. Это помогает избежать переобучения и корреляции между деревьями. Каждое дерево решений строится независимо от других, используя метод деревьев решений на подвыборке данных и случайных признаках. В итоге для классификации применяется голосование большинства (то есть класс, спрогнозированный большинством деревьев (1.9)), а для регрессии — усреднение значений, предсказанных деревьями (1.10).

$$\hat{y} = \text{mode}(T_1(x), T_2(x), \dots, T_B(x)), \quad (1.9)$$

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B T_b(x), \quad (1.10)$$

где $T_1(x), T_2(x), \dots, T_B(x)$ – прогнозы B деревьев.

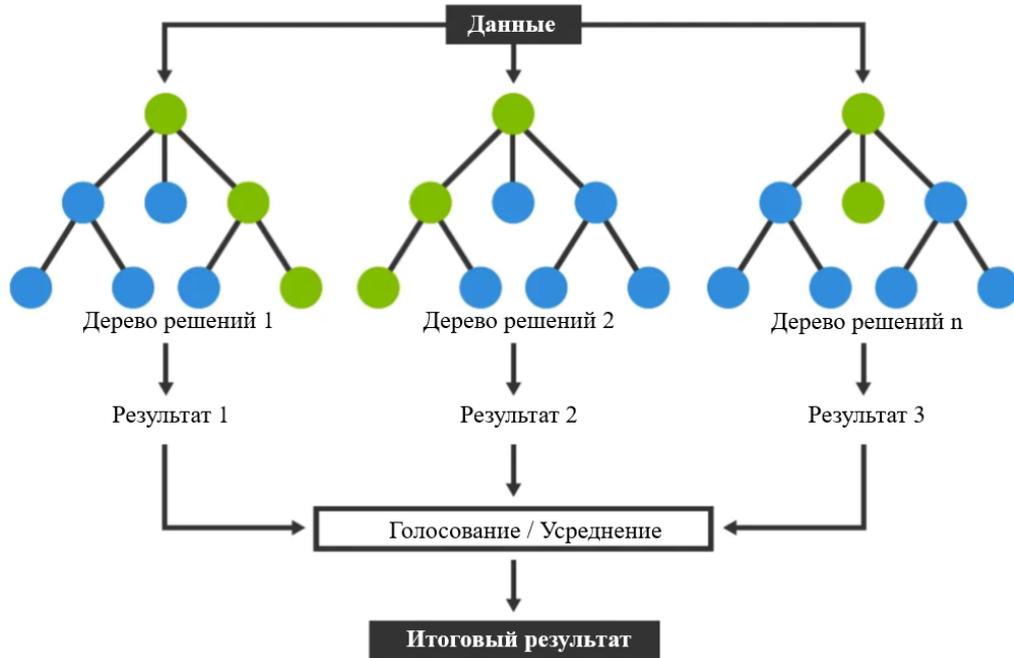


Рисунок 1.23 – Схематичное изображение алгоритма «случайный лес»

«Случайный лес» использовался для классификации дефектов типа поры и несплавления в изделиях аддитивного производства анализируя данные оптической послойной томографии [99]. Так же с помощью «случайного леса» классифицируют дефекты сварных соединений алюминиевых сплавов типа неполное проплавление, прожог и пористость, на основе шести признаков, полученных из спектрального анализа сварочной дуги [100]. В работе [101] производилась оценка степени повреждения бетонных конструкций из-за коррозии арматуры по четырем показателям таким, как коэффициент воздухопроницаемости, скорость ультразвуковых колебаний, прочность на сжатие, электрическое сопротивление. Было установлено, что алгоритм «случайного леса» обеспечивает лучшую точность, чем оценка повреждений отдельными методами НК.

«Случайный лес» обеспечивает высокую точность прогнозов, помимо этого объединение результатов работы множества деревьев уменьшает риск

переобучения и увеличивает устойчивость алгоритма к наличию шума в данных. «Случайный лес» хорошо работает на больших объемах данных различных типов, таких как категориальные и непрерывные. Так же он позволяет оценивать вклад входных параметров в классификацию или регрессию. На практике часто используются модели на основе «случайного леса» с большим количеством деревьев, из-за чего их довольно сложно интерпретировать и визуализировать.

1.3.5 Градиентный бустинг

«Градиентный бустинг» (Gradient Boosting) является алгоритмом машинного обучения, который представляет собой ансамбль слабых моделей (обычно деревьев решений), обучаемых последовательно (рисунок 1.24). Каждый новый член ансамбля строится таким образом, чтобы уменьшить ошибку, сделанную предыдущими моделями, с помощью оптимизации методом градиентного спуска. Итоговый прогноз осуществляется путем суммирования вкладов всех деревьев, включая начальное приближение. «Градиентный бустинг» применяется как для задач классификации, так и для задач регрессии.

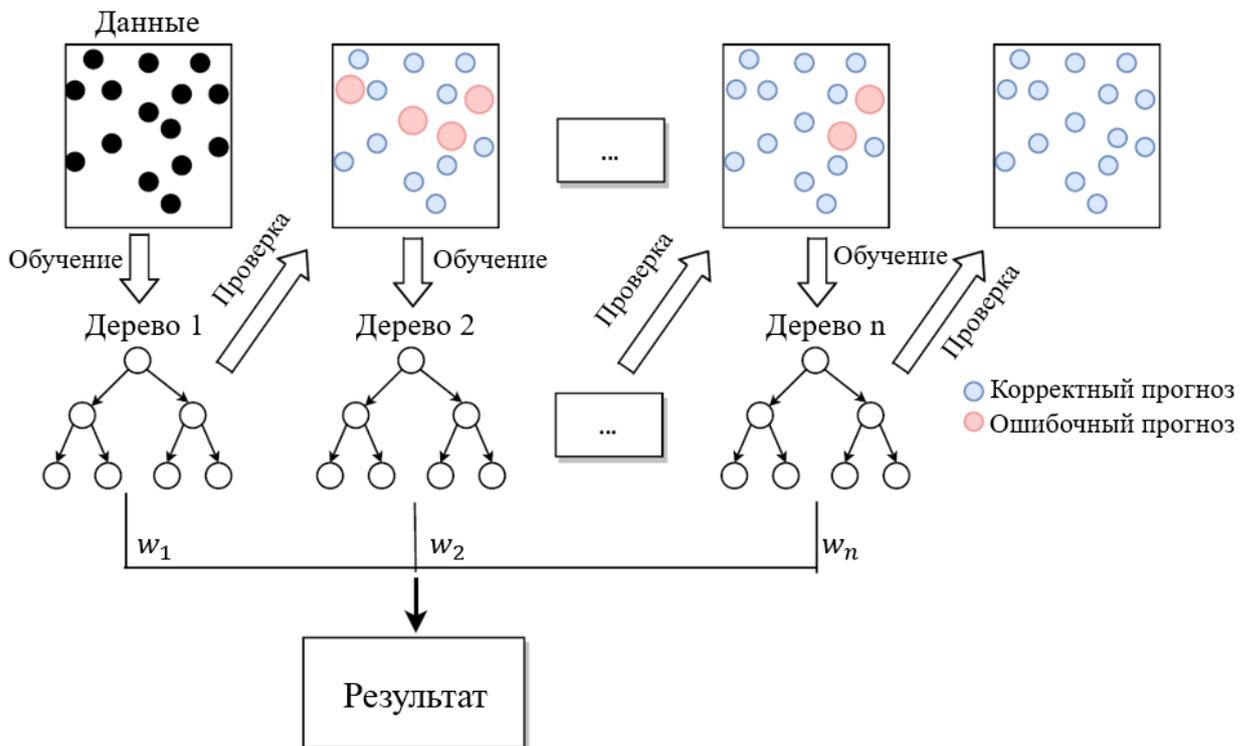


Рисунок 1.24 – Схематичное изображение алгоритма «градиентный бустинг»

Формально, если $F_m(x)$ является совокупной моделью после шага m , то «градиентный бустинг» строит её в виде итеративного приближения к оптимальной модели, добавляя новую модель $h_m(x)$, которая минимизирует ошибку текущего ансамбля. На каждом шаге m обновление модели можно записать как:

$$F_{m+1}(x) = F_m(x) + \gamma h_m(x), \quad (1.11)$$

где $h_m(x)$ это новое дерево, которое обучается на ошибках предыдущего ансамбля, а γ - это шаг обновления (обычно называется скоростью обучения).

«Градиентный бустинг» использовали для оценки параметров коррозии на трубопроводах, предназначенных для перекачки шлама, по результатам ультразвукового контроля [102]. Так же «градиентный бустинг» применялся для оценки развития коррозии на трубопроводах [103].

«Градиентный бустинг» обеспечивает высокие показатели метрик, как в задачах классификации, так и в задачах регрессии, причем он хорошо работает как на категориальных, так и на непрерывных данных без предварительной обработки. Однако данный алгоритм сложен для интерпретации и визуализации, помимо этого требуется тщательный выбор гиперпараметров модели.

1.3.10 Полносвязная нейронная сеть

«Полносвязная нейронная сеть», или «многослойный перцептрон», представляет собой алгоритм машинного обучения и одну из основных форм искусственных нейронных сетей, где каждый нейрон одного слоя соединён с каждым нейроном следующего. «Полносвязные нейронные сети» применяются для решения задач классификации и регрессии, а также служат основой для множества более сложных архитектур глубокого обучения.

«Полносвязная нейронная сеть» состоит из следующих компонентов. Изначально данные поступают на входной слой. Количество нейронов во

входном слое равно количеству параметров в данных. Далее они поступают на скрытые слои, состоящие из одного или нескольких слоёв нейронов, которые выполняют преобразования данных с использованием нелинейных функций активации. В итоге информация поступает на выходной слой, где выдается результат прогноза. Для задач классификации количество нейронов на выходном слое соответствует количеству классов, для регрессии — количеству целевых переменных. На каждом слое все нейроны связаны со всеми нейронами следующего слоя, что даёт название "полносвязная сеть" (рисунок 1.25). Связи между нейронами имеют веса, которые оптимизируются в процессе обучения.

Каждый нейрон в «полносвязной нейронной сети» можно рассматривать как узел, выполняющий следующее вычисление:

$$z_i = \sum_{j=1}^n \omega_{ij}x_j + b_i, \quad (1.12)$$

где z_i – выход нейрона, ω_{ij} – вес связи между нейронами i -го слоя и j -го предыдущего слоя, x_j – выход нейрона предыдущего слоя, b_i – смещение для нейрона i .

На выходе нейрона применяется функция активации $\sigma(z_i)$ которая вводит нелинейность в модель:

$$y_i = \sigma(z_i), \quad (1.13)$$

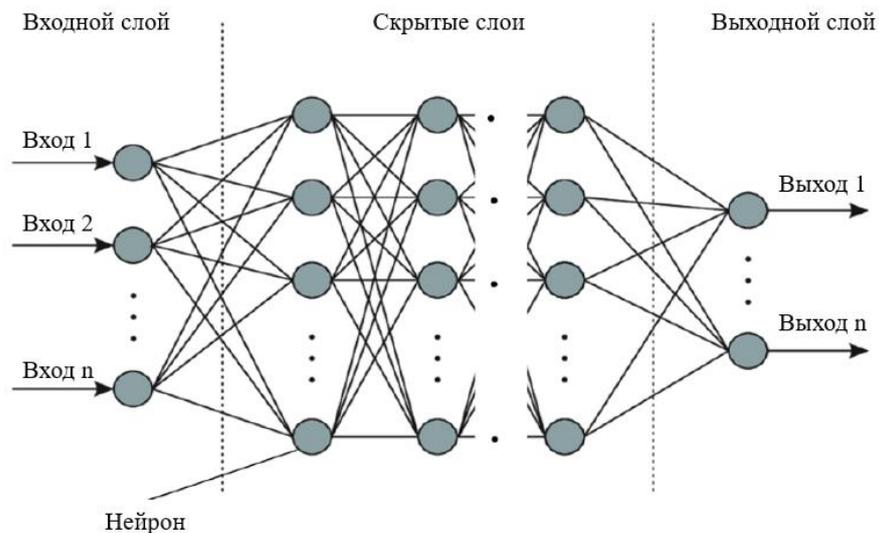


Рисунок 1.25 – Схема «полносвязной нейронной сети»

На скрытых слоях в качестве функций активации обычно используется ReLU (1.14) и гиперболический тангенс (1.15)

$$f(x) = \max(0, x) \quad (1.14)$$

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1.15)$$

На выходном слое в случае классификации на два класса в качестве функции активации применяется сигмоида (1.16), а в случае более двух классов применяется softmax (1.17).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1.16)$$

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (1.17)$$

Процесс обучения полносвязных нейронных сетей обычно состоит из прямого прохода и обратного распространения ошибки. На этапе прямого прохода входные данные передаются через нейронную сеть, начиная с входного слоя, через скрытые слои и заканчивая выходным слоем. Для каждого слоя происходит вычисление линейной комбинации входов с весами, а затем применяется функция активации. Далее вычисляется функция потерь. Для задач классификации часто используется кросс-энтропийная функция потерь:

$$L(y, \hat{y}) = - \sum_{i=1}^c y_i \log(\hat{y}_i), \quad (1.18)$$

где C – количество классов, y_i – истинное значение (один из классов), \hat{y}_i – спрогнозированная вероятность.

Обратное распространение ошибки как правило основывается на градиентном спуске. Цель состоит в минимизации функции потерь путём изменения весов и смещений. Градиенты функции потерь вычисляются относительно каждого веса с использованием цепного правила:

$$\frac{\partial L}{\partial \omega_{ij}} = \frac{\partial L}{\partial z_i} \cdot \frac{\partial z_i}{\partial \omega_{ij}} \quad (1.19)$$

Затем веса обновляются с использованием метода градиентного спуска

$$\omega_{ij} \leftarrow \omega_{ij} - \eta \frac{\partial L}{\partial \omega_{ij}}, \quad (1.20)$$

где η - скорость обучения.

«Полносвязные нейронные сети» успешно применяются для интерпретации сигналов, сочетания данных от нескольких систем, обнаружения и классификации различных объектов [87, 104, 105]. Помимо этого, их применяют для обнаружения целей, распознавания образов и классификации [68, 75, 106]. Также с их помощью выполняется фильтрация и сегментация изображений [61]. В работе [10] «полносвязная нейронная сеть» осуществляет сочетание данных на уровне пикселей, также с помощью нейронной сети выполняется идентификация объектов на изображениях [49]. «Полносвязные нейронные сети» применялись для классификации сигналов вихретокового контроля труб [107, 108], помимо этого в работе [105] определяются параметры дефектов. В работе [90] «полносвязная нейронная сеть» используется для классификации дефектов сварных соединений по результатам УЗК. С помощью «полносвязной нейронной сети» производится сочетание данных вихретокового и ультразвукового контроля в результате чего определяется глубина боковых сверлений в алюминиевых блоках, итоговая погрешность определения глубины находится в пределах 4 %.

«Полносвязные нейронные сети» являются сильным инструментом для задач классификации и регрессии т.к. они могут аппроксимировать практически любую функцию, имея относительно простую структуру. Но они склонны к переобучению в случае недостатка данных. Также нейронные сети имеют большое количество гиперпараметров, нахождение оптимальной конфигурации которых иногда является довольно сложным процессом.

По результатам проделанного анализа можно сказать, что на сегодняшний день не существует модели сочетания данных ВИК, РНК, УЗК эхо-импульсным/эхо-зеркальным (тандем) и ДВМ, которая позволят достоверно

прогнозировать тип и параметры дефектов сварных швов МГ. На разработку данных моделей и методики направления данная диссертационная работа.

1.4 Заключение

Выполнен обзор существующих технологий и оборудования НК сварных швов МГ, а также существующего порядка оценки их качества. Предложен новый порядок оценки качества МГ с применением сочетания данных НК, не противоречащий действующей НД. Также выполнен обзор опыта применения сочетания данных НК в различных областях и для сварных швов. Помимо этого, выполнен обзор существующих технологий и алгоритмов совместной обработки данных.

Таким образом, цель работы заключается в повышении темпов строительства МГ путем уменьшения количества ремонтов, вызванных перебраковкой кольцевых сварных соединений, путем оценки качества по типу и параметрам дефектов, определенных по методике НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК.

В работе решаются следующие поставленные задачи:

- исследование информационных признаков дефектов на изображениях, полученных по результатам НК кольцевых сварных швов МГ с последующим формированием системы входных параметров для моделей сочетания данных.

- научное обоснование возможности определения типа дефекта каждым параметром системы по отдельности, а также установление наличия корреляционных зависимостей между непрерывными параметрами и связи между категориальными параметрами системы.

- исследование степени влияния входных параметров моделей сочетания данных на возможность прогноза типа и параметров дефектов сварных швов.

- разработка и научное обоснование выбора оптимальных моделей сочетания данных, которые позволяют производить прогноз типа и размеров дефектов, используя в качестве входных параметров информационные признаки

дефектов на изображениях, полученных по результатам НК кольцевых сварных швов МГ. Также оценка работоспособности данных моделей.

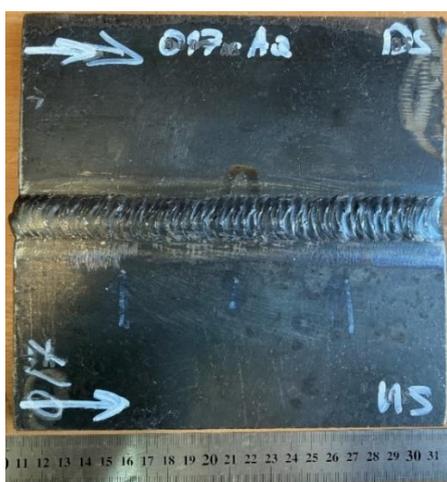
- разработка методики НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК на основе проведенных исследований.

ГЛАВА 2 НАУЧНОЕ ОБОСНОВАНИЕ ВЫБОРА СИСТЕМЫ ИНФОРМАЦИОННЫХ ПРИЗНАКОВ ДЕФЕКТОВ

Согласно предыдущей главе, для разработки моделей сочетания данных, позволяющих производить прогноз типа и параметров дефектов кольцевых сварных швов МГ на основе данных ВИК, РНК и УЗК необходим набор данных, полученных экспериментально. На этом наборе данных будет проводиться разработка моделей и их верификация. Для формирования подобного набора данных требуется наличие сварных соединений с дефектами различных типов и размеров.

2.1 Изготовление экспериментальных образцов

Для формирования набора данных был изготовлен комплект из 82 образцов сварных соединений, содержащих как естественные, так и искусственные дефекты. Сварные соединения были выполнены из пластин толщиной 14 мм и размером 200x100 мм, изготовленных из стали 20. Сварные швы сваривались либо ручной дуговой сваркой покрытыми электродами, либо механизированной сваркой плавящимся электродом в среде защитных газов с V-образной разделкой кромок. Примеры внешнего вида образцов представлены на рисунке – 2.1.



а)



б)

Рисунок 2.1 – Пример фото изготовленных образцов. Фото одного из образцов (а), все образцы (б)

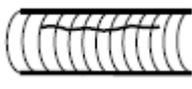
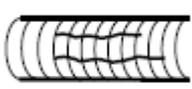
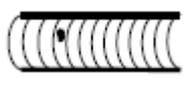
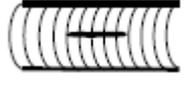
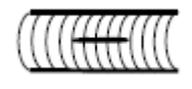
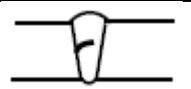
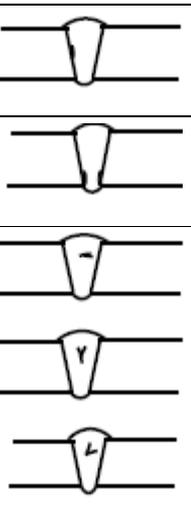
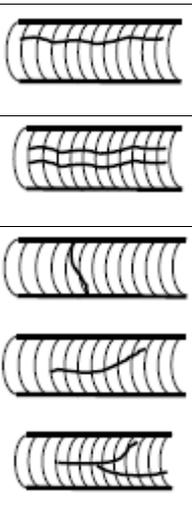
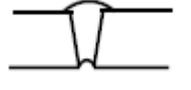
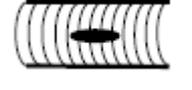
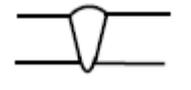
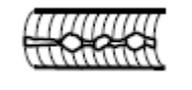
В каждом из образцов было заложено от одного до трех дефектов в зависимости от их типа и размеров. Основным критерием пригодности образца для получения данных являлось отсутствие естественных дефектов в области закладываемого дефекта. Закладываемые дефекты всех типов прошли выборочную верификацию на макрошлифах.

Типы исследуемых дефектов соответствовали НД ПАО «Газпром», а именно документу [1]. Перечень типов дефектов представлен в таблице 2.1.

Таблица 2.1 – Типы дефектов из [1]

Название дефекта	Условное обозначение дефекта	Схематическое изображение дефектов		Вид дефекта
		В сечении	В плане	
Поры	Aa			Одиночные (сферические и удлиненные)
	Ab			Цепочки
	Ac			Скопления
	Ak			Канальные, в том числе «чревообразные»
Неметаллические (шлаковые) включения	Ba			Одиночные компактные
	Bb			Цепочки
	Bc			Скопления

Таблица 2.1 (продолжение)

	Bd ₁			Односторонние удлиненные
	Bd ₂			Двухсторонние удлиненные
Металлические включения	Mw			Вольфрамовые и включения других нерастворимых металлов
Непровары	Da ₁			В корне шва
	Da ₂			В корне шва из-за смещения кромок
	Da ₃			Внутренние при двухсторонней сварке
Несплавления	Db			Межслойные
	Dc ₁			По разделке кромок
	Dc ₂			По разделке кромок, выходящие на поверхность
Трещины	E			Любой длины и направления относительно сварного шва
Дефекты формы шва	Fa			Вогнутость корня шва (утяжина)
	Fb			Превышение проплавления (провис)

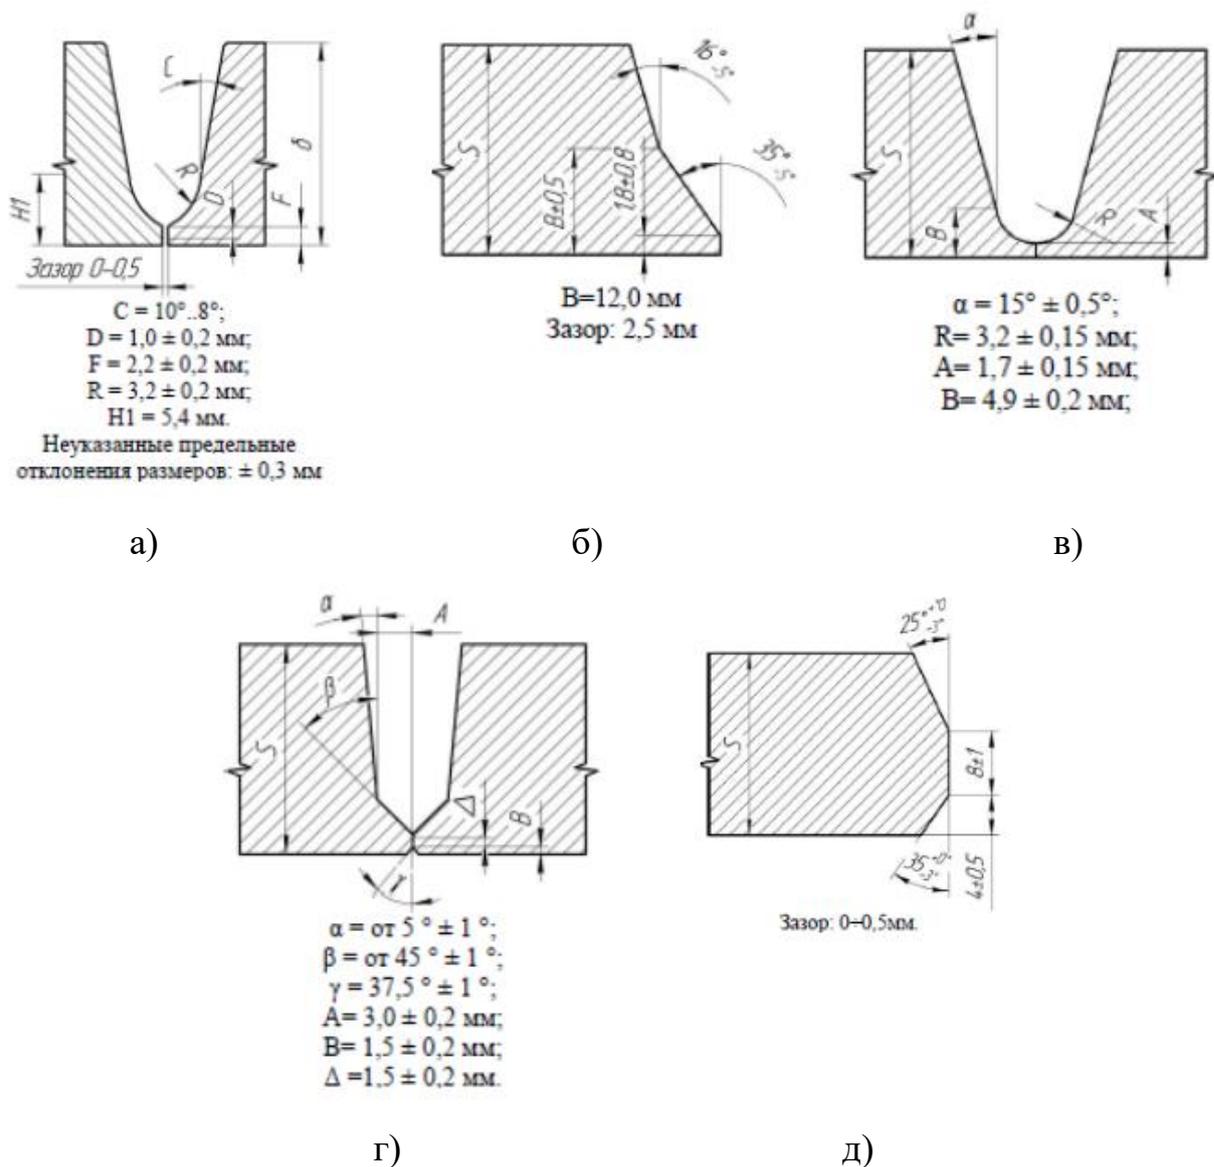


Рисунок 2.3 – Форма и параметры разделки кромок на фрагментах МГ при следующих способах сварки: автоматическая односторонняя сварка проволокой сплошного сечения в среде защитных газов на медном подкладном кольце (а), автоматическая сварка порошковой проволокой в среде защитных газов в стандартную заводскую разделку кромок по корневому слою, выполненному механизированной сваркой плавящимся электродом (б), автоматическая сварка порошковой проволокой в среде защитных газов в специальную заууженную разделку кромок по корневому слою, выполненную автоматической сваркой плавящимся электродом (в), автоматическая двухсторонняя сварка проволокой сплошного сечения в среде защитных газов (г), двусторонняя автоматическая сварка под флюсом.

Общее количество дефектов, результаты сканирования которых вошли в исследуемый набор данных, составило 322 шт. Из них 209 шт. содержится в

плоских образцах, 93 шт. содержится в фрагментах МГ малого диаметра и 20 шт. - в фрагментах МГ малого диаметра. В таблице 2.2 представлено количество дефектов и их типы для каждого плоского образца.

Таблица 2.2 – Количество дефектов и их типы для каждого плоского образца

№	Название	Кол.	Дефекты	№	Название	Кол.	Дефекты
1	003-Dc1Db	3	Dc ₁ , Dc ₁ , Db	42	044-Ak	2	Ak, Ak
2	004-Aa	3	Aa, Aa, Aa	43	045-Ak	2	Ak, Ak
3	005-Ak	2	Ak, Ak	44	046-Ak	2	Ak, Ak
4	006-Ac	2	Ac, Ac	45	047-Ak	2	Ak, Ak
5	007- Dc1Db	3	Dc ₁ , Dc ₁ , Db	46	048-Ak	2	Ak, Ak
6	008-BaMw	3	Ba, Ba, Mw	47	049-Ak	2	Ak, Ak
7	009-Bc	2	Bc, Bc	48	050-Dc1	3	Dc ₁ , Dc ₁ , Dc ₁
8	010-Bd1	1	Bd ₁	49	051-Dc1	2	Dc ₁ , Dc ₁
9	011-E	13	Bc – 13 шт.	50	052-Dc1	3	Dc ₁ , Dc ₁ , Dc ₁
10	012-E	2	E, E	51	053-Dc1Dc2	3	Dc ₁ , Dc ₁ , Dc ₂
11	013-Aa	3	Aa, Aa, Aa	52	054-Dc1Dc2	3	Dc ₁ , Dc ₁ , Dc ₂
12	014-Aa	3	Aa, Aa, Aa	53	55-Dc1	3	Dc ₁ , Dc ₁ , Dc ₁
13	015-Aa	3	Aa, Aa, Aa	54	56-Dc2	3	Dc ₂ , Dc ₂ , Dc ₂
14	016-Aa	3	Aa, Aa, Aa	55	57-Dc2	3	Dc ₂ , Dc ₂ , Dc ₂
15	017-Aa	3	Aa, Aa, Aa	56	58-Bd1	2	Bd ₁ , Bd ₁
16	018-Aa	3	Aa, Aa, Aa	57	59-Bd1	2	Bd ₁ , Bd ₁
17	019-Aa	3	Aa, Aa, Aa	58	60-Bd1	2	Bd ₁ , Bd ₁
18	020-Bd1	2	Bd ₁ , Bd ₁	59	61-Bd1	2	Bd ₁ , Bd ₁
19	021-Bd1	2	Bd ₁ , Bd ₁	60	62-Bd1	2	Bd ₁ , Bd ₁
20	022-Ba	3	Ba, Ba, Ba	61	63-Bd1	2	Bd ₁ , Bd ₁
21	023-Ak	2	Ak, Ak	62	64-Bd1	2	Bd ₁ , Bd ₁
22	024-E	1	E	63	65-Bd1	2	Bd ₁ , Bd ₁
23	025-Dc1	3	Dc ₁ , Dc ₁ , Dc ₁	64	66-Bd1	2	Bd ₁ , Bd ₁
24	026-Dc1	1	Dc ₁	65	67-Bd1	2	Bd ₁ , Bd ₁
25	027-Da1Dc1	2	Dc ₁ , Dc ₁	66	68-Bd1	2	Bd ₁ , Bd ₁
26	028-Ba	3	Ba, Ba, Ba	67	69-Ac	2	Ac, Ac
27	029-Ba	3	Ba, Ba, Ba	68	70-Ac	2	Ac, Ac,
28	030-Ba	3	Ba, Ba, Ba	69	71-Ac	2	Ac, Ac

Таблица 2.2 (продолжение)

29	031-Ba	3	Ba, Ba, Ba	70	73-Mw	3	Mw, Mw, Mw
30	032-Ba	3	Ba, Ba, Ba	71	74-Mw	3	Mw, Mw, Mw
31	033-Ba	3	Ba, Ba, Ba	72	75-Mw	3	Mw, Mw, Mw
32	034-Ba	3	Ba, Ba, Ba	73	76-Mw	3	Mw, Mw, Mw
33	035-Dc1	3	Dc1, Dc1, Dc1	74	77-Mw	3	Mw, Mw, Mw
34	036-Dc1	3	Dc1, Dc1, Dc1	75	78-FdDa	2	Da2, Da2
35	037-Da1Dc1	3	Dc1, Da1, Dc1	76	79-FdDa	2	Da2, Da2
36	038-Ak	2	Ak, Ak	77	80-Ab	2	Ab, Ab
37	039-Ak	2	Ak, Ak	78	81-Ab	2	Ab, Ab
38	040-Ak	2	Ak, Ak	79	82-Bb	2	Bb, Bb
39	041-Ak	2	Ak, Ak	80	83-Bb	2	Bb, Bb
40	042-Ak	2	Ak, Ak	81	84-E	2	E, E
41	043-Ak	2	Ak, Ak	82	91-Bc	1	Bc

В таблице 2.3 представлено количество дефектов и их типы для каждого фрагмента МГ. (Б.д. – большой диаметр (1420 мм), М.д. – мальнький диаметр (219 мм.))

Таблица 2.3 – Количество дефектов и их типы для каждого фрагмента МГ

№	Фрагмент МГ	Количество дефектов, шт.	Наименования дефектов
1	Б.д. 1	21	Dc1, Dc1, Dc1, Db, Dc1, Db, Dc1, Dc1, Da1, Dc1, Dc1, Ac, Dc1, Fc, E, E, Dc1, Db, E, Dc1, Da1
2	Б.д. 2	25	Dc1, E, Mw, Mw, Mw, Dc1, Db, E, Mw, Dc1, Fc, Mw, Ac, Mw, Ac, Da1, Dc1, Dc1, Dc1, Mw, Dc1, Db, Dc1, Aa, Aa
3	Б.д. 3	30	Aa, Dc1, Fc, E, Db, Dc1, Dc1, Ac, E, Dc1, Ac, Ab, Aa, Aa, Aa, Dc1, Dc1, Ac, Aa, Dc1, Da1, Aa, Aa, Dc1, Aa, Da1, Mw, Dc1, Ac, Dc1
4	Б.д. 4	10	Dc1, Dc1, Dc1, E, Db, Dc1, Dc1, Fc, Db, Mw
5	Б.д. 5	7	Aa, Mw, Aa, Mw, Mw, Mw, Dc1
6	М.д. 1	10	Mw, Mw, Mw, Mw, Mw, Mw, Mw, Mw, Mw, Mw
7	М.д. 2	10	Mw, Mw, Mw, Mw, Mw, Mw, Mw, Mw, Mw, Mw

2.2 Проведение неразрушающего контроля экспериментальных образцов

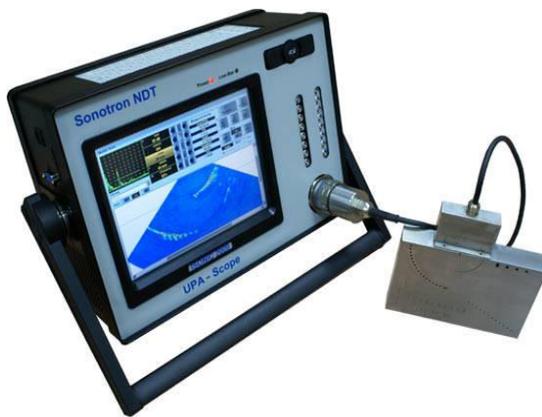
Все плоские образцы и фрагменты МГ были просканированы системами ВИК, РНК и УЗК. При ВИК поверхность образцов снималась на камеру, а также была просканирована лазерным триангуляционным датчиком РФ603HS (рисунок 2.4 – а). РНК проводился с применением аппарата РАП220-5 (рисунок 2.4 – б) и детектора ПРОДИС.МАРК. Параметры РНК были следующими: фокусное расстояние – 910 мм, напряжение на трубке – 200 кВ, сила тока – 4,5 мА. УЗК эхо-импульсным методом проводился с применением фазированной антенной решетки, которая содержит 16 элементов и имеет центральную частоту 4 МГц. Фазированная антенная решетка была установлена на призме, которая обеспечивает ввод поперечных волн в сталь под углом 55° . Контроль проводился в режиме секторного сканирования с диапазоном углов ввода поперечных волн в сталь 40° - 70° с шагом 1° . Браковочный уровень чувствительности настраивался в соответствии с уровнем качества «А» согласно [1]. В качестве дефектоскопа применялся iSonic 2009 фирмы Sonotron NDT (рисунок 2.4 – в). УЗК ДВМ (TOFD) при контроле толщины 14 мм проводился преобразователями диаметром 3 мм и частотой 10 МГц, установленных на призмы, обеспечивающие ввод продольных волн в сталь под углом 70° с расстоянием между точками ввода 51 мм. При контроле толщины 26 мм УЗК ДВМ проводился преобразователями диаметром 6 мм и частотой 5 МГц, на призмах для ввода продольных волн в сталь под углом 60° с расстоянием между точками ввода 60 мм. В качестве дефектоскопа применялся Omniscan MX фирмы Olympus NDT (рисунок 2.4 – г). ВИК, РНК, УЗК проводились полностью в соответствии с НД ПАО Газпром [1, 2, 18].



а)



б)



в)



г)

Рисунок 2.4 – Применяемое оборудование для проведения НК.
Триангуляционный датчик РФ603HS (а), рентгеновский аппарат РАП 220-5 (б),
ультразвуковые дефектоскопы: iSonic 2009 (в) Omniscan MX (г)

Согласно НД ПАО Газпром [1, 2, 18] по результатам НК кольцевых сварных соединений МГ оформляются заключения, которые содержат параметры дефектов. По ВИК определяются тип и параметры поверхностных дефектов. По РНК определяется тип, протяженность и ширина дефекта. По УЗК эхо-импульсным/эхо зеркальным методом (тандем) методом определяются глубина залегания/положение относительно разделки кромок, условная протяженность и условная высота/эквивалентная площадь дефектов. По УЗК ДВМ фиксируются глубина залегания, условная протяженность и условная высота дефектов.

Сегодня большинство методов НК проводится в автоматизированном режиме с представлением результатов в виде файлов, содержащих изображения или набор изображений, которые содержат больше информации о выявленных дефектах, чем заключения, регламентированные НД. Причем каждый из методов НК имеет особенный, свойственный только ему, формат представления результатов контроля. Далее рассмотрим информационные признаки дефектов, которые можно получить при расшифровке результатов контроля каждым из методов НК [А6, А7].

По результатам ВИК для выявленных дефектов измеряются значения длины и ширины дефекта и, по возможности, глубина (рисунок 2.5 – а), помимо этого измеряются геометрические параметры сварного шва, такие как ширина (рисунок 2.5 – б) и высота (рисунок 2.5 – в) шва, а также величина смещения кромок (рисунок 2.5 – г).

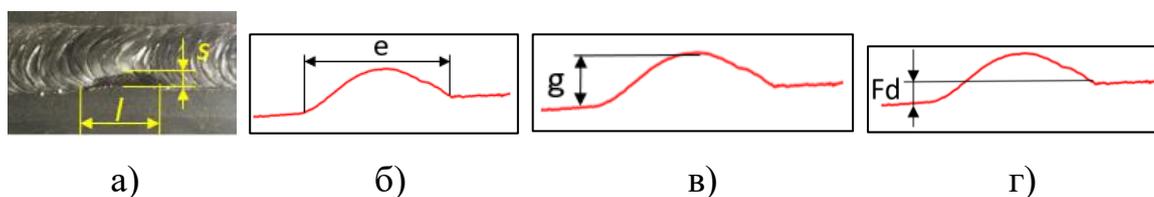


Рисунок 2.5 – Информационные признаки дефектов, получаемые по результатам ВИК: длина и ширина дефекта и по возможности глубина (а); ширина шва (б); высота шва (в); смещение кромок (г)

По результатам РНК для выявленных дефектов определяются следующие информационные параметры (рисунок 2.6): одиночный или составной дефект, ширина дефекта, протяженность дефекта, разница градаций серого между дефектом и сварным швом. Разница градаций серого определяется как среднее арифметическое между измерениями вначале, середине и конце дефекта.

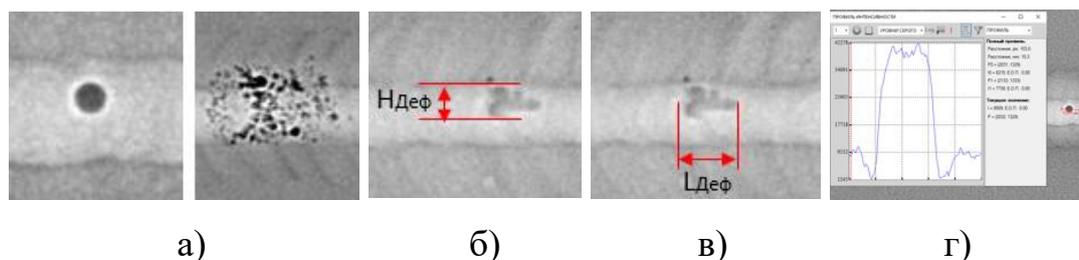


Рисунок 2.6 – Информационные признаки дефектов, получаемые по результатам РНК: одиночный или составной дефект (а); ширина дефекта (б); протяженность дефекта (в); разница градаций серого между дефектом и сварным швом (г)

По результатам УЗК ДВМ для выявленных дефектов определяются следующие информационные параметры (рисунок 2.7): одиночный или составной сигнал, условная протяженность дефекта, количество сигналов от дефекта (1 или 2), условная высота дефекта, фаза первого сигнала, фаза второго сигнала, амплитуда сигнала дефекта относительно сигнала головной волны.

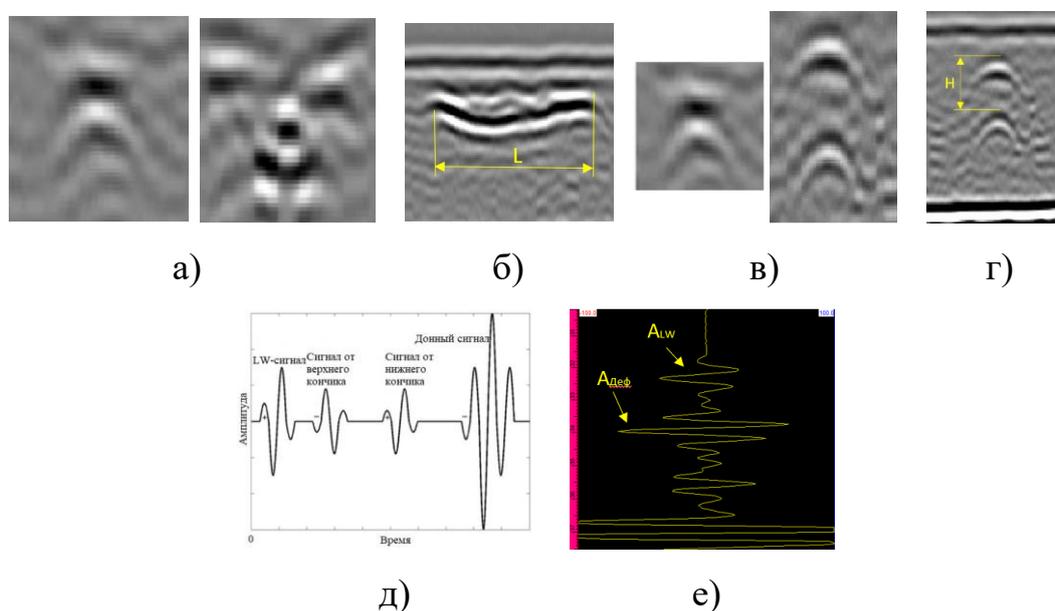


Рисунок 2.7 – Информационные признаки дефектов, получаемые по результатам УЗК ДВМ: одиночный или составной сигнал (а); условная протяженность дефекта (б); количество сигналов от дефекта (1 или 2) (в); условная высота дефекта (г); фаза первого и второго сигналов (д); амплитуда сигнала дефекта относительно сигнала головной волны (е)

По результатам УЗК эхо-импульсным методом для выявленных дефектов определяются следующие информационные параметры (рисунок 2.8): одиночный или составной сигнал, условная протяженность дефекта, положение в шве, амплитуда максимума сигнала, положение в разделке сварного шва, условная высота дефекта. Условная высота оценивалась по технике «MaxAmp» [26], при которой условной высотой является расстояние между краями сигнала, которые определяются по падению амплитуды его максимума на 10%. Параметры ультразвукового контроля эхо-импульсным методом на базе фазированных антенных решеток фиксировались при положении ультразвукового преобразователя с обеих сторон сварного шва, поэтому их количество удваивается.

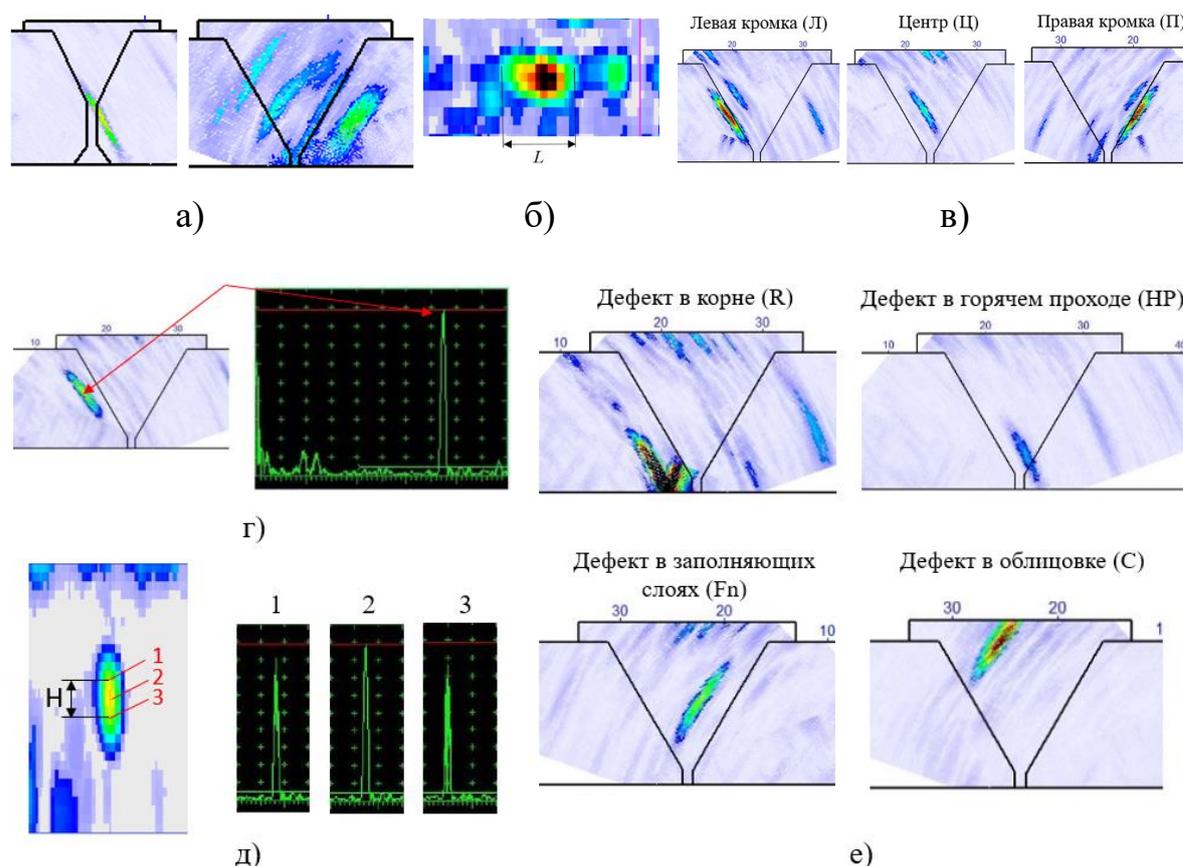


Рисунок 2.8 – Информационные признаки дефектов, получаемые по результатам УЗК эхо-импульсным методом: одиночный или составной сигнал (а); условная протяженность дефекта (б); положение в шве (в); амплитуда максимума сигнала (г); положение в разделке сварного шва (д); условная высота дефекта (е)

2.3 Формирование исследуемого массива данных

В итоге экспериментальных исследований получился набор данных, состоящий из 322 несплошностей, для каждой из которых было получено 23 параметра (информационных признака по результатам НК). Причем данные параметры являются как непрерывными (Н) (содержащими вещественное число, к примеру: 10,2; 30,1 и т.д.), так и категориальными (К) (содержащими категории к примеру: «синий», «красный», «зеленый»; или «0», «1», «2»). Параметры (информационных признаки по результатам НК) и их тип представлены в таблице 2.5.

Таблица 2.5 – Параметры НК и их типы

№	Параметры РНК	Тип	№	Параметры УЗК TOFD	Тип	№	Параметры УЗК ФАР	Тип
1	Одиночный/ составной	К	5	Одиночный/ составной	К	12	Одиночный/ составной	К
2	Ширина	Н	6	Условная протяженность	Н	13	Условная протяженность	Н
3	Протяженность	Н	7	Количество сигналов (1 или 2)	К	14	Положение в шве	К
4	Разница градаций серого	Н	8	Условная высота	Н	15	Амплитуда	Н
			9	Фаза 1ого сигнала	К	16	Положение в разделке	К
			10	Фаза 2ого сигнала	К	17	Условная высота	Н
			11	Амплитуда	Н			

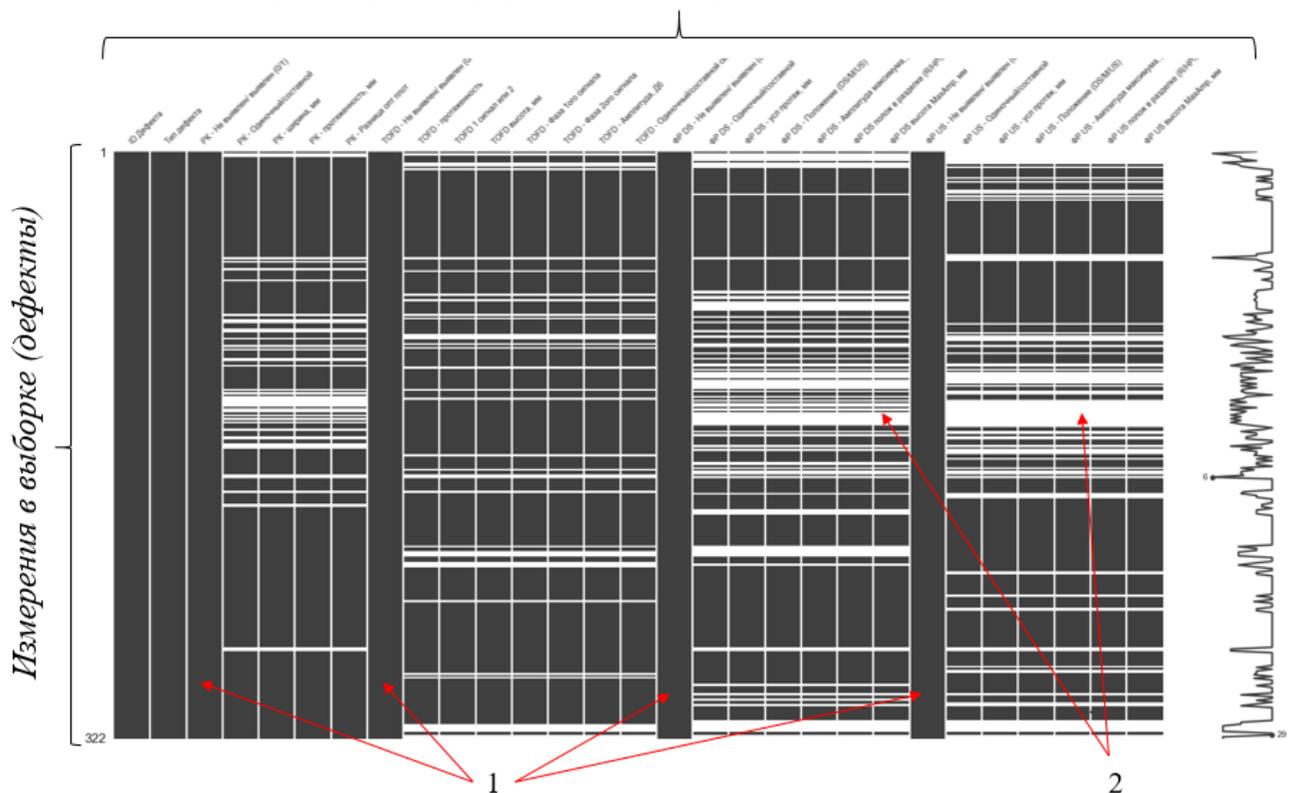
В итоге из 23х параметров (УЗК ФАР проводился с двух сторон от сварного шва и его параметры удваиваются) 12 параметров являются непрерывными и 11- категориальными.

Полученный набор данных учитывает тот факт, что не все дефекты одновременно выявляются всеми используемыми методами НК. В случае не

выявления дефекта методом НК в значениях его переменных образуются пропущенные данные, полученные не случайным образом. При их заполнении значениями «0» или «1» это внесет неоднозначность для других параметров. Для сохранения информации о выявляемости были введены «индикаторные параметры» для каждого метода НК. В случае выявления дефекта методом НК индикаторному параметру присваивается значение «1», в случае не выявления – «0». После введения индикаторных параметров все пропущенные данные заменяются на «0».

Общая схема набора данных показана на рисунке 2.9, где белые поля являются полями с отсутствием данных определенного метода НК из-за не выявления дефекта.

Параметры (информационные признаки по результатам НК)



1 – индикаторные параметры выявляемости, 2 – пропущенные данные

Рисунок 2.9 – Общая схема набора данных, где белые поля являются полями с отсутствием данных определенного метода НК из-за не выявления дефекта

В полученном наборе данных присутствует дисбаланс классов. Количество измерений в наборе данных для одних типов дефектов больше, чем для других. Количество измерений в наборе данных для каждого типа дефекта представлено на рисунке 2.10, откуда видно, что наибольшее количество измерений было произведено для дефектов типа несплавление по разделке кромок Dc₁ и металлических включений Mw со значениями 67 и 52 соответственно. Наименьшее количество измерений было произведено для дефектов типа цепочки неметаллических включений Bb, и непровар в корне шва из-за смещения кромок Da₂ и подрез Fc со значениями по 4 шт. каждого.

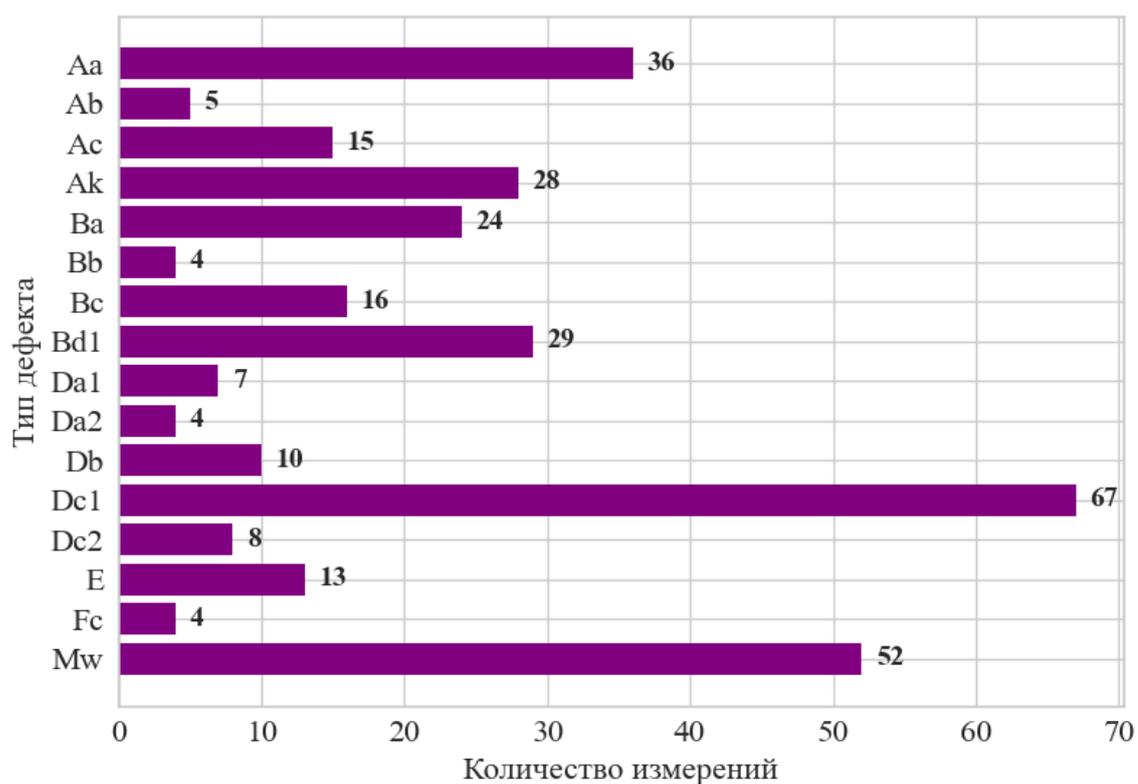


Рисунок 2.10 – Количество измерений в наборе данных для каждого типа дефекта

Большое количество классов с сильным дисбалансом (16 классов с дисбалансом 67 – максимум, 4 – минимум) сильно затрудняет создание моделей классификации. Для исключения дисбаланса классов в наборе данных существуют различные техники, такие как субдискретизация (undersampling) и передискретизация (oversampling). Субдискретизация позволяет удалять измерения из набора данных для получения баланса классов, а

передискретизация – добавлять измерения. Наиболее распространенным алгоритмом передискретизации является SMOTE (Synthetic Minority Over-sampling Technique) [110]. Оригинальный алгоритм SMOTE работает только для непрерывных параметров, для работы с непрерывными и категориальными параметрами существует его расширение SMOTE-NC (Synthetic Minority Over-sampling Technique for Nominal and Continuous) [111].

В SMOTE-NC для каждого измерения класса меньшинства определяется k -ближайших соседей [112] из того же класса. Для числовых признаков используется расстояние Евклида, а для категориальных — расстояние Хэмминга. Синтетическое измерение создается путём добавления к существующему измерению случайной разницы, умноженной на случайное число в диапазоне от 0 до 1 включительно, между этим измерением и его соседом:

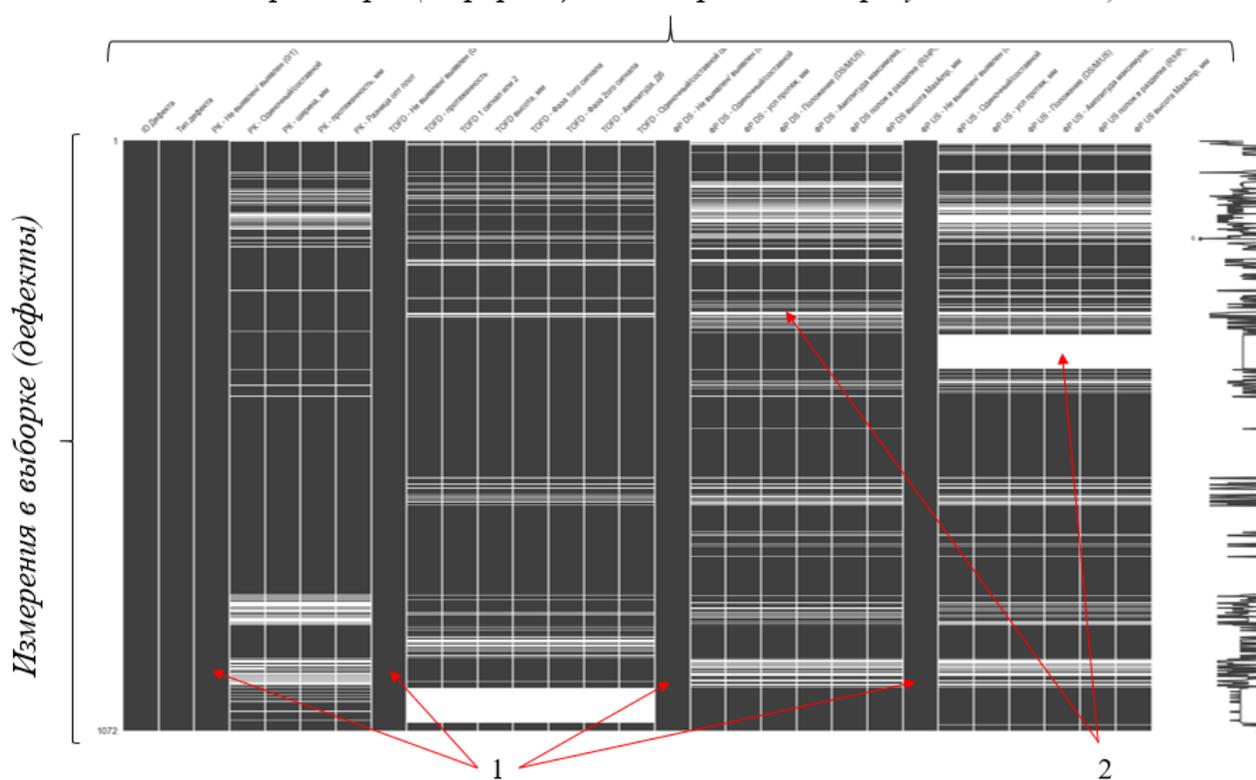
$$x_{new} = x_{original} + \lambda \cdot (x_{neighbor} - x_{original})\beta_1, \quad (2.1)$$

где λ – случайное число из диапазона от 0 до 1 включительно.

Для категориальных признаков синтетическое измерение получает категорию от одного из соседей с вероятностью, пропорциональной частоте появления этой категории среди соседей. В итоге синтетические измерения добавляются к исходному набору, создавая более сбалансированный набор данных.

После применения алгоритма SMOTE-NC с последующей ручной корректировкой полученных примеров исследуемый набор данных стал содержать по 67 измерений для каждого класса, и суммарно 1072 измерения. Общая схема набора данных без дисбаланса классов представлена на рисунке 2.11.

Параметры (информационные признаки по результатам НК)



1 – индикаторные параметры выявляемости, 2 – пропущенные данные

Рисунок 2.11 – Общая схема набора данных без дисбаланса классов, где белые поля являются полями с отсутствием данных определенного метода НК из-за не выявления дефекта

2.4 Результаты и выводы второй главы

1. Для создания набора данных с целью разработки обучаемых моделей сочетания данных методов НК сварных швов МГ изготовлено 82 плоских образца, содержащих сварные соединения. Помимо плоских образцов для создания набора данных использовалось 7 фрагментов МГ с кольцевыми сварными швами. Суммарное количество естественных и заложенных дефектов сварных швов составило 322 шт.

2. Был произведен контроль всех плоских образцов и фрагментов МГ, в результате чего были получены данные в виде файлов контроля, содержащих изображения. Для ВИК, РНК, УЗК эхо-импульсным и ДВМ были определены и научно обоснованы информационные признаки дефектов.

3. Сформирован массив данных, где для каждого дефекта (измерения) получено 23 информационных признака по результатам различных методов НК. Над полученным набором данных произведена операция передискретизации с целью исключения дисбаланса измерений для каждого типа дефекта с применением алгоритма SMOTE-NC. Итоговое количество измерений для каждого типа дефектов составило 67 шт., и суммарно во всем наборе данных присутствует 1072 измерения.

ГЛАВА 3 НАУЧНОЕ ОБОСНОВАНИЕ ВОЗМОЖНОСТИ СОЧЕТАНИЯ ДАННЫХ ДЛЯ ПОЛУЧЕННОЙ СИСТЕМЫ ИНФОРМАЦИОННЫХ ПРИЗНАКОВ ДЕФЕКТОВ

Полученный в предыдущей главе набор данных является многомерным и довольно массивным. Для разработки обучаемых моделей сочетания данных на исследуемом наборе необходимо определить, выделяются ли явные кластеры определенных измерений, присутствуют ли зависимые параметры, помимо этого определить степень влияния различных информационных параметров методов НК на прогнозирование типа дефектов и их параметров.

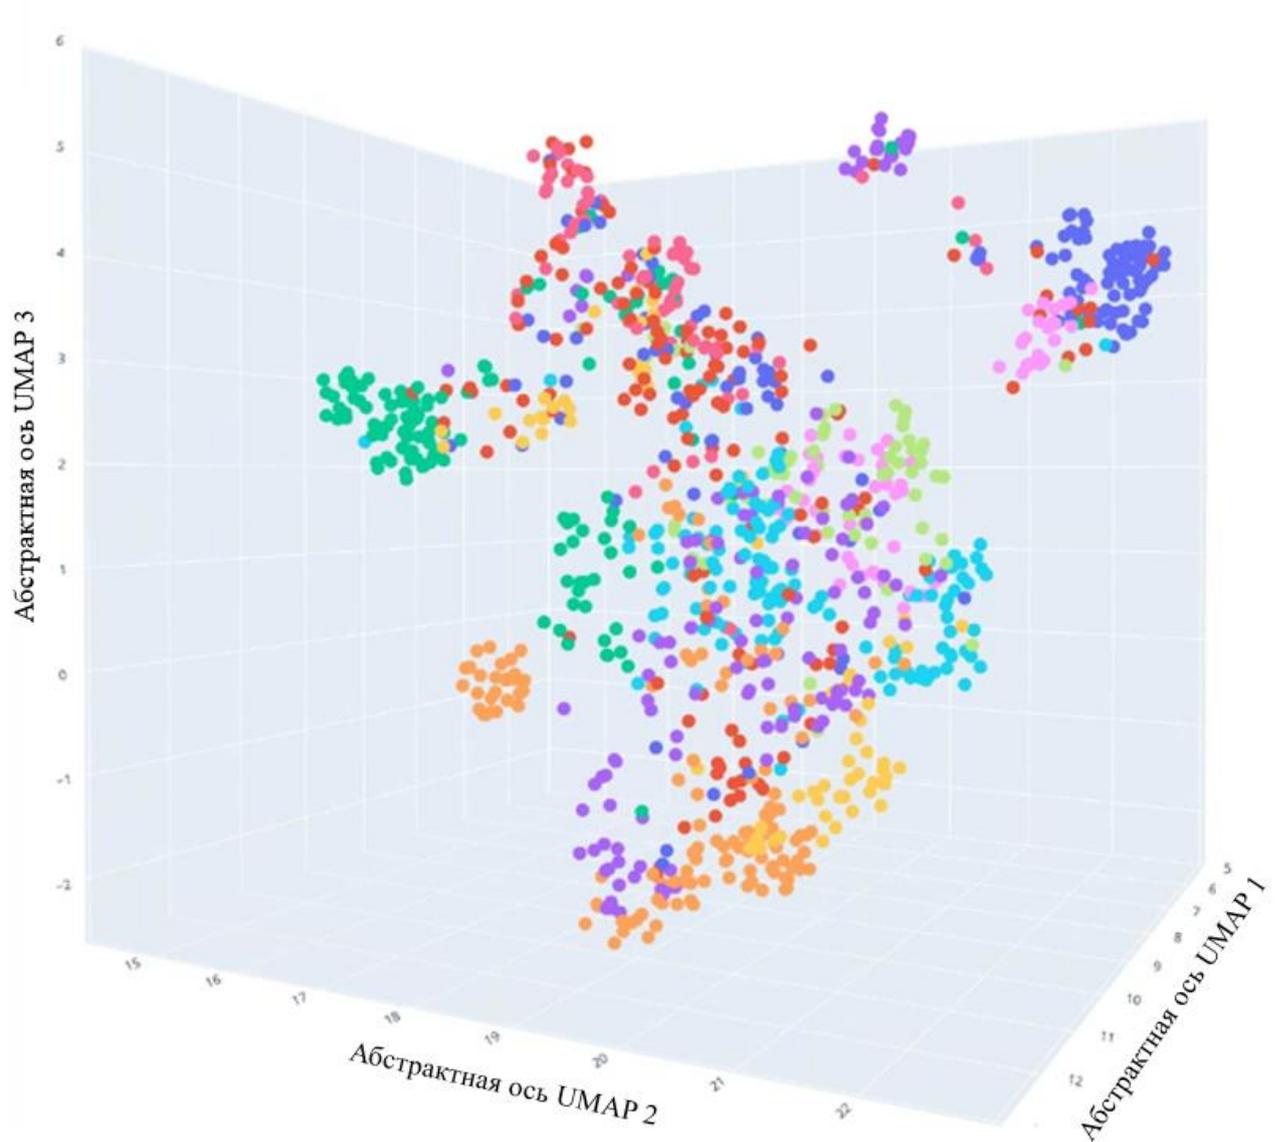
3.1 Проведение визуализации полученного набора данных с применением технологий снижения размерностей

Поскольку полученный набор данных является многомерным, а именно имеет 23х кратную размерность, то его визуализация в исходном виде затруднительна. Для решения подобных задач обычно применяются алгоритмы снижения размерностей. Алгоритмы снижения размерности как правило используются для уменьшения количества случайных переменных (атрибутов) в данных, при этом, сохраняя как можно больше важной информации. Наиболее частым алгоритмом снижения размерности является метод главных компонент (Principal component analysis - PCA). PCA представляет собой ортогональное линейное преобразование, которое отображает данные из исходного пространства признаков в новое пространство меньшей размерности. При этом первая ось новой системы координат строится таким образом, чтобы дисперсия данных вдоль неё была максимальной. Вторая ось строится ортогонально первой так, чтобы дисперсия данных вдоль неё была максимальной из оставшихся возможных и т.д. В новом пространстве признаков меньшей размерности дисперсия между осями будет перераспределена так, чтобы максимизировать дисперсию по каждой из них [113].

Помимо PCA существует алгоритм снижения размерностей под названием t-SNE (t-distributed Stochastic Neighbor Embedding). t-SNE сначала вычисляет вероятности схожести точек в высокоразмерном пространстве, используя нормальное распределение, а затем преобразует эти вероятности в низкоразмерное пространство с использованием распределения Стьюдента. Далее t-SNE минимизирует расхождение между этими распределениями с помощью расстояния Кульбака-Лейблера, чтобы найти оптимальное расположение точек в пространстве меньшей размерности [114].

Третьим используемым на практике алгоритмом снижения размерностей является UMAP (Uniform Manifold Approximation and Projection). В основе алгоритма лежат топология и теории графов, которые позволяют выявлять структуры данных и проецировать их в пространство с меньшим количеством измерений при сохранении глобальной и локальной структуры данных. UMAP строит граф, который соединяет каждую точку с её ближайшими соседями, и затем оптимизирует этот граф в пространстве меньшей размерности, используя стохастические методы градиентного спуска. Данный подход позволяет UMAP сохранять глобальные и локальные структуры данных лучше, чем многие другие методы, такие как PCA или t-SNE, и делает его эффективным для различных задач визуализации и кластеризации [115].

Для визуализации полученного набора данных был выбран алгоритм снижения размерностей UMAP. Гиперпараметры были следующими: число «соседей» – 1000; минимальное расстояние – 0,5; дистанция – Канберрское расстояние. Результаты визуализации набора данных с применением снижения размерностей с 23х до 3х представлены на рисунке 3.1, откуда видно, что визуально не получается выделить отдельные кластеры, принадлежащие определенному типу дефектов, поэтому необходим анализ каждого параметра системы по отдельности с целью идентификации определенного типа дефекта.



- | | |
|-------------------------------------|--|
| ● Непровар по разделке кромок (Dc1) | ● Непровар по разд. кромок на пов. (Dc2) |
| ● Непровар межслойный (Db) | ● Поры, скопление (Ac) |
| ● Пора единичная (Aa) | ● Подрез (Fc) |
| ● Пора канальная (Ak) | ● Металлическое включение (Mw) |
| ● Не мет. вкл. удлиненное (Bd1) | ● Поры, пепочки (Ab) |
| ● Не мет. вкл. Единичное (Ba) | ● Не мет. вкл. скопление (Bc) |
| ● Трещина (E) | ● Не мет. вкл. пепочки (Bb) |
| ● Непровар в корне шва (Da1) | ● Непровар в корне шва из-за см. кр. (Da2) |

Рисунок 3.1 – Визуализации набора данных с применением алгоритма снижения размерностей «UMAP»

3.2 Проведение анализа каждого параметра системы по отдельности с целью идентификации определенного типа дефекта

Для анализа каждого параметра системы по отдельности с целью идентификации определенного типа дефекта необходимо произвести визуализацию всех измерений для каждого типа дефекта и оценить возможность разделения данных. Для непрерывных параметров для подобных целей обычно используются диаграммы размаха. Диаграмма размаха представляет собой графический способ изображения распределения числовых данных на основе квартилей. Диаграмма размаха показывает медиану, нижний и верхний квартили, а также минимальные и максимальные значения выборки. Также она может включать "усы", которые указывают на вариабельность за пределами верхнего и нижнего квартилей, и точки, представляющие выбросы.

Центральная часть диаграммы размаха, ящик, охватывает значения от первого квартиля (Q1, нижний квартиль) до третьего квартиля (Q3, верхний квартиль), визуализируя таким образом межквартильный размах (IQR), который служит мерой статистического разброса данных. Ширина ящика показывает вариабельность данных: чем она больше, тем больше разброс. Внутри ящика находится линия, указывающая на медиану (Q2) выборки, которая делит данные на две равные части и представляет среднее значение выборки. От ящика вверх и вниз тянутся "усы", которые достигают крайних точек данных (рисунок 3.2).

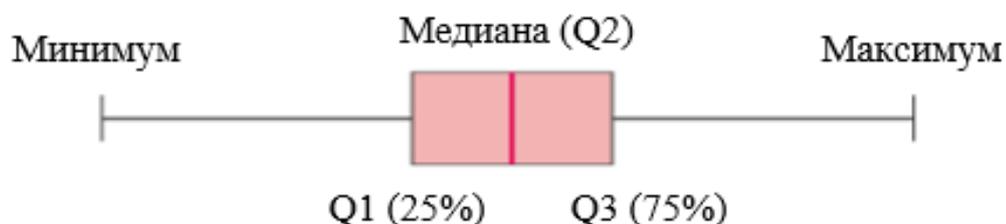


Рисунок 3.2 – Схема диаграммы размаха

Для оценки возможности определения типа дефектов только по конкретному категориальному параметру строилась гистограмма и матрица

количества измерений определенной категории. Матрица количества измерений определенной категории отображается слева, а гистограмма – справа.

На рисунке 3.3 показаны диаграммы размаха непрерывных и гистограммы категориальных параметров для РНК.

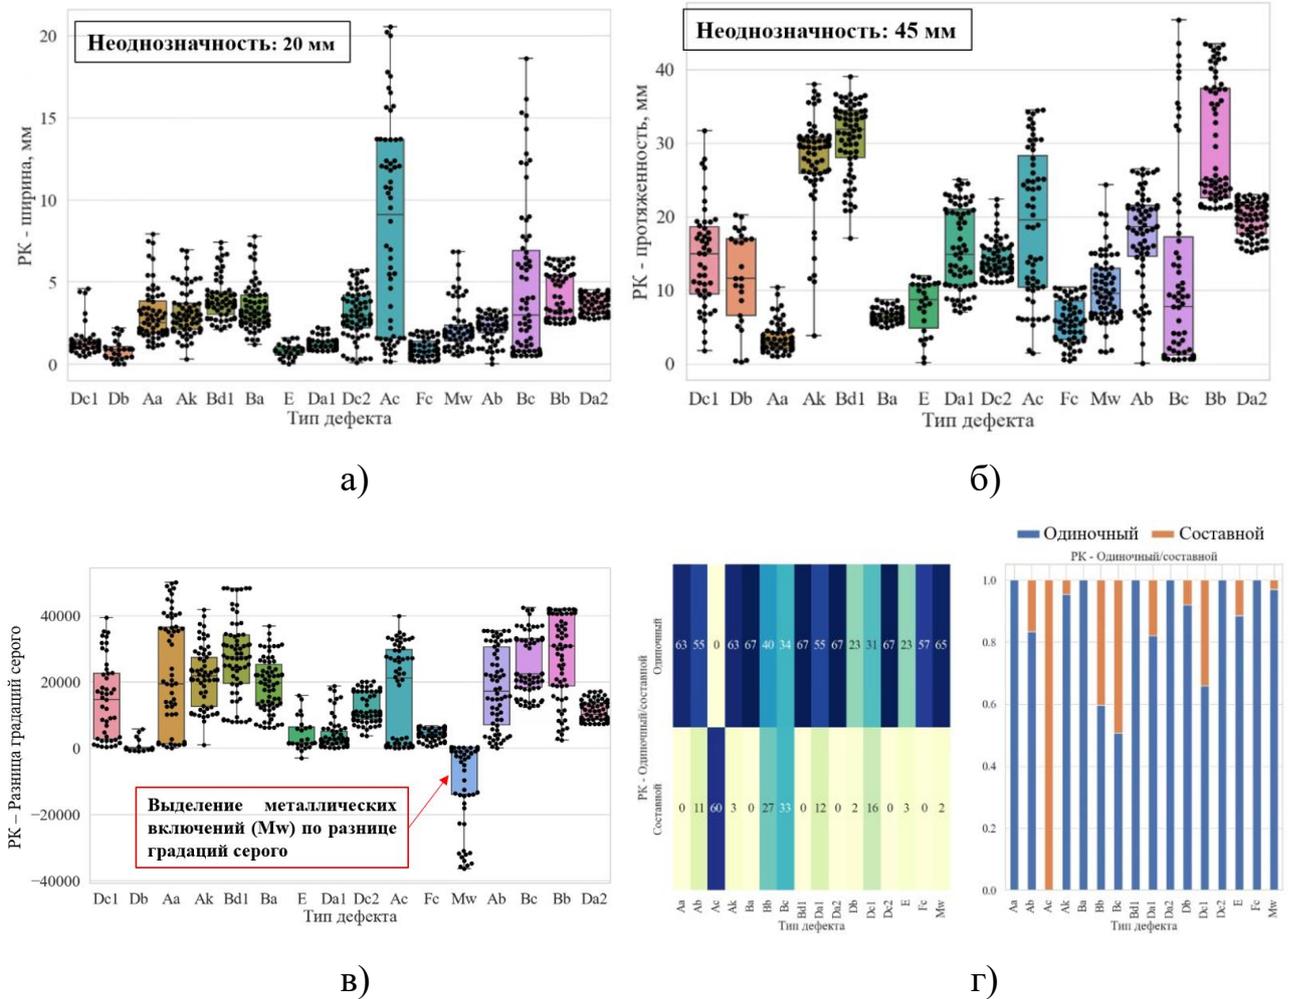


Рисунок 3.3 – Диаграммы размаха непрерывных параметров РНК: ширина (а); протяженность (б); разница градаций серого (в). Гистограмма категориальных параметров: одиночный или составной дефект (г)

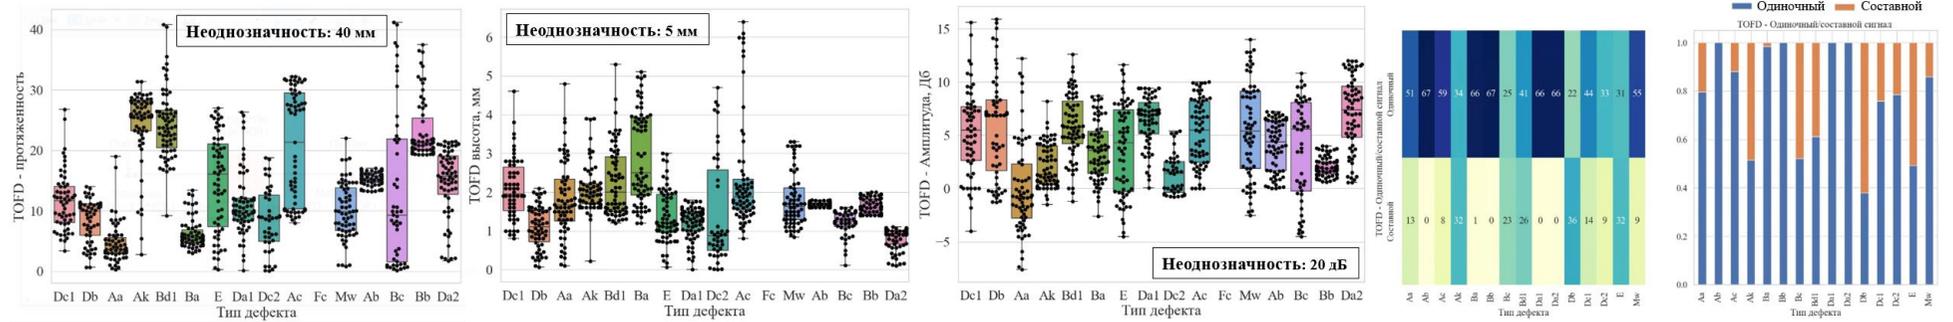
Из рисунка 3.3 видно, что только металлические включения (Mw) надежно идентифицируются по разнице градаций серого при РНК. Для остальных параметров присутствует существенная неоднозначность при классификации дефектов по типам.

На рисунке 3.4 показаны диаграммы размаха непрерывных и гистограммы категориальных параметров для УЗК ДВМ. Анализируя рисунок 3.4 можно сказать, что для всех непрерывных и категориальных параметров УЗК ДВМ

присутствует существенная неоднозначность при классификации дефектов по типам и выделить определенный тип дефекта по отдельному параметру не представляется возможным.

На рисунке 3.5 показаны диаграммы размаха непрерывных и гистограммы категориальных параметров для УЗК эхо-импульсным методом на базе секторного сканирования ФАР с левой стороны сварного шва. Анализируя рисунок 3.5 можно сказать, что для всех непрерывных и категориальных параметров УЗК эхо-импульсным методом на базе секторного сканирования ФАР с левой стороны сварного шва присутствует существенная неоднозначность при классификации дефектов по типам и выделить определенный тип дефекта по отдельному параметру не представляется возможным.

На рисунке 3.6 показаны диаграммы размаха непрерывных и гистограммы категориальных параметров для УЗК эхо-импульсным методом на базе секторного сканирования ФАР с правой стороны сварного шва. Анализируя рисунок 3.6 можно сказать, что для всех непрерывных и категориальных параметров УЗК эхо-импульсным методом на базе секторного сканирования ФАР с правой стороны сварного шва присутствует существенная неоднозначность при классификации дефектов по типам и выделить определенный тип дефекта по отдельному параметру не представляется возможным. В итоге можно сказать, что только металлические включения (M_w) надежно идентифицируются по разнице градаций серого при РНК, а для всех остальных типов дефектов присутствует существенная неоднозначность при идентификации.

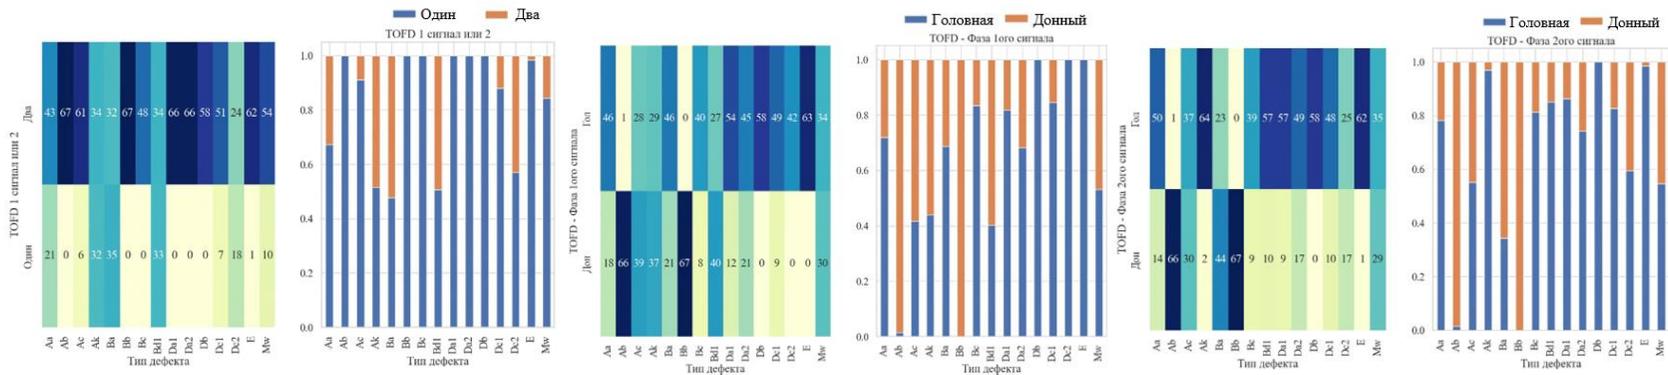


а)

б)

в)

г)

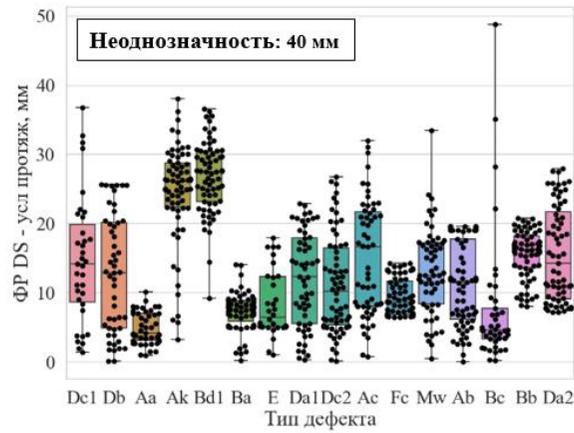


д)

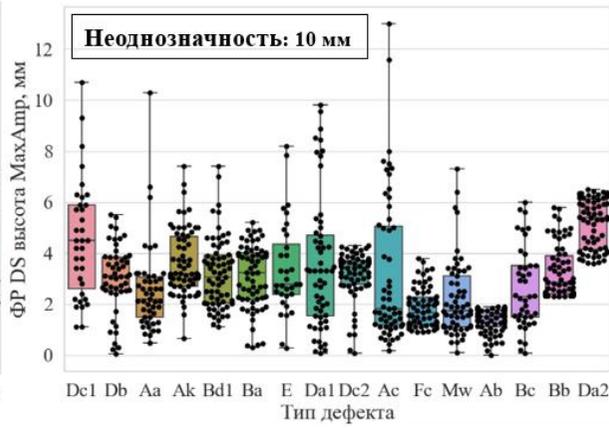
е)

ж)

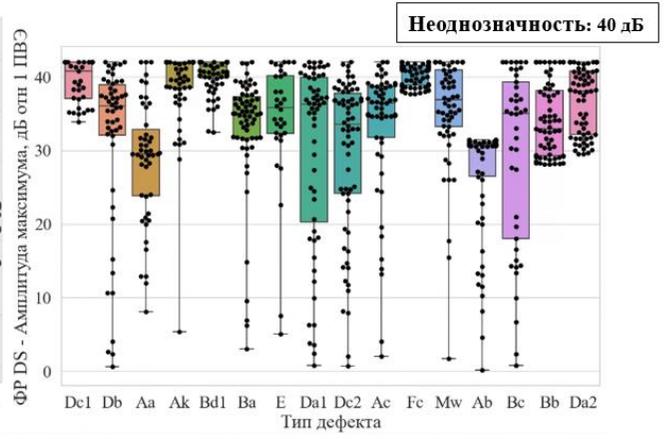
Рисунок 3.4 – Диаграммы размаха непрерывных параметров УЗК ДВМ: условные протяженность (а) и высота (б); амплитуда (в). Гистограмма категориальных параметров: одиночный или составной сигнал (г); один сигнал или 2 (д); фаза первого (е) и второго сигналов (ж)



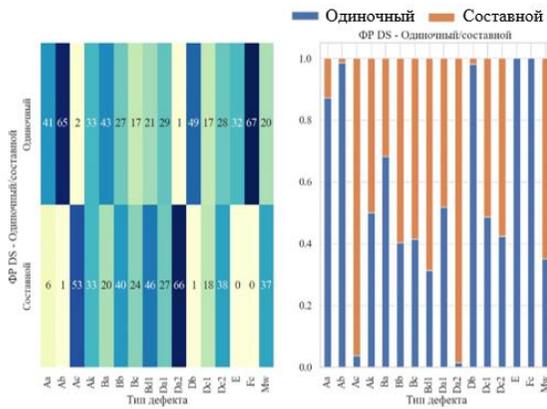
а)



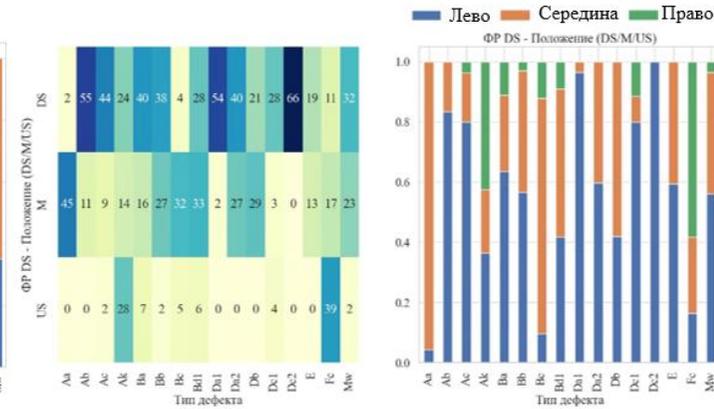
б)



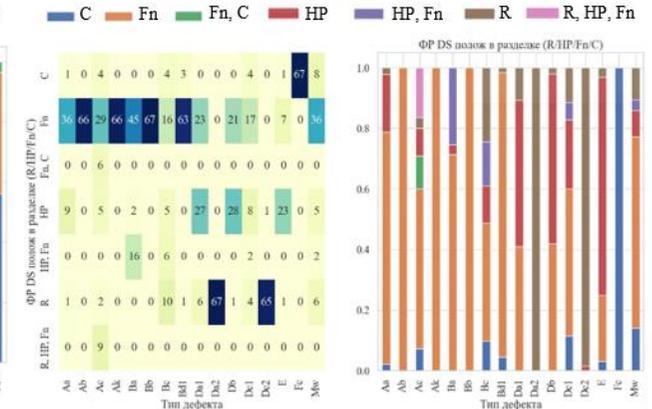
в)



г)

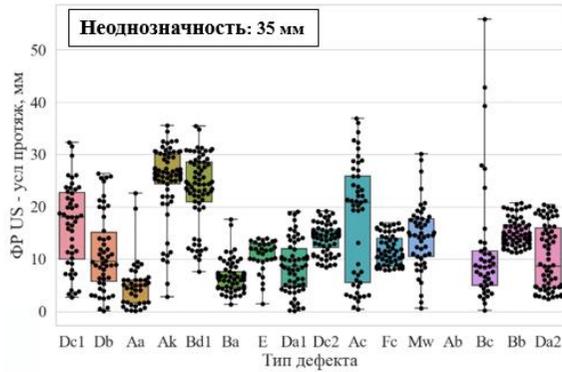


д)

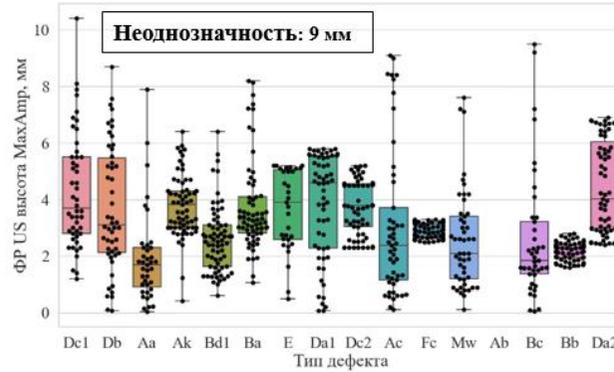


е)

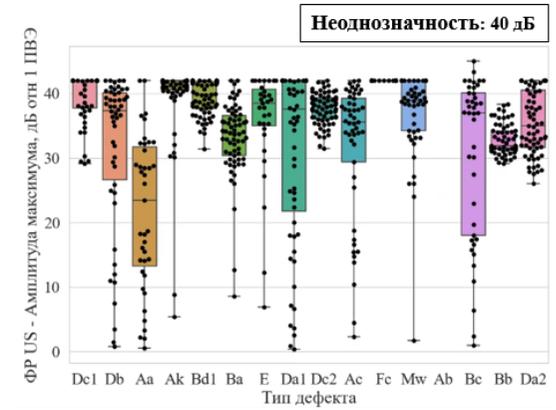
Рисунок 3.5 – Диаграммы размаха непрерывных параметров УЗК эхо-импульсным методом на базе секторного сканирования ФАР с левой стороны сварного шва: условные протяженность (а) и высота (б); амплитуда (в). Гистограмма категориальных параметров: одиночный или составной сигнал (г); положение в сварном (д) и относительно разделки (е)



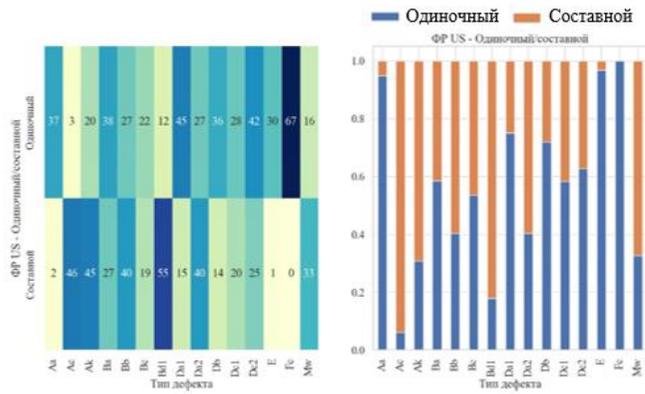
а)



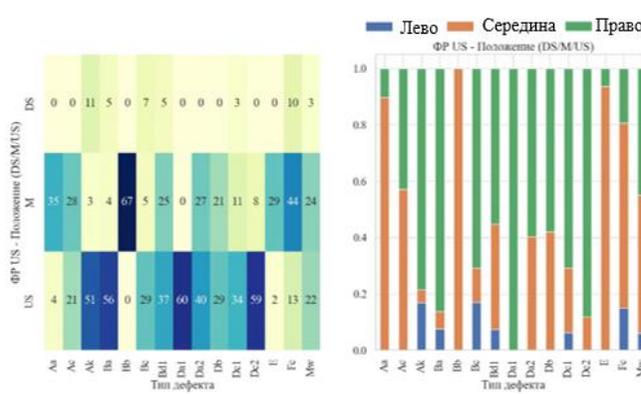
б)



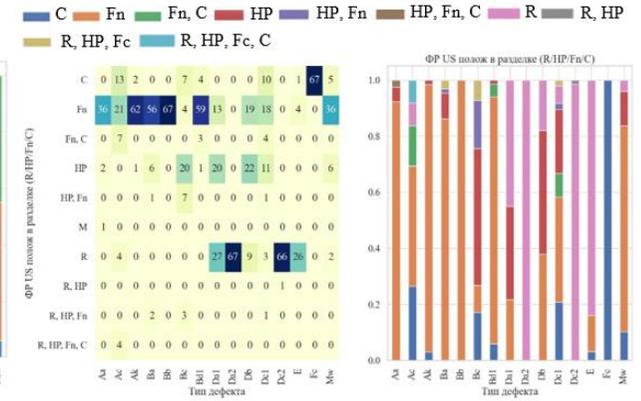
в)



г)



д)



е)

Рисунок 3.6 – Диаграммы размаха непрерывных параметров УЗК эхо-импульсным методом на базе секторного сканирования ФАР с правой стороны сварного шва: условные протяженность (а) и высота (б); амплитуда (в). Гистограмма категориальных параметров: одиночный или составной сигнал (г); положение в сварном (д) и относительно разделки (е)

Система идентификационных признаков методов НК пригодна в качестве входных данных для моделей сочетания данных в случае отсутствия в ней зависимых между собой как непрерывных, так и категориальных параметров. Если два параметра зависимы, то значит один может быть выражен через другой, и он не несет полезной информации для модели сочетания данных во входных параметрах.

3.3 Установление зависимостей между параметрами системы НК

Для определения наличия зависимых параметров системы методов НК между собой произведен кросскорреляционный анализ. Построена матрица кросс корреляции, которая показывает квадраты коэффициента Спирмена зависимости каждого параметра друг от друга (рисунок 3.7).

В отличие от коэффициента Пирсона, который оценивает линейные зависимости, корреляция Спирмена оценивает, насколько хорошо переменные могут быть описаны монотонной функцией. Коэффициент корреляции Спирмена является не параметрической мерой ассоциации между двумя переменными, основанной на рангах данных [116]. Для расчета коэффициента Спирмена используется следующая формула:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2-1)}, \quad (3.1)$$

где d_i — разность между рангами каждой пары значений, а n — количество наблюдений.

Анализируя рисунок 3.7 можно сказать, что сильной зависимости между параметрами системы не наблюдается, а максимальный квадрат коэффициент корреляции: 0,67 – между амплитудой максимума сигнала и условной протяженностью при УЗК эхо-импульсным методом. При все значения коэффициентов корреляции, также были вычислены р-значения, которые не превышали 0,05, что говорит о статистической значимости всех экспериментов.

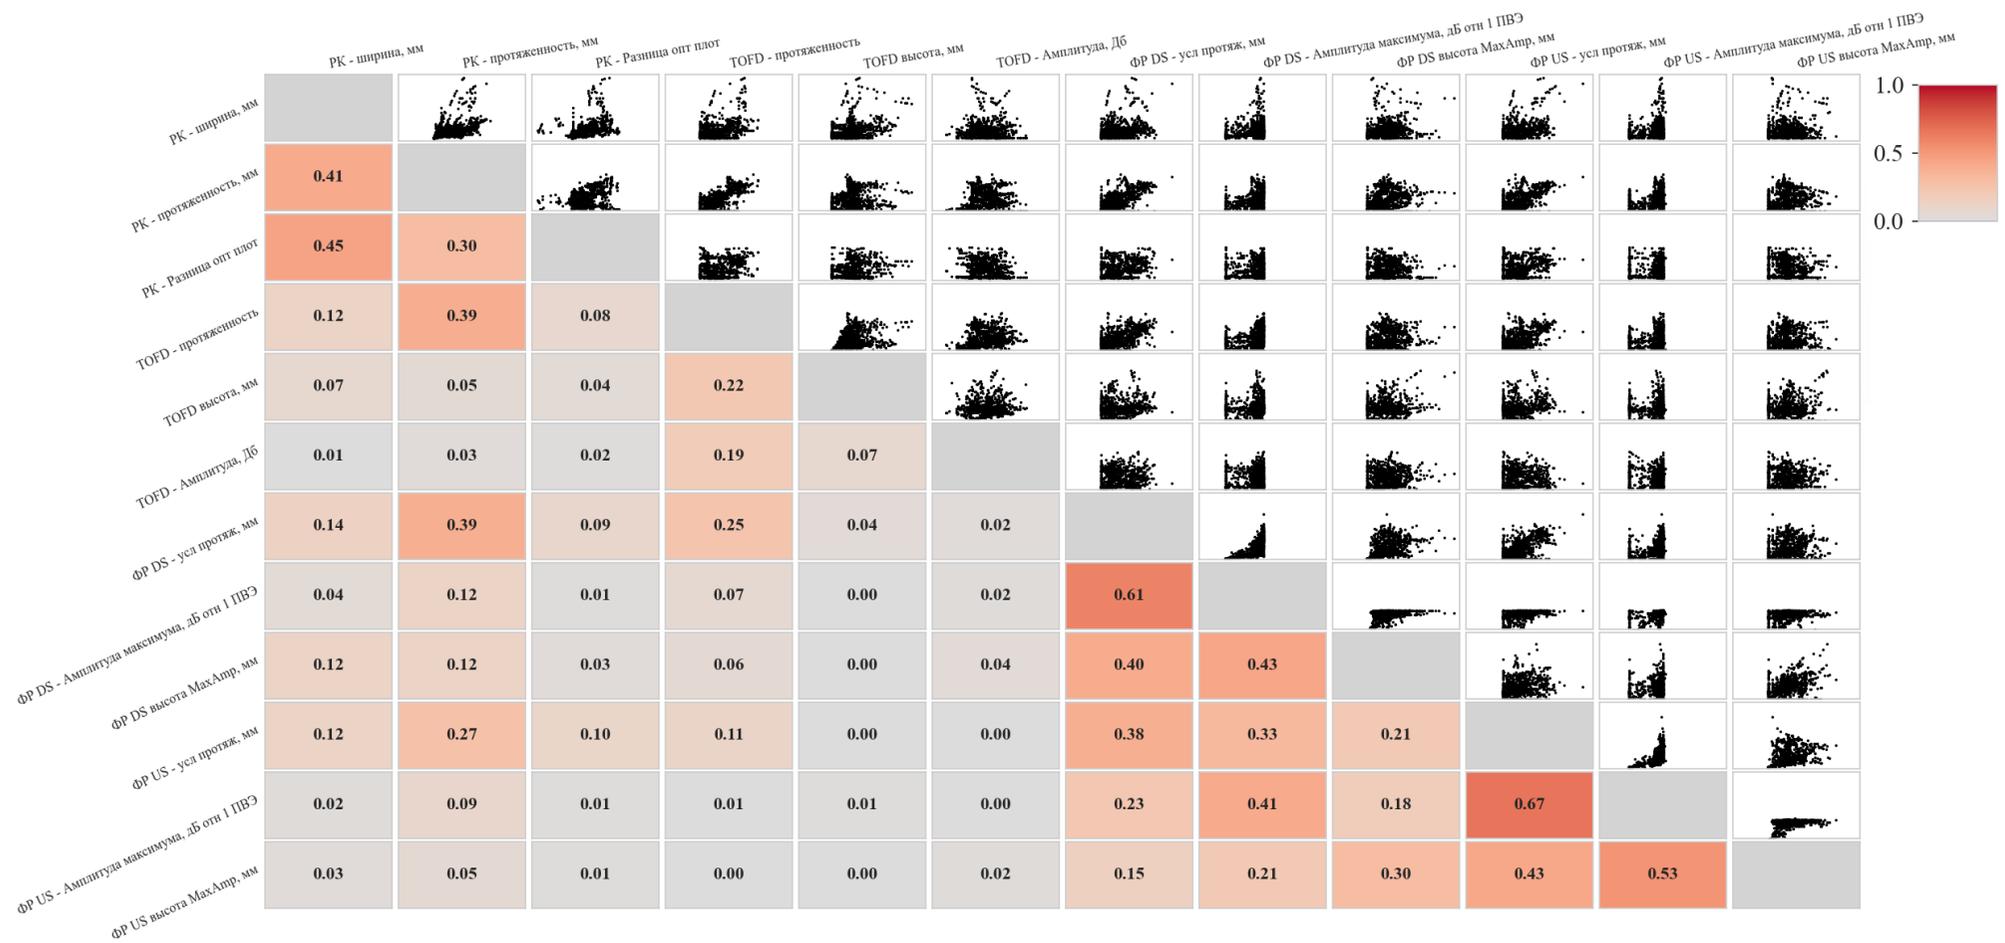


Рисунок 3.7 – Матрица кросскорреляции коэффициента Спирмена системы параметров методов НК сварных швов

В соответствии с формулами Ермолова [117] для цилиндрического отражателя с длиной l_c и диаметром d_c (3.2), амплитуда ультразвукового сигнала зависит не только от длины l_c , но и от диаметра d_c , что означает, что амплитуда сигнала содержит дополнительную информацию.

$$\frac{V_c}{V_0} = (1 \sim 4) \cdot \frac{l_c \sqrt{d_c \lambda}}{2S} e^{-T\delta} \quad (3.2)$$

В итоге можно сказать, что непрерывные параметры полученной системы не имеют сильной зависимости между собой, что означает, что они пригодны для сочетания данных методов НК.

Для оценки связи между категориальными параметрами обычно используется коэффициент V-Крамера. V-Крамера является нормализованной версией критерия χ^2 (хи-квадрат) (3.3) и обеспечивает более понятную интерпретацию результатов анализа.

$$\chi^2 = \sum_{i,j} \frac{\left(n_{ij} - \frac{n_i n_j}{n}\right)^2}{\frac{n_i n_j}{n}} \quad (3.3)$$

Значения V-Крамера варьируются от 0 до 1, где 0 указывает на отсутствие связи, а 1 свидетельствует о полной взаимно-однозначности между категориальными переменными [118]. Вычисляется V-Крамера по формуле 3.4:

$$V = \sqrt{\frac{\chi^2/n}{\min(k-1, n-1)}}, \quad (3.4)$$

где χ^2 — значение критерия хи-квадрат, n — общее количество наблюдений, а k — минимальное количество строк или столбцов в таблице сопряженности.

С целью определения связи категориальных параметров системы НК между собой была построена матрица их зависимостей друг от друга, элементами которой являлись коэффициенты V-Крамера (рисунок 3.8).

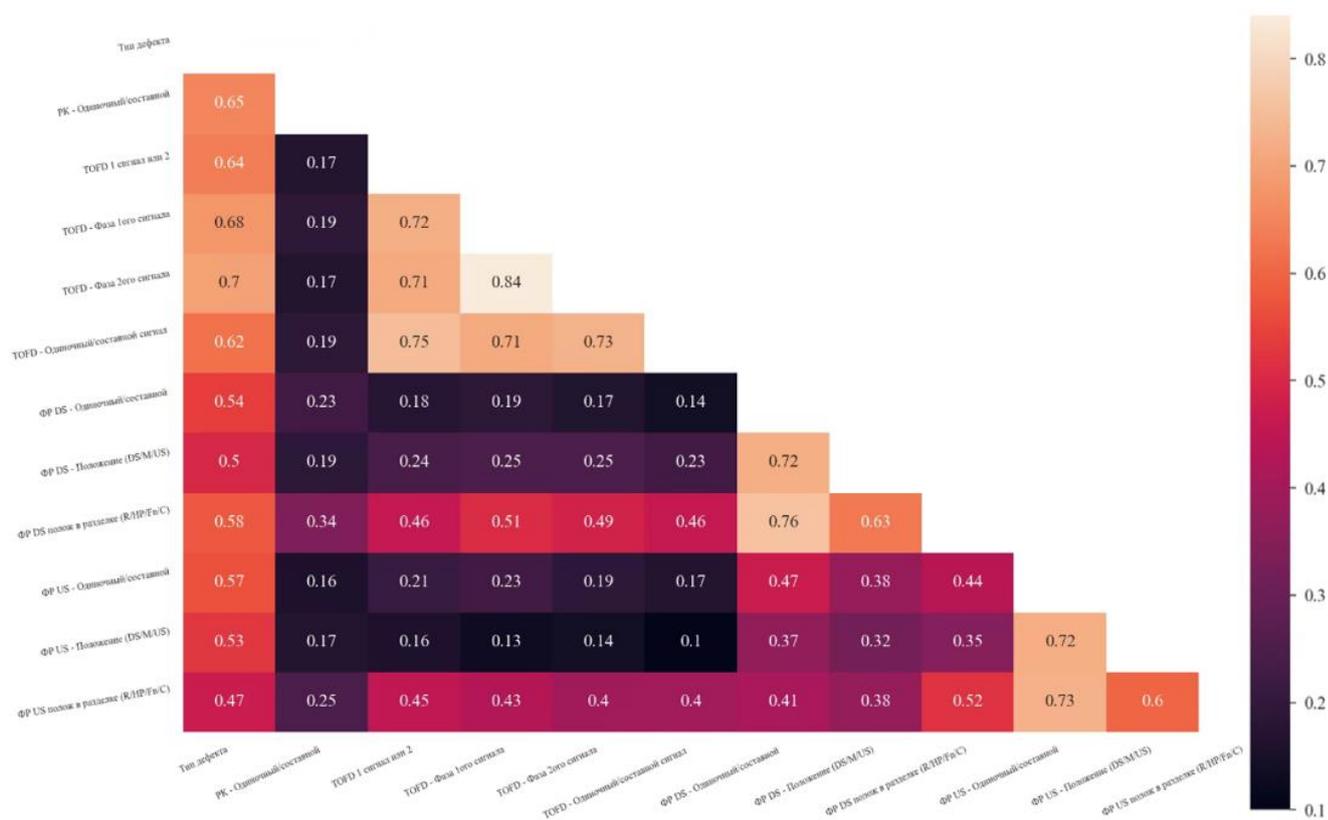


Рисунок 3.8 – Матрица зависимостей параметров методов НК друг от друга элементами которой являются коэффициенты V-Крамера

Как видно из рисунка 3.8, максимальным значением коэффициента V-Крамера имеют фаза первого и второго сигнала при УЗК ДВМ со значением 0,84. Если проанализировать связь параметров каждого метода НК по отдельности, которые не содержат пустых значений, соответствующих пропущенным дефектам (рисунок 3.9), то коэффициент V-Крамера не будет превышать 0,63, что говорит о том, что рассматриваемая система категориальных параметров не имеет сильных связей между собой, что означает, что ни один из категориальных параметров не может быть выражен через другой и они несут максимум информации для моделей сочетания данных.

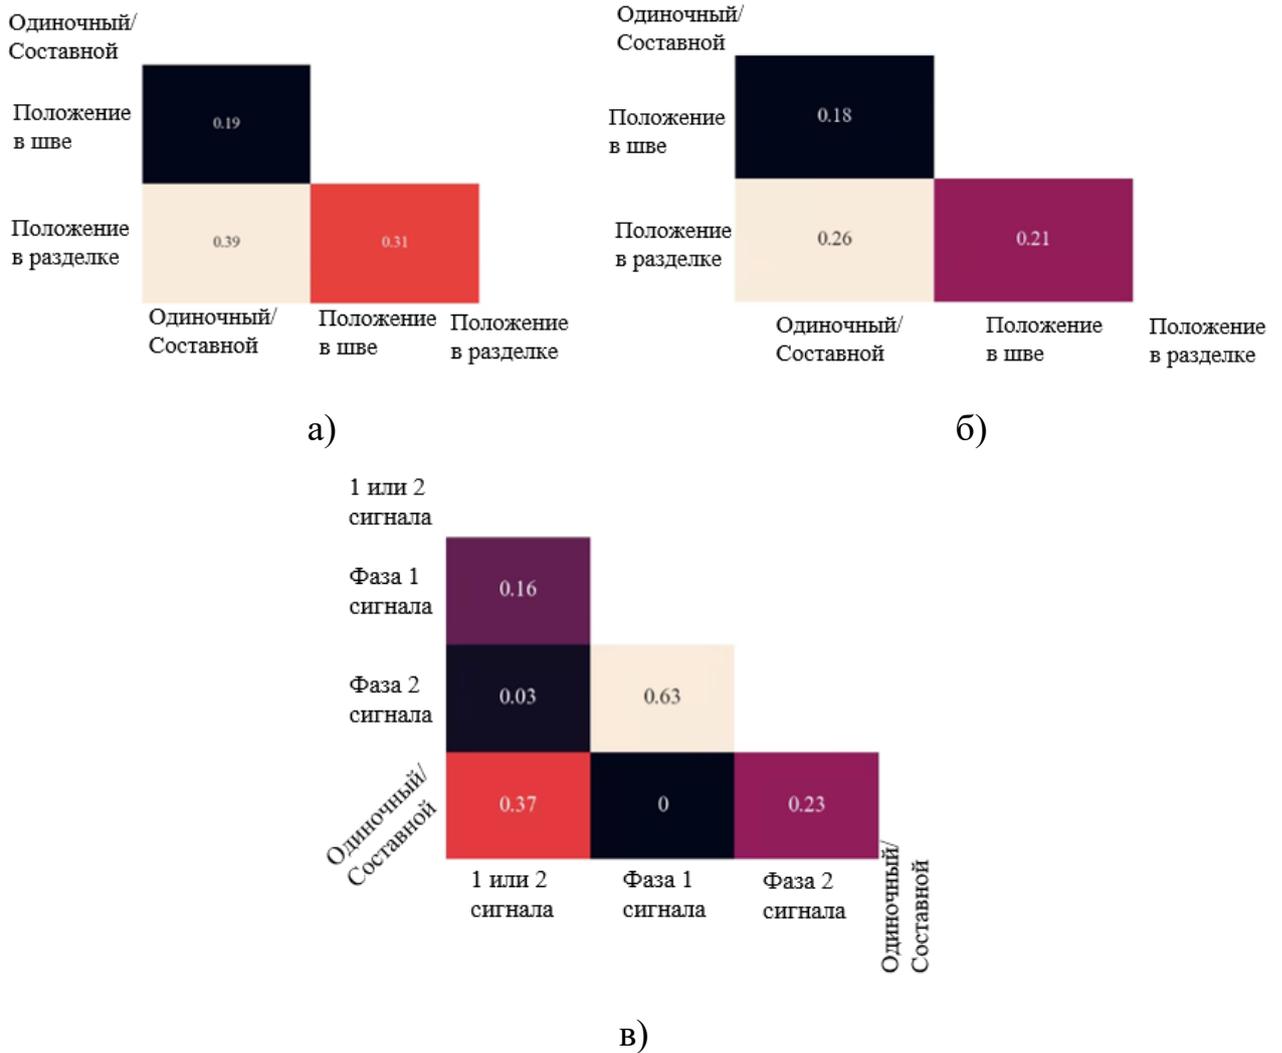


Рисунок 3.9 – Матрица зависимостей параметров методов НК по отдельности элементами которой являются коэффициенты V-Крамера. УЗК эхо-импульсный метод слева (а), справа (б) и УЗК ДВМ (в)

Для окончательного определения, пригодна ли полученная система информационных параметров методов НК в качестве входных данных моделей совместного анализа необходимо определить, вносят ли все 23 параметра системы существенный вклад в определение типа дефекта сварных швов МГ.

3.4 Обоснование степени влияния параметров систем НК на определение типа и параметров дефектов сварных швов

Существует множество критериев оценки степени влияния параметров для задач классификации и регрессии, такие как дисперсионный анализ (ANOVA), критерий «совместной информации», критерий «экстра деревьев» и т.д. Данные критерии как правило выбираются в зависимости от типа входных и выходных параметров (категориальные или непрерывные). В рассматриваемом случае входные параметры являются и категориальными, и переменными, поэтому для оценки степени влияния применялись критерии «совместной информации» и «экстра деревьев».

Критерий «совместной информации» определяет количество информации, которое одна случайная величина содержит о другой, и для дискретных случайных величин вычисляется по формуле:

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p_{(X,Y)}(x, y) \log \left(\frac{p_{(X,Y)}(x, y)}{p_X(x)p_Y(y)} \right) \quad (3.5)$$

Критерий «экстра деревьев» для определения степени влияния признаков оценивает значимость каждого признака на основе его роли в построении деревьев в ансамбле. В отличие от традиционных деревьев решений, где признаки выбираются для максимального уменьшения неопределенности, в экстра деревьях пороги для разделений выбираются случайным образом, что снижает возможные смещения. Однако оценка значимости признаков все равно возможна путем анализа улучшений, вызванных использованием конкретного признака на каждом уровне дерева [119]. Формула для оценки значимости признака k может быть записана как:

$$\text{Значимость}(k) = \frac{1}{M} \sum_{i=1}^M \sum_{j \in N_i} \Delta Q_{ij} \cdot 1_{\{v_{ij}=k\}}, \quad (3.6)$$

где M – число деревьев, N_i – множество узлов в i -м дереве, ΔQ_{ij} – улучшение качества разделения в узле j -го дерева, $1_{\{v_{ij}=k\}}$ – индикатор использования признака k в узле j -го дерева.

Значения степени влияния каждого из параметров на определение типа дефектов представлены на рисунках 3.10 и 3.11. Наиболее значимыми параметрами являются: разница градаций серого, протяженность и ширина при РНК, протяженность при УЗК эхо-импульсном и ДВМ, а также положение в разделке при УЗК эхо-импульсным методом. Также из рисунков 3.10 и 3.11 видно, что степень влияния всех используемых параметров превышает третью часть среднего значения общей степени влияния. Следовательно, для модели совместного анализа прогнозирующей тип дефекта необходимо использовать все 23 параметра системы методов НК в качестве входных данных.

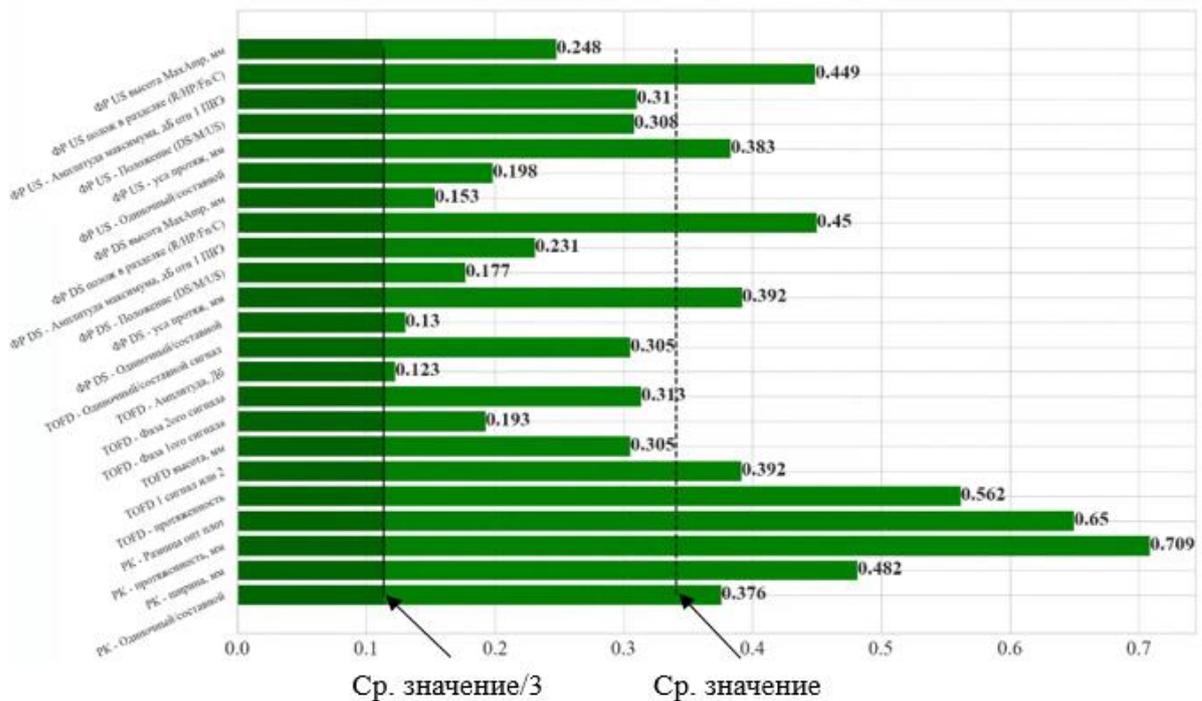


Рисунок 3.10 – Диаграммы степени влияния параметров системы методов НК на классификацию согласно критерия «совместной информации»

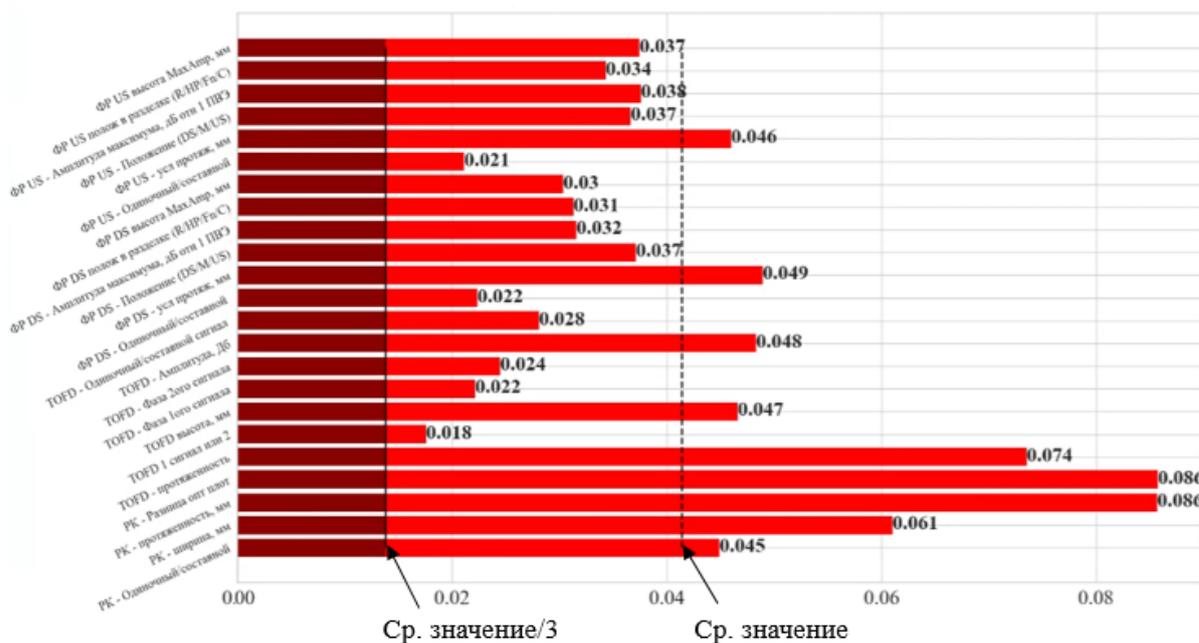


Рисунок 3.11 – Диаграммы степени влияния параметров системы методов НК на классификацию согласно критерию «экстра деревьев»

В качестве параметров дефекта в данной работе рассматривалась их высота и длина, т.е. в задаче регрессии присутствуют две целевые переменные. Значения степени влияния по критерию «экстра деревьев» каждого из параметров на прогнозирование высоты дефекта представлены на рисунке 3.12., а на прогнозирование длины дефекта – на рисунке 3.13. Из рисунка 3.12 видно, что степень влияния всех используемых параметров для прогнозирования высоты дефекта превышает третью часть среднего значения общей степени влияния. Это означает, что для модели совместного анализа прогнозирующей высоты дефекта необходимо использовать все 23 параметра системы методов НК в качестве входных данных. Из рисунка 3.13 видно, что в основном на прогнозирование протяженности дефекта оказывают влияние следующие параметры: длина дефекта, определенная по РНК, условная протяженность, определенная по УЗК ДВМ и условная протяженность, определенная по УЗК эхо-импульсным методом слева и справа. В итоге, видно, что для модели совместного анализа, прогнозирующей длину дефекта, необходимо использовать только 4 указанных параметра системы методов НК в качестве входных данных.

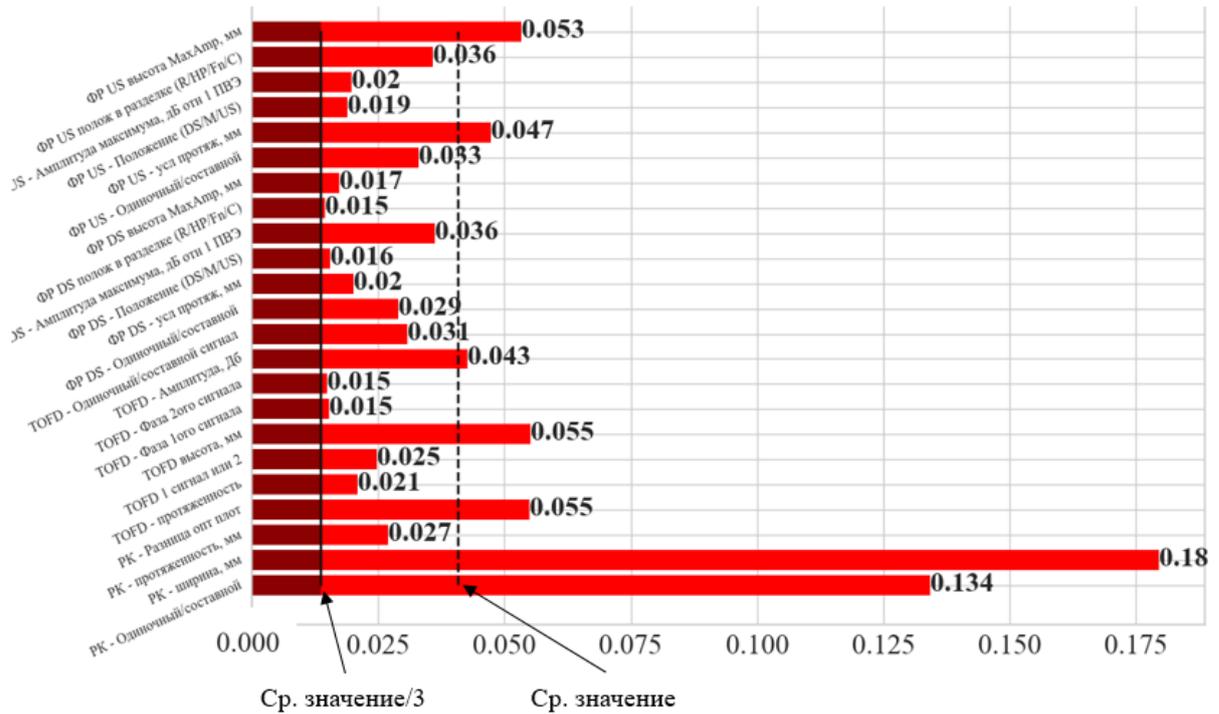


Рисунок 3.12 – Диаграммы степени влияния параметров по критерию «экстра деревьев» системы методов НК для прогнозирования высоты дефектов

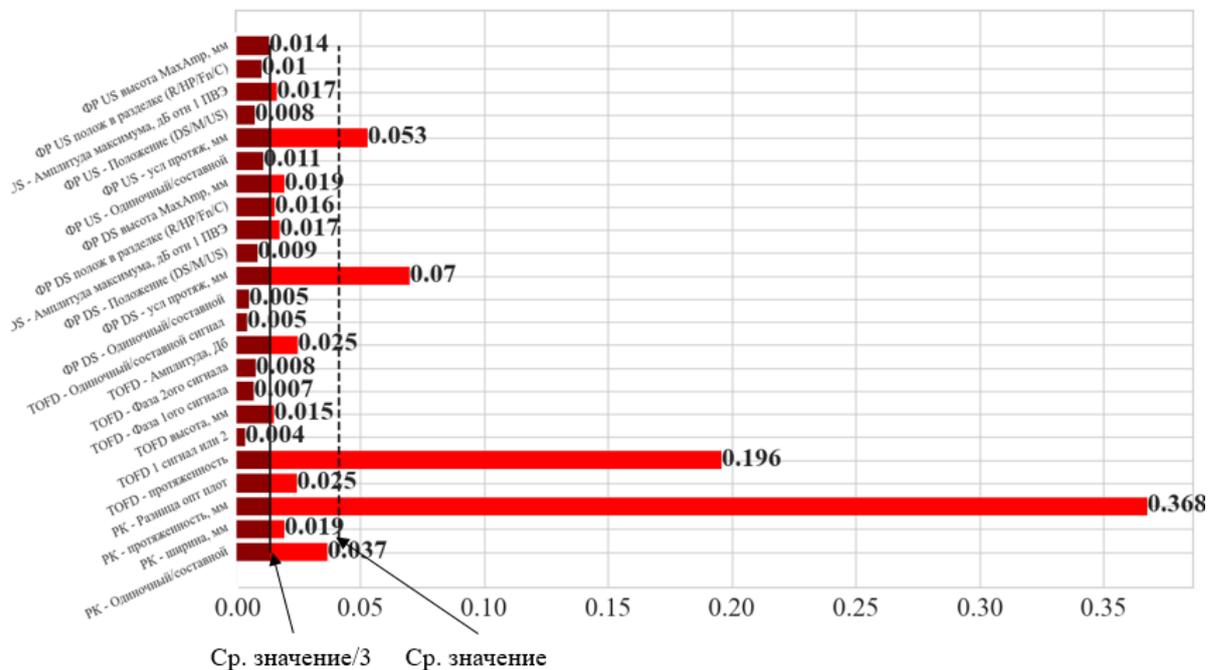


Рисунок 3.13 – Диаграммы степени влияния параметров по критерию «экстра деревьев» системы методов НК для прогнозирования длины дефектов

3.5 Результаты и выводы третьей главы

1. Произведена визуализация полученного набора данных, содержащего 23 параметра, с применением технологии снижения размерностей UMAP с 23х до 3х. В результате визуально не удалось выделить отдельные скопления данных, которые можно отнести к определенному типу.

2. Произведен анализ каждого параметра системы НК по отдельности с целью идентификации определенного типа дефекта. В итоге можно сказать, что только металлические включения надежно идентифицируются по разнице градаций серого при РНК, а для всех остальных типов дефектов присутствует существенная неоднозначность при идентификации.

3. На основе статистического анализа установлено, что параметры системы используемых методов НК, являются независимыми друг от друга, что подтверждается критериями Спирмена и V-Крамера, которые не превышают значений 0,67 и 0,63 соответственно.

4. Установлена степень влияния параметров системы методов НК на возможность классификации дефектов сварных швов по типам согласно критериям «совместной информации» и «экстра деревьев». Количественно обоснована необходимость использования всех 23х предложенных параметров для совместного анализа. Наиболее значимыми параметрами являются: разница градаций серого, протяженность и ширина при РНК, протяженность при УЗК ДВМ, положение в разделке при УЗК эхо-импульсном методе контроля.

5. Установлена степень влияния параметров системы на прогнозирование параметров дефектов, таких как высота и длина с применением критерия «экстра деревьев». Количественно обоснована необходимость использования всех 23х предложенных параметров для прогнозирования высоты дефекта, и четырех параметров, а именно длины по РНК, протяженности по УЗК ДВМ и эхо-импульсным методом с обеих сторон, для прогнозирования длины дефекта.

ГЛАВА 4 ПОСТРОЕНИЕ И НАУЧНОЕ ОБОСНОВАНИЕ ВЫБОРА ОПТИМАЛЬНЫХ МОДЕЛЕЙ СОЧЕТАНИЯ ДАННЫХ, ПРОГНОЗИРУЮЩИХ ТИП И ПАРАМЕТРЫ ДЕФЕКТОВ

Для построения обучаемых моделей сочетания данных исследуемый набор данных был разделен на тренировочную и тестовую выборки. Количество измерений в тренировочной и тестовой выборке составило 857 и 215 измерений соответственно (80% и 20% соответственно от общей выборки с синтетическими данными). Разбиение происходило случайным образом, при котором сохранялся баланс классов, т.е. обе выборки содержали измерения со всеми 16и типами дефектов в соответствующем процентном соотношении.

На тренировочной выборке происходило обучение моделей и определение их оптимальных гиперпараметров. Определение оптимальных гиперпараметров производилось с помощью случайного поиска. При случайном поиске реализуется итерационный процесс, при котором из пространства гиперпараметров выбирается определенная конфигурация, после чего происходит обучение модели с такой конфигурацией. На тестовой выборке происходит оценка работоспособности данной модели по определенной метрике. В итоге выбирается та конфигурация гиперпараметров, для которой значение выбранной метрики будет оптимальной [120].

4.1 Определение оптимальных гиперпараметров моделей классификации

Модели прогнозирования типа дефекта строились на основе следующих подходов машинного обучения: байесовский вывод [39], «дерево решений» [121], «случайный лес» [122], «градиентный бустинг» [123], «полносвязная нейронная сеть» [124, 125]. Модели на основе байесовский вывода не содержат гиперпараметров.

Модели на основе деревьев, или ансамблей деревьев, такие как «дерево решений», «случайный лес» и «градиентный бустинг» имеют следующие гиперпараметры:

- Критерий разделения:
 - Gini: Использует индекс Джини для оценки целесообразности разбиений;
 - Entropy: Использует энтропию для оценки целесообразности разбиений;
 - Log Loss: Логистическая функция ошибки;
 - Squared Error: критерий, минимизирующий среднеквадратичную ошибку прогноза для моделей регрессии или «градиентного бустинга»;
 - Friedman MSE: критерий, который минимизирует среднеквадратичную ошибку прогноза с адаптацией для последовательного улучшения модели на каждом этапе моделей регрессии или «градиентного бустинга», учитывая остаточные ошибки предыдущих деревьев.
- Максимальная глубина дерева: Ограничивает максимальную глубину дерева, предотвращая переобучение;
- Минимальное количество измерений для разбиения узла: Минимальное количество измерений, необходимое для дальнейшего разбиения узла;
- Минимальное количество измерений в листовом узле: Минимальное количество измерений, находящееся в листовом узле;
- Количество деревьев (присутствует в алгоритмах «случайный лес» и «градиентный бустинг»): количество деревьев в лесу. Больше количество деревьев улучшает производительность, но требует вычислительных ресурсов;
- Скорость обучения (присутствует в алгоритме «градиентный бустинг»):

Пространство гиперпараметров для моделей на основе деревьев, или ансамблей деревьев, такие как «дерево решений», «случайный лес» и «градиентный бустинг» представлены в таблице 4.1

Таблица 4.1 – Пространство гиперпараметров для моделей на основе деревьев, или ансамблей деревьев

№	Гиперпараметр	Пространство значений
1	Критерий разделения (все модели кроме моделей на основе «градиентного бустинга»)	{ Gini, Entropy, Log Loss }
	Критерий разделения («градиентный бустинг»)	{ Squared Error, Friedman MSE }
2	Максимальная глубина дерева (все модели)	[1, 50]
3	Минимальное количество измерений для разбиения узла (все модели)	[2, 40]
4	Минимальное количество измерений в листовом узле (все модели)	[1, 40]
5	Количество деревьев («случайный лес» и «градиентный бустинг»)	[1, 3000]
6	Скорость обучения (только «градиентный бустинг»)	[0, 1]

В итоге после 1000 итераций были получены следующие значения (таблица 4.2) гиперпараметров для моделей на основе деревьев или ансамблей деревьев.

Таблица 4.2 – Гиперпараметры моделей на основе деревьев, или ансамблей деревьев

№	Гиперпараметр	Дерево решений	Случайный лес	Градиентный бустинг
1	Критерий разделения	Log Loss	Log Loss	Friedman MSE
2	Максимальная глубина дерева	43	47	30
3	Минимальное количество измерений для разбиения узла	5	2	18
4	Минимальное количество измерений в листовом узле	1	1	22

5	Количество деревьев	-	310	1406
6	Скорость обучения	-	-	0,192

Модели на основе «полносвязной нейронной сети» имеют следующие гиперпараметры:

- Число слоев: Определяет количество скрытых слоев в нейронной сети. Чем больше слоев, тем более сложные зависимости может моделировать сеть, но увеличивается риск переобучения и вычислительная сложность;

- Число нейронов в каждом слое: Определяет количество нейронов в каждом скрытом слое. Большее количество нейронов увеличивает способность сети к обучению сложных функций, но также может привести к переобучению;

- Функция активации: Определяет нелинейность, вводимую в каждом нейроне. Общие функции активации включают ReLU и Tanh. Выбор функции активации влияет на скорость обучения и способность модели к представлению сложных зависимостей.

- Скорость обучения: Определяет, насколько сильно корректируются веса сети при каждом обновлении. Высокая скорость обучения может ускорить процесс, но привести к нестабильности, в то время как низкая скорость может замедлить обучение.

- Регуляризация: Методы регуляризации, такие как L1, L2 или Dropout, используются для предотвращения переобучения. Регуляризация добавляет штрафы за слишком большие веса, что помогает модели обобщать данные.

- Метод оптимизации: Определяет алгоритм, используемый для обновления весов сети. Общие алгоритмы включают SGD (Stochastic Gradient Descent), Adam. Выбор оптимизатора влияет на скорость и стабильность сходимости модели.

Пространство гиперпараметров для модели на основе «полносвязной нейронной сети» представлены в таблице 4.3.

Таблица 4.3 – Пространство гиперпараметров для модели на основе «полносвязной нейронной сети»

№	Гиперпараметр	Пространство значений
1	Число нейронов на каждом из слоев	{(10,8,6,4,2), (100, 80,60,40,20,10), (1000,800,600,400,200,100), (100,100,100), (100,100), (100,100,50),(100,50,50), (50,50,50), (100,100,50,50), (200,150,150,150,100,80, 60,40,20)}
	Функции активации	{ReLU, Tanh}
2	Скорость обучения	[0, 1]
3	Регуляризация L2	[0, 1]
4	Метод оптимизации	{SGD, Adam}

В итоге после 1000 итераций были получены следующие значения (таблица 4.4) гиперпараметров модели на основе «полносвязной нейронной сети».

Таблица 4.4 – Гиперпараметры модели на основе «полносвязной нейронной сети»

№	Гиперпараметр	Пространство значений
1	Число нейронов на каждом из слоев	(200, 150, 150, 150, 100, 80, 60, 40, 20)
2	Функции активации	ReLU
3	Скорость обучения	0,001
4	Регуляризация L2	0,01
5	Метод оптимизации	Adam

4.2 Разработка и научное обоснование выбора оптимальной модели классификации

Как правило, для оценки работоспособности разработанных моделей сочетания данных необходимо использовать определенные метрики в

зависимости от типа выходных данных моделей. Поскольку полученные модели производят классификацию значительного количества типов дефектов (в данном случае 16 типов), необходимо использовать метрики, которые позволяют оценивать модели классификации на три и более класса, или так называемую мультиклассовую классификацию.

Одной из основ различных метрик является матрица достоверности, поскольку она содержит всю необходимую информацию о работе модели. В случае двухклассовой классификации матрица достоверности (рисунок 4.1 - а) содержит информацию об истинных и спрогнозированных классах. При этом, строки представляют пример истинного класса, а столбцы - спрогнозированный класс. Внутри таблицы записываются следующие показатели: TP (истинно положительные примеры) - количество положительных примеров, правильно спрогнозированных как положительные; TN (истинно отрицательные примеры) - количество отрицательных примеров, правильно спрогнозированных как отрицательные; FP (ложно положительные примеры) - количество отрицательных случаев, ошибочно спрогнозированных как положительные; FN (ложно отрицательные примеры) - количество положительных примеров, ошибочно спрогнозированных как отрицательные.

В случае мультиклассовой классификации матрица достоверности расширяется, чтобы включить аналогичные метрики для каждого класса, и представляет собой таблицу (рисунок 4.1 - б), где столбцы отображают классы, спрогнозированные моделью, а строки — истинные классы. Внутри таблицы, соответственно, записывается количество совпадений между спрогнозированными классами и истинными значениями. При этом поскольку классы в столбцах и строках записываются в одном и том же порядке, то правильно классифицированные элементы расположены на главной диагонали сверху слева направо.

		Спрогнозированные классы		Всего
		Предсказано правильно	Предсказано неправильно	
Истинные классы	Классы			
	Истинно правильно	TP = 20	FN = 5	25
	Истинно неправильно	FP = 10	TN = 15	25
	Всего	30	20	50

а)

		Спрогнозированные классы				Всего
		Классы	А	Б	В	
Истинные классы	А	6	0	1	2	9
	Б	3	9	1	1	14
	В	1	0	10	2	13
	Г	1	2	1	12	16
	Всего	11	11	13	17	52

б)

Рисунок 4.1 – Матрица достоверности: двухклассовая (а), мультиклассовая (б)

Одними из основных метрик, которые рассчитываются на основании матрицы достоверности являются точность (Precision) и полнота (Recall), а также точность (Accuracy) и F1-мера (F1-score) и площадь под кривой рабочей характеристики приемника (ROC AUC) [126].

Точность (Precision) представляет собой долю истинно положительных примеров, деленную на общее количество положительно спрогнозированных примеров и вычисляется по формуле (4.1):

$$Precision = \frac{TP}{TP + FP} \quad (4.1)$$

Таким образом точность (Precision) выражает долю примеров, которые разработанная модель называет положительными, и которые на самом деле являются положительными. Другими словами, точность (Precision) показывает, насколько можно доверять модели, когда она прогнозирует пример как положительный.

Полнота (Recall) представляет собой долю истинно положительных примеров, разделенную на общее количество положительно спрогнозированных примеров и вычисляется по формуле (4.2):

$$Recall = \frac{TP}{TP + FN} \quad (4.2)$$

Полнота (Recall) оценивает точность прогнозирования модели для положительного класса, таким образом она показывает способность модели определять все положительные примеры в наборе данных.

Точность (Accuracy) является одной из самых популярных метрик и она непосредственно вычисляется из матрицы ошибок. Формула точности (Accuracy) учитывает сумму элементов Истинно Положительных и Истинно Отрицательных в числителе и сумму всех элементов матрицы ошибок в знаменателе. Точность (Accuracy) вычисляется по формуле (4.3):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.3)$$

Таким образом точность (Accuracy), в случае прогноза одного случайного примера, показывает вероятность того, что прогноз модели верный. Базовым элементом данной метрики являются отдельные примеры в наборе данных, при этом каждый пример имеет одинаковый вес и одинаково влияет на значение точности.

F1-мера оценивает эффективность модели классификации, также основываясь на матрице достоверности, она является средним гармоническим значением таких показателей, как точность (Precision) и полнота (Recall) и рассчитывается по формуле (4.4):

$$F1 \text{ мера} = 2 \cdot \left(\frac{Recall \cdot Precision}{Recall + Precision} \right) \quad (4.4)$$

F1-мера является гармоническим средним между точностью (Precision) и полнотой (Recall), которая обеспечивает баланс между ними. Таким образом ее можно использовать для нахождения наилучшего компромисса между этими двумя величинами. F1-мера достигает максимального значения - 1 (идеальная точность и полнота) и минимального значения - 0 (наихудшая точность и полнота).

F1-мера особенно полезна в условиях несбалансированных классов, где истинные и ложные классы существенно различаются по количеству. В таких ситуациях использование только точности (Precision) или только полноты

(Recall) может дать неполное представление об эффективности модели. F1-мера использует и точность, и полноту, давая более сбалансированную оценку производительности модели.

F1-мера, рассчитываемая по формуле (4.4) подходит для двухклассовой классификации, в случае если необходима мультиклассовая классификация F1-мера должна включать в расчет все классы. Для этого требуется мультиклассовая мера Точности и Полноты, которая будет использована при расчете гармонического среднего. В этом случае можно использовать два разных варианта метрики, а именно Микро-F1-мера и Макро-F1-мера [126].

Для Макро-F1-меры вначале необходимо вычислить Макро-Точность и Макро-Полноту. Они вычисляются соответственно путем усреднения точности для каждого спрогнозированного класса и усреднения полноты для каждого фактического класса. Таким образом, Макро-подход рассматривает все классы как основные элементы расчета: каждый класс имеет одинаковый вес в среднем, так что нет различия между классами с высоким и низким количеством примеров.

Для расчета Макро-Точности и Макро-Полноты для каждого класса используется своя матрица достоверности. Схема составления такой матрицы достоверности для класса «Б» представлена на рисунке 4.2.

		Спрогнозированные классы			
		Классы	А	Б	В
Истинные классы	А	TN	FP	TN	TN
	Б	FN	TP	FN	FN
	В	TN	FP	TN	TN
	Г	TN	FP	TN	TN

Рисунок 4.2 – Схема составления матрицы достоверности для класса «Б» при расчете Макро-Точности и Макро-Полноты

Как видно из рисунка 4.2 для класса «Б» за Истинно Положительные (TP) примеры принимаются только единственно правильно спрогнозированные примеры для рассматриваемого класса, в то время как Ложно Положительными (FP) и Ложно Отрицательными (FN) являются неправильно классифицированные примеры в колонке и строке класса соответственно. За Истинно Отрицательные (TN) примеры принимаются все остальные ячейки матрицы достоверности. При переходе к другому классу матрица достоверности перестраивается аналогичным образом.

Точность (Precision) и полнота (Recall) для каждого класса отдельно вычисляются с использованием формул (4.1) и (4.2) аналогичным образом.

После вычисления точности и полноты для каждого отдельно класса необходимо рассчитать Макро-средние значения точности (Macro Average Precision) и Макро-средние значения полноты (Macro Average Recall), они вычисляются как среднее арифметическое метрик для отдельных классов по формулам (4.5) и (4.6):

$$\text{Macro Average Precision} = \frac{\sum_{k=1}^K \text{Precision}_k}{K}, \quad (4.5)$$

$$\text{Macro Average Recall} = \frac{\sum_{k=1}^K \text{Recall}_k}{K}, \quad (4.6)$$

где K – количество классов; Precision_k – значение точности для класса k ; Recall_k – значение полноты для класса k .

Макро-F1-мера рассчитывается по формуле (4.7):

$$\text{Макро } F1 \text{ мера} = 2 \cdot \left(\frac{\text{Macro Average Precision} \cdot \text{Macro Average Recall}}{\text{Macro Average Precision} + \text{Macro Average Recall}} \right) \quad (4.7)$$

Поскольку Макро-F1-мера вычисляется как гармоническое среднее, то она обеспечивает сбалансированную оценку, где каждый класс вносит равный вклад, что особенно полезно при работе с несбалансированными данными. Она оценивает алгоритм с точки зрения класса: высокие значения указывают на то, что модель хорошо работает со всеми классами, низкие значения указывают на

то, что есть необходимость дальнейшей оптимизации или перебалансировки классов.

Для Микро-F1-меры вначале необходимо вычислить Микро-точность и Микро-полноту. Идея Микро-усреднения заключается в том, чтобы рассматривать все единицы вместе, не учитывая возможные различия между классами. Таким образом, Микро-средняя точность вычисляется следующим образом по формуле (4.8):

$$\text{Micro Average Precision} = \frac{\sum_{k=1}^K TP_k}{\sum_{k=1}^K \text{Всего в столбце}_k} = \frac{\sum_{k=1}^K TP_k}{\text{Всего примеров}}, \quad (4.8)$$

Как видно из формулы (4.8) для определения Микро-средней точности необходимо просуммировать истинно положительные значения для всех классов в числителе и количество примеров в столбце для каждого класса в знаменателе. Однако если сложить количество примеров в столбце для каждого класса, то в итоге мы получим общее количество примеров.

Микро-средняя полнота вычисляется следующим образом по формуле (4.9):

$$\text{Micro Average Recall} = \frac{\sum_{k=1}^K TP_k}{\sum_{k=1}^K \text{Всего в строке}_k} = \frac{\sum_{k=1}^K TP_k}{\text{Всего примеров}}, \quad (4.9)$$

Как видно из формулы (4.10) для определения Микро-Средней полноты необходимо просуммировать истинно положительные значения для всех классов в числителе и количество примеров в строке для каждого класса в знаменателе. Однако если сложить количество примеров в строке для каждого класса, то в итоге мы получим общее количество примеров.

Таким образом Микро-средняя точность и Микро-средняя полнота являются одинаковыми значениями. Поскольку Микро-F1-мера является средним гармоническим для одинаковых величин Микро-средней точности и Микро-средней полноты, то она тоже будет равна этому же значению и будет вычисляться по формуле (4.10):

$$\text{Micro Average F1} = \frac{\sum_{k=1}^K TP_k}{\text{Всего примеров}} \quad (4.10)$$

Как видно из формулы (4.10) Микро-средняя F1-мера по значению равна точности (Accuracy). Таким образом они имеют одинаковые преимущества и недостатки. Обе они придают большее значение классам с большим количеством примеров. Однако, не точное прогнозирование на классах с небольшим количеством примеров не так важно, поскольку количество примеров в этих классах, мало по сравнению с размером набора данных.

В общем, можно рассматривать Макро F1-меру как среднюю меру средней точности и средней полноты классов. Эта мера рассчитывается на уровне класса, так что каждый класс имеет одинаковый вес. Классы с небольшим количеством примеров эквивалентны классам с большим количеством примеров, и производительность алгоритма на них одинаково важна, независимо от размера класса. Напротив, использование Микро F1-меры приводит к простому определению точности (Accuracy).

В рамках выполнения моделирования для совместного анализа экспериментальных данных и классификации дефектов по типам были разработаны модели на основе алгоритмов, представленных в данном разделе. Для сравнения работоспособностей разработанных моделей классификации дефектов использовалась F1-мера, которая рассчитывалась для каждого класса по отдельности, в качестве классов выступали типы дефектов кольцевых сварных соединений. Помимо F1-меры для каждого класса вычислялись общие усредненные значения Макро и Микро (которая, в данном случае, совпадает с достоверностью (Accuracy)) F1-меры. Для этого была составлена таблица, в столбцы которой записывались рассматриваемые модели, а в строки – типы дефектов и усредненные значения метрик. При этом возможности моделей оценивались на двух наборах данных: на обучающем и тестовом. Итоговая работоспособность разработанных моделей классификации представлены в таблице 4.5.

Таблица 4.5 – Итоговая возможность разработанных моделей классификации

Тип дефекта	Байесовский вывод		Дерево решений		Случайный лес		Градиентный бустинг		Полносвязная нейронная сеть	
	Трен.	Тест.	Трен.	Тест.	Трен.	Тест.	Трен.	Тест.	Трен.	Тест.
Aa	0,58	0,77	0,97	0,81	0,99	0,96	0,99	0,92	0,99	0,96
Ab	0,94	0,86	0,98	0,80	0,99	0,92	0,99	0,99	0,99	0,86
Ac	0,68	0,77	0,96	0,86	0,99	0,93	0,99	0,93	0,99	0,83
Ak	0,36	0,12	0,97	0,73	0,99	0,85	0,99	0,88	0,99	0,92
Ba	0,72	0,80	0,97	0,97	0,99	0,99	0,99	0,97	0,99	0,93
Bb	0,92	0,89	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99
Bc	0,42	0,57	0,98	0,82	0,99	0,94	0,99	0,94	0,99	0,88
Bd ₁	0,64	0,65	0,99	0,71	0,99	0,91	0,99	0,91	0,99	0,96
Da ₁	0,57	0,45	0,99	0,82	0,99	0,99	0,99	0,99	0,99	0,82
Da ₂	0,96	0,92	0,99	0,91	0,99	0,99	0,99	0,99	0,99	0,99
Db	0,59	0,62	0,97	0,84	0,99	0,85	0,99	0,82	0,97	0,79
Dc ₁	0,15	0,29	0,92	0,57	0,99	0,76	0,99	0,80	0,99	0,55
Dc ₂	0,84	0,89	0,99	0,88	0,99	0,99	0,99	0,99	0,99	0,95
E	0,43	0,45	0,94	0,65	0,99	0,79	0,99	0,88	0,96	0,69
Fc	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99
Mw	0,15	0,29	0,98	0,96	0,99	0,96	0,99	0,99	0,99	0,83
Микро F1-мера	0,66	0,67	0,98	0,83	0,99	0,93	0,99	0,93	0,99	0,87
Макро F1-мера	0,62	0,65	0,98	0,83	0,99	0,93	0,99	0,94	0,99	0,87

Как видно из таблицы 4.1, наилучшую работоспособность показала модель на основе «градиентного бустинга» с усредненным значением Макро F1-меры 0,94. Показатели метрик по большинству типов дефектов имеют высокие значения. Для дефектов типа межслойное несплавление (Db), несплавление по разделке кромок (Dc₁) и трещина (E) значение метрик находится в диапазоне от 0,8 до 0,9 [A8].

Для анализа работоспособности модели, основанной на алгоритме «градиентного бустинга» были построены матрица достоверности (Таблица 4.6).

Таблица 4.6 – Матрица достоверности для разработанной модели

		Спрогнозированный класс															
		Aa	Ab	Ac	Ak	Ba	Bb	Bc	Bd ₁	Da ₁	Da ₂	Db	Dc ₁	Dc ₂	E	Fc	Mw
Истинный класс	Aa	12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	Ab	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	Ac	0	0	13	0	0	0	0	0	0	0	0	0	0	1	0	0
	Ak	0	0	0	11	0	0	0	1	0	0	1	0	0	0	0	0
	Ba	0	0	0	0	14	0	1	0	0	0	0	0	0	0	0	0
	Bb	0	0	0	0	0	17	0	0	0	0	0	0	0	0	0	0
	Bc	0	0	1	0	0	0	17	0	0	0	0	0	0	0	0	0
	Bd ₁	0	0	0	1	0	0	0	10	0	0	0	0	0	0	0	0
	Da ₁	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0
	Da ₂	0	0	0	0	0	0	0	0	0	11	0	0	0	0	0	0
	Db	0	0	0	0	0	0	0	0	0	0	14	1	0	1	0	0
	Dc ₁	2	0	0	0	0	0	0	0	0	0	2	12	0	0	0	0
	Dc ₂	0	0	0	0	0	0	0	0	0	0	0	0	18	0	0	0
	E	0	0	0	0	0	0	0	0	0	0	1	1	0	14	0	0
	Fc	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0
	Mw	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12

Из таблицы 4.6 видно, что два межслойных несплавления (Db) идентифицированы как несплавление по разделке кромок (Dc₁) и трещина (E), и две трещины (E) идентифицированы как межслойное несплавление (Db) и несплавление по разделке кромок (Dc₁). Скорее всего данные классы содержат граничные примеры (Tomek Links). Созданная модель выдает вектор из 16 вещественных чисел от 0 до 1, где каждое число соответствует вероятности каждого класса. В построенной матрице достоверности класс определялся как тип дефекта с наибольшей вероятностью. В некоторых случаях может быть

граничный вариант (Tomek Link), при котором вероятности нескольких классов практически равны, что приводит к ошибкам. Для оценки классификатора в целом, как правило, используется ROC-анализ.

Кривая рабочей характеристики приемника (ROC-кривая) — это график зависимости частоты истинных положительных результатов (TPR) от частоты ложных положительных результатов (FPR) при различных пороговых значениях классификатора. TPR и FPR вычисляются следующим образом (4.11) - (4.12):

$$TPR = Recall = \frac{TP}{TP + FN} \quad (4.11)$$

$$FPR = \frac{FP}{FP + TN} \quad (4.12)$$

По мере изменения порога классификации, значения FPR и TPR меняются, и на графике образуется кривая. Идеальный классификатор будет стремиться к точке (0,1), где нет ложноположительных результатов, и все положительные случаи классифицируются правильно.

Основной характеристикой ROC-кривой является площадь под кривой (AUC). Значение площади лежит в диапазоне от 0 до 1, где 1 означает идеальную способность модели правильно прогнозировать положительные и отрицательные примеры. Значение 0,5 говорит о том, что эффективность прогнозирования у модели равносильна случайному угадыванию. Значения менее 0,5 указывают на то, что модель работает хуже случайного угадывания. Одно из ключевых преимуществ AUC ROC заключается в том, что эта метрика не зависит от конкретного порогового уровня при классификации, что позволяет оценить общую способность модели различать классы без привязки к определенному порогу решения [127].

В случае мультиклассовой классификации ROC-кривую можно строить несколькими способами. Первый способ заключается в построении отдельной ROC-кривой для каждого класса, где данный класс рассматривается как положительный, а все остальные классы объединяются и рассматриваются как

отрицательный. Для каждого из классов вычисляется AUC, и таким образом можно оценить способность модели отличить каждый класс от остальных.

Второй способ называется макроусреднением и заключается в том, что сначала для каждого класса рассчитываются TPR и FPR, после чего вычисляется среднее арифметическое этих метрик по всем классам (Один против всех (One-vs-All)). Таким образом, получается средняя ROC-кривая, отражающая общую способность модели различать классы. Этот способ дает равный вес каждому классу, независимо от его размера [128].

Третий способ называется микроусреднением и подразумевает суммирование истинно положительных, ложно положительных и ложно отрицательных результатов по всем классам перед расчетом метрик TPR и FPR. В результате строится одна ROC-кривая, основанная на общих показателях по всем классам. Этот способ может быть более чувствительным к производительности модели на классах с большим количеством примеров [127].

На рисунке 4.3 приведены ROC-кривые для каждого класса, а также усредненные Макро и Микро ROC-кривые. Видно, что при общей оценке модели классификации согласно ROC анализу, площади под ROC кривыми (AUC) для классификации дефектов типа межслойное несплавление (Db), несплавление по разделке кромок (Dc₁) и трещина (E) составили 1,00; 0,99 и 0,99 соответственно, что говорит о том, что данные типы дефектов имели граничные значения вероятностей и в целом модель имеет высокую достоверность.

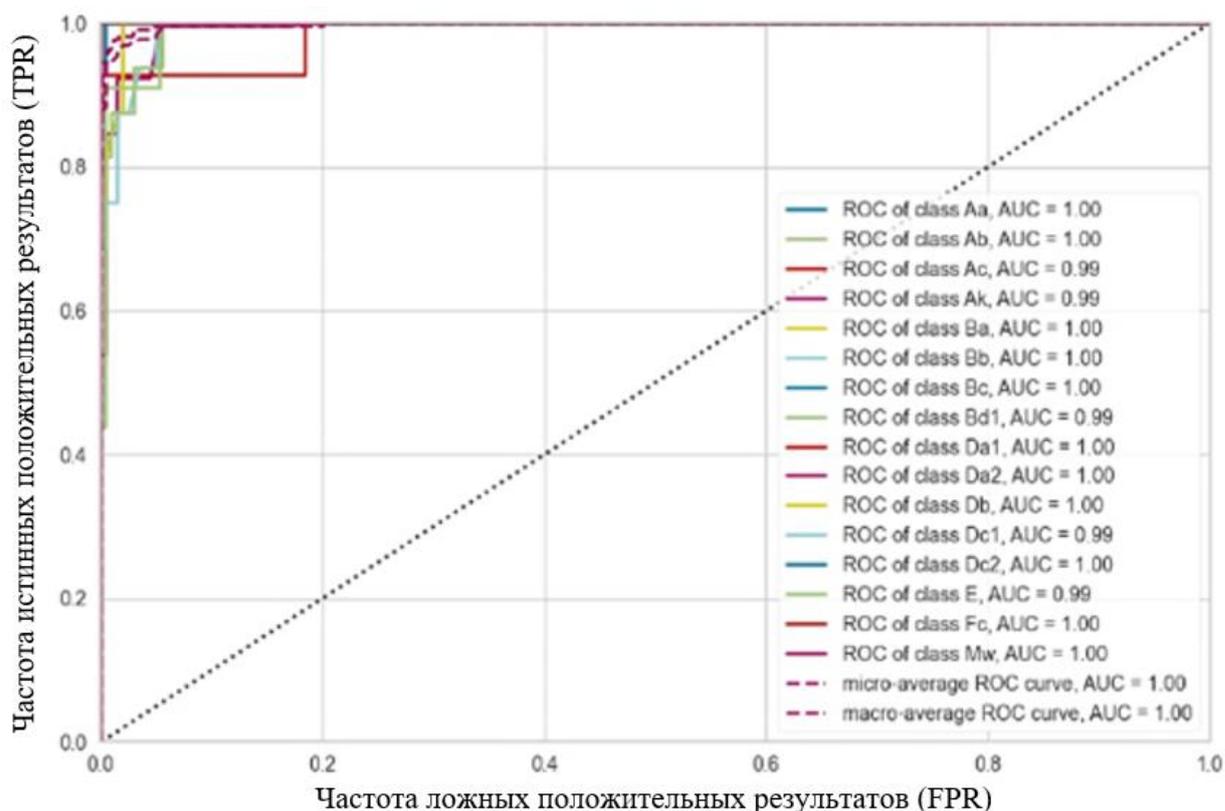


Рисунок 4.3 – ROC-кривые для каждого класса и усредненная по всем классам для полученной модели, основанной на алгоритме «градиентный бустинг»

4.3 Определение оптимальных гиперпараметров моделей регрессии

Как было определено в третьей главе у моделей сочетания данных НК, прогнозирующих параметры дефектов, должны присутствовать две целевые переменные: высота и длина дефекта. Как правило удобнее разрабатывать отдельную модель для каждой из целевых переменных.

Модели прогнозирования высоты дефектов имеют все 23 информационных параметра различных методов НК в качестве входных данных и одну прогнозируемую целевую переменную, являющуюся вещественным числом в качестве выходных данных. Модели прогнозирования высоты дефекта строились на основе следующих подходов машинного обучения: «дерево решений» [121], «случайный лес» [122], «градиентный бустинг» [123], линейная регрессия с регуляризацией L1 («Lasso регрессия») и L2 («Ridge регрессия») [129], а также «полносвязная нейронная сеть» [124, 125]. Гиперпараметры моделей на основе

деревьев, или ансамблей деревьев, такие как «дерево решений», «случайный лес» и «градиентный бустинг» подробно описаны в разделе 4.1, как и параметры «полносвязных нейронных сетей». Lasso и Ridge регрессии являются вариантами линейной регрессии, оснащенными L1 и L2 регуляризацией с гиперпараметрами λ_1 и λ_2 соответственно для уменьшения их переобучения. Выражения для их функций потерь представлены в уравнениях (4.13) и (4.14):

$$L = \frac{1}{2n} \sum_{i=1}^n (y_i - X_i \omega)^2 + \lambda_1 \sum_{j=1}^p |\omega_j| \quad (4.13)$$

$$L = \frac{1}{2n} \sum_{i=1}^n (y_i - X_i \omega)^2 + \lambda_2 \sum_{j=1}^p \omega_j^2 \quad (4.14)$$

, где λ_1 и λ_2 — гиперпараметры регуляризации, ω_j — коэффициенты модели, n — количество наблюдений, p — количество признаков.

Пространство гиперпараметров для моделей, прогнозирующих высоту и длину дефектов, на основе деревьев, или ансамблей деревьев, такие как «дерево решений», «случайный лес» и «градиентный бустинг» соответствовало таблице 4.1, модели на основе «полносвязной нейронной сети» – таблице 4.3. Для моделей на основе Lasso и Ridge регрессий значение параметров регуляризации λ_1 и λ_2 выбиралось из диапазона от 0 до 1 включительно.

В итоге после 1000 итераций были получены следующие значения гиперпараметров для моделей на основе деревьев или ансамблей деревьев, прогнозирующих высоту дефекта (таблица 4.7) и длину дефекта (таблица 4.8).

Значения параметров регуляризации λ_1 и λ_2 моделей на основе Lasso и Ridge регрессий, прогнозирующих высоту и длину дефекта составили 0,16 и 0,99 соответственно.

Таблица 4.7 – Гиперпараметры моделей на основе деревьев, или ансамблей деревьев, прогнозирующих высоту дефекта

№	Гиперпараметр	«Дерево решений»	«Случайный лес»	«Градиентный бустинг»
1	Критерий разделения	Squared Error	Squared Error	Friedman MSE
2	Максимальная глубина дерева	4	46	7
3	Минимальное количество измерений для разбиения узла	24	3	17
4	Минимальное количество измерений в листовом узле	24	1	12
5	Количество деревьев	-	1988	645
6	Скорость обучения	-	-	0,02

Таблица 4.8 – Гиперпараметры моделей на основе деревьев, или ансамблей деревьев, прогнозирующих длину дефекта

№	Гиперпараметр	«Дерево решений»	«Случайный лес»	«Градиентный бустинг»
1	Критерий разделения	Squared Error	Squared Error	Friedman MSE
2	Максимальная глубина дерева	43	40	20
3	Минимальное количество измерений для разбиения узла	10	16	19
4	Минимальное количество измерений в листовом узле	8	1	9
5	Количество деревьев	-	1482	542
6	Скорость обучения	-	-	0,008

Гиперпараметры моделей на основе «полносвязных нейронных сетей», прогнозирующих высоту и длину дефекта, представлены в таблицах 4.9 и 4.10 соответственно.

Таблица 4.9 – Гиперпараметры модели на основе «полносвязной нейронной сети», прогнозирующей высоту дефекта

№	Гиперпараметр	Пространство значений
1	Число нейронов на каждом из слоев	(1000, 800, 600, 400, 200, 100)
2	Функции активации	ReLU
3	Скорость обучения	0,001
4	Регуляризация L2	0,055
5	Метод оптимизации	SGD

Таблица 4.10 – Гиперпараметры модели на основе «полносвязной нейронной сети», прогнозирующей длину дефекта

№	Гиперпараметр	Пространство значений
1	Число нейронов на каждом из слоев	(50, 50, 50)
2	Функции активации	ReLU
3	Скорость обучения	0,001
4	Регуляризация L2	0,096
5	Метод оптимизации	Adam

4.4 Разработка и научное обоснование выбора оптимальных моделей регрессии

Для обучения и проверки работоспособности моделей регрессии применялась кросс-валидация, при которой производились 100 итераций, где все данные, полученные при измерениях, были разделены на 5 различных обучающих и тестовых выборок, составивших 857 и 215 элементов соответственно.

Работоспособность моделей регрессии на тестовой выборке определялась по средним арифметическим для всех итераций кросс-валидации таких метрик, как средняя абсолютная ошибка (MAE) и корень из среднеквадратичной ошибки (RMSE) [130], которые вычисляются по формулам (4.15) и (4.16) соответственно.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (4.15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (4.16)$$

где n - количество прогнозов, y_i - истинное значение зависимой переменной для i -го наблюдения, \hat{y}_i - значение зависимой переменной, спрогнозированное моделью.

В рамках выполнения моделирования для совместного анализа экспериментальных данных и прогнозирования параметров дефектов были разработаны модели на основе алгоритмов, представленных в данном разделе. Для сравнения возможностей разработанных моделей прогнозирования высоты и длины дефекта применялись метрики MAE и RMSE, которые вычислялись на тренировочной и тестовой выборках. Поскольку применялась кросс-валидация, то тренировочных и тестовых наборов данных было по 500 шт. и фиксировалось минимальное, среднее и максимальное значение данных метрик. Итоговая работоспособность разработанных моделей, прогнозирующих высоту дефектов представлены в таблице 4.11, прогнозирующих длину дефектов - в таблице 4.12.

Таблица 4.11 – Работоспособность моделей, прогнозирующих высоту дефектов

№	Модель	Сред. MAE обуч., мм	Сред. MAE тест., мм	Сред. RMSE обуч., мм	Сред. RMSE тест., мм
1	«Дерево решений»	1,168	1,312	1,573	1,761
2	«Случайный лес»	0,442	1,147	0,677	1,714
3	«Градиентный бустинг»	0,568	0,856	1,200	1,712
4	Lasso регрессия	1,319	1,406	1,801	1,918
5	Ridge регрессия	1,259	1,644	1,484	1,937
6	«Полносвязная нейронная сеть»	0,091	1,203	0,287	1,702

Таблица 4.12 – Работоспособность моделей, прогнозирующих длину дефектов

№	Модель	Сред. MAE обуч., мм	Сред. MAE тест., мм	Сред. RMSE обуч., мм	Сред. RMSE тест., мм
1	«Дерево решений»	4,058	4,447	5,465	5,941
2	«Случайный лес»	2,710	3,790	3,845	5,364
3	«Градиентный бустинг»	3,698	4,341	4,724	5,525
4	Lasso регрессия	3,946	4,094	5,122	5,301
5	Ridge регрессия	3,871	4,029	5,097	5,288
6	«Полносвязная нейронная сеть»	2,162	4,32	3,163	6,037

Как видно из таблицы 4.11, среди моделей, прогнозирующих высоту дефекта, наилучшую работоспособность показала модель на основе «полносвязной нейронной сети» со средними показателями MAE и RMSE 1,203 и 1,702 мм соответственно. Из таблицы 4.12 видно, что из моделей, прогнозирующих длину дефекта, наилучшую работоспособность показала модель на основе «ridge регрессии» со средними показателями MAE и RMSE 4,029 и 5,288 мм соответственно.

Визуализация работоспособности моделей регрессии обычно производится с применением диаграмм Тейлора. На диаграмме Тейлора по углу отображается корреляция, по радиусу — стандартное отклонение, а расстояние до точки с идеальной корреляцией и совпадающим стандартным отклонением отражает RMSE [131]. Диаграммы Тейлора для моделей, прогнозирующих высоту и длину дефекта, представлены на рисунке 4.4 – а) и – б) соответственно.

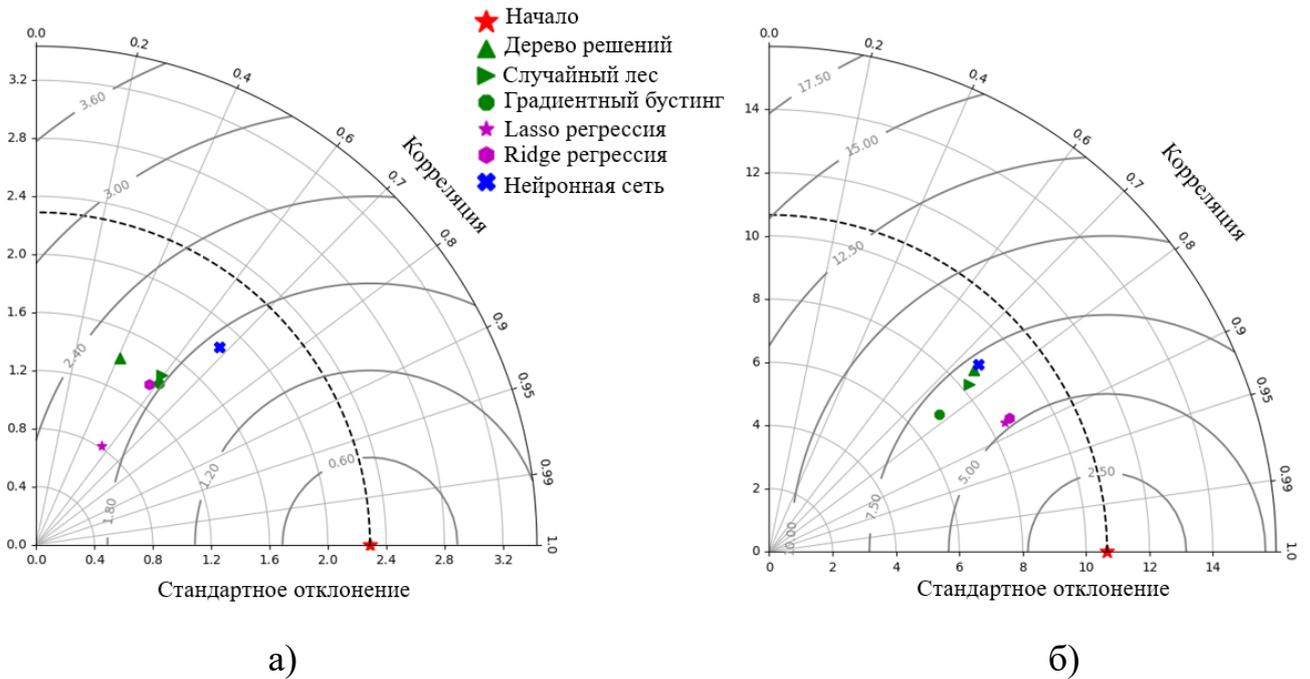
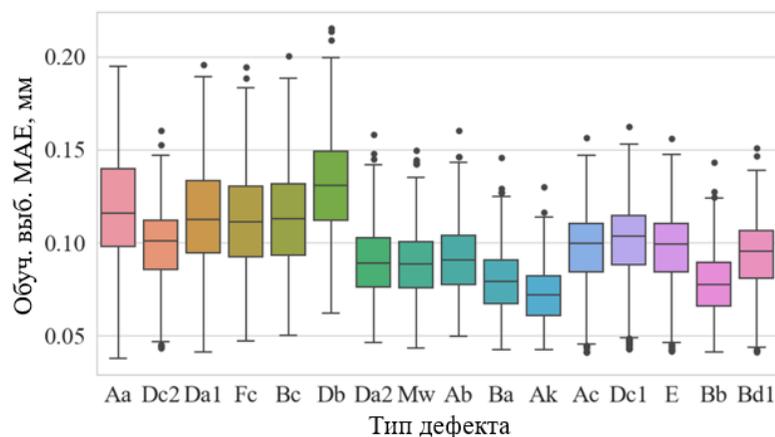


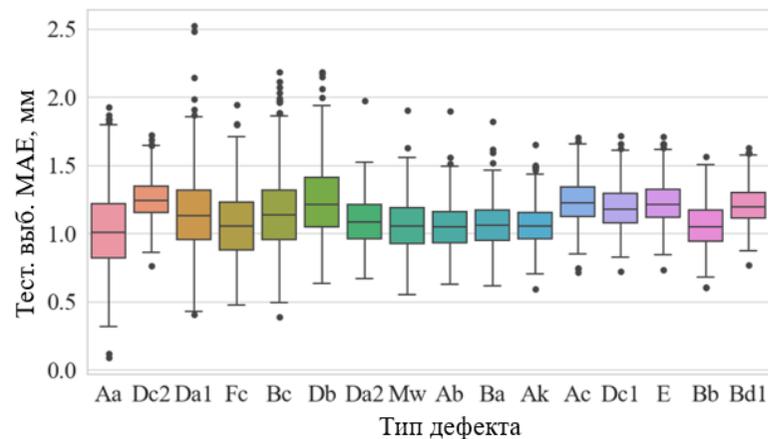
Рисунок 4.4 – Диаграммы Тейлора для моделей, прогнозирующих высоту дефекта (а) и длину дефекта (б)

В таблицах 4.11 и 4.12 и на рисунке 4.4. показаны значения метрик MAE и RMSE общие для всех типов дефектов. С целью оценки значения данных метрик для каждого типа дефекта на обучающей и тестовой выборках были построены диаграммы размаха рассматриваемых метрик на обучающей и тестовой выборках для модели на основе «полносвязной нейронной сети», прогнозирующей высоту дефектов (рисунок 4.5) и для модели на основе «ridge регрессии», прогнозирующей длину дефектов (рисунок 4.6).

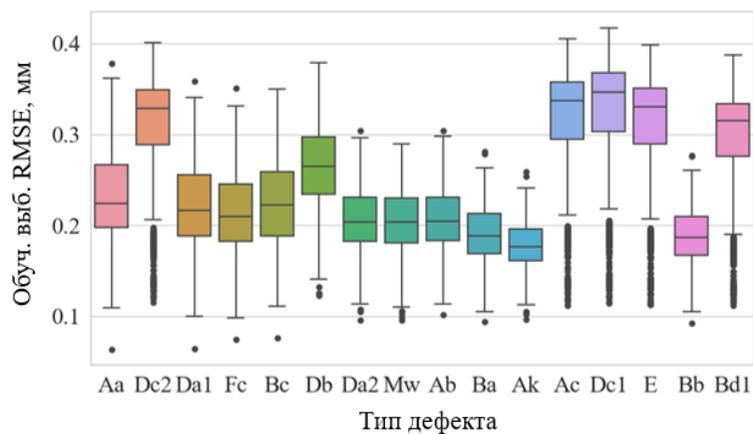
Анализируя рисунки 4.5 и 4.6 можно сказать, то на тестовых выборках не удастся выделить типы дефектов, для которых значения метрик будут существенно отличаться от остальных, поэтому создание дополнительных моделей для дефектов определенных типов не является актуальным.



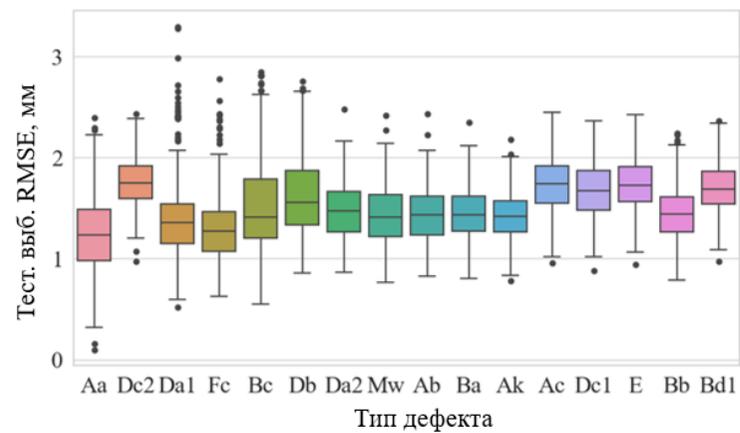
а)



б)

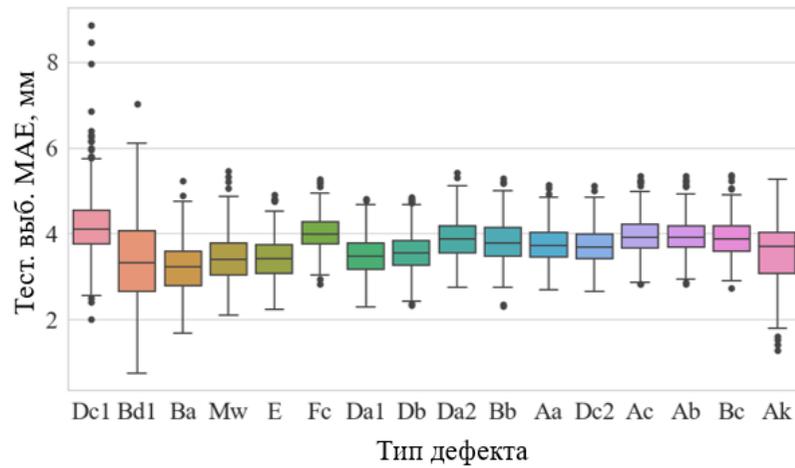


в)

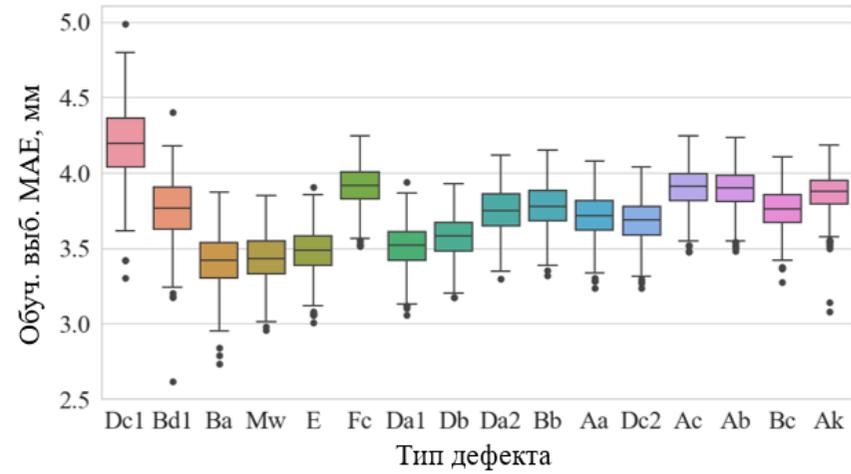


г)

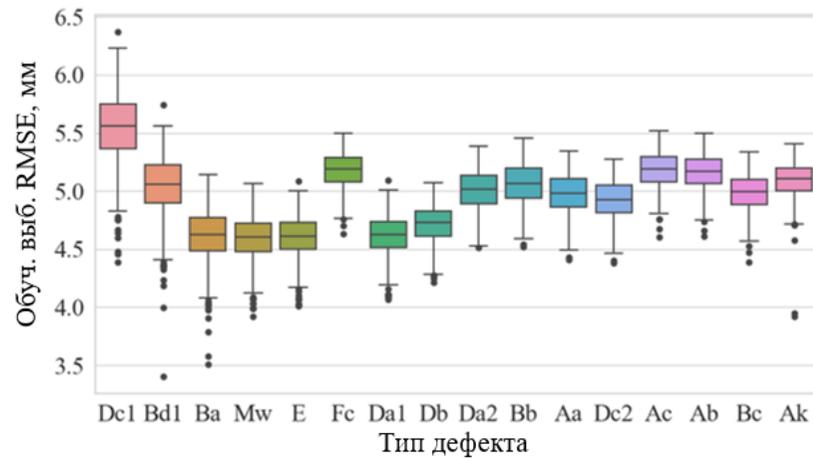
Рисунок 4.5 – Диаграммы размаха метрик MAE, вычисленных на обучающей (а) и тестовой (б) выборках и RMSE – на обучающей (в) и тестовой (г) выборках для модели на основе «полносвязной нейронной сети», прогнозирующей высоту дефекта



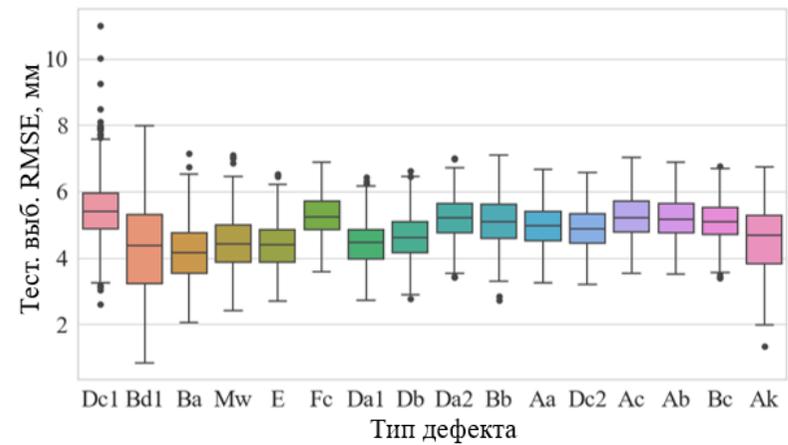
а)



б)



в)



г)

Рисунок 4.6 – Диаграммы размаха метрик MAE, вычисленных на обучающей (а) и тестовой (б) выборках и RMSE – на обучающей (в) и тестовой (г) выборках для модели на основе «ridge регрессии», прогнозирующей длину дефекта

4.5 Результаты и выводы четвертой главы

1. Произведен выбор оптимальных гиперпараметров с применением случайного поиска для моделей на основе таких алгоритмов как байесовский вывод, «дерево решений», «случайный лес», «градиентный бустинг», «полносвязная нейронная сеть». Данные модели позволяют производить классификацию дефектов по типам.

2. Произведено обучение моделей классификации дефектов по типам на основе рассматриваемых алгоритмов. Определена оптимальная модель согласно метрике F1-мера для каждого класса дефекта, а также микро и макро усредненной F1-меры. Оптимальной моделью, в данном случае, является модель на основе «градиентного бустинга» с макро усредненной F1-мерой, составляющей 0,94.

3. Произведен выбор оптимальных гиперпараметров с применением случайного поиска для моделей на основе таких алгоритмов как, «дерево решений», «случайный лес», «градиентный бустинг», «lasso регрессия», «ridge регрессия» и «полносвязная нейронная сеть». Данные модели позволяют производить прогнозирование высоты и глубины дефектов.

4. Произведено обучение моделей прогнозирования высоты и глубины дефектов на основе рассматриваемых алгоритмов. Определена оптимальная модель согласно усредненным метрикам MAE и RMSE по результатам кросс-валидации. Оптимальной моделью прогнозирования высоты дефекта в данном случае является модель на основе «полносвязной нейронной сети» со средними значениями MAE и RMSE 1,203 и 1,702 мм соответственно. Оптимальной моделью прогнозирования длины дефекта, в данном случае, является модель на основе «ridge регрессии» со средними значениями MAE и RMSE 4,029 и 5,288 мм соответственно.

ГЛАВА 5 РАЗРАБОТКА МЕТОДИКИ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ С ВЫПОЛНЕНИЕМ СОВМЕСТНОГО АНАЛИЗА ДАННЫХ НА ОСНОВЕ ПРОВЕДЕННЫХ ИССЛЕДОВАНИЙ

Разработанные модели прогнозирования типа и параметров дефектов сварных швов МГ являются многомерными функциями, позволяющими получая на вход идентификационные признаки дефектов сварных швов спрогнозировать тип и параметры данных дефектов. Для применения полученных моделей на практике необходима методика НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК, а также программное обеспечение для проведения всех вычислений.

5.1 Разработка методики НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК

Приведенная в данном разделе методика реализована в Р Газпром «Сварка и неразрушающий контроль сварных соединений. Методика неразрушающего контроля сварных соединений трубопроводов с выполнением совместного анализа данных визуального и измерительного, радиографического и ультразвукового методов», которые разработаны авторским коллективом в следующем составе: С.В. Скрынников, Н.А. Щипаков, Д.М. Козлов, Н.В. Крысько, А.Г. Кусый, Е.М. Вышемирский, М.Ю. Тульский, Т.В. Артеменко, Ю.А. Соловьев, А.А. Цыба.

Основные положения методики приведены ниже.

5.1.1 Общие положения

5.1.1.1 Настоящая методика распространяется на проведение ВИК, РНК, УЗК кольцевых стыковых сварных соединений МГ диаметром от DN 50 с толщиной стенки от 6,0 мм и более, полученных дуговыми способами сварки, при строительстве и эксплуатации, в случае возможности сохранения и

обработки в цифровом виде всех данных НК и определения информационных признаков для каждого из методов НК.

5.1.1.2 НК сварных соединений, выполненных дуговой сваркой с использованием ручных, механизированных и автоматизированных методов ВИК, РНК и УЗК, проводится для обнаружения, идентификации и оценки условных размеров дефектов, таких как высота и протяженность.

5.1.1.3 НК сварных соединений, выполненных дуговыми способами сварки, с применением ручных, механизированных и автоматизированных ВИК, РНК, УЗК следует применять для решения следующих задач:

- контроль сварного соединения;
- обнаружение и идентификация дефектов;
- определение условных размеров дефектов;
- оценка качества сварного соединения.

5.1.2 Порядок выбора средств НК

5.1.2.1 При проведении ВИК применяют средства в соответствии с [1] (подраздел 8.2), рекомендуется использовать средства, которые в электронном виде обеспечивают:

- ввод и хранение данных об объекте контроля и параметров контроля;
- программную установку критериев оценки дефектов и геометрических параметров;
- запись результатов контроля с заданной точностью;
- автоматизированное формирование заключения по результатам контроля;
- возможность сохранения и просмотра результатов.

5.1.2.2 При проведении РНК применяют средства в соответствии с [1] (подраздел 9.2), рекомендуется использовать средства, которые в электронном виде обеспечивают:

- ввод и хранение данных об объекте контроля и параметров контроля;
- программную установку критериев оценки допустимости дефектов;

- запись результатов с заданным шагом;
- автоматизированное формирование заключения по результатам контроля;
- возможность сохранения и просмотра результатов.

5.1.2.3 При проведении ручного, механизированного и автоматизированного УЗК применяют средства в соответствии с [1] (подраздел 10.2) и [2] (раздел 6), рекомендуется использовать средства, которые в электронном виде обеспечивают:

- ввод и хранение данных об объекте контроля и параметров контроля;
- программную установку критериев оценки допустимости дефектов;
- запись результатов с заданным шагом;
- автоматизированное формирование заключения по результатам контроля;
- возможность сохранения и просмотра результатов.

5.1.3 Порядок проведения НК сварных соединений.

5.1.3.1 Для выполнения НК качества следует обеспечить беспрепятственный и безопасный доступ к сварным соединениям.

5.1.3.2 Поверхность сварного соединения и основного металла трубы очищают с обеих сторон вдоль шва от металлических брызг, отслаивающейся окалины, следов коррозии, пыли, грязи и других загрязнений, мешающих проведению контроля.

5.1.3.3 Подготовку контролируемых поверхностей обеспечивает производитель сварочно-монтажных работ.

5.1.3.4 Шероховатость поверхности объекта контроля обеспечивают в соответствии с требованиями из [1] (подраздел 7.6).

5.1.3.5 Для проведения УЗК кольцевых сварных соединений следует соблюдать условия удаления на концах труб наружного и внутреннего усиления продольных швов, а также антикоррозионного изоляционного покрытия, грунтовочного слоя и адгезива в соответствии с [1] (раздел 7).

5.1.3.6 Ширину подготавливаемой зоны с каждой стороны сварного соединения приводят в операционных технологических картах НК.

5.1.3.7 Освещенность участка подготавливаемой зоны при проведении работ следует обеспечивать в соответствии с требованиями операционных технологических карт НК.

5.1.3.8 НК качества сварных соединений следует проводить в следующей последовательности: ВИК (автоматизированный ВИК), РНК, УЗК.

5.1.3.9 При проведении НК всеми методами следует применять единую систему отсчета координат в соответствии с [1] (подраздел 7.14).

5.1.3.10 ВИК сварных соединений следует проводить в соответствии с [1] (подраздел 8.1).

5.1.3.11 РНК сварных соединений следует проводить в соответствии с [18] (подразделы 7.7, 8.9, 9.6) и [1] (подраздел 9.2).

5.1.3.12 УЗК сварных соединений следует проводить в соответствии с [2] (раздел 7) и [1] (подраздел 10.2).

5.1.4 Порядок сохранения и обработки результатов НК.

5.1.4.1 При использовании методов НК без возможности сохранения файлов с данными контроля и обработки их в программном обеспечении, используемого оборудования, результаты контроля сохраняют и обрабатывают в виде заключений в соответствии с [1] (раздел 15) после завершения НК, выполняемого по 5.1.3.10-5.1.3.12.

5.1.4.2 При использовании методов НК с возможностью сохранения файлов с данными контроля и обработки их в программном обеспечении (ПО), используемого оборудования, результаты контроля сохраняют согласно руководству по эксплуатации (РЭ) применяемого устройства после завершения НК, выполняемого по 5.1.3.10-5.1.3.12. В файле, в котором сохраняются результаты контроля, следует указывать следующие параметры:

- данные об организации и специалисте, проводивших контроль;
- наименование объекта контроля;

- геометрические параметры объекта контроля;
- вид сварки и параметры разделки кромок контролируемого сварного соединения;
- данные о средствах, материалах и параметрах контроля.

5.1.4.3 При использовании методов НК с возможностью сохранения файлов с данными контроля и обработки их в ПО, используемого оборудования, обработку результатов НК следует выполнять в следующем порядке:

- регистрация информационных признаков для ВИК, РНК и УЗК (по 5.1.4.4-9. 5.1.4);
- совместный анализ данных ВИК, РНК и УЗК (по 5.1.4.9).

5.1.4.4 При обработке результатов ВИК сварных соединений следует регистрировать следующие информационные признаки:

- дефект не выявлен/выявлен;
- номер дефекта;
- протяженность дефекта;
- ширина дефекта;
- высота дефекта.

5.1.4.4.1 Значение параметра дефект не выявлен/выявлен устанавливается равным «0» в случае если дефект не выявлен и «1» в случае если дефект выявлен.

5.1.4.4.2 Номер дефекта присваивается регистрируемым дефектам последовательно в зависимости от расположения дефекта относительно начала отсчета координат. В случае выявления одного и того же дефекта несколькими методами контроля, данному дефекту присваивается одинаковый номер. Дефект считается выявленным несколькими методами НК, если:

- он находится в одной зоне сварного шва по результатам контроля всеми методами;
- его глубина совпадает для всех методов НК, причем глубина определяется экспертно согласно зоне расположения;

- его образ, по результатам методов НК, спроецированный на продольную ось сварного шва (координаты дефектов), полностью совпадают. При этом допускается синхронный сдвиг всех обнаруженных дефектов вдоль сварного шва для компенсации систематической погрешности оборудования НК, определяющего координаты. Либо один из образов находится внутри границ другого.

5.1.4.4.3 Значение протяженности дефекта следует определять по 5.1.4.4.3.1-5.1.4.4.3.2.

5.1.4.4.3.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на изображении вдоль сварного шва найти координаты двух положений курсора, которые соответствуют началу и концу этой индикации. Значение протяженности дефекта следует определять как разность между найденными координатами. Пример определения протяженности дефекта приведен на рисунке 2.4.

5.1.4.4.3.2 В случае наличия в ПО для обработки результатов контроля функции автоматического определения протяженности, значение условной протяженности дефекта определять в соответствии с РЭ на ПО.

5.1.4.4.4 Значение ширины дефекта следует определять по 5.1.4.4.4.1-5.1.4.4.4.2.

5.1.4.4.4.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на изображении поперек сварного шва найти координаты двух положений курсора, которые соответствуют началу и концу этой индикации. Значение ширины дефекта следует определять, как разность между найденными координатами. Пример определения ширины дефекта приведен на рисунке 2.4.

5.1.4.4.4.2 В случае наличия в ПО для обработки результатов контроля функции автоматического определения ширины, значение ширины дефекта определять в соответствии с РЭ на ПО.

5.1.4.4.5 Значение высоты дефекта следует определять по 5.1.4.4.5.1-5.1.4.4.5.2.

5.1.4.4.5.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на изображении, найти место, в котором в поперечном сечении высота индикации будет максимальной. Значение высоты дефекта следует определять, как максимальную высоту индикации. Пример определения высоты дефекта приведен на рисунке 2.4.

5.1.4.4.5.2 В случае наличия в ПО для обработки результатов контроля функции автоматического определения высоты, значение высоты дефекта определять в соответствии с РЭ на ПО.

5.1.4.5 При обработке результатов РНК сварных соединений следует регистрировать следующие информационные признаки:

- дефект не выявлен/выявлен;
- номер дефекта;
- одиночный дефект или составной;
- протяженность дефекта;
- ширина дефекта;
- разница значений градации серого на дефекте и рядом.

5.1.4.5.1 Значение параметра дефект не выявлен/выявлен устанавливается аналогично по 5.1.4.4.1.

5.1.4.5.2 Номер дефекта следует присваивать аналогично по 5.1.4.4.2.

5.1.4.5.3 Значение параметра одиночный или составной дефект определяется по 5.1.4.5.3.1-5.1.4.5.3.2.

5.1.4.5.3.1 При наличии на РНК изображении индикации, соответствующей одному дефекту, значение параметра устанавливается равным 0. Пример одиночного дефекта приведен на рисунке 2.5 - а) слева.

5.1.4.5.3.2 При наличии на РНК изображении нескольких индикаций, соответствующих одному дефекту, значение параметра устанавливается равным 1. Пример составного дефекта приведен на рисунке 2.5 - а) справа.

5.1.4.5.4 Значение протяженности дефекта следует определять по 5.1.4.5.4.1-5.1.4.5.4.2.

5.1.4.5.4.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на РНК изображении вдоль сварного шва найти координаты двух положений курсора, которые соответствуют началу и концу этой индикации. Значение протяженности дефекта следует определять, как разность между найденными координатами. Пример определения протяженности дефекта приведен на рисунке 2.5 - в).

5.1.4.5.4.2. В случае наличия в ПО для обработки результатов контроля функции автоматического определения протяженности, значение протяженности дефекта определять в соответствии с РЭ на ПО.

5.1.4.5.5 Значение ширины дефекта следует определять по 5.1.4.5.5.1-5.1.4.5.5.2.

5.1.4.5.5.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на РНК изображении поперек сварного шва найти координаты двух положений курсора, которые соответствуют началу и концу этой индикации. Значение ширины дефекта следует определять, как разность между найденными координатами. Пример определения ширины дефекта приведен на рисунке 2.5 - б).

5.1.4.5.5.2. В случае наличия в ПО для обработки результатов контроля функции автоматического определения протяженности, значение ширины дефекта определять в соответствии с РЭ на ПО.

5.1.4.5.6 Значение разницы градации серого на дефекте и рядом следует определять по 5.1.4.5.6.1-5.1.4.5.6.2.

5.1.4.5.6.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на РНК изображении вдоль сварного шва определить максимальные значения градации серого в начале, середине и конце дефекта. Пример определения максимального значения градации серого в начале дефекта приведен на рисунке 2.5-г). После чего навести курсор на сварной

шов возле индикации и измерить максимальные значения градации серого возле начала, середины и конца дефекта. Пример определения максимального значения градации серого на сварном шве вначале дефекта приведен на рисунке 2.5-г).

5.1.4.5.6.2 Значение разницы градации серого $P_{\text{разн.}}$ следует вычислять по формуле

$$GV_{\text{разн.}} = \frac{(GV_{\text{нач.деф.}} - GV_{\text{св.нач.деф.}}) + (GV_{\text{сер.деф.}} - GV_{\text{св.сер.деф.}})}{2} + \frac{(GV_{\text{кон.деф.}} - GV_{\text{св.кон.деф.}})}{2}, \quad (4.1)$$

где $GV_{\text{нач.деф.}}$ – значение градации серого в начале дефекта;

$GV_{\text{сер.деф.}}$ – значение градации серого в середине дефекта;

$GV_{\text{кон.деф.}}$ – значение градации серого в конце дефекта;

$GV_{\text{св.нач.деф.}}$ – значение градации серого на сварном шве возле начала дефекта;

$GV_{\text{св.сер.деф.}}$ – значение градации серого на сварном шве возле середины дефекта;

$GV_{\text{св.кон.деф.}}$ – значение градации серого на сварном шве возле конца дефекта.

5.1.4.6 При обработке результатов УЗК сварных соединений с использованием ФАР следует регистрировать следующие информационные признаки:

- дефект не выявлен/выявлен;
- номер дефекта;
- одиночный сигнал или составной;
- положение дефекта в шве;
- положение дефекта в слоях шва;
- амплитуда максимума сигнала от дефекта;
- условная протяженность дефекта;
- условная высота дефекта.

5.1.4.6.1. Порядок регистрации параметров по 5.1.4.6.2-5.1.4.6.10 указан для УЗК с использованием ФАР в режиме секторного сканирования. Допускается выполнять регистрацию параметров по другим техникам в соответствии с [2].

5.1.4.6.2 Поскольку УЗК сварных соединений с использованием ФАР осуществляется с двух сторон от сварного шва, информационные признаки следует регистрировать отдельно для каждой стороны контроля с указанием с какой стороны был зарегистрирован каждый признак.

5.1.4.6.3 Значение параметра дефект не выявлен/выявлен устанавливается аналогично по 5.1.4.4.1.

5.1.4.6.4 Номер дефекта следует присваивать аналогично по 5.1.4.4.2.

5.1.4.6.5 Значение параметра одиночный или составной сигнал следует определять по 5.1.4.6.5.1-5.1.4.6.5.2.

5.1.4.6.5.1 При наличии на S-скане одиночной индикации, соответствующей одному дефекту, сигнал считается одиночным и значение параметра устанавливается равным «0». Пример одиночного сигнала приведен на рисунке 2.7-а) слева.

5.1.4.6.5.2 При наличии на S-скане нескольких индикаций, соответствующих одному дефекту, сигнал считается составным и значение параметра устанавливается равным «1». Пример одиночного сигнала приведен на рисунке 2.7-а) справа.

5.1.4.6.6 Положение дефекта в шве определяется по расположению индикации от этого дефекта на S-скане по горизонтали относительно разделки. В случае если индикация находится ближе к левой кромке разделки положению дефекта в шве присваивается статус «левая кромка (Л)», если она находится ближе к правой кромке – «правая кромка (П)», если в центре – «центр (Ц)». Примеры определения положения дефекта в шве приведены на рисунке 2.7-в).

5.1.4.6.7 Положение дефекта в слоях шва определяется по расположению индикации от этого дефекта на S-скане по вертикали относительно разделки. В случае если индикация находится возле корня сварного шва положению дефекта

в слоях шва присваивается статус «дефект в корне (R)», если она находится в районе горячего прохода – «дефект в горячем проходе (HP)», если в области облицовочного шва – «дефект в облицовке (C)», в остальных случаях присваивается значение – «дефект в заполняющих слоях (Fn)». Примеры определения положения дефекта в слоях шва приведены на рисунке 2.7-е).

5.1.4.6.8 Значение амплитуды максимума сигнала от дефекта следует определять по 5.1.4.6.8.1-5.1.4.6.8.2.

5.1.4.6.8.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на В- и S-сканах найти положение курсора, в котором сигнал индикации на А-скане будет иметь максимальную амплитуду, полученное значение принять за значение максимума амплитуды от дефекта. Пример определения максимума сигнала от дефекта приведен на рисунке 2.7-г).

5.1.4.6.8.2. В случае наличия в ПО для обработки результатов контроля функции автоматического определения максимума амплитуды индикации, значение максимума амплитуды от дефекта определять в соответствии с РЭ на ПО.

5.1.4.6.9 Значение условной протяженности дефекта следует определять по 5.1.4.6.9.1-5.1.4.6.9.2.

5.1.4.6.9.1 Навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на В-скане по горизонтали найти координаты двух положений курсора, в которых сигнал на А-скане будет иметь амплитуду, превышающую контрольный уровень. Условную протяженность дефекта следует определять, как разность между найденными координатами. Пример определения условной протяженности дефекта приведен на рисунке 2.7-б).

5.1.4.6.9.2. В случае наличия в ПО для обработки результатов контроля функции автоматического определения условной протяженности, значение условной протяженности дефекта определять в соответствии с РЭ на ПО.

5.1.4.6.10 Значение условной высоты дефекта следует определять по 5.1.4.6.10.1-5.1.4.6.10.2.

5.1.4.6.10.1 Условную высоту дефекта следует определять по технике «MaxAmp», для этого необходимо навести курсор на индикацию, соответствующую дефекту, путем перемещения курсора по индикации на В-скане по вертикали найти координаты двух положений курсора, в которых сигнал на А-скане будет иметь амплитуду, которая будет на 10% меньше максимальной амплитуды для этой индикации. Условную высоту дефекта следует определять, как разность между найденными координатами. Пример определения условной высоты от дефекта приведен на рисунке 2.7-д). Допускается выполнять измерение условной высоты дефекта по иным существующим техникам в соответствии с [2].

5.1.4.6.10.2. В случае наличия в ПО для обработки результатов контроля функции автоматического определения условной высоты по технике «MaxAmp» или иной техники в соответствии с [2], значение условной высоты дефекта определяется в соответствии с РЭ на ПО.

5.1.4.7 При обработке результатов УЗК ДВМ сварных соединений следует регистрировать следующие информационные признаки:

- дефект не выявлен/выявлен;
- номер дефекта;
- одиночный сигнал или составной;
- один или два сигнала от дефекта;
- фаза первого сигнала от дефекта;
- фаза второго сигнала от дефекта;
- амплитуда максимума сигнала от дефекта;
- условная протяженность дефекта;
- условная высота дефекта.

5.1.4.7.1 При выполнении контроля несколькими парами преобразователей ДВМ регистрацию параметров следует осуществлять по результатам контроля,

полученным той парой преобразователей ДВМ, где индикации от дефектов выявлены лучше.

5.1.4.7.2 Значение параметра дефект не выявлен/выявлен устанавливается аналогично по 5.1.4.4.1.

5.1.4.7.3 Номер дефекта следует присваивать аналогично по 5.1.4.4.2.

5.1.4.7.4 Значение параметра одиночный или составной сигнал следует определять по 5.1.4.7.4.1-5.1.4.7.4.2.

5.1.4.7.4.1 При наличии на В-скане одиночной индикации, соответствующей одному дефекту, сигнал считается одиночным и значение параметра устанавливается равным «0». Пример одиночного сигнала приведен на рисунке 2.6-а) слева.

5.1.4.7.4.2 При наличии на В-скане нескольких индикаций, соответствующих одному дефекту, сигнал считается составным и значение параметра устанавливается равным «1». Пример составного сигнала приведен на рисунке 2.6-а) справа.

5.1.4.7.5 Значение параметра один или два сигнала от дефекта следует определять по 5.1.4.7.5.1-5.1.4.7.5.4.

5.1.4.7.5.1 На В-скане следует выделить индикацию и выводить А-скан на экран.

5.1.4.7.5.2 При наличии на А-скане между сигналом от головной волны и донным сигналом одного сигнала количество сигналов индикации принимают равным одному, параметру присваивается значение «0». Примеры индикации с одним сигналом приведен на рисунке 2.6-в) слева.

9.7.5.3 В случае, если на А-скане присутствует два сигнала, которые имеют различные фазы (рисунок 2.6-в) справа), то оба сигнала принадлежат одной индикации, количество сигналов индикации принимается равным двум, параметру присваивается значение «1».

5.1.4.7.5.4 В случае, если на А-скане присутствует два сигнала, которые имеют одинаковые фазы (рисунок 2.6-д)), то считают, что выявлено несколько

отдельных индикаций, количество сигналов для каждой из них следует указывать равным одному, параметру для каждой индикации присваивается значение «0».

5.1.4.7.6 Фазы первого и второго сигнала от дефекта следует определять по 5.1.4.7.6.1-5.1.4.7.6.4.

5.1.4.7.6.1 На В-скане следует выделить индикацию и выводить А-скан на экран.

5.1.4.7.6.2 Если на А-скане между сигналом головной волны и донным сигналом присутствует один сигнал, для определения его фазы устанавливают знак полуволны, с которой начинается сигнал от дефекта, либо знак пика с максимальной амплитудой этого сигнала. Если индикация совпадает по фазе с сигналом головной волны, параметру фазы первого сигнала присваивается значение «0» (рисунок 2.6-д)). Если индикация находится в противофазе с головной волной, параметру фазы первого сигнала присваивается значение «1» (рисунок 2.6-д)). При наличии только одного сигнала параметр фазы второго сигнала принимает то же значение, что и параметр фазы первого.

5.1.4.7.6.3 В случае, если на А-скане присутствует два сигнала, которые имеют различные фазы (рисунок 2.6-д)), то сигналу, который находится в одной фазе с сигналом головной волны, присваивают значение фазы равное «0». Сигналу, который находится в противофазе с сигналом головной волны, присваивают значение фазы равное «1». За фазу первого сигнала принимаю значение фазы сигнала, который находится ближе к сигналу головной волны.

5.1.4.7.6.4 В случае, если на А-скане присутствует два сигнала, которые имеют одинаковые фазы (рисунок 2.6-д)), то считают, что выявлено несколько отдельных индикаций, фазы для каждого сигнала определяют отдельно по 5.1.4.7.6.2.

5.1.4.7.7 Амплитуду максимума сигнала от дефекта следует определять по 5.1.4.7.7.1-5.1.4.7.7.2.

5.1.4.7.7.1 На В-скане следует выделить индикацию и выводить А-скан на экран.

5.1.4.7.7.2 Путем перемещения курсора по индикации на В-скане найти положение курсора, в котором сигнал индикации на А-скане будет иметь максимальную амплитуду. В этом положении измерить значение максимальной амплитуды сигнала головной волны и значение максимальной амплитуды сигнала индикации. Пример определения максимальной амплитуды сигнала головной волны и максимальной амплитуды сигнала индикации приведен на рисунок 2.6-е).

За значение амплитуды максимума сигнала от дефекта $A_{\text{макс.деф.}}$ принимается значение, вычисленное по формуле

$$A_{\text{макс.деф.}} = 20 \lg \left(\frac{A_{\text{макс.инд.}}}{A_{\text{макс.LW}}} \right), \quad (5.2)$$

где $A_{\text{макс.инд.}}$ – максимальная амплитуда индикации, ПВЭ;

$A_{\text{макс.LW}}$ – максимальная амплитуда сигнала головной волны, ПВЭ.

5.1.4.7.8 Условную протяженность дефекта следует определять в соответствии с [2] (подпункты 7.7.4.5–7.7.4.6).

5.1.4.7.9 Условную высоту дефекта следует определять по 5.1.4.7.9.1–5.1.4.7.9.2.

5.1.4.7.9.1 При наличии дефекта, который имеет один сигнал, необходимо вычислить значение глубины индикации, соответствующей этому дефекту по формуле

$$H_{\text{инд}} = \sqrt{C^2 \cdot \frac{(t_{\text{инд}} - t_{\text{LW}})^2}{k_1} + P \cdot C \cdot (t_{\text{инд}} - t_{\text{LW}})}, \quad (5.3)$$

где C – скорость ультразвуковой волны, м/с;

$t_{\text{инд}}$ – время сигнала индикации, мкс;

t_{LW} – время сигнала головной волны, мкс;

P – половина расстояния между точками ввода, мм;

k_1 – числовой коэффициент, принимаемый равным 4.

Для вычисления глубины индикации следует определять время для сигнала головной волны и индикации от дефекта. Для определения времени следует располагать курсор на характерных точках сигнала головной волны и индикации одним из способов в соответствии [2] (подпункт 7.7.4.7).

Значение условной высоты для дефекта, который имеет один сигнал, определяют по формуле

$$h_{\text{деф}} = \sqrt{\frac{C^2 \left(\frac{k_1 \cdot \sqrt{H_{\text{инд}}^2 + P^2}}{C} + \frac{k_2}{k_1 f} \right)^2}{k_3} - P^2 - H_{\text{инд}}}, \quad (5.4)$$

где $H_{\text{инд}}$ – глубина индикации, мм (см. формулу (5.3));

C – скорость ультразвуковой волны, м/с;

f – частота контроля, МГц;

P – половина расстояния между точками ввода, мм;

k_1 – числовой коэффициент, принимаемый равным 2;

k_2 – числовой коэффициент, принимаемый равным 3;

k_3 – числовой коэффициент, принимаемый равным 4.

5.1.4.7.9.2 Условную высоту внутреннего дефекта, имеющего два сигнала следует определять по разности глубин, рассчитываемых по формуле (5.3), для первого и второго сигналов от дефекта.

5.1.4.8 Информационные признаки, определенные для каждого из методов по 5.1.4.4-5.1.4.7, следует заносить в электронный файл в виде таблицы или в соответствующее ПО.

5.1.4.9 В случае если дефект обнаружен по результатам ВИК его тип следует определять только по результатам ВИК, в других случаях его тип следует определять по 5.1.4.10.

5.1.4.10 Обработку данных ВИК, РНК и УЗК следует выполнять комплексно с использованием специализированных моделей совместного анализа данных. Данные модели могут быть основаны на нечеткой логике,

статистических алгоритмах, алгоритмах машинного или глубокого обучения. В качестве входных данных рассматриваемые модели используют информационные признаки из электронного файла по 5.1.4.8. В результате работы рассматриваемых моделей формируется электронный файл в виде таблицы, которая содержит следующие данные:

- номер дефекта;
- ВИК дефект не выявлен/ выявлен;
- РНК дефект не выявлен/ выявлен;
- УЗК с использованием ФР дефект не выявлен/ выявлен;
- УЗК методом TOFD дефект не выявлен/ выявлен;
- тип дефекта;
- протяженность дефекта;
- высота дефекта;
- ширина дефекта.

5.1.5 Порядок оценки качества сварных соединений трубопроводов, по результатам совместного анализа результатов НК

5.1.5.1 Порядок оценки качества сварных соединений по результатам совместного анализа результатов ВИК, РНК и УЗК приведен в 5.1.5.1.1 – 5.1.5.1.2.

5.1.5.1.1 Обработку результатов ВИК, РНК и УЗК следует проводить по 5.1.4.3.

5.1.5.1.2 По геометрическим параметрам выявленных дефектов провести оценку качества сварных соединений ВИК, РНК и УЗК по нормам, установленным в [1] (раздел 6), [133] (раздел 7).

5.2 Разработка схемы НК сварных соединений трубопроводов с выполнением совместного анализа данных ВИК, РНК и УЗК и ее валидация

В предыдущем разделе описана методика совместного анализа ВИК, РНК и УЗК сварных швов МГ. Схема данной методики представлена на рисунке 5.1.

Согласно данной схемы происходит сбор данных ВИК, РНК, УЗК эхо-импульсным с ФАР и ДВМ с обеих сторон согласно существующей НД, после чего формируется вектор идентификационных признаков. Далее он подается в разработанную модель сочетания данных на основе «градиентного бустинга», которая прогнозирует тип дефекта. В случае выявления дефекта по результатам ВИК тип дефекта определяется по результатам ВИК. Далее по разработанной модели сочетания данных на основе «полносвязной нейронной сети» производится прогноз высоты дефекта, а по разработанной модели сочетания данных на основе «ridge регрессии» производится прогноз длины дефекта.

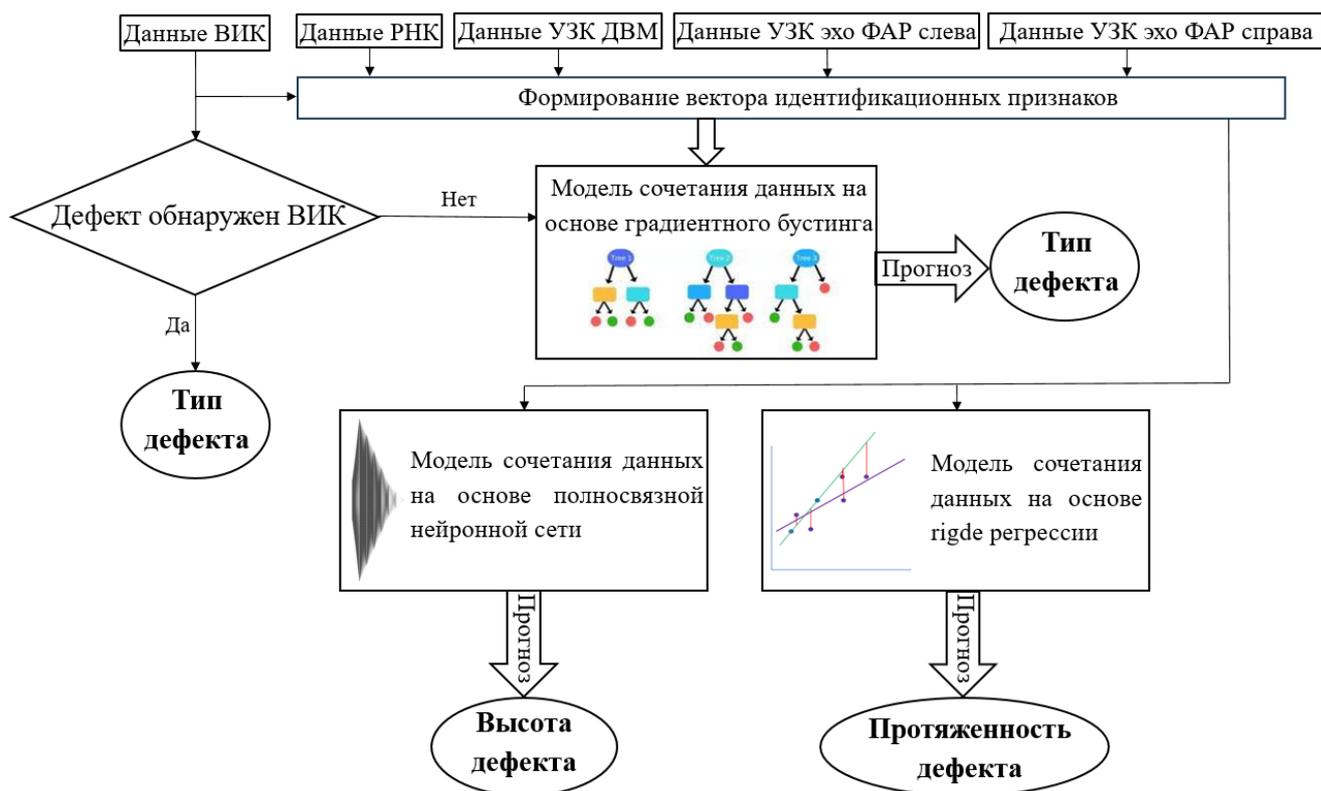


Рисунок 5.1 – Схема методики совместного анализа ВИК, РНК и УЗК сварных швов МГ

Разработанные модели сочетания данных на основе «градиентного бустинга», «полносвязной нейронной сети» и «ridge регрессии» представляют собой многомерные математические выражения, из-за чего ручные вычисления по ним являются затруднительными. В связи с этим было разработано ПО под названием «CoWld», позволяющее производить все вычисления по моделям сочетания данных, которые представлены в данной методике. Интерфейс рассматриваемого ПО «CoWld» представлен на рисунке 5.2.

Совместный анализ методов НК сварных швов (CoWld) (ver. 1.0)

Файл База данных Отчет Язык Помощь О программе

Параметры дефекта		Параметры сварного шва				Применить модели сочетания данных	Завести в базу данных
№	Координата	№	Материал	Толщина стенки	Тип разделки	Сварщик	Результат вычислений по моделям сочетания данных
1	42 мм	35	Ст. 20	14 мм	V-образная	Иванов И.И.	Тип: Несплавление Dc1 Высота: 3.2 мм Длина: 15.3 мм

Идентификационные признаки по результатам методов неразрушающего контроля

Визуальный и измерительный контроль (ВИК)	Радиационный контроль (РНК)	Ультразвуковой контроль дифракционно-временным методом (УЗК ДВМ)	Ультразвуковой контроль эхо-импульсным методом (УЗК ФАР) слева	Ультразвуковой контроль эхо-импульсным методом (УЗК ФАР) справа
<input type="checkbox"/> Не выявлен Тип: - Ширина: мм Длина: мм Ширина шва: 20.3 мм Высота шва: 0.9 мм Смещение кромок: 0.2 мм	<input checked="" type="checkbox"/> Выявлен Тип: Одиночный Ширина: 0.87 мм Длина: 9.48 мм Разница градаций серого <input checked="" type="checkbox"/> Дефект Рядом Начало: 32228 20804 Середина: 32453 15326 Конец: 36929 15187 <input type="checkbox"/> Среднее <input type="checkbox"/> Разница	<input checked="" type="checkbox"/> Выявлен Тип: Сосатной Условная протяженность: 12.2 мм <input type="checkbox"/> Один сигнал Условная высота: 4.6 мм Фаза первого сигнала: Как у головной волны Фаза второго сигнала: Как у головной волны Амплитуда сигнала: 15.6 дБ	<input checked="" type="checkbox"/> Выявлен Тип: Сосатной Условная протяженность: 11.1 мм Положение в шве: В центре Амплитуда сигнала: 35.7 дБ Положение в разделке: Заполнение (F) Условная высота: 4.5 мм	<input checked="" type="checkbox"/> Выявлен Тип: Сосатной Условная протяженность: 16.8 мм Положение в шве: Справа Амплитуда сигнала: 42 дБ Положение в разделке: Заполнение (F) Условная высота: 2.8 мм

Рисунок 5.2 – Основное окно программы “CoWld”, реализующей все вычисления согласно разработанной методике

Валидация разработанной методики проводилась на тестовом наборе дефектов. Матрица достоверности классификации по методике представлена в таблице 4.6. В итоге из 215 дефектов был правильно идентифицирован 201 дефект, что составляет порядка 93%. Два межслойных несплавления (Db) идентифицированы как несплавление по разделке кромок (Dc₁) и трещина (E), две трещины (E) идентифицированы как межслойное несплавление (Db) и несплавление по разделке кромок (Dc₁). По результатам ROC анализа,

приведенного в 4й главе, площади под ROC кривыми (AUC) для классификации дефектов типа межслойное несплавление (Db), несплавление по разделке кромок (Dc₁) и трещина (E) составили 1,00; 0,99 и 0,99 соответственно, что говорит о том, что целом методика имеет высокую достоверность классификации дефектов сварных швов по типам.

Помимо классификации дефектов сварных швов, разработанная методика позволяет прогнозировать параметры дефектов, а именно их высоту и длину. Валидация разработанной методики с точки зрения прогнозирования параметров дефектов проводилась на тестовом наборе, содержащем 128 дефектов различного типа. Значения метрик MAE и RMSE для высоты и протяженности по отдельности приведены в главе 4. Общая работоспособность методики с точки зрения прогнозирования параметров дефектов представлена на рисунке 5.3. В итоге в диапазон однократного значения RMSE попало 103 измерения (80%), в диапазон двукратного значения RMSE – 119 измерения (93%) что говорит о низкой степени разброса.

Применение данной методики позволит уйти от определения типа дефекта оператором или с применением технологий компьютерного зрения на рентгеновских снимках. Согласно [134] справочнику под. ред. В.В. Клюева разброс при ручной расшифровке рентген снимков составляет 30%, следовательно, достоверность идентификации типа дефекта при ручной расшифровке не превышает 0,7. Данная методика позволит идентифицировать дефекты по типам с достоверностью более 0,9, а также спрогнозировать их высоту и ширину путем извлечения из данных контроля простых численных параметров.

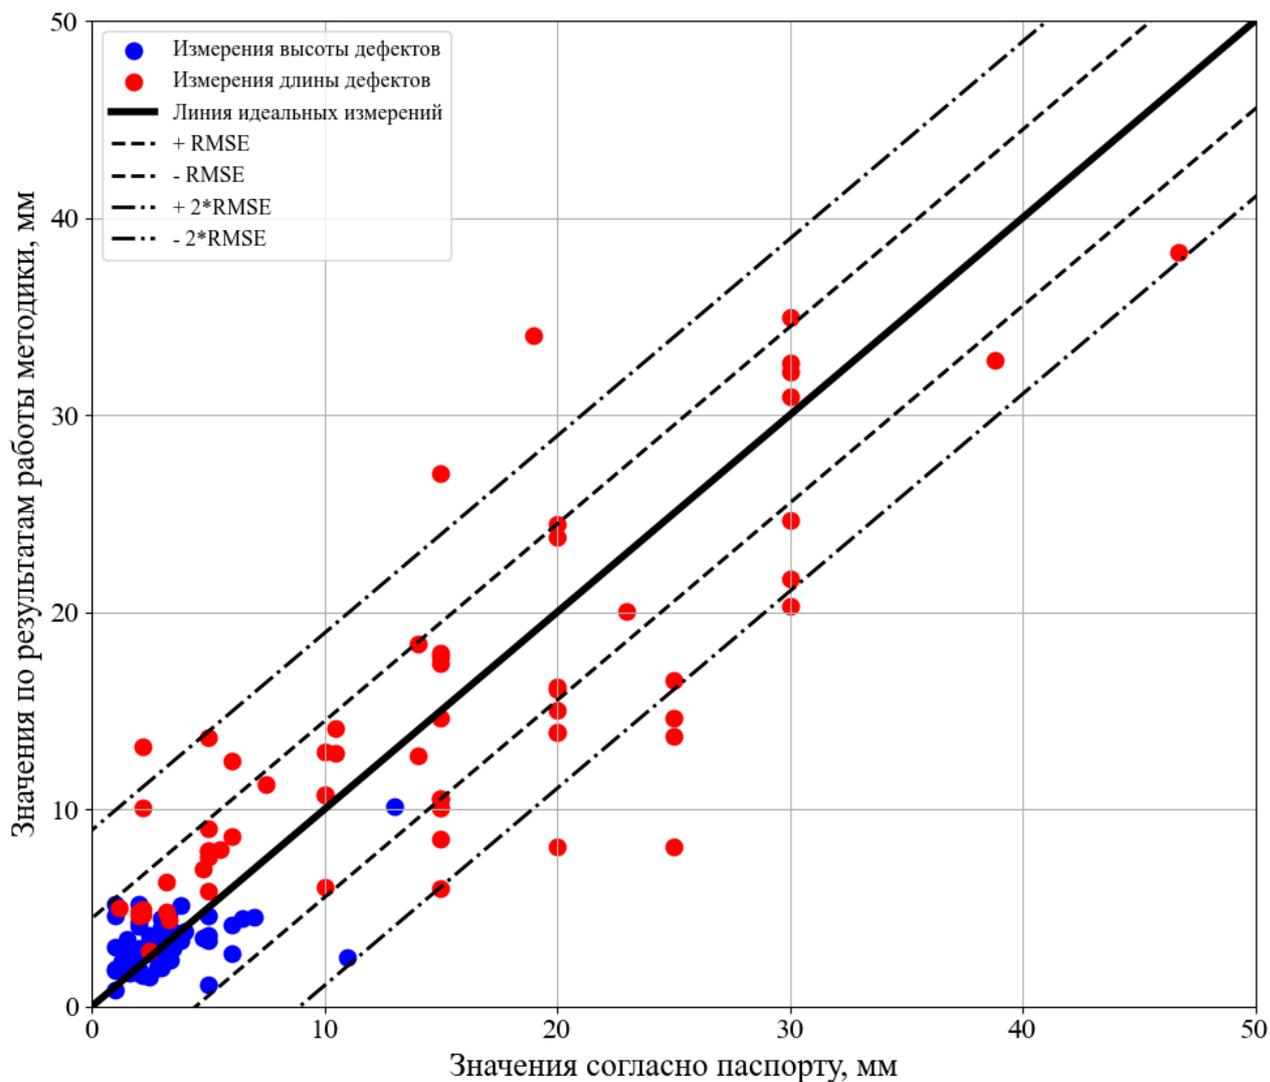


Рисунок 5.3 – Общая работоспособность методики с точки зрения прогнозирования параметров дефектов

5.3 Результаты и выводы пятой главы

1. Разработана методика совместного анализа ВИК, РНК и УЗК, которая позволяет произвести прогноз типа и параметров дефектов кольцевых стыковых сварных швов МГ с применением моделей классификации и регрессии, полученных в данной работе. Произведена валидация разработанной методики.
2. Разработана программа «CoWld», которая позволяет производить многомерные вычисления по полученным в данной работе моделям для методики совместного анализа ВИК, РНК и УЗК.

ЗАКЛЮЧЕНИЕ

Предложен новый порядок оценки качества МГ с применением сочетания данных НК, не противоречащий действующей НД. Применение данного порядка позволяет повысить качество МГ за счет увеличения темпов строительства путем уменьшения количества ремонтов, вызванных перебраковкой кольцевых сварных соединений путем оценки качества по типу и параметрам дефектов, определенных по методике совместного анализа ВИК, РНК, УЗК эхо-импульсным/эхо-зеркальным (тандем) и ДВМ.

1. Определены информационные признаки дефектов сварных швов, полученных по результатам ВИК, РНК, УЗК эхо-импульсного на базе ФАР и ДВМ контроля сварных швов в виде изображений. Данные признаки содержат 23 параметра, из которых 12 – непрерывные, 11 – категориальные.

2. Произведен анализ каждого из параметров системы НК по отдельности с целью идентификации определенного типа дефекта. В итоге можно сказать, что только металлические включения надежно идентифицируются по разнице градаций серого при РНК, а для всех остальных типов дефектов присутствует существенная неоднозначность при идентификации.

3. На основе статистического анализа установлено, что параметры системы используемых методов НК, являются независимыми друг от друга, что подтверждается критериями Спирмена и V-Крамера, которые не превышают значений 0,67 и 0,63 соответственно.

4. Установлена степень влияния параметров системы методов НК на возможность классификации дефектов сварных швов по типам согласно критериям «совместной информации» и «экстра деревьев». Количественно обоснована необходимость использования всех 23х предложенных параметров для совместного анализа. Наиболее значимыми параметрами являются: разница градаций серого, протяженность и ширина при РНК, протяженность при УЗК ДВМ, положение в разделке при УЗК эхо-импульсном методе.

5. Произведено обучение моделей классификации дефектов по типам на основе рассматриваемых алгоритмов. Определена оптимальная модель согласно метрике F1-мера для каждого класса дефекта, а также микро и макро усредненной. Оптимальной моделью в данном случае является модель на основе «градиентного бустинга» с макро усредненной F1-мерой, составляющей 0,94.

6. Произведено обучение моделей прогнозирования высоты и глубины дефектов на основе рассматриваемых алгоритмов. Определена оптимальная модель согласно усредненным метрикам MAE и RMSE по результатам кросс-валидации. Оптимальной моделью прогнозирования высоты дефекта в данном случае является модель на основе «полносвязной нейронной сети» со средними значениями MAE и RMSE 1,203 и 1,702 мм соответственно. Оптимальной моделью прогнозирования длины дефекта, в данном случае, является модель на основе «ridge регрессии» со средними значениями MAE и RMSE 4,029 и 5,288 мм. соответственно.

7. Разработана методика и программное обеспечение для совместного анализа ВИК, РНК и УЗК, которая позволяет произвести прогноз типа и параметров дефектов кольцевых стыковых сварных швов МГ с применением моделей классификации и регрессии, полученных в данной работе. Произведена валидация разработанной методики. Получен патент на изобретение.

СПИСОК РАБОТ, ОПУБЛИКОВАННЫХ АВТОРОМ ПО ТЕМЕ ДИССЕРТАЦИИ

Публикации в изданиях, индексируемых в базе Web of Science, Scopus и входящих в перечень ВАК:

А1. Исследование выявляемости поверхностных объемных дефектов при ультразвуковом контроле с применением волн Рэлея, генерируемых электромагнитно-акустическим преобразователем / Н.П. Алешин, Н.В. Крысько, А.Г. Кусый, С.В. Скрынников, Л.Ю. Могильнер – Текст : непосредственный // Дефектоскопия. – 2021. – № 5. – С. 22-30.

А2. Исследование выявляемости поверхностных плоскостных дефектов ультразвуковым методом с применением волн Рэлея / Н.П. Алешин, Н.В. Крысько, С.В. Скрынников, А.Г. Кусый – Текст : непосредственный // Дефектоскопия. – 2021. – № 6. – С. 26-34.

А3. Классификация поверхностных дефектов основного металла трубопроводов по результатам комплексной диагностики / Н.П. Алешин, С.В. Скрынников, Н.В. Крысько, Н.А. Щипаков, А.Г. Кусый – Текст : непосредственный // Компьютерная оптика. – 2023. – Т. 47. – № 1. – С. 170-178.

А4. Классификация и определение размеров поверхностных дефектов трубопроводов на основе результатов комплексной диагностики ультразвуковым, вихретоковым, визуальным и измерительным методами неразрушающего контроля / Н.В. Крысько, С.В. Скрынников, Н.А. Щипаков, Д.М. Козлов, А.Г. Кусый – Текст : непосредственный // Дефектоскопия. – 2023. – № 12. – С. 69-78.

А5. Алешин, Н.П. Развитие технологии настройки акустических систем при ультразвуковом контроле сварных соединений / Алешин Н.П., Могильнер Л.Ю., Скрынников С.В. – Текст : непосредственный // Наука и технологии трубопроводного транспорта нефти и нефтепродуктов. – 2021. – № 5. – С.535-545.

Публикации в изданиях, рекомендованных перечнем ВАК РФ:

А6. Подходы к оценке качества сварных соединений газопроводов на основе комплексного анализа данных различных методов неразрушающего контроля / Н.П. Алешин, С.В. Скрынников, Н.В. Крысько, Н.А. Щипаков, А.Г. Кусый – Текст : непосредственный // Газовая промышленность. – 2021. – № S3 (823). – С. 28-32.

Публикации в других изданиях:

А7. Комплексный анализ данных различных методов неразрушающего контроля сварных швов магистральных газопроводов / Н.П. Алёшин, Н.В. Крысько, А.Г. Кусый, С.В. Скрынников – Текст : непосредственный // Состояние и основные направления развития неразрушающего контроля качества сварных соединений объектов ПАО "Газпром". Тезисы докладов VIII отраслевого совещания. – Москва. –2021. – С. 14.

А.8. Крысько, Н.В. Подходы к совместному анализу данных неразрушающего контроля сварных швов магистральных газопроводов / Н.В. Крысько, А.Г. Кусый, С.В. Скрынников – Текст : непосредственный // Состояние и основные направления развития неразрушающего контроля сварных соединений объектов ПАО "Газпром". Тезисы докладов IX Отраслевого совещания. – Санкт-Петербург. – 2023. – С. 10.

Результаты интеллектуальной деятельности:

1. Патент № 2764607 Российская Федерация, МПК G01N 29/04 (2006.01), G01M 3/18 (2006.01). Способ проведения неразрушающего контроля цилиндрических объектов и автоматизированный комплекс для его реализации : N 2020138136.; заявл. 19.11.2020 : опубликовано 18.01.2022 / Алешин Н.П.,

Скрынников С.В., Григорьев М.В., Крысько Н.В., Шипилов А.В.; заявитель ПАО «Газпром» – 18 с. : ил. – Текст : непосредственный.

СПИСОК ЛИТЕРАТУРЫ

1. СТО Газпром 15-1.3-004-2023. Сварка и неразрушающий контроль сварных соединений. Неразрушающие методы контроля качества сварных соединений промышленных и магистральных газопроводов : стандарт организации ПАО «Газпром» : издание официальное : утвержден и введен в действие распоряжением ПАО «Газпром» от 24 января 2023 г. № 22 – Санкт-Петербург, 2023. – С. 182. – Текст : непосредственный.

2. СТО Газпром 15-2.3-005-2023. Ультразвуковой контроль качества сварных соединений: утвержден и введен в действие распоряжением ПАО «Газпром» от 24 января 2023 г. № 22 - Санкт-Петербург, 2023. – С. 122. – Текст : непосредственный.

3. Engineering critical analyses to BS 7910 - the UK guide on methods for assessing the acceptability of flaws in metallic structures / C.S. Wiesner, S.J. Maddox, W. Xu, G.A. Webster, F.M. Burdekin, R.M. Andrews, J.D. Harrison – Текст : непосредственный // International Journal of Pressure Vessels and Piping. – 2000. – No. 77. – P. 883-893.

4. Li, N. Mechanical fault diagnosis based on redundant second generation wavelet packet transform, neighborhood rough set and support vector machine / N. Li, R. Zhou, Q. Hu, X.Liu – Текст : непосредственный // Mechanical Systems and Signal Processing. – 2012. – No. 28. – P. 608-621.

5. Dolby, R.E. Welds, Their Quality and Inspection Ability for High Integrity Structures and Components / R.E. Dolby, I.J. Munns, C.R.A. Schneider, R.H. Leggatt. – CRC-Press; 2000. ISBN: 9780367814021 – Текст : непосредственный.

6. Liu, Z. State-of-the-Art Review of Technologies for Pipe Structural Health Monitoring, / Z. Liu, Y. Kleiner – Текст : непосредственный // IEEE Sensors Journal. – 2012. – V. 12. – No. 6. – P. 1987-1992.

7. Haghghat, M. Discriminant Correlation Analysis: Real-Time Feature Level Fusion for Multimodal Biometric Recognition / M. Haghghat, M. Abdel-Mottaleb, W.

Alhalabi – Текст : непосредственный // IEEE Transactions on Information Forensics and Security. – 2016. – Т. 11. – P. 1984-1996.

8. Francois, N. A new advanced multitechnique data fusion algorithm for NDT / N. Francois – Текст : непосредственный // 15th World Conference on NDT (15 WCNDT). – 2000.

9. Kaftandjian, V. The combined use of the evidence theory and fuzzy logic for improving multimodal nondestructive testing systems / V. Kaftandjian, Y. M. Zhu, O. Dupuis, D. Babot – Текст : непосредственный // IEEE Transactions on Instrumentation and Measurement. – 2005. – V. 54. – No. 5. – P. 1968-1977.

10. Edwards, I. Fusion of NDT data / I. Edwards, X.E. Gros, D.W. Lowden, P. Strachan – Текст : непосредственный // British Journal of Non Destructive Testing. – 1993. – V. 35. – No. 12. – P. 710-713.

11. СТО 9701105632-003-2021. Инструкция по визуальному и измерительному контролю: стандарт организации ООО «Сварка и Контроль» : издание официальное : утвержден и введен в действие ООО «Сварка и Контроль» 25.11.21 – Москва, 2021. – С. 77. – Текст : непосредственный.

12. Davis, E.R. Computer Vision: Principles, Algorithms, Applications, Learning / E.R. Davis. – Academic Press; 2018 – 858p. ISBN: 978-0-12-809284-2. – Текст : непосредственный.

13. Chen, S.B. Intelligentized Methodology for Arc Welding Dynamical Processes / S.B. Chen, J. Wu. – Springer; 2009. – Vol. 29. – 276 p. ISBN: 978-3-540-85641-2. – Текст : непосредственный.

14. Гладков, Э.А. Автоматизация сварочных процессов / Э.А. Гладков, В.Н. Бродягин, Р.А. Перковский. – Москва: Издательство МГТУ им. Н.Э. Баумана; 2014. – 421, [3] с.: ил. ISBN: 978-5-7038-3861-7. – Текст : непосредственный.

15. Диагностический комплекс для оценки технического состояния изделий ответственного назначения / Н.П. Алешин Н.П., М.В. Григорьев, Д.М. Козлов, Н.В. Крысько, А.Г. Кусый – Текст: непосредственный // Сварка и диагностика. – 2018 – № 6. – С. 49-51.

16. Модуль автоматизированного визуального контроля (авик). [Электронный ресурс] URL: <https://echoplus.ru/products/sistemy-auzk/modul-avtomatizirovannogo-vizualnogo-kontrolya/> (дата обращения: 17.07.2024). – Режим доступа: свободный.

17. Визио. [Электронный ресурс] URL: <https://digital-xray.ru/product/vizio-mt/#buy> (дата обращения: 17.07.2024). – Режим доступа: свободный.

18. СТО Газпром 2-2.4-917-2014. Инструкция по радиографическому контролю качества сварных соединений при строительстве и ремонте промышленных и магистральных трубопроводов: стандарт организации ПАО «Газпром» : издание официальное : утвержден и введен в действие распоряжением ПАО «Газпром» от 01.01.2014., Санкт-Петербург, 2014. – С. 120. – Текст : непосредственный.

19. Fujifilm. Основы промышленной рентгеновской съемки. [Электронный ресурс] URL: <https://www.ntcexpert.ru/documents/IX-Film-Fundamentals-of-Industrial-Radiography.pdf> (дата обращения: 17.07.2024). – Режим доступа: свободный.

20. Hellier, C.J. Handbook of Nondestructive Evaluation / C.J. Hellier. – McGraw-Hill Books; 2013. – 594 p. ISBN: 9781260441437. – Текст : непосредственный.

21. Транскан. [Электронный ресурс] URL: <https://digital-xray.ru/product/transkan/> (дата обращения: 17.07.2024). – Режим доступа: свободный.

22. RTD Rayscan. [Электронный ресурс] URL: <https://www.applus.com/dam/Energy-and-Industry/nl/services/pdf/-N135.5--21.5-Rayscan-Real-Time-Digital-Radiography-RTR.pdf.pdf> (дата обращения: 17.07.2024). – Режим доступа: свободный.

23. Алешин, Н.П. Физические методы неразрушающего контроля сварных соединений: учебное пособие. 2е изд., перераб. и доп. / Н.П. Алешин — М.:

Инновационное машиностроение, 2019. — 576 с.: ил. ISBN: 978-5-907104-14-3.
– Текст : непосредственный.

24. CRC-Evans welding machine. [Электронный ресурс] URL: https://www.crcevans.com/product_category/welding/ (дата обращения: 23.07.2024). – Режим доступа: свободный.

25. Saturnax welding machine. [Электронный ресурс] URL: <https://serimax.com/ru/weldingmachines-robotics/saturnax-01//> (дата обращения: 23.07.2024). – Режим доступа: свободный.

26. Ginzel, E. Phased Array Ultrasonic Technology / E. Ginzel – Eclipse Scientific Products Inc.; 2013. – 348 p. ISBN: 978-0-9917095-0-2 – Текст : непосредственный.

27. Ginzel, E. Automated Ultrasonic Testing of Pipeline Girth Welds. Fundamentals & Applications for Non-Destructive Testing / E. Ginzel – Eclipse Scientific Products Inc.; 2013. – 304 p. ISBN: 978-0-9917095-3-3 – Текст : непосредственный.

28. Щербинский, В.Г. Технология ультразвукового контроля сварных соединений / В.Г. Щербинский – Санкт-Петербург: СВЕН; 2014. – 495с. ISBN: 978-5-91161-007-4 – Текст : непосредственный.

29. Ginzel, E. Ultrasonic Time of Flight Diffraction Fundamentals & Applications for Non-Destructive Testing. / E. Ginzel – Eclipse Scientific Products Inc.; 2013. – 248 p. ISBN: 978-0-9917095-4-0 – Текст : непосредственный.

30. Система АУЗК Авгур ТФ [Электронный ресурс] URL: <https://echoplus.ru/products/sistemy-auzk/avgur-tf/> (дата обращения: 24.07.2024). – Режим доступа: свободный.

31. Rotoscan [Электронный ресурс] URL: <https://www.applus.com/global/en/what-we-do/sub-service-sheet/rotoSCAN-automated-ut-weld-inspection> (дата обращения: 24.07.2024). – Режим доступа: свободный.

32. Gros, X.E. Applications of NDT Data Fusion / X.E. Gros. – Springer; 2001. – 277 p. ISBN: 978-0-7923-7412-1. – Текст : непосредственный.
33. Gros, X.E. NDT Data Fusion / X.E. Gros. – Arnold; 1997. – 233 p. ISBN: 0470237244, 9780470237243. – Текст : непосредственный.
34. Gros, X. E. NDT data fusion at pixel level / X.E. Gros, J. Bousigue, K. Takahashi – Текст : непосредственный // NDT & E International. – 1999. – V. 32. – P. 283-292.
35. Horn, D. NDE reliability gains from combining eddy-current and ultrasonic testing / D. Horn, W.R. Mayo – Текст : непосредственный // NDT & E International. – 2000. – V. 33. – P. 351-362.
36. Dromigny, A. Improving the dynamic range of real-time X-ray imaging systems via Bayesian fusion / A. Dromigny, Y.M. Zhu – Текст : непосредственный // Journal of Nondestructive Evaluation. – 1997. – V. 16. – P. 147-160.
37. Zadeh, L.A. Fuzzy sets / L.A. Zadeh – Текст : непосредственный // Information and Control. – 1965. V. 8 – P. 338-353.
38. Dempster, A.P. A generalization of Bayesian inference /A.P. Dempster – Текст : непосредственный // Journal of the Royal Statistical Society. – 1968. – V. 30. – P. 205-247.
39. Challa, S. Bayesian and Dempster-Shafer fusion / S. Challa, D. Koks – Текст : непосредственный // Sadhana. – 2004. – Vol. – 29. – P. 145–176.
40. Barnea, D.I. A class of algorithm for fast digital image registration / D.I. Barnea, H.F. Silverman – Текст : непосредственный // Institute of Electrical and Electronics Engineers Transactions on Computers. – 1972. – V. 21. – P. 179-86.
41. Goodenough, D. G. Data fusion and object recognition / D.G. Goodenough, M.A. Robson – Текст : непосредственный // Proceedings of Vision Interface Conference. – 1988. – P. 42.
42. Magee, M. J. Using multisensory images to derive the structure of 3-D objects - A review / M. J. Magee, J. K. Aggarwal – Текст : непосредственный // Computer Vision, Graphics and Image Processing. – 1985. – V. 32. – P. 145-57.

43. Multisensor data fusion of laser radar and forward looking infrared (FLIR) for target segmentation and enhancement / C. W. Tong, S. Rogers, J. Mills, M. Kabrisky – Текст : непосредственный // Infrared Sensors and Sensor Fusion. – 1987. – P. 10-19.

44. Richardson, J. M. Fusion of multisensor data / J.M. Richardson, K.A. Marsh – Текст : непосредственный // International Journal of Robotics Research. – 1988. – Vo. 7. – P. 78-96.

45. Flynn, A.M. Combining sonar and infrared sensors for mobile robot navigation / A.M. Flynn – Текст : непосредственный // International Journal of Robotics Research. – 1988. – V. 7. – P. 5-14.

46. Pau, L.F. Sensor data fusion / L.F. Paul – Текст : непосредственный // Journal of Intelligent and Robotic Systems. – 1988. – V. 1. – P. 103-116.

47. Crowley, J.L. Principles and techniques for sensor data fusion / J.L. Crowley, Y. Demazeau – Текст : непосредственный // Signal Processing. – 1993. – V. 32. – P. 5-27.

48. Pixel level data fusion: from algorithm to chip / B.P. Mathur, H.T. Wang, S.C. Liu, C. Koch, J. Luo – Текст : непосредственный // Visual Information Processing: from Neurons to Chips. – 1991. – P. 153-160.

49. Tsao, T.R. Fusion of multiple sensor imagery based on target motion characteristics / T.R. Tsao, J.M. Libert – Текст : непосредственный // Data Structures and Target Classification. – 1991. – P. 37-47.

50. Multisensor fusion classification with a multilayer Perceptron / D.W. Ruck, S.K. Rogers, M. Kabrisky, J.P. Mills – Текст : непосредственный // Institute of Electrical and Electronics Engineers Proceedings of International Joint Conference on Neural Networks. – 1990. – P. 863-868.

51. Rajapakse, J. Multisensor data fusion within hierarchical neural networks / J. Rajapakse, R. Acharya – Текст : непосредственный // Institute of Electrical and Electronics Engineers Proceedings of International Joint Conference on Neural Networks. – 1990. – P. 17-22.

52. Multisensor knowledge systems: Interpreting 3-D structure / T. Henderson, E. Weitz, C. Hansen, A. Mitiche – Текст : непосредственный // International Journal of Robotics Research. – 1988. – V. 7. – P. 114-137.

53. Duane, G. Pixel-level sensor fusion for improved object recognition / G. Duane – Текст : непосредственный // Sensor Fusion. – 1988. – P. 180-185.

54. Johnson, D.G. Multisensor fusion for classification and change detection in remote sensed imagery / D.G. Johnson, N. Hindley, J. Fullwood – Текст : непосредственный // IEE Colloquium on Principles and Applications of Data Fusion. – 1991. – P. 1-4.

55. Ehlers, M. Multisensor image fusion techniques in remote sensing / M. Ehlers – Текст : непосредственный // Journal of Photogrammetry and Remote Sensing. – 1991. – V. 46. – P. 19-30.

56. Abidi, M.A. Sensor fusion: a new approach and its application / M.A. Abidi – Текст : непосредственный // Sensor Fusion II: Human and Machine Strategies. – 1989. – P. 235-46.

57. Huntsberger, T.L. A framework for multi-sensor fusion in the presence of uncertainty / T.L. Huntsberger, S.N. Jayaramamurthy – Текст : непосредственный // Proceedings of the 1987 Workshop on Spatial Reasoning and Multisensor Fusion. – 1987. – P. 345-350.

58. Seetharaman, G. Image segmentation by multisensor data fusion / G. Seetharaman, C.H. Chu – Текст : непосредственный // Institute of Electrical and Electronics Engineers Proceedings of 22nd South eastern Symposium on System Theory. – 1990. – P. 583-587.

59. Duncan, J.S. Low level information fusion: multisensor scene segmentation using learning automata / J.S. Duncan, G.R. Gindi, K.S. Narendra – Текст : непосредственный // Proceedings of the 1987 Workshop on Spatial Reasoning and Multisensor Fusion. – 1987. – P. 323-333.

60. Wright, W.A. A Markov random field approach to data fusion and color manipulation / W. A. Wright – Текст : непосредственный // Image and Vision Computing. – 1989. – V. 7. – P. 144-150.

61. Kjell, B.P. Data fusion and image segmentation using hierarchical simulated annealing on the connection machine / B.P. Kjell, P.Y. Wang – Текст : непосредственный // Intelligent Robots and Computer Vision. – 1988. – P. 330-337.

62. Lee, R.H. Segmentation of multisensor images / R.H. Lee., R. Leahy – Текст : непосредственный // Proceedings of the 6th Multi-dimensional Signal Processing Workshop. – 1989. – P. 23-36.

63. Llinas, J. Data fusion technology forecast for C3MIS / J. Llinas, D. L. Hall, E. Waltz – Текст : непосредственный // Institute of Electrical and Electronics Engineers Proceedings of 3rd International Conference on Command, Control, Communications and Management Information Systems. – 1989. – P. 148-158.

64. White, F.E. Data fusion: the process of C3I / F.E. White, J. Llinas – Текст : непосредственный // Defence Electronics. – 1990. – P. 77-83.

65. Multisensor information fusion for target detection and classification / M.C. Roggemann, J.P. Mills, S.K. Rogers, M. Kabrisky Llinas – Текст : непосредственный // Sensor Fusion. – 1988. – P. 8-13.

66. Dawn, F.E. Fundamental limits in multisensor data fusion / F.E. Dawn – Текст : непосредственный // IEEE International Conference on Systems Engineering. – 1990. – P. 316-319.

67. Durrant-Whyte, H.F. A modular decentralized architecture for multi-sensor data fusion / H.F. Durrant-Whyte – Текст : непосредственный // IEE Colloquium on Intelligent Measuring Systems for Control Applications. – 1995. – P. 1-2.

68. Multisensor target detection and classification / D.W. Ruck, S.K. Rogers, J.P. Mills, M. Kabrisky // Sensor Fusion. – 1988. – P. 14-21.

69. Parra-Loera, R. Adaptive selection of sensors based on individual performances in a multisensor environment / R. Parra-Loera, W.E. Thompson, A.P.

Salvi – Текст : непосредственный // Data Structures and Target Classification. – 1991. – P. 30-36.

70. Blackman, S.S. Theoretical approaches to data association and fusion / Blackman S. S. – Текст : непосредственный // Sensor Fusion. – 1988. – P. 50-55.

71. Luo, R.C. Multisensor integration and fusion: issues and approaches / R.C. Luo, M.G. Kay // Sensor Fusion. – 1988. – P. 42-51.

72. Thomopoulos, S.C.A. Distributed detection with consulting sensors and communication cost / S.C.A. Thomopoulos, N.N. Okello – Текст : непосредственный // Sensor Fusion. – 1988. – P. 31-40.

73. Thomopoulos, S.C.A. Theories in distributed decision fusion / Thomopoulos S.C.A. – Текст : непосредственный // IF AC Distributed Intelligence Systems. – 1991. – P. 195-200.

74. Dillard, R.A. Tactical inferencing with the Dempster-Shafer theory of evidence / R.A. Dillard – Текст : непосредственный // Proceedings of the Institute of Electrical and Electronics Engineers 17th Asilomar Conference on Circuits, Systems and Computers. – 1983. – P. 312-316.

75. Whittington, G. The application of a neural network model to sensor data fusion / G. Whittington, T. Spraclen – Текст : непосредственный // Applications of Artificial Neural Networks. – 1990. – P. 276-283.

76. Easthope, P.F. A computationally tractable approach to real time multi-sensor data fusion / P.F. Easthope, E.J.G. Goodchild, S.L. Rhodes – Текст : непосредственный // Signal and Data Processing of Small Targets. – 1989. – P. 298-308.

77. Deb, S. A multisensor multitarget data association algorithm for heterogeneous sensors / S. Deb, K.R. Pattipati, Y. Bar-Shalom – Текст : непосредственный // Proceedings of the 1992 American Control Conference. – 1992. – P. 1779-1783.

78. Thompson, W.E. A Pseudo k-means approach to the multisensor multitarget tracking problem / W.E. Thompson, R. Parra-Loera, C. W. O. Ta – Текст : непосредственный // Data Structures and Target Classification. – 1991. – P. 48-58.

79. Shapiro, J. Data fusion in 3D through surface tracking / J. Shapiro, P. Mowforth – Текст : непосредственный // Proceedings of the 3rd International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems. – 1990. – P. 163-168.

80. Harris, C.J. Distributed estimation, inferencing and multi-sensor data fusion for real time supervisory control / C.J. Harris – Текст : непосредственный // Proceedings of the Artificial Intelligence in Real-time Control IF AC Workshop. – 1989. – P. 19-24.

81. Durrant-Whyte, H.F. Sensor models and multisensor integration / H.F. Durrant-Whyte – Текст : непосредственный // The International Journal of Robotics Research. – 1988. – V. 7. – P. 97-113.

82. Durrant-Whyte, H.F. Consistent integration and propagation of disparate sensor observations / H.F. Durrant-Whyte – Текст : непосредственный // International Journal of Robotics Research. – 1987. – V. 6. – P. 3-24.

83. Ferrari, C. Coupling fuzzy logic techniques with evidential reasoning for sensor data interpretation / C. Ferrari – Текст : непосредственный // Proceedings of Conference on Intelligent Autonomous Systems 2. – 1989. – P. 965-971.

84. Xu, H. Efficient fusion technique for disparate sensory data / H. Xu – Текст : непосредственный // Institute of Electrical and Electronics Engineers Proceedings of IECOW91. – 1991. – P. 2535-2540.

85. Chenm, S. Adaptive control of multisensor systems / S. Chenm – Текст : непосредственный // Sensor Fusion. – 1988. – P. 98-102.

86. Franklin, S.E. An example of satellite multisensor data fusion / S.E. Franklin, C.F. Blodgett – Текст : непосредственный // Computers & Geosciences. – 1993. – V. 19. – P. 577-583.

87. Neural network approach to sensory fusion / J.C. Pearson, J.J. Gelfand, W.E. Sullivan, R.M. Peterson, C.D. Spence – Текст : непосредственный // Sensor Fusion. – 1988. – P. 103-108.

88. Thomas, J. MITAS: multisensory imaging technology for airborne surveillance / J. Thomas – Текст : непосредственный // Data Structures and Target Classification. – 1991. – P. 65-74.

89. Eggers, M. Neural network data fusion concepts and application / M. Eggers, T. Khuon – Текст : непосредственный // Institute of Electrical and Electronics Engineers Proceedings of International Joint Conference on Neural Networks. – 1990. – P. 7-16.

90. Windsor, C.G. The classification of weld defects from ultrasonic images: a neural network approach / C.G. Windsor, F. Anselme, L. Capineri, J.P. Mason – Текст : непосредственный // British Journal of Non-Destructive Testing. – 1993. – V. 35. – P. 15-22.

91. Gerhart, G. Thermal Image Modeling / G. Gerhart, G. Martin, T. Gonda – Текст : непосредственный // Infrared Sensors and Sensor Fusion. – 1987. – P. 3-9.

92. NDT Data Fusion / X.E. Gros, P. Strachan, D. Lowden, I. Edwards – Текст : непосредственный // 6th European Conference on Non-Destructive Testing – 1994. – V. 1. – P. 355-359.

93. Experimenting with pixel-level NDT data fusion techniques / X.E. Gros, Z. Liu, K. Tsukada, K. Hanasaki – Текст : непосредственный // IEEE Transactions on Instrumentation and Measurement. – 2000. – V. 49. – P. 1083-1090.

94. A texture-based video processing methodology using Bayesian data fusion for autonomous crack detection on metallic surfaces / F.C. Chen, M. Jahanshahi, R.T. Wu, C. Joffe – Текст : непосредственный // Computer-Aided Civil and Infrastructure Engineering. – 2017. – V. 32. – P. 271-287.

95. Application of multi-sensor data fusion in defects evaluation based on Dempster-Shafer theory / L. Guohou, H. Pingjie, C. Peihua, H. Dibo, Z. Guangxin, Z.

Zekui – Текст : непосредственный // IEEE International Instrumentation and Measurement Technology Conference. – 2011. – P. 1-5.

96. D'Angelo, G. Shape-based defect classification for nondestructive testing / G. D'Angelo, S. Rampone – Текст : непосредственный // IEEE Metrology for Aerospace. – 2015. – P. 406-410.

97. Machine learning based automatic defect detection in non-stationary thermal wave imaging / A.V. Lakshmi, G.V. Subbarao, G.V.P. Chandra Sekhar Yadav, G.T. Vesala – Текст : непосредственный // Journal of Engineering and Applied Sciences. – 2020. – V. 15. – P. 172-178.

98. Fahim, A. Data-driven Weld Nugget Width Prediction with Decision Tree Algorithm / A. Fahim, K. Kyoung-Yun – Текст : непосредственный // Procedia Manufacturing. – 2017. – V. 10. – P. 1009-1019.

99. A Random Forest Classifier for Anomaly Detection in Laser-Powder Bed Fusion Using Optical Monitoring / I.A. Khan, H. Birkhofer, D. Kunz, D. Lukas, V. Ploshikhin – Текст : непосредственный // Materials. – 2023. – V. 16. – P. 6470.

100. Random forest-based real-time defect detection of Al alloy in robotic arc welding using optical spectrum / Z. Zhang, Z. Yang, W. Ren, G. Wen – Текст : непосредственный // Journal of Manufacturing Processes. – 2019. – V. 42. – P. 51-59.

101. Random forest-based evaluation technique for internal damage in reinforced concrete featuring multiple nondestructive testing results / P. Chun, I. Ujike, K. Mishima, M. Kusumoto, S. Okazaki – Текст : непосредственный // Construction and Building Materials. – 2020. – V. 253. – P. 1-11.

102. Dia, A.K. Walk-Through Corrosion Assessment of Slurry Pipeline Using Machine Learning / A.K. Dia, A.G. Bosca, N. Ghazzali – Текст : непосредственный // Hindawi International Journal of Corrosion. – 2024. – V. 2024. P. 1-11.

103. Ossai, C.I. A Data-Driven Machine Learning Approach for Corrosion Risk Assessment—A Comparative Study / C.I. Ossai – Текст : непосредственный // Big Data Cognitive Computing. – 2019. – V.3. – P. 2-22.

104. Beard, W. Harnessing neural network / W. Beard, A. Jones – Текст : непосредственный // Electronics World and Wireless World. – 1990. – P. 1047-1052.
105. Charlton, P.C. Investigation into the suitability of a neural network classifier for use in an automated tube inspection system / P.C. Charlton – Текст : непосредственный // British Journal of Non-Destructive Testing. – 1993. – V. 35. – P. 433-437.
106. Chilips M.L. Non-destructive evaluation using neural network / M.L. Chilips, N.F. Steele – Текст : непосредственный // Nuclear Plant Journal. – 1989. – P. 44-50.
107. Udpa, L. Application of neural network to non-destructive evaluation / L. Udpa, S.S. Udpa – Текст : непосредственный // Colorado State University. – 1989. – P. 143-147.
108. Udpa, L. Eddy current defect characterization using neural network / L. Udpa, S.S. Udpa – Текст : непосредственный // Materials Evaluation. – 1990. – V. 48. – P. 342-353.
109. A Data Fusion Method for Non-Destructive Testing by Means of Artificial Neural Networks / R. Cormerais, A. Duclos, G. Wasselynck, G. Berthiau, R Longo – Текст : непосредственный // Sensors. – 2021. – V. 21. – P. 1-12.
110. Chawla, N.V. SMOTE: Synthetic Minority Over-sampling Technique / N.V. Chawla, K.W. Bowyer, L.O. Hall, W.P. Kegelmeyer – Текст : непосредственный // Journal of Artificial Intelligence Research. – 2002. – V. 16. – P. 321-357.
111. Han, H. Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning / H. Han, W.Y. Wang, B.H. Mao – Текст : непосредственный // International Conference on Intelligent Computing. – 2005. – P. 878-887.
112. Cunningham, P. k-Nearest neighbour classifiers / P. Cunningham, S.J. Delany – Текст : непосредственный // ACM Computing Surveys. – 2007. – V. 54. PP. 1-17.

113. Murphy, K.P. Machine learning: A probabilistic perspective / K.P. Murphy – MIT Press Publisher; 2012. ISBN: 978-0262018029 – Текст : непосредственный.
114. V. Maaten. Visualizing Data using t-SNE / V. Maaten, L. Hinton – Текст : непосредственный // Journal of Machine Learning Research. – 2008. – V. 9. – PP. 2579-2605.
115. McInnes, L. UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction / L. McInnes, J. Healy, J. Melville – Текст : непосредственный // Journal of Open Source Software. – 2018. – V. 3. – PP. 861.
116. Zar, J.H. Biostatistical Analysis / J.H. Zar – Pearson College Div.; 1999 – 200 p. ISBN: 978-0130815422 – Текст : непосредственный.
117. И.Н. Ермолов, Ю.В. Ланге Ультразвуковой контроль. – Том 3 справочника в 8 т. «Неразрушающий контроль» – М.: Машиностроение, 2004. – 864 с.
118. Agresti, A. Categorical Data Analysis / A. Agresti – Wiley-Interscience; 2002 – 742 p. ISBN: 9780471249689 – Текст : непосредственный.
119. Barker, T.B. Quality by experimental design / T.B. Barker, A. Milivojevich – CRC Press; 2016. ISBN: 9781032098050 – Текст : непосредственный.
120. Bergstra, J. Random Search for Hyper-Parameter Optimization / J. Bergstra, Y. Bengio – Текст : непосредственный // Journal of Machine Learning Research. – 2012. – V. 13. – P. 281-305.
121. Quinlan, J.R. Induction of decision trees / J.R. Quinlan – Текст : непосредственный // Machine Learning. – 1986. – № 1. – P. 81-106.
122. Breiman, L. Random Forest / L. Breiman – Текст : непосредственный // Machine Learning. – 2001. – No. 45(1). – P. 5-32.
123. Friedman, J.H. Greedy Function Approximation: A Gradient Boosting Machine/ J.H. Friedman – Текст : непосредственный // Annals of Statistics. – 2001. – No. 29(5). – P. 1189-1232.

124. Rosenblatt, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain / F. Rosenblatt – Текст : непосредственный // Psychological Review. – 1958. – No. 65(6). – P. 386-408.
125. Rumelhart, D.E. Learning representations by back-propagating errors / D.E. Rumelhart, G.E. Hinton, R.J. Williams – Текст : непосредственный // Nature. – 1986. – No. 323(6088) – P. 533-536.
126. Grandini, M. Metrics for Multi-Class Classification: an Overview / M. Grandini, E. Bagli, G. Visani – Текст : непосредственный // arXiv:2008.05756v1 – 2001. – P. 1-17.
127. Fawcett, T. An introduction to ROC analysis / T. Fawcett – Текст : непосредственный // Pattern Recognition Letters. – 2006. – 27(8). – P. 861-874.
128. Hand D.J. A simple generalization of the area under the ROC curve for multiple class classification problems / D.J. Hand, R.J. Till – Текст : непосредственный // Machine Learning. – 2001. – V. 45(2). – P. 171-186.
129. Zou H. Regularization and variable selection via the elastic net / H. Zou, T. Hastie – Текст : непосредственный // Journal of the Royal Statistical Society: Series B (Statistical Methodology). – 2005. – V. 67(2). – P. 301-320.
130. Chai, T. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature / T. Chai, R.R. Draxler – Текст : непосредственный // Geoscientific Model Development. – 2014. – No. 7(3). – P. 1247-1250.
131. Taylor, K.E. Summarizing multiple aspects of model performance in a single diagram / K.E. Taylor – Текст : непосредственный // Journal of Geophysical Research: Atmospheres. – 2001. – V. 106(D7). – P. 7183-7192.
132. ГОСТ ISO 17636-2–2017 Неразрушающий контроль сварных соединений. Радиографический контроль. Часть 2. Способы рентгено- и гаммаграфического контроля с применением цифровых детекторов = Non-destructive testing of welds. Radiographic testing. Part 2. X- and gamma-ray control with digital detectors: межгосударственный стандарт : издание официальное :

утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии от 1 марта 2018 г. N 111-ст : введен впервые : дата введения 2018-11-01 / подготовлен Техническим комитетом по стандартизации ТК 357 "Стальные и чугунные трубы и баллоны", Негосударственным образовательным учреждением дополнительного профессионального образования "Научно-учебный центр "Контроль и диагностика" ("НУЦ "Контроль и диагностика") и Открытым акционерным обществом "Российский научно-исследовательский институт трубной промышленности" (ОАО "РосНИТИ") – Москва : Стандартиформ, 2017. – С. 54. - Текст : непосредственный.

133. СТО Газпром 2-2.4-715–2013 Методика оценки работоспособности кольцевых сварных соединений магистральных газопроводов: стандарт организации ПАО «Газпром» : издание официальное : утвержден и введен в действие распоряжением ПАО «Газпром» от 29.12.2012, – Санкт-Петербург, 2013. – С. 391. – Текст : непосредственный.

134. Соснин, Ф.Р. Неразрушающий контроль: Справочник: В 7 т. Под общ. ред. В.В. Клюева. Т.1: В 2 кн.: Кн. 1: Визуальный и измерительный контроль. Кн. 2: Радиационный контроль. /Ф.Р. Соснин – М: Машиностроение, 2003. – 560с.: ил. ISBN 5-217-03186-7 – Текст : непосредственный.

135. Атрощенко, В.В. Практическая проверка преимущества неразрушающего контроля сварных соединений газопроводов с выполнением совместного анализа данных радиографического и ультразвукового методов / В.В. Атрощенко, М.П. Савичев, Р.Е. Артемьев – Текст : непосредственный // Состояние и основные направления развития неразрушающего контроля качества сварных соединений объектов ПАО "ГАЗПРОМ" : Тезисы докладов VIII отраслевого совещания – Москва. – 2021. – С. 15.

136. Артемьев, Р.Е. Разработка методики неразрушающего контроля сварных соединений газопроводов с выполнением совместного анализа данных визуально-измерительного, радиографического и ультразвукового методов / Р. Е.

Артемьев, В.В. Атрощенко, М.П. Савичев – Текст : непосредственный // Инновации в топливно-энергетическом комплексе и машиностроении (ТЭК-2022) : сборник трудов III Международной научно-практической конференции – Кемерово. – 2022. – С. 172-177.

ПРИЛОЖЕНИЕ 1



Общество с ограниченной ответственностью
«Научно-исследовательский институт природных газов и газовых технологий – Газпром ВНИИГАЗ»
(ООО «Газпром ВНИИГАЗ»)

«04» сентября 2024 г.

№ 8/4

УТВЕРЖДАЮ
Генеральный директор
ООО «Газпром ВНИИГАЗ»,
канд. экон. наук


М.Ю. Недзвецкий
«04» _____ 2024 г.


АКТ

О применении результатов диссертационной работы С.В. Скрынникова
«Комплексный контроль кольцевых сварных соединений магистральных
газопроводов»

Результаты диссертационной работы Скрынникова Сергея Владимировича были использованы ООО «Газпром ВНИИГАЗ» при разработке Р Газпром «Сварка и неразрушающий контроль сварных соединений. Методика неразрушающего контроля сварных соединений трубопроводов с выполнением совместного анализа данных визуального и измерительного, радиографического и ультразвукового методов».

Результаты работы будут использованы Департаментом, отвечающим за реализацию единой корпоративной политики ПАО «Газпром» в области сварочного производства, а также дочерними обществами ПАО «Газпром», строительными и диагностическими компаниями при организации и контроле мероприятий по проведению неразрушающего ультразвукового контроля сварных соединений газопроводов, начиная с 2022 года.

Экономический эффект обусловлен совершенствованием нормативного управления при проведении неразрушающего контроля стыковых кольцевых сварных соединений газопроводов, что обуславливается повышением

надежности и безопасности эксплуатации газопроводов за счет совершенствования системы оценки качества сварных соединений труб на основе повышения информативности о состоянии металла и вероятности выявления дефектов при ультразвуковом контроле сварных соединений газопроводов.

**Заместитель Генерального директора
по науке, канд. техн. наук**



Р.Р. Кантюков

**Заместитель начальника Корпоративного
научно-технического
центра сварки и контроля
сварных соединений, канд. техн. наук**



С.П. Севостьянов