

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Оренбургский государственный университет»

Д.П. Бугаев, М.И. Кузьмин, Н.А. Соловьев

КОМПЬЮТЕРНОЕ ЗРЕНИЕ В ЗАДАЧАХ ИДЕНТИФИКАЦИИ И РАСПОЗНАВАНИЯ ПОВЕРХНОСТНЫХ ДЕФЕКТОВ ТОНКОЛИСТОВОГО ПРОКАТА

Монография

Рекомендовано к изданию ученым советом федерального государственного
бюджетного образовательного учреждения высшего образования
«Оренбургский государственный университет»

Оренбург
2019

УДК 004.932.72(681.78)
ББК 32.973.26-018
С 147

Рецензент – доктор технических наук, профессор Пищухин А.М.

Соловьев, Н.А.

С 147 Компьютерное зрение в задачах идентификации и распознавания поверхностных дефектов тонколистового проката [Электронный ресурс]: монография / Д.П. Бугаев, М.И. Кузьмин, Н.А. Соловьев ; Оренбургский гос. ун-т. – Оренбург : ОГУ, 2019 – 128 с.
ISBN 978-5-7410-2342-6

В монографии изложены результаты научных исследований, проведенных коллективом кафедры программного обеспечения вычислительной техники и автоматизированных систем ФГФОУ ВО «Оренбургский государственный университет» за 2010-2017 годы в рамках госбюджетной НИР № 02201001067 «Развитие информационных технологий принятия решений в автоматизированных системах». Теоретический материал дополнен алгоритмами и программами автоматической идентификации и распознавания поверхностных дефектов тонколистового проката, выполненных в рамках диссертационных исследований аспирантов Бугаева Д.П. и Кузьмина М.И.

Монография предназначена для магистрантов и аспирантов образовательных учреждений высшего образования, обучающихся по направлениям магистратуры: 09.04.01 Информатика и вычислительная техника и 09.04.04 Программная инженерия; по группам научных специальностей: 05.13.00 Информатика, вычислительная техника и управление и 05.11.00 Приборостроение, метрология и информационно-измерительные приборы и системы, как методическое обеспечение научно-исследовательских работ.

УДК 004.932.72(681.78)
ББК 32.973.26-018

ISBN 978-5-7410-2342-6

© Соловьев Н.А и др., 2019
© ОГУ, 2019

Содержание

Введение	5
1 Системный анализ проблем контроля качества тонколистового проката	7
1.1 Особенности технологии тонколистового проката цветных металлов	7
1.2 Анализ проблем производства тонколистового проката цветных металлов	9
1.2.1 Обоснование необходимости системы компьютерного зрения	9
1.2.2 Исследование поверхностных дефектов тонколистового проката	12
1.2.3 Формирование пространства признаков поверхностных дефектов тонколистового проката.....	15
1.3 Анализ проблем теории контроля качества продукции тонколистового проката.....	18
1.3.1 Обоснование метода бесконтактного контроля качества продукции листового проката	18
1.3.2 Анализ аналогов средств компьютерного зрения обнаружения поверхностных дефектов.....	23
1.3.3 Выбор метода распознавания поверхностных дефектов тонколистового проката.....	25
1.4 Концепция построения системы компьютерного зрения для задачи контроля качества готовой продукции тонколистового проката.....	34
1.4.1 Методологические основы исследований	34
1.4.2 Концепция совершенствования системы компьютерного зрения	36
2 Цифровая обработка изображений в задачах идентификации и распознавания поверхностных дефектов	39
2.1 Систематизация моделей для цифровой обработки изображений.....	39
2.2 Моделирование изображений для выделения структурных элементов	42
2.3 Развитие вейвлет-модели изображения для задачи идентификации поверхностных дефектов	48
2.4 Моделирование изображения поверхностного дефекта для задачи распознавания	53
2.4.1 Исследование моделей представления распознаваемого объекта	53
2.4.2 Модель изображения в виде расширенного вектора признаков	54
3 Методический аппарат идентификации и распознавания поверхностных дефектов тонколистового проката.....	57
3.1 Методика формирования изображения.....	58
3.2 Методика идентификации поверхностных дефектов	61
3.2.1 Исследование алгоритмов фильтрации изображений	62
3.2.2 Методика фильтрации и бинаризации вейвлет-коэффициентов.....	65
3.2.3 Методика ускорения работы медианного фильтра.....	68
3.2.4 Методика выделения областей поверхностных дефектов	70
3.3 Методика распознавания поверхностных дефектов.....	72
3.3.1 Методика использования метода окрестностей в задаче распознавания поверхностных дефектов.....	73

3.3.2 Особенности индексации подкубов и окрестностей	74
3.4 Алгоритмизация процессов обучения и распознавания анализатора класса поверхностных дефектов	77
4 Разработка прототипа системы компьютерного зрения распознавания поверхностных дефектов листового проката	83
4.1 Разработка архитектуры высокопроизводительной системы распознавания поверхностных дефектов	83
4.2 Разработка модульной структуры системы компьютерного зрения	86
4.3 Разработка базы данных	89
4.4 Разработка интерфейса клиентской части	91
Выводы по разделу	95
5 Экспериментальные исследования системы компьютерного зрения	96
5.1 Методика оценки эффективности системы компьютерного зрения	96
5.2 Технология проведения эксперимента	98
5.3 Методика оценки погрешности метрик распознавания	100
5.4 Результаты экспериментальной оценки эффективности системы компьютерного зрения	102
5.5 Направления дальнейших исследований	108
Выводы по разделу	109
Заключение	111
Список использованных источников	114
Приложение А (<i>обязательное</i>) Свидетельство о государственной регистрации программы для ЭВМ «Defectoscope_wavelets»	126
Приложение Б (<i>обязательное</i>) Свидетельство о государственной регистрации программы для ЭВМ «Программа идентификации поверхностных дефектов по изображениям цифрового видеопотока холоднокатанного листового проката в реальном масштабе времени «Defekt Detektor for Cold-Rolling Mill»»	127
Приложение В (<i>обязательное</i>) Свидетельство о государственной регистрации программы для ЭВМ «Программа распознавания поверхностных дефектов»	128

Введение

Продукция цветного металлопроката используется на предприятиях пищевой, авиационной и автомобильной промышленности, при этом повышенный интерес вызывает продукция холодного тонколистового проката. В связи с ростом количества дефектов, связанным с переходом к тонколистовому прокату, становится актуальной задача контроля качества поверхности продукции. Для решения этой задачи используются оптико-электронные информационно-измерительные системы (ОЭИИС) обнаружения поверхностных дефектов, являющиеся системам компьютерного зрения (СКЗ), по данным которой корректируются входные параметры систем автоматического регулирования прокатных станов для последующего устранения дефектов в процессе производства.

Исследованиям ОЭИИС обеспечения качества холодного проката металлов посвящены работы известных российских ученых: Ермаков А.А., Логунова О.С., Орлов А.А., Пчелинцев Д.О., Трофимов В.Б., Шевченко Н.А., а также зарубежных исследователей G. Wu, R. Medina, J. Li. Таким образом, в настоящее время сложилась система моделей, методов и средств оценки качества продукции холодного проката цветных металлов, разработаны общие принципы их использования, позволяющие решать задачу обнаружения поверхностных дефектов листового проката. Вместе с тем установлено, что изменения входных параметров технологического процесса проката не всегда приводит к устранению поверхностных дефектов различных типов. Это определяет актуальность проведения исследований в области совершенствования СКЗ на основе идентификации и распознавания поверхностных дефектов тонколистового проката цветных металлов в процессе производства.

Объект исследования – СКЗ контроля качества продукции холодной обработки цветных металлов давлением.

Предмет исследования – методы, модели и средства идентификации и распознавания поверхностных дефектов по изображениям металлопроката.

Цель исследований – разработка системы компьютерного зрения для контроля качества продукции холодной обработки цветных металлов давлением на основе идентификации и распознавания поверхностных дефектов в процессе производства.

Для достижения цели необходимо решить ряд задач научного характера:

1. Провести системный анализ проблем обеспечения качества готовой продукции холодного тонколистового проката цветных металлов.

2. Разработать модель описания изображения поверхности листового металлопроката для решения задач идентификации и распознавания поверхностных дефектов в процессе производства.

3. Разработать методику и алгоритм принятия решений по идентификации и распознаванию поверхностных дефектов листового проката с достоверностью, не хуже зарубежных аналогов.

4. Разработать прототип системы компьютерного зрения для контроля качества готовой продукции холодного тонколистового проката цветных металлов и оценить его эффективность.

1 Системный анализ проблем контроля качества тонколистового проката

В настоящей монографии объектом исследований является контроль качества тонколистового проката цветных металлов. Системный анализ объекта исследований предполагает выявление особенностей производства готовой продукции станов холодной обработки цветных металлов давлением в современных условиях, выделение основных классов дефектов листового проката и их признаков, исследование состояния существующей системы обнаружения дефектов, проведение информационного поиска и формирование концепции совершенствования системы контроля качества продукции холодной обработки цветных металлов давлением.

1.1 Особенности технологии тонколистового проката цветных металлов

Для анализа особенностей технологии и проблем качества готовой продукции цветного металлопроката выбран стан «КВАРТО 400 ŠKODA», который позволяет производить ленты цветных металлов толщиной от 0,4 до 1,0 мм особо твердого, полутвердого и мягкого состояния [18].

В качестве исходного материала для холодной прокатки служат полосы толщиной от 3 до 6 мм. Относительное обжатие за пропуск обычно находится в пределах 10-45%. На реверсивных и непрерывных станах с моталками ведется прокатка с натяжением. В качестве технологической смазки используют маловязкие минеральные масла или эмульсии концентрацией от 1 до 5% [4, 96, 99]. Скорость прокатки на непрерывных станах зависит от числа клетей, толщины заготовок и составляет от 1 м/с в станах с одной клетью, до 17 м/с. в станах с несколькими клетями. На рисунке 1.1 изображена кинематическая схема реверсивного двухклетевого прокатного стана «КВАРТО 400 ŠKODA».

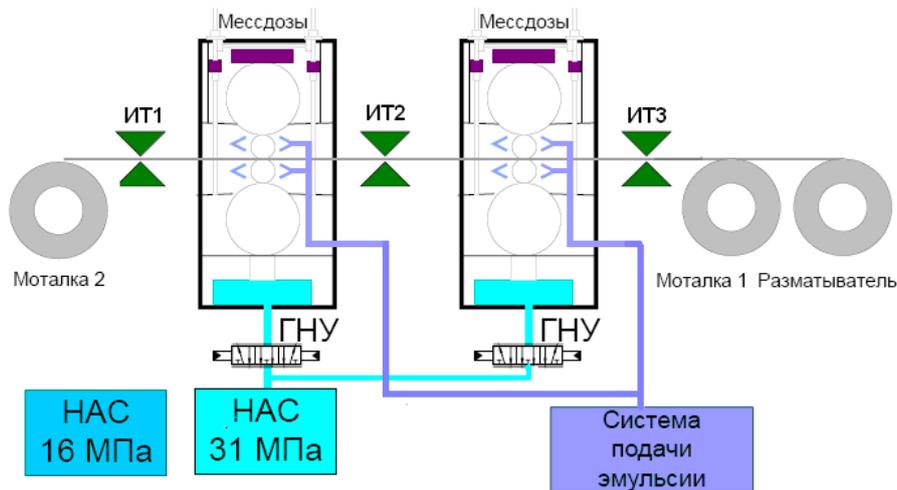


Рисунок 1.1 – Кинематическая схема двухклетевого реверсивного прокатного стана «КВАРТО 400 ŠKODA»

Производительность станов холодной прокатки зависит от массы рулонов, скорости прокатки, количества сварных швов и сортамента прокатываемых полос в них, длительности простоев станов и других факторов, которая обеспечивается автоматизированной системой управления технологическим процессом (АСУТП), схема которой представлена на рисунке 1.2 [11,109,113].

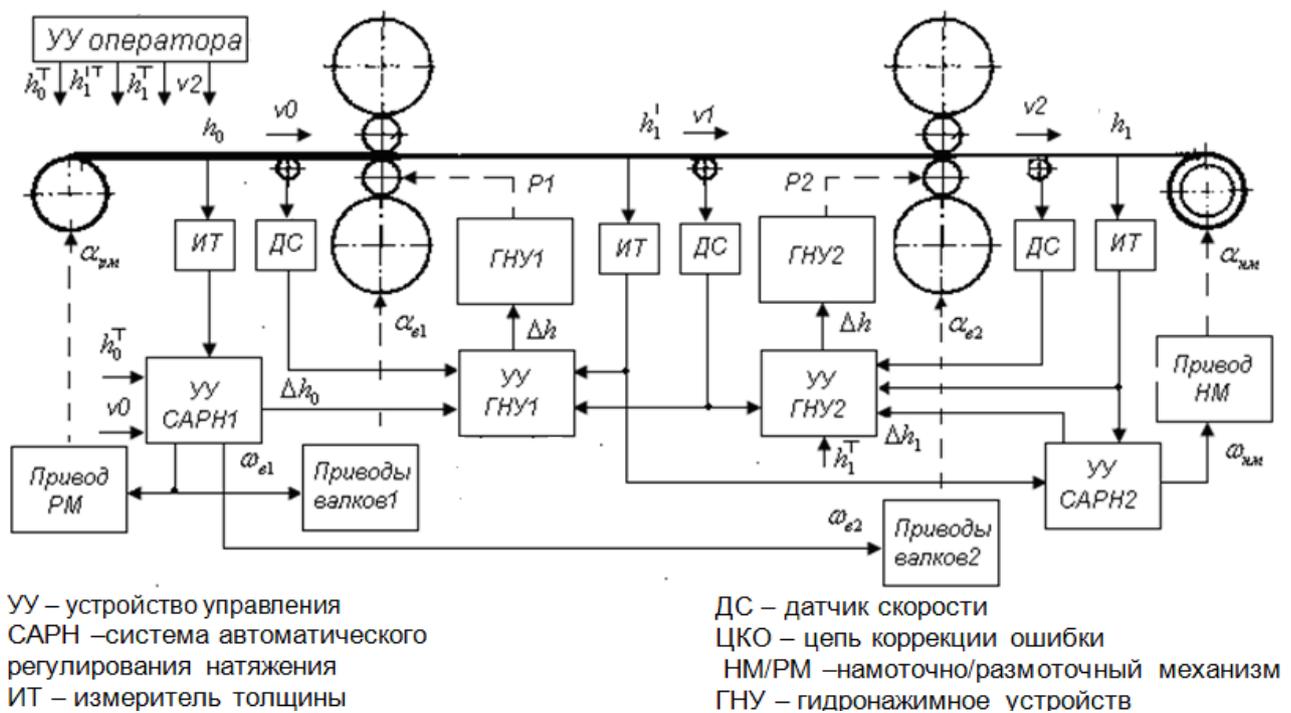


Рисунок 1.2 – АСУТП двухклетевого стана холодного проката «КВАРТО 400 ŠKODA»

Одной из подсистем АСУТП является система автоматического регулирования толщины (САРТ). САРТ служит для решения задачи обеспечения требуемой толщины прокатываемой полосы, которая оценивается механическим индикатором толщины (ИТ) [11,37,42,106].

Характерной особенностью современного производства металлопроката становится повышение требований к толщине проката, так для проката цветных металлов нормой становится толщина листа 0,1-0,12 мм при проектной толщине для существующих станов 0,4 мм.

1.2 Анализ проблем производства тонколистового проката цветных металлов

1.2.1 Обоснование необходимости системы компьютерного зрения

Результатом перехода к тонколистовому прокату цветных металлов становится скачкообразный рост числа поверхностных дефектов, большая часть которых не выявляется в процессе производства существующими средствами, что приводит к возврату бракованной продукции от заказчика на стадию плавки (рисунок 1.3) [18].



Рисунок 1.3 – Динамика роста числа поверхностных дефектов

Увеличение количества дефектов и, как следствие, рекламаций, доказывает необходимость автоматизации обнаружения поверхностных дефектов листового проката с целью их последующего устранения при реверсивных прогонах [45, 72, 85].

В ОАО «Уральский медный прокат» (г. Гай, Оренбургской области) для обеспечения качества выпускаемой продукции используется оптоэлектронная информационно-измерительная система (ОЭИИС) «Defectoscope_wavelet» [65].

АСУТП с ОЭИИС двухклетевого стана холодного проката «КВАРТО 400 ŠKODA» представлена на рисунке 1.4.

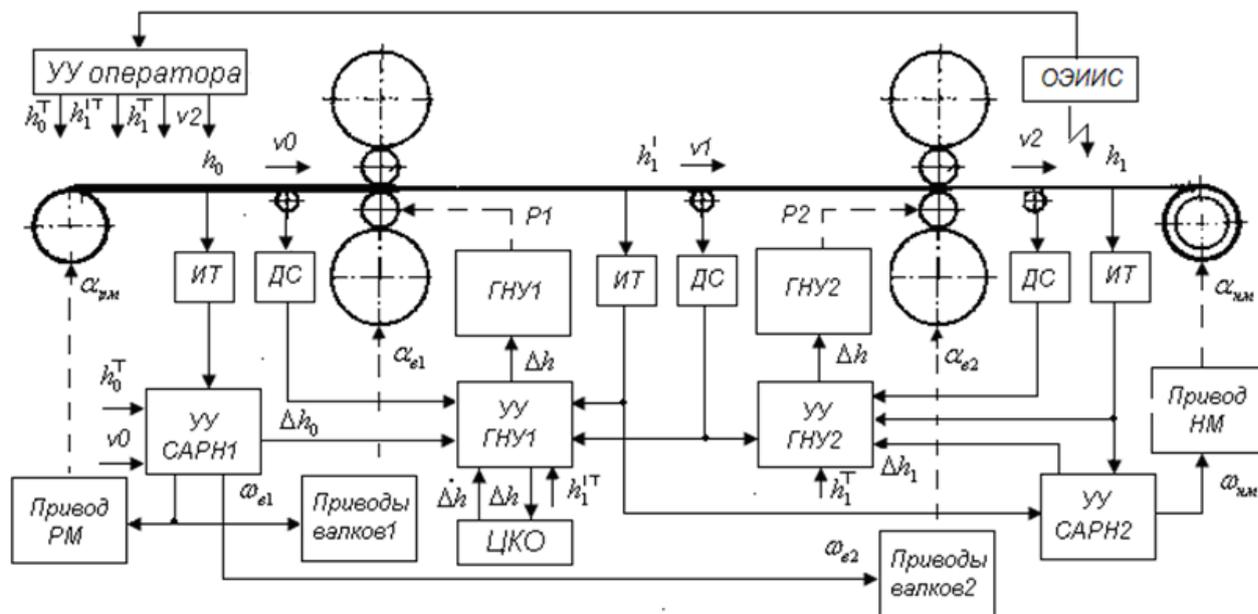


Рисунок 1.4 – АСУТП с ОЭИИС

ОЭИИС обнаружения поверхностных дефектов листового проката цветных металлов на основе «Defectoscope wavelet» является системой компьютерного зрения (СКЗ), архитектура которой представлена на рисунке 1.5 [19, 65].

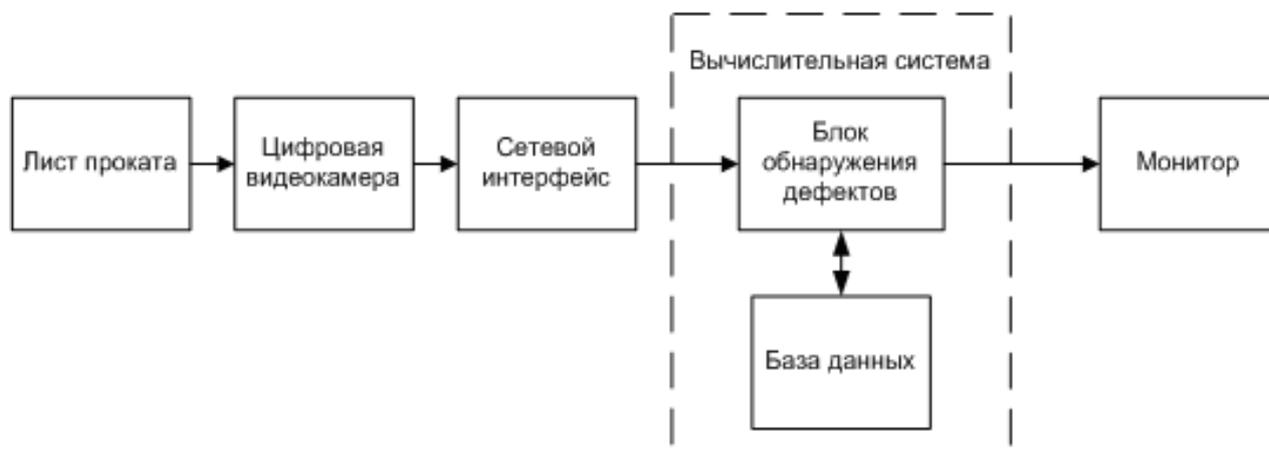


Рисунок 1.5 – Архитектура СКЗ обнаружения поверхностных дефектов

Оператор стана при увеличении числа поверхностных дефектов, регистрируемых СКЗ (рис 1.7), изменяет входные технологические параметры проката (рис.1.5), такие как скорость проката после второй клетки v_2 , требуемую толщину полосы на выходе клеток h_1^{IT} , h_1^T , что позволяет на последующих технологических операциях реверсного прогона устранить часть дефектов.

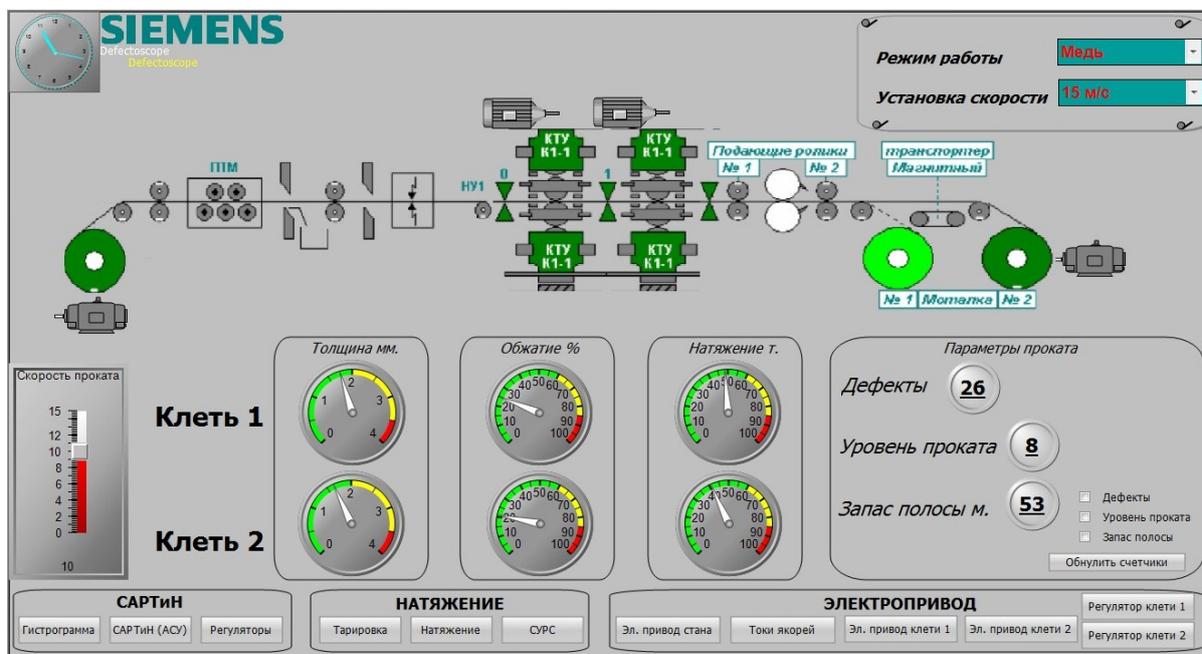


Рисунок 1.6 – Интерфейс «Defectoscope_wavelets»

Однако, такая СКЗ обеспечивает только обнаружение дефекта без определения его класса, что не всегда приводит к правильному изменению оператором входных параметров проката при коррекции технологического процесса [19,52].

Для устранения указанного недостатка необходимо развитие существующей СКЗ контроля качества продукции холодной обработки цветных металлов давлением на основе распознавания класса поверхностных дефектов.

Внедрение новой СКЗ позволит:

- повысить качество готовой продукции тонколистового проката за счет оперативной корректировки технологического процесса при реверсных прогонах для устранения поверхностных дефектов;

– сократить затраты на модернизацию производства на основе импортозамещения.

Таким образом, выявлены недостатки существующей системы обнаружения поверхностных дефектов, обоснована необходимость разработки и внедрения системы компьютерного зрения для идентификации и распознавания поверхностных дефектов.

1.2.2 Исследование поверхностных дефектов тонколистового проката

Установлено [19, 52], что наиболее распространенными классами поверхностных дефектов тонколистового проката являются «мятость», «отверстие», «плена» и «царапина» (рисунок 1.8).

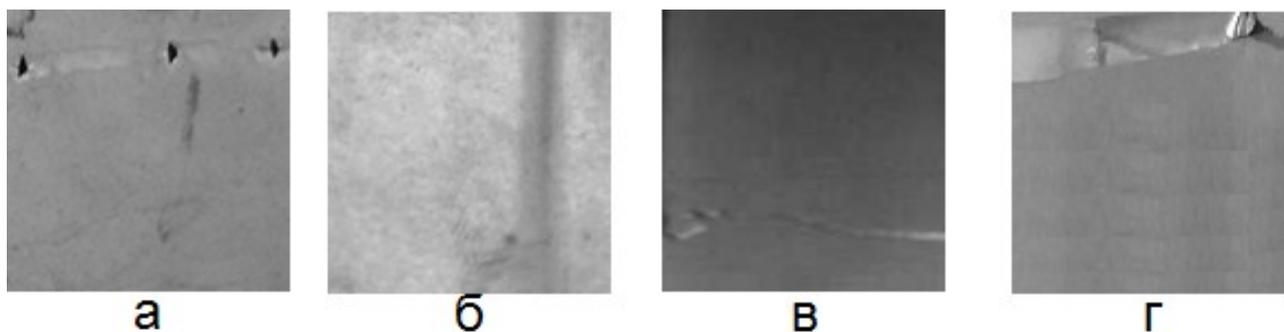


Рисунок 1.7 – Наиболее распространенные поверхностные дефекты: а – «отверстие»; б – «мятость»; в – «царапина»; г – «плена»

Согласно ГОСТ 21014-88 [33]:

– Отверстие – дефект поверхности в виде сквозных несплошностей листа и ленты, образующихся при деформации полосы с вкатанными инородными телами или неравномерной толщины. Причиной неравномерной толщины полосы может быть наличие рыхлости, поперечной разнотолщинности или зачистка дефектов на глубину, превышающую допуск.

– Мятость – дефект поверхности в виде углублений различной формы, расположенных произвольно, которые образуются вследствие повреждения и

ударов поверхности при складировании, правке, транспортировке и других операциях.

– Плена – отслоение металла языкообразной формы, с одной стороны соединенное с листом металла, образовавшееся вследствие сильной выработки валков, расковки или раскатки рванин, следов глубокой зачистки дефектов или подрезов, а также грубых механических повреждений.

– Царапина – несквозной разрыв металла, идущий вглубь под прямым углом к поверхности, образовавшийся вследствие напряжений, связанных с неравномерным нагревом и охлаждением или структурными превращениями.

Структурированное распределение рассматриваемых поверхностных дефектов, согласно результатам эксплуатации прокатного стана «КВАРТО 400 ŠKODA» [18], представлено на рисунке 1.8.

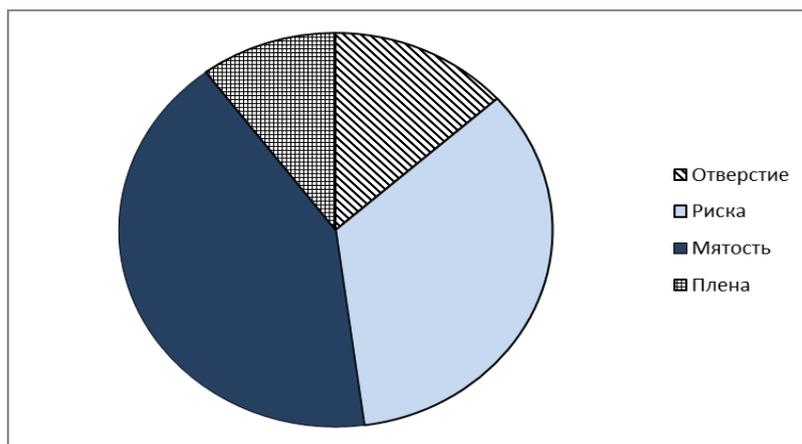


Рисунок 1.8 – Распределение наиболее распространенных классов поверхностных дефектов

Дефекты классов «Отверстие» и «Плена» являются неустраняемыми, а дефекты классов «Мятость» и «Царапина» можно устранить за счет увеличения числа реверсных прокатов. Распределение устранимых и неустраняемых поверхностных дефектов по годам представлено на рисунке 1.9.

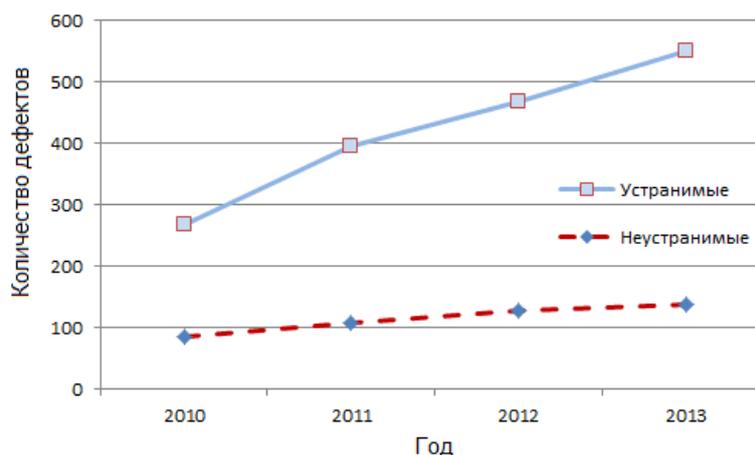


Рисунок 1.9 – Распределение классов поверхностных дефектов

Результаты исследований [18, 19] зависимости числа устраненных дефектов от количества дополнительных реверсных прогонов показана на рисунке 1.10).

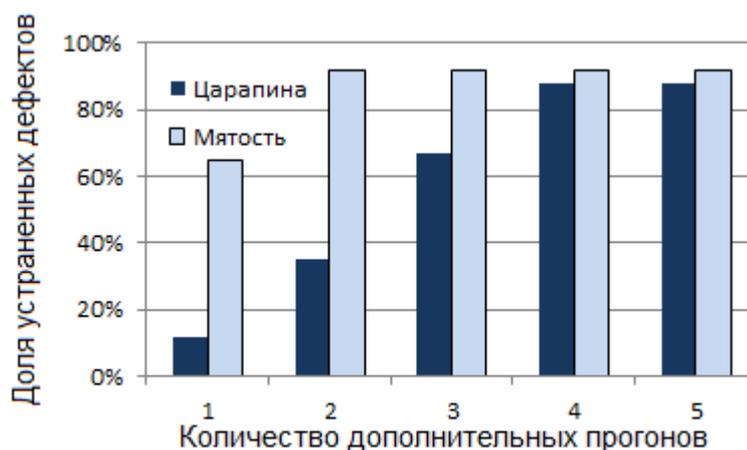


Рисунок 1.10 – Число устраненных дефектов за счет дополнительных реверсных прогонов листового проката

В результате установлено, что для устранения дефектов класса «Царапина» достаточно два дополнительных реверсных прогонов, а для класса «Мягость» необходимо четыре дополнительных прогона [18, 19].

Таким образом, выявлены наиболее распространенные классы поверхностных дефектов тонколистового проката и определено необходимое число дополнительных реверсных прогонов для их устранения.

1.2.3 Формирование пространства признаков поверхностных дефектов тонколистового проката

Важной задачей цифровой обработки изображений проката является формирование пространства признаков [22, 23, 35, 71]. Предложено расширенное пространство признаков для решения задачи распознавания поверхностных дефектов листового проката, представленное на рисунке 1.11.



Рисунок 1.11 – Расширенное пространство признаков поверхностных дефектов

Геометрические признаки [32,66]:

1. Периметр P – количество точек, лежащих на границе области дефекта (ОД).

$$P = \sum_{(x,y) \in R_{гр.деф}} 1, \quad (1.1)$$

где $R_{гр.деф}$ – граница области дефекта (ОД);

x, y – координаты точки в изображении.

2. Площадь S – количество точек (пикселей), принадлежащих ОД.

$$S = \sum_{(x,y) \in R_{деф}} 1, \quad (1.2)$$

где $R_{деф}$ – область дефекта (включая границу).

3. Компактность q является безразмерной величиной, инвариантной к однородным изменениям масштаба, принимающая минимальное значение в области круглой формы. С точностью до погрешностей, возникающих при повороте дискретных областей, компактность также инвариантна к ориентации объекта.

$$q = \frac{P^2}{S}. \quad (1.3)$$

Среди оптических признаков можно выделить [24, 32, 66]:

1. Среднее значение яркости в области дефекта m

$$m = \frac{1}{S} \sum_{(x,y) \in R_{def}} I(x,y), \quad (1.4)$$

где I – матрица изображения (матрица яркости).

2. Среднеквадратическое отклонение (СКО) яркости в области дефекта

$$\sigma = \sqrt{\frac{1}{S} \sum_{(x,y) \in R_{def}} (I(x,y) - m)^2}. \quad (1.5)$$

Переход к спектральному представлению изображений предложено осуществлять на основе вейвлет-преобразования (ВП) изображения [19, 52, 69, 70].

Признаки на основе ВП:

1 Средние значения вейвлет-коэффициентов (ВК) в горизонтальных, вертикальных, диагональных компонентах ВП, вычисленные внутри области, идентифицированного дефекта

$$mw_z^i = \frac{1}{n_i} \sum_{(x,y) \in R_{def}} w_z^i(x,y), \quad (1.6)$$

где i – уровень вейвлет-разложения изображения, $i=1,2,3$;

z – направление преобразования ЛН (вертикальное), НЛ (горизонтальное), НН (диагональное);

w_z^i – коэффициенты ВП на уровне i по направлению z ;

n_i – количество точек, принадлежащих области дефекта, на i -м уровне ВП.

2 СКО ВК горизонтальных, вертикальных, диагональных компонент идентифицированного дефекта

$$\sigma w_z^i = \sqrt{\frac{1}{n} \sum_{(x,y) \in R_{\text{деф}}} (w_z^i(x,y) - mw_z^i)^2}. \quad (1.7)$$

Экспериментально определены диапазоны значений выделенных признаков поверхностных дефектов листового проката для каждого из классов дефектов, представленные в таблице 1.1 [18].

Таблица 1.1 – Диапазоны значений признаков поверхностных дефектов

Признак дефекта/класс	Отверстие	Плена	Мягость	Царапина
Периметр, пикселей	4-71	50-200	344-720	148-700
Площадь, пикселей	4-203	250-4472	1500-5130	400-2100
Компактность, безразмерный	4-20	10-36	62-162	54-200
Среднее значение яркости, ед.	72-132	100-180	150-212	160-213
СКО яркости, единиц	6-28	22-63	20-40	15-36
Средние значения ВК в ОД (на первом уровне), б/р	9-20	3-21	2-12	4-18
СКО ВК в ОД (1-ый уровень), б/р	15-659	90-1500	3-37	15-300
Средние значения ВК в ОД (2-ой уровень), б/р	15-112	60-160	13-97	31-128
СКО ВК в ОД (второй уровень), б/р	220-11390	15000-50000	115-2010	688-8921
Средние значения ВК в ОД (на третьем уровне), б/р	67-475	380-2300	68-596	200-850
СКО ВК в ОД (на третьем уровне), б/р	3550-200000	57000-1533000	2700-141000	20000-270000

Таким образом, определено пространство признаков поверхностных дефектов тонколистового проката: геометрических, оптических и спектральных, позволяющих повысить достоверность цифровой обработки изображений.

1.3 Анализ проблем теории контроля качества продукции тонколистового проката

1.3.1 Обоснование метода бесконтактного контроля качества продукции листового проката

На рисунке 1.12 представлены существующие методы бесконтактного контроля качества (МБКК) готовой продукции листового проката.

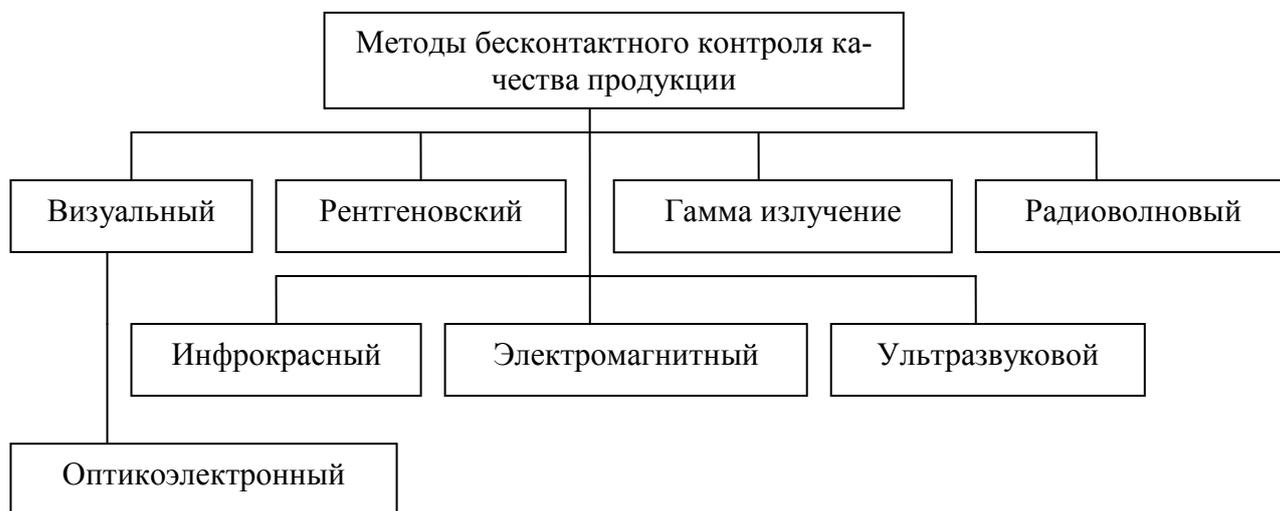


Рисунок 1.12 – Методы бесконтактного контроля качества продукции металлопроката

Наиболее простым МБКК листового проката является визуальный, который осуществляется невооруженным глазом или с помощью оптических приборов. Данный метод контроля позволяет идентифицировать дефекты поверхности (царапины, плены и др.) металлопроката. Минимальный размер дефектов, которые может обнаружить человек невооруженным глазом, составляет 0,1-0,2 мм, при скоростях проката до 4 м/с. [25].

МБКК на основе рентгеноскопии основан на поглощении рентгеновских лучей. Наличие таких дефектов, как отверстия, плена или мятость, приводит к

тому, что проходящие через материал лучи ослабляются в различной степени. Можно определить наличие и расположение различных неоднородностей материала, регистрируя распределение интенсивности проходящих лучей [6, 113].

МБКК на основе гамма-лучей в отличие от рентгенодефектоскопии, используют гамма-излучение, испускаемое радиоактивными искусственными изотопами таких металлов как кобальт, иридий, европий и др. [14, 62].

МБКК на основе радиоволн используют проникающие свойства радиоволн миллиметрового и сантиметрового диапазонов, что позволяет идентифицировать поверхностные дефекты неметаллических изделий [6, 113].

МБКК на основе инфракрасного излучения основаны на использовании тепловых инфракрасных лучей для идентификации непрозрачных включений. Инфракрасное изображение дефекта получают в отражённом, проходящем или собственном излучении продукции. Данным способом осуществляют контроль качества изделия, нагревающегося в процессе производства. Дефектные области в изделии изменяют тепловой поток. Инфракрасное излучение пропускается через изделие и теплочувствительный приемник регистрируют его распределение (ультрафиолетовая дефектоскопия) [6, 113].

Электроиндуктивной (токовихревой) МБКК продукции листового проката использует возбуждение вихревых токов при помощи переменного магнитного поля. Вихревые токи создают собственное поле, которое по знаку противоположно возбуждающему. При взаимодействии этих полей изменяется сопротивление катушки датчика, что отмечается индикатором. При этом на показания индикатора влияют размеры изделия, электропроводность, магнитная проницаемость металла и изменение электропроводности из-за нарушений целостности металла или структурных неоднородностей [17, 112].

Ультразвуковые МБКК продукции листового проката используют упругие колебания ультразвукового диапазона частот [6]. Нарушения однородности или целостности среды влияют на режим распространения упругих волн изделия. Основные подходы: теневой, эхометод, резонансный и др. [75].

МБКК на основе теневого метода ультразвуковые колебания [6], встретив на своём пути дефект, отражаются в обратном направлении. О наличии дефекта судят по уменьшению энергии ультразвуковых колебаний, огибающих дефект, или изменению фазы колебаний. Средства ультразвукового контроля подвергаются анализу не все сигналы, поступающие от преобразователя, а только те, которые попадают в некоторый диапазон задержек. Средство идентификации имеет строб, отмечающий зону ожидания сигналов от дефектов, и один или несколько порогов, на основе которых производится идентификация дефектов и оценка их опасности.

Наиболее универсальным является эхометод, основанный на посылке коротких импульсов ультразвуковых колебаний и регистрации времени прихода и интенсивности эхосигналов, отраженных от дефектов. Метод позволяет идентифицировать структурные и поверхностные дефекты различной ориентации в пространстве. Чувствительность эхометода является высокой: на частоте 2-4 МГц. возможно идентифицировать дефекты, площадь которых около 1 мм². В эхометоде ультразвукового контроля строб устанавливается на экране дефектоскопа (рисунок 1.13) в соответствии с диапазоном глубин залегания дефектов.



Рисунок 1.13 – Принцип работы системы идентификации эхометода

На заводе «Уральский медный прокат» (г. Гай, Оренбургская обл.) дефекты радиаторной ленты обнаруживаются при помощи ультразвукового устройства бесконтактного контроля общего назначения УД9812 "Уралец" (рисунок 1.14).



Рисунок 1.14 – Ультразвуковое устройство УД9812 "Уралец"

Результаты экспериментальных исследований УД9812 "Уралец" для обнаружения поверхностных дефектов приведены в таблице 1.2.

Таблица 1.2 – Ультразвуковое представление дефектов

Название дефекта	Коэфф. отражения	Коэфф. затухания ультразвув. волны (Нп/м)	Амплитуда (дБ)
Чистый металл	1	5-8	до 30
Царапина	0.836	3-5	30-40
Плена	0.91	3-5	30-35
Отверстие	0.374	0-1	80-120
Мягость	0.556	0-1	75-93

Исследования показали, что при скорости объектов до 5 м/с УД9812 "Уралец" обнаруживает 57% дефектов, при скорости от 5 до 5.7 м/с количество идентифицированных дефектов составляет 28.3% [19, 52].

Известны ИИС тепловой оценки качества продукции металлопроката. Данные ИИС осуществляют нагрев движущегося по рольгангу листа при помощи нагревателя (используются линейчатые лампы типа КГ-220-1000 или газовые горелки) [6,43]. Тепловизоры или линейные сканеры осуществляют сканирование температуры на поверхности прокатного листа со стороны, противоположной нагреву. Время нагрева для каждой точки должно составлять от 0,5 до 1 с., а плотность энергии нагрева должна находиться в пределах от 100 до 400 кВт/м² при скорости проката от 100 до 2200 мм/с. При указанных параметрах контроля качества время идентификации одного кадра составляет 1 с., причем 0,96 с. уходит на обработку информации, а 0,04 с – на запись температуры [20]. Помехами являются: наличие ржавчины, окалины, трещин, полированных зон, изменения температуры окружающей среды и толщины листа проката.

В таблице 1.3 приведено сравнение систем ультразвукового и теплового методов неразрушающего контроля [15, 46].

Таблица 1.3 – Сравнительные характеристики систем теплового и ультразвукового неразрушающего контроля металлопроката

Технический параметр системы	Система ТК	Система УЗНК	Требуемое
Размер выявляемого дефекта, мм.	2 и более	5	1
Толщина объекта контроля, мм	0,5-30	0,5-30	0,1-0,2
Максимальная скорость перемещения материала, м/с	3	5	8-9
Ширина участка контроля, мм	50-400	50-2500	50-6000
Максимальная температура, С ⁰	500	100	300
Возможность контроля изделий произвольной формы	Имеется	только листы	Имеется
Точность определения глубины залегания дефектов, %	10	30	10
Уровень требований к качеству контролируемой поверхности	Средний	Высокий	Низкий
Уровень требований к состоянию окружающей среды	Средний	Высокий	Низкий
Возможность распознавания дефектов	Нет	Нет	Да

Анализ результатов сравнительной оценки МБКК листового проката свидетельствует о несоответствии известных методов требованиям к обнаружению дефектов холодной обработке цветных металлов давлением.

В настоящее время для контроля качества продукции листового проката используются оптико-электронные информационно-измерительные системы (ОЭИИС) оценки качества продукции [64, 72, 93, 92, 95, 110]. Данные МБКК продукции листового проката основаны на цифровой обработке видеоизображений, получаемых с видеокамер, устанавливаемой над полосой проката [44, 45, 69, 71]. Преимуществами данного метода является возможность выявления дефектов на высокой скорости проката – до 8-9 м/с. Минимальный размер дефекта, который способны выявлять данные системы ограничивается размерностью матрицы видеокамеры. Например, для камеры с шириной матрицы в 1024 пикселя минимальный размер обнаруживаемого дефекта – 1мм. Недостатком метода является отсутствие возможности выявить внутренние (структурные) дефекты металлопроката [105].

Таким образом, обоснован выбор оптико-электронного метода контроля качества продукции тонколистового проката цветных металлов.

1.3.2 Анализ аналогов средств компьютерного зрения обнаружения поверхностных дефектов

Известен аналог средств идентификации (обнаружения) поверхностных дефектов металлопроката по видеоизображениям [117]. Метод, заложенный в указанное средство, заключается в следующем: по изображению, получаемому камерой с низкой выдержкой, рассчитывается пороговое значение яркости, по которому фон отделяется от области дефекта. На основе полученной области дефекта вычисляются признаки дефектов (геометрические, статистические и частотные (на основе преобразования Фурье)), которые подаются на вход нейронной сети. Обученная нейронная сеть определяет класс дефекта.

Недостатком Фурье-анализа изображения является отсутствие представления о локальных свойствах сигнала при быстрых временных изменениях его спек-

трального состава, что затрудняет работу распознавателя в процессе производства. Кроме того, недостатком данного метода является высокая вероятность выделения ложной области дефекта вследствие отсутствия фильтрации помех [8, 10].

Известны аналоги средств идентификации на основе фильтра Габора [110] с последующим анализом гистограммы распределения по результатам применения фильтра. Основным недостатком данного средства является ограничение по скорости проката до 3,5 м/с.

Известно средство идентификации поверхностных дефектов с использованием цифровых видеокамер [61]. Основная идея метода в том, что изображения формируются при помощи спектральных подсветок, направленных на поверхность. Полученное после сканирования поверхности цветное изображение преобразуется в изображение с нулевым контрастом, далее изображение нормируется и бинаризуется. После чего осуществляется элиминирование искажающих изображение фрагментов поверхности – помех. Идентификация поверхностных дефектов выполняется автоматически на основе искусственной нейронной сети. Если с помощью нейронной сети не удастся с заданной достоверностью установить класс поверхностного дефекта, то производится автоматический запуск динамической продукционно-ситуационной экспертной системы, которая по генетическим и морфологическим признакам распознает класс дефекта и оценивает его параметры. Нейронная сеть идентифицирует 3-и класса дефектов стального проката рельса: плена, раскатанная трещина и раскатанный пузырь. Недостатком метода является отсутствие возможности распознавания дефектов, характерных для тонколистового проката цветных металлов: отверстие, вмятины, пятна ржавчины, отпечатки валков и мелкие волны. Кроме того, в прототипе признаки идентификации формируются по всему изображению, что значительно увеличивает время обработки одного кадра, а использование матричных камер со скоростью съемки 25-30 кадров в секунду и скорости проката 6 м/с. приводит к «смазыванию» изображения, что делает невозможным идентификацию дефектов в процессе производства с требуемой достоверностью.

Авторским коллективом реализован метод идентификации поверхностных дефектов [65, 66], основанный на использовании вейвлет-преобразования изображений проката с пороговой фильтрацией. Метод позволяет обнаружить поверхностные дефекты для их устранения при реверсных прогонах. Однако данный метод не позволяет определить класс дефекта и, соответственно, ограничивает возможность формирования управляющих воздействий оператором прокатного стана [52].

Таким образом, существующие аналоги контроля качества продукции тонколистового проката цветных металлов не имеют средств распознавания поверхностных дефектов, что снижает эффективность устранения дефектов за счет коррекции входных параметров технологического процесса.

1.3.3 Выбор метода распознавания поверхностных дефектов тонколистового проката

Каноническая постановка задачи распознавания образов [22, 23] – для заданного множества объектов, относительно которого необходимо провести распознавание, задаётся множество, состоящее из подмножеств, называемых классами. Заданы: описание всего множества, информация о классах и информация об объекте, для которого необходимо определить принадлежность к одному из классов. По имеющимся признакам объекта устанавливается класс, к которому относится этот объект.

Среди методов распознавания можно выделить две базовые группы: структурные методы [47, 79] и методы на основе теории решений [32, 74]. Классификация методов распознавания образов на основе компьютерного зрения представлена на рисунке 1.15.

Структурные методы основаны на распознавание объектов по информации о структурных связях составных частей объектов. Для некоторых классов поверхностных дефектов («плена», «мятость»), форма может быть разнообразной, что делает весьма сложной задачей описание формы данных дефектов в виде их структурных составляющих.



Рисунок 1.15 – Методы распознавания на основе компьютерного зрения

Методы на основе теории решений используют дискриминантные функции. Пусть $x = \{x_1, x_2, \dots, x_n\}$ – вектор, в котором содержатся значения для n количественных признаков объекта. Тогда можно сформулировать основную задачу распознавания [32] в теории решений следующим образом. Если существует W классов объектов $\omega_1, \omega_2, \dots, \omega_W$, то необходимо найти W дискриминантных функций $d_1(x), d_2(x), \dots, d_W(x)$, таких, что если образ принадлежит классу ω_i , то

$$d_i(x) > d_j(x), j=1, 2, \dots, W; j \neq i. \quad (1.8)$$

В группе методов, основанных на теории решений, выделяют методы, основанные на вероятностном подходе, на сопоставлении и нейронные сети [32, 74].

В методах, основанных на сопоставлении, распознаваемый объект относится тому классу объектов, прототип которого является ближайшим в смысле заданной метрики [32, 74]. В задаче распознавания поверхностных дефектов тонколистового проката основной проблемой методов, основанных на сопоставлении, является сложность построения прототипов дефектов [48].

Методы, основанные на вероятностном подходе, такие как Байесовский классификатор, позволяют минимизировать ошибки классификации. Однако должны быть известны как функции плотности распределения вероятностей образов каждого класса, так и вероятности появления каждого из классов для достижения оптимальности.

Нейронные сети позволяют непосредственно в процессе обучения строить дискриминантную функцию (18). При этом отсутствует необходимость делать предположения о функции распределения вероятностей или других вероятностных параметрах классов объектов [60].

Классификатор по минимуму расстояния. Для классификатора по минимуму расстояния [32,60] принимается, что прототип каждого класса определяется как вектор математического ожидания образов из этого класса:

$$m_j = \frac{1}{N_j} \sum_{x \in \omega_j} x_j, j=1,2,\dots,W, \quad (1.9)$$

где N_j – число векторов признаков объектов x_j класса ω_j ;

W – число классов объектов.

Принимается, что объект относится к тому классу, прототип которого окажется ближайшим. Наиболее распространенной мерой расстояния является евклидова норма:

$$D_j(x) = \|x - m_j\|, j=1,2,\dots,W, \quad (1.10)$$

где $\|a\| = \sqrt{\{a^T a\}}$ – евклидова норма.

После этого объект x относится к тому классу ω_j , для которого $D_j(x)$ оказывается наименьшим.

Классификатор по минимуму расстояния хорошо работает в тех практических задачах, где расстояния между точками математических ожиданий клас-

сов велики по сравнению с диапазоном разброса объектов каждого класса. Поэтому классификатор по минимуму расстояния не подходит для решения задачи распознавания поверхностных дефектов.

Корреляционное сопоставление предполагает использование корреляции как средства поиска эквивалентов эталона $w(x,y)$ размерами $J * K$ на изображении $f(x,y)$ размерами $M * N$ [58,74]. Предполагается, что $J < M, K < N$.

Корреляция между изображениями $f(x,y)$ и $w(x,y)$ задается выражением

$$c(x,y) = \sum \sum f(s,t)w(x+s,y+t), \quad (1.11)$$

для $x=0,1,2,\dots,M-1, y=0,1,2,\dots,N-1$, где суммирование ведется по той области изображения, где w и f пересекаются. Для функции $c(x,y)$ оценивается пороговое значение t и принимается, что если $c(x,y) \geq t$, то в этой области обнаружен объект класса, соответствующего классу эталона.

Преимуществом корреляционного сопоставления является то, что нет необходимости предварительно выделять область объекта на исходном изображении и его признаки. Однако само вычисление корреляционной функции необходимо выполнять в $(M-J)(N-K)$ точках, что требует значительных временных затрат. Кроме того, нормировка относительного изменения размера или поворота является трудоемкой операцией в вычислительном плане. Также, для обеспечения требуемой достоверности распознавания необходимо большое количество эталонов для каждого из классов объектов, что требует еще больших временных затрат на распознавание. Поэтому, корреляционное сопоставление не может быть использовано для распознавания поверхностных дефектов в процессе производства.

Сопоставление с эталонами. Для классификатора путем сравнения с эталоном [32,74,76], предполагается наличие эталонов r , для которых известно к какому классу они относятся. В этом случае принимается, что объект относится к тому классу, расстояние до которого минимально. В качестве меры расстояния чаще всего применяется евклидово расстояние.

Для обеспечения требуемой достоверности распознавания путем сравнения с эталонами требуется большая база эталонов. При этом для каждого распознаваемого объекта необходимо вычислять расстояние до каждого из эталонов, что предполагает большие временные затраты на распознавание. Поэтому данный метод не может быть применен для распознавания поверхностных дефектов листового проката.

Байесовский классификатор. Пусть $p(\omega_j|x)$ – вероятность того, что поступивший образ x принадлежит классу ω_j . Если классификатор относит к классу ω_i образ x , который в действительности относится к классу ω_j , это приводит к потерям, которые обозначаются $L_{i,j}$. Поскольку образ может принадлежать любому из рассматриваемых W классов, средняя величина потерь, связанных с отнесением x к классу ω_j , определяется как

$$r_j(x) = \sum_{k=1}^W L_{r,j} p(\omega_k | x). \quad (1.12)$$

Из теории вероятностей известно, что при $p(A)>0$ и $p(B)>0$ справедливо равенство $p(A|B)=[p(A)p(B|A)]/p(B)$. Тогда выражение (1.12) можно представить в форме:

$$r_j(x) = \frac{1}{p(x)} \sum_{k=1}^W L_{r,j} p(x | \omega_k) P(\omega_k). \quad (1.13)$$

где $p(x|\omega_k)$ – функция плотности распределения вероятностей образов класса ω_k , а $P(\omega_k)$ – вероятность появления образа из класса ω_k . Поскольку множитель $1/p(x)$ положителен и одинаков для всех $r_j(x)$, $j=1,2,\dots,W$, его можно опустить в выражении (1.13), при этом упорядоченность значений функции $r_j(x)$ не изменится. Тогда выражение для условных потерь сводится к

$$r_j(x) = \sum_{k=1}^W L_{r,j} p(x | \omega_k) P(\omega_k). \quad (1.14)$$

В этом случае, для обеспечения условия минимальности потерь, классификатор должен отнести неизвестный x к классу ω_j , если $r_i(x) < r_j(x)$ для $j=1,2,\dots,W; j \neq i$. Данное неравенство можно записать в виде

$$\sum_{k=1}^W L_{r,j} p(x | \omega_k) P(\omega_k) < \sum_{k=1}^W L_{r,i} p(x | \omega_k) P(\omega_k), \quad (1.15)$$

для всех $j \neq i$.

Такой классификатор называют байесовским [3].

Величина потерь при правильном выборе класса принимается нулевой, а потери при ошибочном выборе класса считаются одинаковыми и равными 1.

При таких условиях функция потерь принимает вид

$$L_{i,j} = 1 - \delta_{i,j}, \quad (1.16)$$

где $\delta_{i,j} = 1$ при $i=j$ и $\delta_{i,j} = 0$ при $i \neq j$.

Применение (1.16) к (1.15) определяет

$$r_j(x) = \sum_{k=1}^W (1 - \delta_{i,j}) p(x | \omega_k) P(\omega_k) = p(x) - p(x | \omega_j) P(\omega_j). \quad (1.17)$$

Тогда классификатор приписывает образ x к классу ω_j , если для $j=1,2,\dots,W; j \neq i$.

$$p(x) - p(x | \omega_i) P(\omega_i) < p(x) - p(x | \omega_j) P(\omega_j), \quad (1.18)$$

или если

$$p(x | \omega_i) P(\omega_i) > p(x | \omega_j) P(\omega_j). \quad (1.19)$$

Тогда байесовский классификатор в случае вычисления нуль-единичной функции потерь есть не что иное, как вычисление дискриминантных функций

$$d(x) = p(x | \omega_j) P(\omega_j), j=1,2,\dots,W, \quad (1.20)$$

с отнесением образа x к тому классу, у которого значение дискриминантной функции $d_i(x)$ оказывается наибольшим [108].

На практике для работы байесовского классификатора необходимо, чтобы были известны функция плотности распределения вероятностей каждого из классов, так и вероятности появления каждого объекта в классе [74,77,78]. Оценка функций плотности распределения является трудоемкой задачей, так как является многомерной функцией и требует использования методов теории вероятностей, описывающих многомерные случайные величины. По этим причинам байесовский классификатор не подходит для решения задачи распознавания поверхностных дефектов листового проката.

Нейронная сеть представляет собой математическую модель, характеризующуюся использованием большого числа простейших вычислительных элементов, называемых нейронами [32,60]. Организация нейронных сетей напоминает предположительный способ связи нейронов в головном мозге.

На рисунке 1.16 представлена модель нейрона.

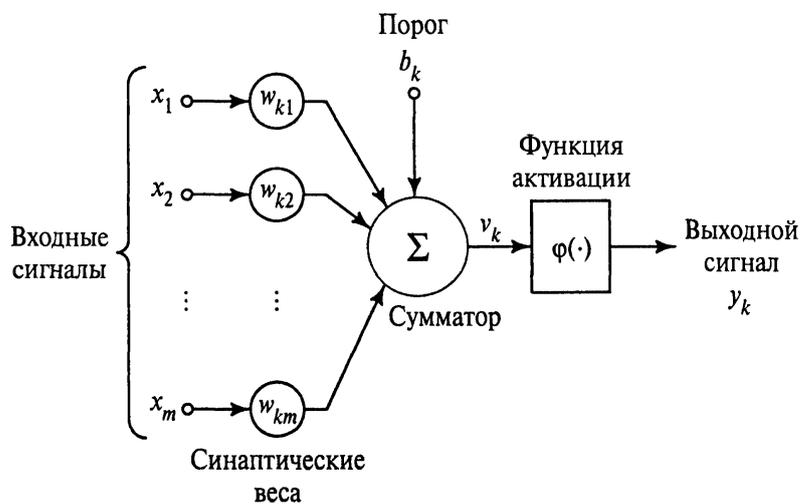


Рисунок 1.16 – Модель нейрона

Каждый нейрон имеет несколько входов, называемых дендритами, и один выход, называемый аксоном. Выходной сигнал нейрона имеет вид

$$y(x) = f\left(\sum_{i=1}^n w_i x_i\right), \quad (1.21)$$

где x_i – значения входного сигнала;

w_i – коэффициенты связи между нейронами, называемые весами;

f – функция активации нейрона;

n – количество нейронов в предыдущем слое (для первого слоя – количество признаков)

Наиболее распространенной архитектурой нейронной сети является многослойный персептрон [32,60]. Передача сигнала в таких сетях происходит только в одном направлении от входа к выходу. Архитектура многослойного персептрона представлена на рисунке 1.17.

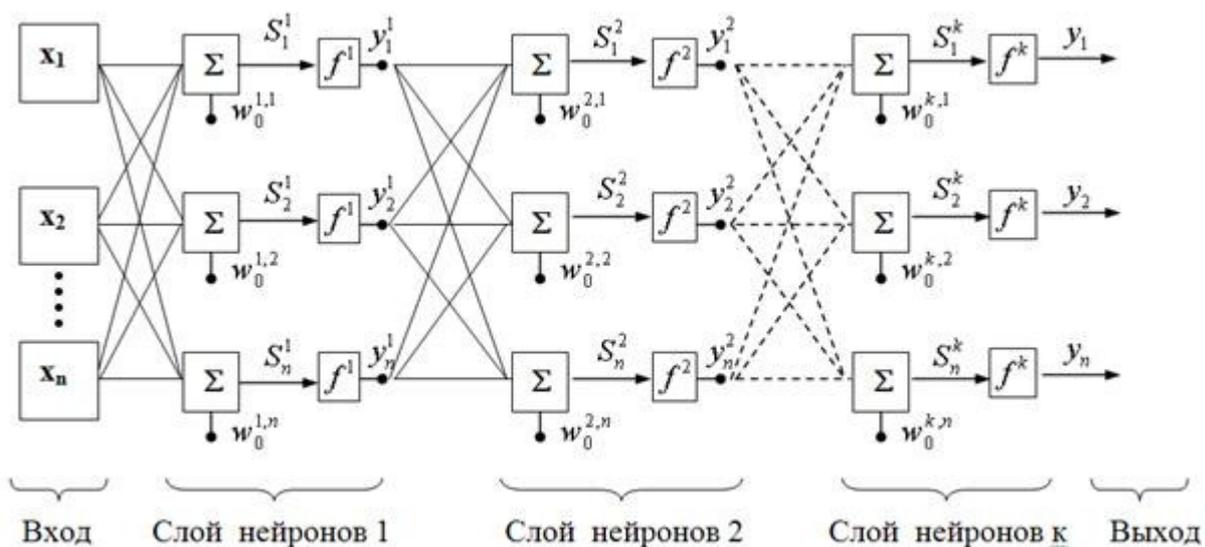


Рисунок 1.17 – Архитектура нейронной сети типа «многослойный персептрон».

Однако у нейронных сетей существует ряд недостатков [60]:

- большинство подходов для проектирования искусственных нейронных сетей являются эвристическими и не всегда приводят к однозначным решениям или к тупиковым ситуациям;
- значительные временные затраты на обучение нейронной сети;
- необходимость пересмотра архитектуры и переобучения всей сети при введении нового класса объектов.

Отсюда, значительные временные затраты на переобучение и неоднозначное поведение нейронной сети в ряде ситуаций ограничивают применение нейронной сети для решения задачи распознавания поверхностных дефектов листового проката.

Метод окрестностей. Определяющим фактором при выборе метода распознавания поверхностных дефектов листового проката является скорость работы алгоритма, так как распознавание должно производиться в процессе производства. Эффективное (в вычислительном отношении) использование распознающих алгоритмов предполагает наличие некоторого аппарата оценки близости, не требующего сравнения распознаваемого объекта с каждым элементом обучающего набора. Одним из таких методов является метод окрестностей [29], который позволяет по построенной в пространстве признаков системе окрестностей для распознаваемого объекта найти бинарным поиском минимальную окрестность, в которой содержится необходимое число образцов (дефектов) известного класса. Использование бинарного поиска определяет вычислительную эффективность данного метода, что является критическим фактором при распознавании в процессе производства проката и делает метод окрестностей наиболее подходящим для использования в СКЗ распознавания поверхностных дефектов.

Таким образом, наличие существенных недостатков известных методов распознавания поверхностных дефектов, ограничивающих их применение на потенциально возможных скоростях проката с достаточной достоверностью, доказывает актуальность исследований в области совершенствования систем компьютерного зрения на основе метода окрестностей.

1.4 Концепция построения системы компьютерного зрения для задачи контроля качества готовой продукции тонколистового проката

1.4.1 Методологические основы исследований

Системный анализ проблем контроля качества продукции тонколистового проката цветных металлов позволил определить методологические основы исследований.

Объект исследования – система компьютерного зрения (СКЗ) для контроля качества продукции холодной обработки цветных металлов давлением

Предмет исследования – методы, модели и средства идентификации и распознавания поверхностных дефектов для построения СКЗ.

Границы исследования: цифровая обработка изображений на скоростях проката до 8-9 м/с.

Результат системного анализа проблем контроля качества продукции тонколистового проката цветных металлов позволяет выявить основное противоречие между требованиями практики и состоянием теории – противоречие между ростом числа устранимых поверхностных дефектов тонколистового проката и отсутствием средств автоматизации их идентификации и распознавания в процессе производства на потенциально возможных скоростях проката (рис. 1.18).

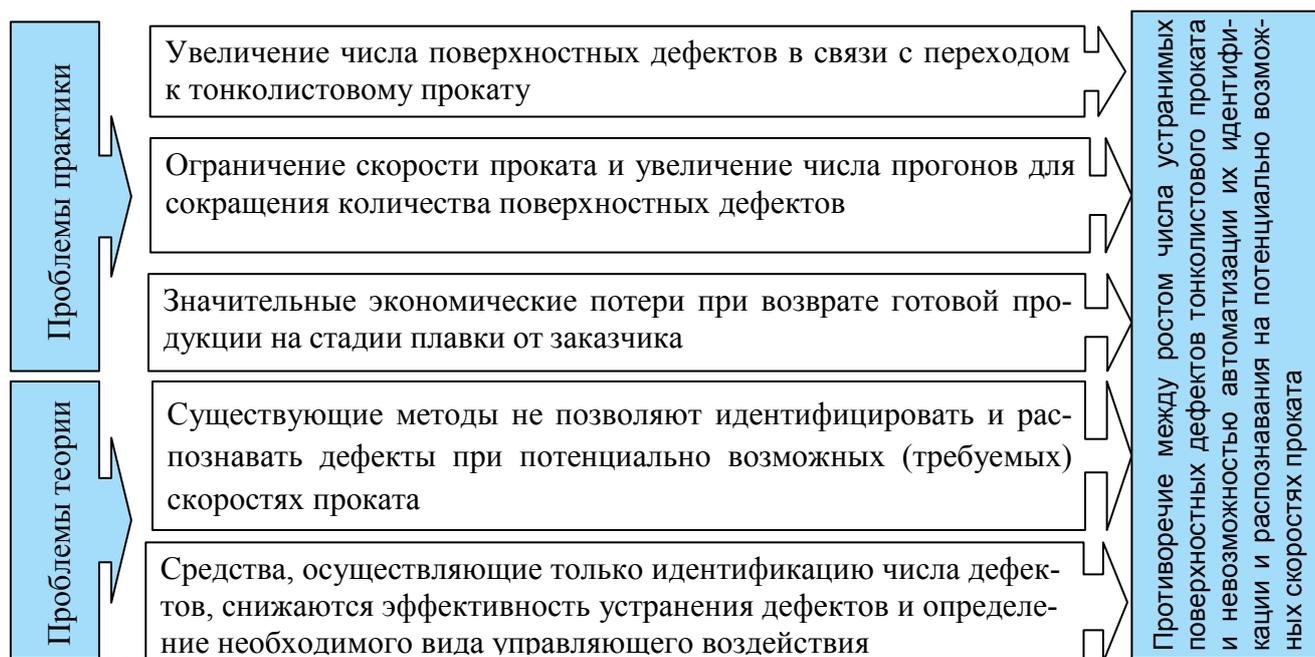


Рисунок 1.18 – Основное противоречие между требованиями практики и состоянием теории контроля качества продукции тонколистового проката

Для преодоления выявленного противоречия сформулирована **цель исследований**: разработать систему компьютерного зрения для контроля качества продукции холодной обработки цветных металлов давлением на основе идентификации и распознавания поверхностных дефектов в процессе производства.

Для достижения поставленной цели необходимо решить ряд задач научного характера:

- 1) анализ проблем обеспечения качества готовой продукции холодного тонколистового проката цветных металлов;
- 2) разработка модели изображения поверхности тонколистового проката для распознавания дефектов в процессе производства на основе современных методов вейвлет-преобразований;
- 3) разработка методики и алгоритмов принятия решений для распознавания поверхностных дефектов листового проката в процессе производства;

4) разработка прототипа системы компьютерного зрения идентификации и распознавания поверхностных дефектов листового проката и оценка ее достоверности и быстродействия.

Требования к разрабатываемой системе компьютерного зрения:

- распознавать дефекты следующих видов: «плена», «царапина», «мятость», «отверстие»;
- работать при скоростях проката до 8-9 м/с;
- определять пространственное положение областей дефекта на листе проката и рассчитать их геометрические признаки;
- определять возможность устранения дефекта.

Таким образом, сформулировано основное противоречие между проблемами практики, связанными с возникновением поверхностных дефектов при переходе к производству тонколистового проката, и состоянием теории, заключающемся в отсутствие методов автоматической идентификации и распознавания поверхностных дефекты в процессе производства с использованием компьютерного зрения.

1.4.2 Концепция совершенствования системы компьютерного зрения

Для преодоления выявленного противоречия предложен новый принцип построения системы компьютерного зрения для контроля качества продукции холодной обработки цветных металлов давлением (рисунок 1.19), в основе которого два процесса: идентификация и распознавание дефекта [10, 11, 70].

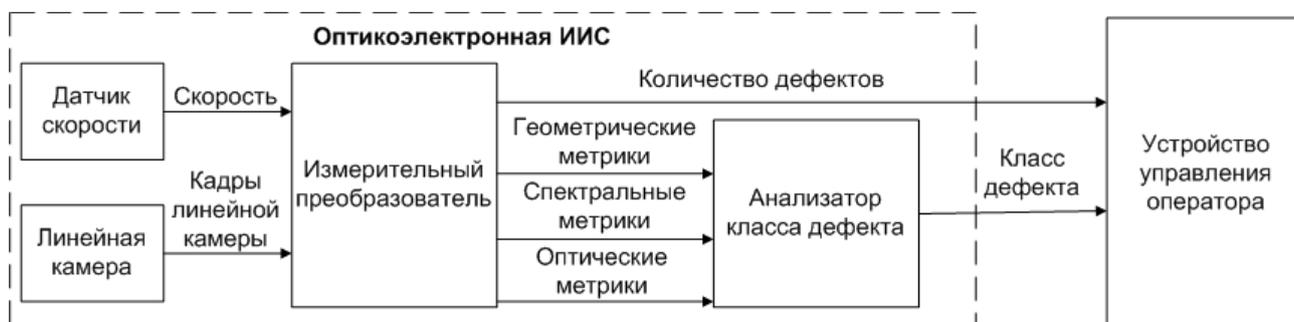


Рисунок 1.19 – Принцип построения системы компьютерного зрения контроля качества продукции холодной обработки цветных металлов давлением

Измерительный преобразователь позволит по сформированному на основе кадров линейной камеры изображению поверхности проката определить наличие дефектов, выделить положение дефекта (область) и вычислить значения метрологических признаков дефектов.

Анализатор класса дефекта позволяет установить класс поверхностного дефекта на основе анализа значений пространства признаков.

На основании сформулированной цели исследований и предложенного принципа построения системы компьютерного зрения для контроля качества продукции холодной обработки цветных металлов давлением определена целевая функция вида:

$$N_{\text{пд}}(v, N_{\text{прох}}, h) \rightarrow \min, \quad (1.22)$$

$$\text{при } v \leq v_{\text{зад}}, \quad h \leq h_{\text{зад}},$$

где $N_{\text{пд}}$ – число поверхностных дефектов;

v – скорость проката, м/с.;

$N_{\text{прох}}$ – число реверсивных проходов, раз;

h – толщина готовой продукции, мм.

Таким образом, обобщение результатов системного анализа проблем контроля качества тонколистового проката цветных металлов позволяет определить методологические основы исследований на новом принципе построения системы компьютерного зрения для идентификации и распознавания поверхностных дефектов тонколистового проката

Выводы по разделу

1 Характерной особенностью современного производства холодного проката цветных металлов становится переход к тонколистовому прокату с толщиной листа 0,1-0,12 мм при проектной толщине для существующих станов 0,4 мм.

2 Результатом перехода к тонколистовому прокату цветных металлов становится скачкообразный рост числа поверхностных дефектов, большая часть которых не выявляется в процессе производства существующими средствами, что доказывает необходимость совершенствования существующих средств контроля качества продукции обработки цветных металлов давлением.

3 Выявлены наиболее распространенные классы поверхностных дефектов: «мятость», «отверстие», «плена» и «царапина», и определено необходимое число дополнительных реверсных прогонов для их устранения.

4 Определено расширенное пространство признаков поверхностных дефектов тонколистового проката: геометрических, оптических и спектральных, позволяющих повысить достоверность цифровой обработки изображений.

5 Обоснован выбор оптико-электронного метода контроля качества продукции тонколистового проката цветных металлов.

6 Существующие аналоги контроля качества продукции тонколистового проката цветных металлов решают задачу идентификации поверхностных дефектов без решения задачи их классификации, что снижает эффективность устранения дефектов за счет коррекции входных параметров технологического процесса.

7 Наличии существенных недостатков известных методов распознавания поверхностных дефектов, ограничивающих их применение на потенциально возможных скоростях проката с достаточной достоверностью доказывает актуальность исследований в области совершенствования систем компьютерного зрения на основе метода окрестностей.

8 Обобщение результатов системного анализа проблем контроля качества тонколистового проката цветных металлов позволяет определить методологические основы исследований на новом принципе построения системы компьютерного зрения идентификации и распознавания поверхностных дефектов тонколистового проката.

2 Цифровая обработка изображений в задачах идентификации и распознавания поверхностных дефектов

Любая из процедур цифровой обработки опирается на модель изображений – формализованное описание, выполненное с определенной степенью абстрагирования. Роль модели изображения в процессе извлечения информации состоит в обеспечении адекватного описания существенных свойств изображения, позволяющего дать конструктивную основу для построения эффективных вычислительных процедур.

2.1 Систематизация моделей для цифровой обработки изображений

Цифровая обработка изображений осуществляется после преобразования изображения в цифровую форму [32, 41]. Эффективность цифровой обработки зависит от адекватности описывающей изображение модели [54, 56]. Изображение может быть представлено функцией пяти аргументов: трех пространственных координат x, y, z , времени t и длины волны электромагнитного излучения λ [49].

Выбор модели изображения для идентификации и распознавания поверхностных дефектов тонколистового проката представлено на рисунке 2.1.

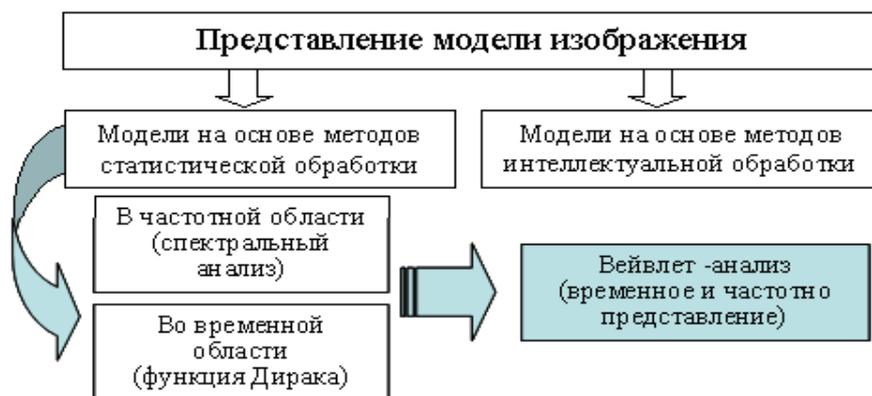


Рисунок 2.1 – Систематизация моделей изображения

Спектральные модели изображений. При цифровой обработке изображений широко применяется спектральный анализ, как способ перехода от представления модели из временной области в частотную (спектральную). Истори-

чески первым способом спектрального анализа являлось преобразование Фурье [21]. Спектр изображения на основе двумерного прямого преобразования Фурье описывается функцией [63]:

$$F(\omega_x, \omega_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \exp(-i(\omega_x x + \omega_y y)) dx dy, \dots\dots\dots(2.1)$$

где ω_x, ω_y - пространственные частоты (гармоники);

$i = \sqrt{-1}$, мнимая единица.

Функция $\exp(-i(\omega_x x + \omega_y y))$ описывает плоскую волну изображения (x, y) при фиксированных значениях пространственных частот.

Преобразование (2.2) связывает действительную функцию яркости изображения $f(x, y)$ с комплексной функцией частоты, называемой спектром изображения

$$F(\omega_x, \omega_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cos(\omega_x x + \omega_y y) dx dy +$$

$$+ i \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (-f(x, y)) \sin(\omega_x x + \omega_y y) dx dy = \text{Re}(\omega_x, \omega_y) + i \text{Im}(\omega_x, \omega_y), \quad (2.2)$$

где $\text{Re}(\omega_x, \omega_y)$ – реальная часть спектра;

$\text{Im}(\omega_x, \omega_y)$ – мнимая часть спектра.

Амплитуда и фаза спектра определяются по зависимостям (2.3) и (2.4):

$$A(\omega_x, \omega_y) = \sqrt{\text{Re}(\omega_x, \omega_y)^2 + \text{Im}(\omega_x, \omega_y)^2}, \quad (2.3)$$

$$\varphi(\omega_x, \omega_y) = \text{arctg}(\text{Im}(\omega_x, \omega_y) / \text{Re}(\omega_x, \omega_y)). \quad (2.4)$$

Используя обратное преобразования Фурье возможно по спектру восстановить изображение:

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(\omega_x, \omega_y) \exp(i(\omega_x x + \omega_y y)) d\omega_x d\omega_y. \quad (2.5)$$

Помимо преобразования Фурье, спектр изображения может быть получен на основе вейвлет-преобразования (ВП), подробнее данная модель рассмотрена в разделе 2.1.2. Сравнивая два данных метода можно отметить следующие преимущества использования ВП: возможность преобразования с различным размером окна, возможность использования различных базисных функций. Также, ВП является пространственно-частотным, поэтому можно анализировать коэффициенты вейвлет-преобразования (КВП) только в идентифицированных областях дефекта R_{def} [21, 49]. Также следует отметить, что КВП рассчитываются в процессе идентификации поверхностных дефектов и, поэтому, их использование в процессе расчета значений признаков распознаваемого объекта позволяет сократить общий объем вычислений при распознавании.

Вероятностные модели изображений и функции автокорреляции. Вероятностные модели изображений широко распространены при описании изображений [2, 12, 77]. Изображение в этом случае рассматривается как случайная функция времени t и пространственных координат (x,y) . Случайный процесс является стационарным в широком смысле, если он имеет постоянные значения дисперсии и математического ожидания, а его функция автокорреляции зависит от разностей координат. Случайный процесс является стационарным в узком смысле, если n -мерная плотность распределения вероятностей сигнала инвариантна к сдвигу. В этом случае моменты более высокого порядка не зависят от времени (в частности, эксцесс и асимметрия). Случайный процесс для некоторого фиксированного момента времени t описывается плотностью вероятности распределения яркости в изображении по пространственным координатам.

В соответствии с определением математическое ожидание (среднее):

$$Mf = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) p(x, y) dx dy = const \dots\dots\dots(2.6)$$

Дисперсия:

$$Df = \sigma^2 = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (f(x, y) - Mf)^2 p(x, y) dx dy = const \dots\dots\dots(2.7)$$

Функция автокорреляции вычисляется как:

$$R(\tau_x, \tau_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) f(x - \tau_x, y - \tau_y) dx dy, \quad (2.8)$$

где τ_x, τ_y – сдвиги изображения по соответствующим осям координат.

Для действительной функции f автокорреляционная функция является четной и действительной.

Таким образом, выдвигается гипотеза, что спектральное представление оцифрованного изображения наиболее приемлемо для решения задачи выделения структурных элементов (поверхностных дефектов) с учетом заданных требований.

2.2 Моделирование изображений для выделения структурных элементов

Описание моделей изображений с целью выделения их структурных элементов (поверхностных дефектов) базируется на математическом аппарате кратномасштабного анализа (КМА) [12, 16, 69, 116], в основе которого лежат операторы вейвлет-преобразования (ВП) W .

Под ВП понимается разложение изображения по системе базисных функций, каждая из которых является сдвинутой и масштабированной (сжатой или растянутой) копией одной функции – порождающего вейвлета [12].

В процедурах разложения изображений I с помощью локальных операторов (базисных, порождающих функций) применяются так называемые локальные модели случайного поля, характеризующие статистическую зависимость интенсивности изображения f в точке (x, y) , от значений интенсивности в соседних точках, представляя $f(x, y)$ как линейную комбинацию значений $\{f(x+k, y+l), (k, l) \in F\}$ и аддитивного шума ε , где F – множество соседей, не включающих точку $f(x, y)$ [20, 32]:

$$f(x, y) = \sum_{(k,l) \in F} a_{k,l} f(x+k, y+l) + \varepsilon(x, y), \quad (2.9)$$

где $A = \{a_{k,l}, (k,l) \in F\}$ – вектор неизвестных коэффициентов модели.

Выражение (2.1) можно переписать как $f = f^* + \varepsilon$, где f – исходное изображение, f^* – поле значений пикселей, ε – поле случайного шума. После проведения ВП выполняется $W_f = W_{f^*} + W_\varepsilon$. Это означает, что коэффициенты двумерного ВП могут быть описаны, как показано на рисунке 2.1, посредством линейной комбинации соседних коэффициентов из четырех наборов W_{LL} , W_{HL} , W_{LH} , W_{HH} .

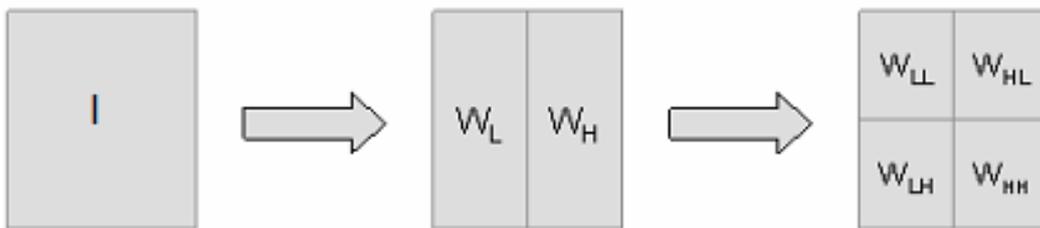


Рисунок 2.1 – Технология двумерного ВП кадра изображения I

Другой подход предполагает рассмотрение поля яркости, соответствующего изображению, как статистически однородного случайного поля [93]. В данном случае задание модели сводится к количественному описанию тех или иных характеристик случайного поля: одномерной или многомерной плотности распределения вероятностей, функции корреляции и т.п. Очевидно, что подобный подход можно применить и для описания свойств коэффициентов $a_{i,l}$ на разных уровнях разрешения, а их наборы в W_{HL} , W_{LH} , W_{HH} рассматриваются как случайные двумерные некоррелированные поля с нулевым средним [93]. Как показывает практика, хотя общая гистограмма всех коэффициентов является экспоненциальной ($a = \exp(-\lambda k)$), гистограммы каждого отдельного шага преобразования являются симметричными, одномодальными, и, приближенно, могут быть приняты за нормальные.

Исходя из этого, математическая модель полутонного изображения может быть представлена в виде [15, 68, 84]

$$f(x, y) = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} \sum_{k=-\infty}^{+\infty} (\varepsilon_{1j,k}^{(i)} \varphi \psi_{j,k}^{(i)}(x, y) + \varepsilon_{2j,k}^{(i)} \psi \varphi_{j,k}^{(i)}(x, y) + \varepsilon_{3j,k}^{(i)} \psi \psi_{j,k}^{(i)}(x, y)), \quad (2.10)$$

где $\varepsilon_{1j,k}^{(i)}$, $\varepsilon_{2j,k}^{(i)}$, $\varepsilon_{3j,k}^{(i)}$ – случайные поля i -го поля изображения, с нормальным распределением, нулевым средним и дисперсиями, соответственно, равными дисперсиям W_{HL} , W_{LH} , W_{HH} ;

$\varphi \psi(x, y) = \varphi(x)\psi(y)$, $\psi \varphi(x, y) = \psi(x)\varphi(y)$, $\psi \psi(x, y) = \psi(x)\psi(y)$ – тензорные произведения одномерных порождающих функций вейвлета.

Очевидно, что подобные модели являются весьма удобными при синтезе алгоритмов разложения изображений, в частности, позволяют развить применительно к ВП изображений основные результаты классической теории фильтрации [74, 105, 108]. Кроме того, данная модель, основанная на статистических свойствах коэффициентов разложения, позволяет описать процедуры вейвлет – анализа изображений.

Другим подходом к описанию изображения является его представление в виде совокупности областей [101], которые могут различаться по характеристикам. Разработка модели в рамках такого подхода заключается, во-первых, в описании пространственных признаков областей (размеров, взаимного расположения, формы границ и т.п.) и, во-вторых, в описании свойств поля внутри каждой области. Очевидно, что подобные модели являются наиболее подходящими для описания алгоритмов выделения структурных элементов изображения, сегментации и т.д.

Порождающие (базисные) функции ВП, которые называются вейвлетами, могут быть самые различные функции с компактным носителем, в том числе со скачками, разрывами и перепадами значений с большой крутизной. Выбор порождающего вейвлета во многом определяется тем, какую информацию необ-

ходимо извлечь из изображения. С учетом характерных особенностей различных вейвлетов во временном и в частотном пространстве, можно выявлять в анализируемых изображениях те или иные свойства и особенности, которые незаметны на гистограммах, особенно в присутствии сильных шумов. При этом задача реконструкции сигнала может и не ставится, что расширяет семейство используемых регулярных и симметричных порождающих вейвлетов. Более того, вейвлет может конструироваться непосредственно под ту локальную особенность в изображении, которая подлежит выделению или обнаружению, если ее форма априорно известна [32, 84, 103, 105, 116].

Существует большое количество вейвлет-базисов, но применительно к обработке изображений используются ортогональные и биортогональные вейвлеты [15, 105, 116]. В общем случае ортогональность вейвлетов не является обязательным требованием при анализе двухмерных сигналов. Однако, ортогональность базиса позволяет реализовать быстрые алгоритмы.

Другими важными свойствами вейвлет-функций являются симметричность и компактность носителя в пространственной и частотной области.

Симметричность (асимметричность) функции в некоторой степени определяет ориентацию вейвлет-базиса. Ориентация базисной функции в свою очередь определяет способность корректно анализировать ориентированные структуры, типичные для изображений. Точность определения местоположения деталей изображения на стадии анализа определяется пространственной локализацией вейвлет-функции.

В таблице 2.1 представлены основные базисные вейвлет-функции, используемые для обработки изображений [36].

Таблица 2.1 – Базисные вейвлет-функции

<i>HAAR</i> - вейвлет:	
$\psi(t) = \begin{cases} 1, & 0 \leq t < 1/2 \\ -1, & 1/2 \leq t < 1 \\ 0, & t < 0, t \geq 1 \end{cases}$	
<i>FHAT</i> - вейвлет ("Французская шляпа" - French hat):	
$\psi(t) = \begin{cases} 1, & t \leq 1/3 \\ -1/2, & 1/3 < t \leq 1 \\ 0, & t > 1 \end{cases}$	
<i>Wave</i> - вейвлет:	
$\psi(t) = t \exp\left(-\frac{t^2}{2}\right)$	
<i>MHAT</i> - вейвлет ("Мексиканская шляпа" - Mexican hat):	
$\psi(t) = (1-t^2) \exp\left(-\frac{t^2}{2}\right)$	
<i>Вейвлет Морле</i> (образует комплексный базис):	
$\psi(r) = \exp\left(ik_{\psi}r - \frac{r^2}{2}\right)$	

Локальность функции в частотной области важна при подробном анализе спектра. Таким образом, степень симметричности или отклонения от симметрии для вейвлет-функции наряду с ее пространственной локализацией влияет на определение формы и ориентации деталей изображения, а также их пространственных координат. Для анализа изображений желательно использовать симметричные ортогональные вейвлет-базисы.

Принципиальным отличием вейвлет-преобразования от фурье-преобразования является возможность вейвлетов анализировать нестационар-

ные сигналы с изменением компонентного содержания во времени или в пространстве. Основная область применения ВП – анализ и обработка сигналов и функций, нестационарных во времени или неоднородных в пространстве, когда результаты анализа должны содержать не только общую частотную характеристику сигнала (распределение энергии сигнала по частотным составляющим), но и сведения об определенных локальных координатах, на которых проявляют себя те или иные группы частотных составляющих, или на которых происходят быстрые изменения частотных составляющих сигнала.

По сравнению с разложением функций на ряды Фурье, вейвлеты способны с гораздо более высокой точностью представлять их локальные особенности, вплоть до разрывов 1-го рода (скачков). Кроме того, ВП одномерных сигналов обеспечивает двумерную развертку, при этом частота и координата рассматриваются как независимые переменные, что дает возможность анализа сигналов сразу в двух пространствах.

Исследования [16, 48, 55] показали, что изображения могут быть описаны моделью двумерного случайного поля в виде суммы двух компонент для идентификации поверхностных дефектов листового проката

$$f(x, y) = f_1(x, y) + f_2(x, y), \quad (2.11)$$

где x, y – координаты изображения;

$f(x, y)$ – поле яркости;

$f_1(x, y)$ – яркость стационарного поля (текстурная компонента);

$f_2(x, y)$ – яркость меняющегося поля дефектов.

Такая модель позволит при принятии решений анализировать не всё изображение, а только области дефектов (вторая составляющая 2.3), что значительно сократит объём обрабатываемой информации.

Таким образом, наиболее приемлемой моделью описания изображения листового проката с поверхностными дефектами является модель вейвлет –

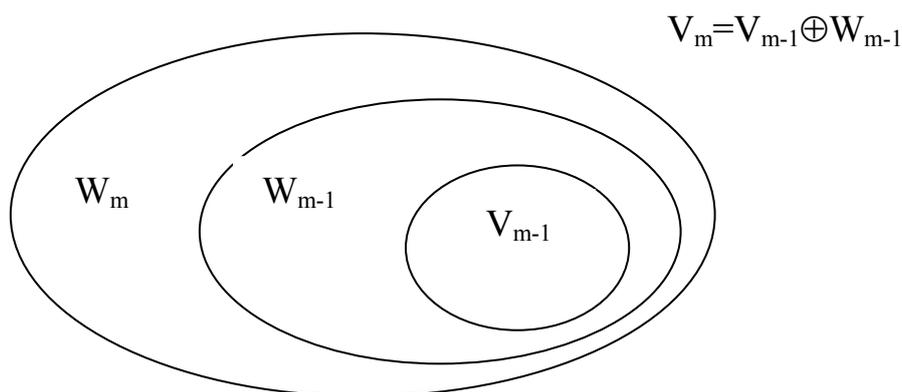
разложения (преобразования) изображения в виде суммы двух компонент – текстурной компоненты и медленно меняющегося поля (области) дефектов.

Основным недостатком такого подхода является высокая сложность алгоритмической реализации, что требует развития аппарата вейвлет-анализа к задачам идентификации и распознавания поверхностных дефектов в процессе производства.

2.3 Развитие вейвлет-модели изображения для задачи идентификации поверхностных дефектов

В основе КМА [16, 84] лежат иерархические свойства масштабирующих скейлинг-функций $\varphi_{m,k}(x)$ и детализирующих вейвлет-функций $\psi_{m,k}(x)$, которые позволяют представить любую одномерную функцию $f(x)$ в виде ее последовательных вейвлет-преобразований (ВП). Пусть пространство V_m , где m – масштаб преобразования, натянуто на $\varphi_{m,k}(x)$, т.е. $V_m = \text{span}\{\varphi_{m,k}(x)\}$, и обладает свойствами иерархичности $(f(x) \in V_m \Leftrightarrow f(2x) \in V_{m+1})$ и вложенности $(V_0 \subset V_1 \subset \dots \subset V_m \subset \dots \subset L^2(\mathbf{R}))$. Тогда, пространство V_{m+1} может быть определено

$$V_{m+1} = V_m \oplus W_m = V_{m-1} \oplus W_{m-1} \oplus W_m$$



как сумма пространства V_m и дополнения к нему W_m (базис пространства W_m образуют вейвлеты $\psi_{m,k}(x)$), т.е. $V_{m+1} = V_m \otimes W_m$ (см. рис 2.1).

Рисунок 2.2 – Физический смысл процесса разложения пространств ВП

Тогда, произвольную функцию $f(x) \in L^2(\mathbf{R})$ можно аппроксимировать последовательностью функций $f_m(x) \in V_m$ в соответствии с зависимостью, которая хорошо согласуется с моделью (2.2) [84]

$$f(x) = \sum_{k=-\infty}^{\infty} c_{m,k} \varphi_{m,k}(x) + \sum_{m=m'}^{\infty} \sum_{k=-\infty}^{\infty} w_{m,k} \psi_{m,k}(x), \quad m, k \in \mathbf{R}, \quad (2.3)$$

где $c_{m,k}$, $w_{m,k}$ – аппроксимирующие и детализирующие вейвлет-коэффициенты (ВК);

m, k – параметры масштаба и сдвига в пространстве целых чисел \mathbf{R} .

Такое представление вейвлет-модели изображения двумерного ВП I (матрица яркости пикселей $n \times n$) примет вид

$$I(x, y) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} c_{j,k} \varphi \varphi(x, y) + \sum_{i=0}^{\infty} \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} (w_{1j,k}^{(i)} \varphi \psi_{j,k}^{(i)}(x, y) + w_{2j,k}^{(i)} \psi \varphi_{j,k}^{(i)}(x, y) + w_{3j,k}^{(i)} \psi \psi_{j,k}^{(i)}(x, y)), \quad (2.12)$$

Используя понятия теории фильтрации (2.12) представляет собой свертку с низкочастотным $g(n)$ и высокочастотным $h(n)$ фильтрами с прореживанием результата вдвое. Тогда расчет низкочастотных c_i и высокочастотных w_i коэффициентов дискретного вейвлет-преобразования (ДВП) изображения можно реализовать по зависимостям [32, 47, 62, 84]:

$$c_i = \sum_{k=1}^n I_{2i+k} \cdot g_k, \quad (2.13)$$

$$w_i = \sum_{k=1}^n I_{2i+k} \cdot h_k. \quad (2.14)$$

Выражения (2.5), (2.6) обеспечивают выполнение быстрого ДВП одномерного числового ряда на основе пирамидального алгоритма вычисления вейвлет-коэффициентов (алгоритм Маллата) [15, 62], приведенного на рисунке 2.3.

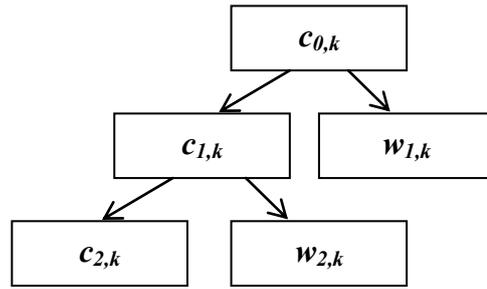


Рисунок 2.3 – Алгоритм Маллата

Сущность операций алгоритма Маллата заключается в следующем. С учетом коэффициентов h_n и g_n (рис. 2.3), на первом этапе преобразования первый цифровой фильтр h_n из числового ряда $f_k = c_{0,k}$ выделяет низкие частоты $|\omega| \leq \pi/2$, а другой (октавный) фильтр g_n выделяет верхние частоты $\pi/2 \leq |\omega| \leq \pi$. Поскольку на выходе фильтра h_n отсутствует верхняя половина частот, то частота дискретизации выходного изображения может быть уменьшена в 2 раза, т.е. выполнена децимация выходного массива, что и производится по зависимости (2.13) сдвигами $(2k+n)$ через 2 отсчета по входному массиву. Соответственно, на выходе фильтра g_n освобождается место в области низких частот, и аналогичное прореживание выходного числового массива приводит к транспонированию верхних частот на освободившееся место. Следовательно, каждый из выходных числовых массивов несет информацию о своей половине частот, при этом выходная информация представлена таким же количеством отсчетов, что и входная.

При таком описании процессов ДВП изображений особый интерес представляет вейвлет Хаара, так как в ДВП соответствующие низкочастотный (аппроксимирующих) и высокочастотный (детализирующих) фильтры состоят из коэффициентов $g = \begin{bmatrix} 1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix}$, $h = \begin{bmatrix} 1/\sqrt{2} & -1/\sqrt{2} \end{bmatrix}$. Отсюда, вычисление низкочастотных и высокочастотных вейвлет-коэффициентов реализуется в виде:

$$c_i = \frac{1}{\sqrt{2}} (I_{2i} + I_{2i+1}), \quad (2.15)$$

$$w_i = \frac{1}{\sqrt{2}} (I_{2i} - I_{2i+1}), \quad (2.16)$$

Поэтому в качестве базисного вейвлета в задачах идентификации и распознавания поверхностных дефектов выбран вейвлет Хаара.

При вычислении двумерного ДВП изображения сначала выполняется преобразование по строкам, а затем по столбцам [2,13]. Для преобразования каждого следующего уровня применяется схема разложения для матрицы W_{LL} (см. рис. 2.1)

Значения элементов матрицы яркости I лежат в диапазоне от 0 до 255. Тогда при ВП одного уровня разложения изображения максимальные значения высокочастотных и низкочастотных коэффициентов могут возрасти в 4 раза (при суммировании – в 2 раза при горизонтальном преобразовании и в 2 раза при вертикальном). Соответственно на 3-ем уровне преобразования максимальные значения могут возрасти в $2^8=256$ раз. Поэтому, для расчета целочисленных значений коэффициентов достаточно использовать двухбайтные числа [47, 48].

Современные процессоры позволяют использовать команды для оперирования векторами по 128 бит, то есть по 8 двухбайтных чисел [94, 97, 103, 107].

Тогда ВП по строкам матрицы яркости I изображения вида

$$I = \begin{bmatrix} I_{1,1} & I_{1,2} & \dots & I_{1,n} \\ I_{2,1} & I_{2,2} & \dots & I_{2,n} \\ \dots & \dots & \dots & \dots \\ I_{n,1} & I_{n,2} & \dots & I_{n,n} \end{bmatrix}, \quad (2.17)$$

можно представить в виде матрицы пакетов пикселей

$$I = \begin{bmatrix} V_{1,1..8} & V_{1,9..16} & \dots & V_{1,n-7..n} \\ V_{2,1..8} & V_{2,9..16} & \dots & V_{2,n-7..n} \\ \dots & \dots & \dots & \dots \\ V_{n,1..8} & V_{n,9..16} & \dots & V_{n,n-7..n} \end{bmatrix}, \quad (2.18)$$

где $V_{i,j..k} = [I_{i,j}, I_{i,j+1}, \dots, I_{i,k}]$.

Отсюда расчет аппроксимирующих и детализирующих вейвлет-коэффициентов по строкам можно представить в виде

$$c_{i,j..j+7} = ((V_{i,2j..2j+7} + (V_{i,2j..2j+7} \ll 1)) \downarrow) + \\ + ((V_{i,2j+8..2j+15} + (V_{i,2j+8..2j+15} \ll 1)) \downarrow \gg 4), \quad (2.19)$$

$$w_{i,j..j+7} = ((V_{i,2j..2j+7} - (V_{i,2j..2j+7} \ll 1)) \downarrow) + \\ + ((V_{i,2j+8..2j+15} - (V_{i,2j+8..2j+15} \ll 1)) \downarrow \gg 4), \quad (2.20)$$

где \gg , \ll – операции сдвига элементов вектора вправо и влево соответственно на $\gg 4$ и $\ll 1$ элементов;

\downarrow - обозначает операцию прореживания вдвое:

$$V_{i,j..j+7} \downarrow = [V_{i,j}, V_{i,j+2}, V_{i,j+4}, V_{i,j+6}, 0, 0, 0, 0] - \text{результат прореживания.}$$

Переход к операциям сложения, сдвига и прореживания при расчете вейвлет-коэффициентов приведет к значительному сокращению вычислительных операций при идентификации дефектов.

Матрицу ВП, полученную после преобразования по строкам, можно представить в виде матрицы векторов. Тогда расчет аппроксимирующих и детализирующих ВК ВП изображений по столбцам будет реализован в виде

$$c_{i.k,j} = V_{2i,j.k} + V_{2i+1,j.k}, \quad (2.21)$$

$$w_{i.k,j} = V_{2i,j.k} - V_{2i+1,j.k}, \quad (2.22)$$

Таким образом, получила развитие (модифицирована) вейвлет-модель изображения поверхности проката, отличающаяся от известных представлением изображения в виде **пакетов** пикселей для использования **векторных команд** процессора и переходом к **операциям сложения, сдвига и прореживания** при расчете вейвлет-коэффициентов для сокращения вычислительных операций идентификации дефектов.

2.4 Моделирование изображения поверхностного дефекта для задачи распознавания

2.4.1 Исследование моделей представления распознаваемого объекта

Модели представления распознаваемого объекта зависят от методов распознавания [79, 81]. Можно выделить следующие основные методы распознавания образов для задачи распознавания поверхностных дефектов:

Списки признаков. Методы данной категории основаны на возможности распознавания объектов на основе некоторых характерных признаков данных объектов. Существуют два основных подхода. Первый подход основан на предположении, что простые измерения, проводимые над изображением, есть результат действия совокупности небольшого числа порождающих признаков. В этом случае разработка метода распознавания сводится к определению пространства признаков, которые необходимо измерить. Пространство признаков в этом случае имеет меньшую размерность. При данном подходе используются методы факторного анализа [59].

Второй подход определяет признаки как подмножества множеств простых измерений. При распознавании бинарных изображений такими признаками могут служить число черных точек на характеристической линии, наличие черных точек в определённых областях т.д. Распознаваемые объекты представляются как различные совокупности наблюдаемых признаков [59].

Данный класс моделей использует в основном эвристические методы. Эффективность данных методов определяется правильностью выбора анализируемых признаков.

Структурное описание основывается на представлении объектов в виде совокупности «непроизводных элементов» и отношений между ними. Под непроизводными элементами понимаются фрагменты распознаваемых образов, которые формируют эти образы и являются простыми по собственной структуре, т.е. не содержат других непроизводных элементов, сколь-нибудь значимых для описания образа [39].

Как правило, системы, использующие структурное описание объектов, реализуют последовательную процедуру распознавания. В процессе решения информационной задачи обрабатывается входной образ, обходя его структуру элемент за элементом. Процесс распознавания делится на два потока: выделение структурных элементов определенного вида в образе и согласование получаемой информации о структуре с моделями для классов изображений, имеющимися в системе [39].

Одним из видов структурных методов являются методы грамматической классификации образов. Представление образов осуществляется в виде предложений специального языка. При этом требуется определить виды возможных структурных элементов изображений на этапе инициализации алгоритма. Построение правила классификации сводится к выводу грамматики, описывающей язык классифицируемых образов. Распознавание заключается в определении возможности вывода рассматриваемого предложения с помощью определенной грамматики [39].

Таким образом, наиболее приемлемым для задачи распознавания поверхностных дефектов признается структурное описание признакового пространство объектов распознавания.

2.4.2 Модель изображения в виде расширенного вектора признаков

Для распознавания дефектов структурными методами используется модель в виде вектора признаков. Для получения вектора признаков над первичным представлением распознаваемого образа производится серия вычислений, определяющих необходимые для классификации показатели.

Каждой такой показатель, называемой признаком, ставится в соответствие порядковый номер [48, 70, 81]. Таким образом, признаки образуют вектор

$$u = \{u_1, u_2, \dots, u_n\}, \quad (2.23)$$

где n – число признаков

u_i – значение i -го признака, $i \in \overline{1, n}$.

Для решения задачи распознавания дефектов предлагается в дополнении к спектральным признакам, извлекаемым из вейвлет-модели детализирующих ВК области дефекта (ОД) w_z^i , где i – уровень разложения, $1 \leq i \leq 3$, z – направление преобразования, $Z \in \{LH, HL, HH\}$, сформировать оптические и геометрические признаки.

Для расчета значений геометрических признаков $P_{def}, S_{def}, q_{def}, m, \sigma$ формируется матрица ОД Map , в которой пикселям, принадлежащим ОД, соответствуют значения равные единице, а пикселям, относящимся к текстурной области – значения, равные нулю.

Для определения оптических признаков $P_{def}, S_{def}, q_{def}, m, \sigma$ необходимо использовать матрицу яркости I (исходная матрица изображения).

После извлечения признаков модель изображения для задачи распознавания принимает вид вектора:

$$u = \left(P_{def}, S_{def}, q_{def}, m, \sigma, mw_{HL}^1, mw_{LH}^1, mw_{HH}^1, mw_{HL}^2, mw_{LH}^2, mw_{HH}^2, mw_{HL}^3, mw_{LH}^3, mw_{HH}^3, \sigma w_{HL}^1, \sigma w_{LH}^1, \sigma w_{HH}^1, \sigma w_{HL}^2, \sigma w_{LH}^2, \sigma w_{HH}^2, \sigma w_{HL}^3, \sigma w_{LH}^3, \sigma w_{HH}^3 \right), (2.24)$$

Таким образом, для решения задачи распознавания предложено использовать модель изображения поверхностного дефекта в виде вектора признаков, отличающегося расширенным информационным полем классификации дефектов на основе спектральных, пространственных и оптических метрик признаков, обеспечивающих повышение достоверности распознавания класса дефекта.

Выводы по разделу

1. Принята гипотеза о спектральном описании оцифрованного изображения как наиболее приемлемого для решения задачи выделения структурных элементов (поверхностных дефектов) с учетом заданных требований.

2. Предложена модель описания изображения тонколистового проката с поверхностными дефектами на основе вейвлет – разложения изображения в

виде суммы двух компонент – текстурной компоненты и медленно меняющегося поля дефектов.

3. Модифицирована вейвлет-модель изображения поверхности проката для задачи идентификации поверхностных дефектов, отличающаяся от известных представлением изображения в виде пакетов пикселей для использования векторных команд процессора и переходом к операциям сложения, сдвига и прореживания при расчете вейвлет-коэффициентов для сокращения вычислительных операций идентификации области дефектов.

4. Разработана модель изображения поверхности проката для задачи распознавания поверхностных дефектов, отличающаяся расширенным информационным полем классификации дефектов на основе спектральных, пространственных и оптических метрик признаков для повышения достоверности распознавания класса дефекта.

3 Методический аппарат идентификации и распознавания поверхностных дефектов тонколистового проката

Для использования разработанных моделей представления изображений необходимо разработать серию методик их применения в задачах идентификации и распознавания.

На рисунке 3.1 представлена реализация концепции СКЗ идентификации и распознавания поверхностных дефектов, предложенная в разделе 1.4, на основе разработанных моделей изображения.



Рисунок 3.1 – Реализация концепции СКЗ идентификации и распознавания поверхностных дефектов тонколистового проката

3.1 Методика формирования изображения

Для формирования изображения в СКЗ используется линейная камера *Basler web ral2048* (рисунок 3.2) [115], обладающая следующими характеристиками: количество пикселей в строке $c = 1024$, частота съемки $f = 30$ кГц. Стандартная ширина прокатного листа составляет $w=600$ мм, погрешность $\Delta w = 10$ мм.

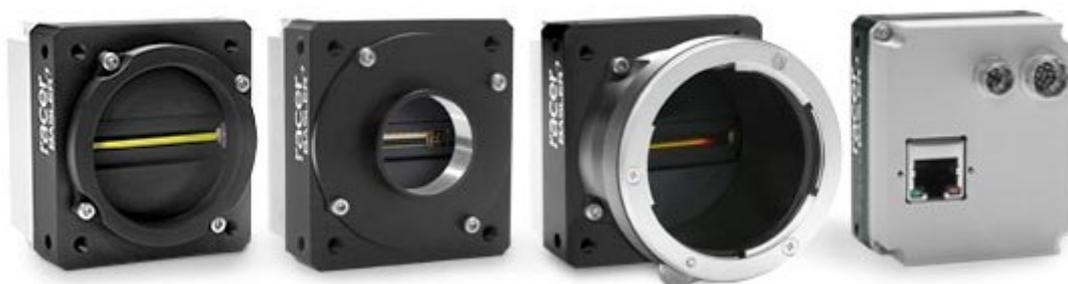


Рисунок 3.2 – Камера Basler web ral2048

Камера развернута таким образом, чтобы охватывать всю ширину листа проката. Для охвата всей площади поверхности на прокатном стане устанавливаются две камеры – фиксирующие верхнюю и нижнюю стороны прокатного листа соответственно. Схема размещения камер представлена на рисунке 3.3

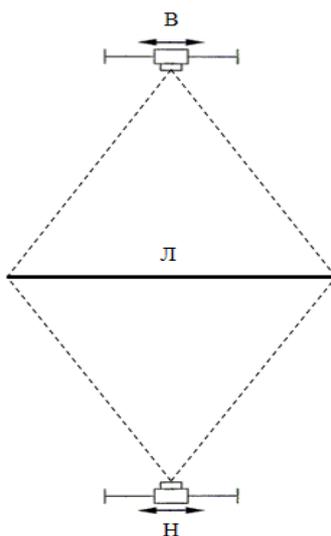


Рисунок 3.3 – Схема размещения камер

(Л – лист проката, В и Н – верхняя и нижняя камеры)

Тогда стороне одного пикселя соответствует размер:

$$l_{pixw} = \frac{b}{c}, \quad (3.1)$$

где b – ширина прокатного листа;

c – число пикселей в строке.

Для продукции тонколистового проката $l_{pixw} = \frac{600}{1024} = 0,586$ мм.,

Для оценки размеров пикселя в направлении движения листа необходимо учитывать скорость движения листа. При движении листа со скоростью v смещение листа за время съемки одного кадра примет вид:

$$dl_{pixl} = \frac{v}{f}. \quad (3.2)$$

где f – число пикселей в строке.

Если $v = 8$ м/с = 8000 мм/с, то $dl_{pixl} = \frac{8000}{30000} = 0,267$ мм.

С другой стороны, учитывая что длина, захватываемая одним пикселем $l_{pixw} = 0,586$ мм, в 2 раза больше, чем смещение листа $dl_{pixl} = 0,267$ мм (рисунок 3.4), при формировании изображения можно пропускать k строк:

$$k = \left\lfloor \frac{l_{pixw}}{dl_{pixl}} - 1 \right\rfloor \quad (3.3)$$

где $k = \left\lfloor \frac{0,586}{0,267} - 1 \right\rfloor = 1$ строку пикселей ($\lfloor x \rfloor$ обозначает округление вниз до целого).

При таком способе формирования изображения, длина листа, соответствующая одному пикселю равна:

$$dl_{pixl}' = v \cdot t \cdot (k + 1). \quad (3.4)$$

При этом $dl_{pixl}' \approx l_{pixl}$.

Очевидно, что количество пропускаемых кадров k должно быть неотрицательным. Это возможно только при условии $dl_{pixl}' \leq l_{pixl}$.



Рисунок 3.4 – Области проката, попадающие в 4 последовательных кадра

Из (3.1), (3.2) следует $v \cdot t \leq \frac{b}{c}$.

Отсюда можно рассчитать максимально возможную скорость проката, при которой не будет потерь информации

$$v \leq \frac{b}{c \cdot t}. \quad (3.5)$$

Для используемой линейной камеры

$$v \leq \frac{600 \cdot 30000}{1024} = 17578,125 \text{ мм/с} \approx 17,6 \text{ м/с}.$$

Данное ограничение максимальной скорости соответствует требованиям к разрабатываемой СКЗ распознавания дефектов. Следовательно, камера *Basler web ral2048* применима для распознавания поверхностных дефектов в требуемом временном диапазоне.

Для цифровой обработки используются кадры изображения размером 1024*1024 пикселя. Поэтому для формирования такого изображения необходи-

мо накопить 1024 кадра линейной камеры. Укрупненный алгоритм формирования изображения представлен на рисунке 3.5

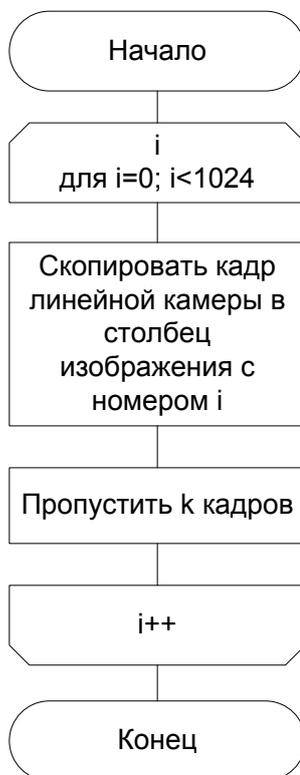


Рисунок 3.5 – Укрупненная схема алгоритма формирования изображения из кадров линейной камеры

При таком способе формирования кадра время обработки одного изображения из 1024 строк для скорости проката 8 м/с должно быть менее 0,0683 с.

Таким образом, предложена методика формирования изображения проката с линейной видеокамеры, отличающаяся пропуском части кадров, содержащих дублирующую информацию, что позволяет СКЗ идентифицировать дефекты на потенциально возможных скоростях проката.

3.2 Методика идентификации поверхностных дефектов

Сформированное изображение проката подвергается двумерному вейвлет-разложению. Для идентификации поверхностных дефектов к каждой из детализирующих четвертей преобразования на каждом уровне разложения изображения применяется пороговый фильтр. Однако, вследствие влияния шу-

мов от технологической смазки, коэффициенты ВП необходимо предварительно отфильтровать.

3.2.1 Исследование алгоритмов фильтрации изображений

В цифровой обработке двумерных сигналов широко используется масочная фильтрация [32, 47]. Масочная фильтрация является двумерной фильтрацией с конечной импульсной характеристикой (КИХ) фильтра. Маска представляет собой множество весовых коэффициентов, которые заданы во всех точках окрестности S , которые обычно симметрично окружают текущую точку кадра.

На практике чаще всего используется окрестность являющаяся квадратом 3×3 , в центре которого находится текущий элемент. Возможно применение различных масок. Одним из эвристических вариантов является равномерная маска, для которой все весовые коэффициенты равны $1/9$. В этом случае сохраняется средняя яркость изображения. Применение фильтрации существенно снижает уровня шума изображения.

Линейная пространственная фильтрация. Пространственная фильтрация двумерного сигнала $f(x,y)$ позволяет применять фильтры с КИХ [5, 73].

Пространственная фильтрация осуществляется как двумерная свертка импульсной характеристики фильтра $h(s,t)$ с двумерным сигналом изображения $f(x,y)$, где t – координата характеристики в вертикальном направлении вдоль оси y , $t \in [-m/2, m/2]$, s – координата характеристики в горизонтальном направлении вдоль оси x , $s \in [-n/2, n/2]$:

$$g(x,y) = f(x,y) \otimes h(x,y) = \sum_{t=-m/2}^{m/2} \sum_{s=-n/2}^{n/2} f(s,t)h(x-s,y-t) = \sum_{t=-m/2}^{m/2} \sum_{s=-n/2}^{n/2} f(x-s,y-t)h(x,y) \quad (3.6)$$

Маской фильтра называется прямоугольная область размером $m \times n$, на которой задана импульсная характеристика.

Элементы импульсной характеристики фильтра и соответствующей области изображения для случая $m=3$, $n=3$ представлены на рисунке 3.6. Начало координат фильтра устанавливается в центр импульсной характеристики. Отклик

фильтра $g(x,y)$ рассчитывается как сумма произведений отсчетов изображения на соответствующие отсчеты повернутой импульсной характеристики. Данная операция выполняется для каждого отсчета изображения.

	$s = -1$	$s = 0$	$s = 1$		$s = -1$	$s = 0$	$s = 1$
$t = -1$	$f(-1,-1)$	$f(0,-1)$	$f(1,-1)$		$h(1,1)$	$h(0,1)$	$h(-1,1)$
$t = 0$	$f(-1,0)$	$f(0,0)$	$f(1,0)$		$h(1,0)$	$h(0,0)$	$h(-1,0)$
$t = 1$	$f(-1,1)$	$f(0,1)$	$f(1,1)$		$h(1,-1)$	$h(0,-1)$	$h(-1,-1)$

Рисунок 3.6 – Положение отсчетов импульсной характеристики

В случае, когда импульсная характеристика фильтра симметрична, вместо свертки можно использовать корреляционную оценку:

$$g(x, y) = f(x, y) \otimes h(x, y) = \sum_{t=-m/2}^{m/2} \sum_{s=-n/2}^{n/2} f(x+s, y+t)h(x, y). \quad (3.7)$$

Данная операция представляет собой расчет в маске фильтра, скользящей по двумерному изображению, суммы произведений коэффициентов фильтра на соответствующие отсчеты двумерного изображения (рисунок 3.7).

Нелинейная пространственная фильтрация. Сглаживающие линейные фильтры не только подавляют шумы, но также размывают границы между областями с разной амплитудой сигнала изображения. Для уменьшения эффекта «смаза» границ используются нелинейные фильтры. Нелинейные КИХ фильтры, как и линейные фильтры, работают в скользящем окне. Но нелинейные фильтры основаны на нелинейных преобразованиях отсчетов в окрестности элементов, определяемой маской фильтра.

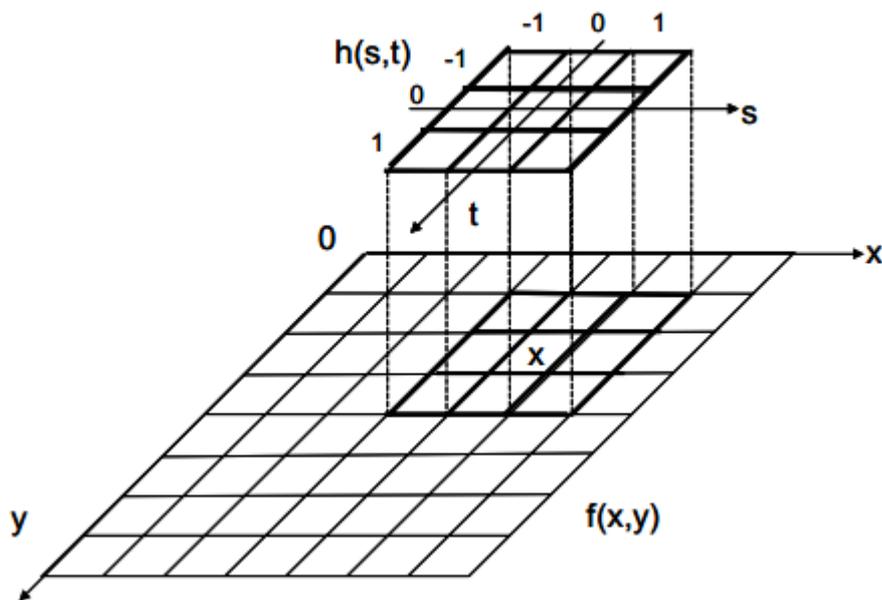


Рисунок 3.7 – Корреляционная оценка двумерного изображения $f(x,y)$ с маской $h(s,t)$

Медианный фильтр. Медианный фильтр (МФ), предложенный Тьюки [116] в 1974 г., заменяет центральный элемент маски медианой упорядоченной (по возрастанию или по убыванию амплитуды) выборки, сформированной из всех амплитуд отсчетов, покрываемых маской фильтра. При медианной фильтрации используется скользящее двумерное окно. Для каждого отсчета выполняется оценка медианы в окне [86]. Для ускорения оценки целесообразно использовать ранее выполненные вычисления алгоритмически на каждом шаге. Размер окна принимается нечетным и равным $m \times n$. Оказавшиеся в пределах окна отсчеты изображения образуют обрабатываемую выборку текущего отсчета. При упорядочивании последовательности $\{f_i, i=[1, mn]\}$ по возрастанию, ее медианой будет являться элемент выборки, занимающий центральное положение в этой упорядоченной последовательности. Этот элемент является результатом медианной фильтрации в текущей точке изображения [86]. Формальное обозначение описанной процедуры $g_{med} = med(f_1, f_2, \dots, f_n)$.

Таким образом, действие МФ состоит в игнорировании как отрицательных, так и положительных выбросов. Медианная фильтрация лучше сохраняет границы между областями двумерного сигнала, чем любая линейная фильтрация [83].

Импульсная помеха, размер которой меньше или равен $mn/2$, медианным фильтром подавляется, а резкие изменения амплитуды сохраняются.

Рассмотренные фильтры исследованы на эффективность подавления шумов в вейвлет-коэффициентах [47]. Наилучшие результаты при этом получены с использованием медианного фильтра.

3.2.2 Методика фильтрации и бинаризации вейвлет-коэффициентов

Отклик медианного фильтра в окне для каждой четверти z детализирующих ВК на каждом уровне разложения вычисляется по формуле:

$$w_{\Phi Z}^i(x, y) = med \{w_z^i(x + m, y + n) : m = -1, 0, 1; n = -1, 0, 1\}, \quad (3.8)$$

где w_z^i – матрицы ВК i -м уровне, $i=1, 2, 3$, до применения фильтра;

$w_{\Phi Z}^i$ – матрицы ВК после применения фильтра.

Для определения элементов матриц, лежащих на границе дефекта предлагается выполнить бинаризацию по динамическому порогу.

Бинаризация осуществляется по принципу:

$$w_{BZ}^i(x, y) = \begin{cases} 1, w_z^i(x, y) \geq threshold^i_Z \\ 0, w_z^i(x, y) < threshold^i_Z \end{cases}, \quad (3.9)$$

с порогом значений вейвлет-коэффициентов

$$threshold^i_Z = 3 \sqrt{\frac{1}{nw} \sum_{x=1}^{nw} \sum_{y=1}^{nw} (w_{\Phi Z}^i(x, y) - mw_{\Phi Z}^i)^2}, \quad (3.10)$$

где $w_z^i(x, y)$ – КВП на уровне i в четверти z ;

$mw_{\Phi Z}^i$ – среднее значение КВП на уровне i в четверти z ;

nw – размерность матриц w_{BZ}^i , $nw = n / 2^i$;

n – размерность матрицы изображения, $n = 1024$.

Результат идентификации поверхностного дефекта класса «Отверстие» представлен на рисунке 3.8

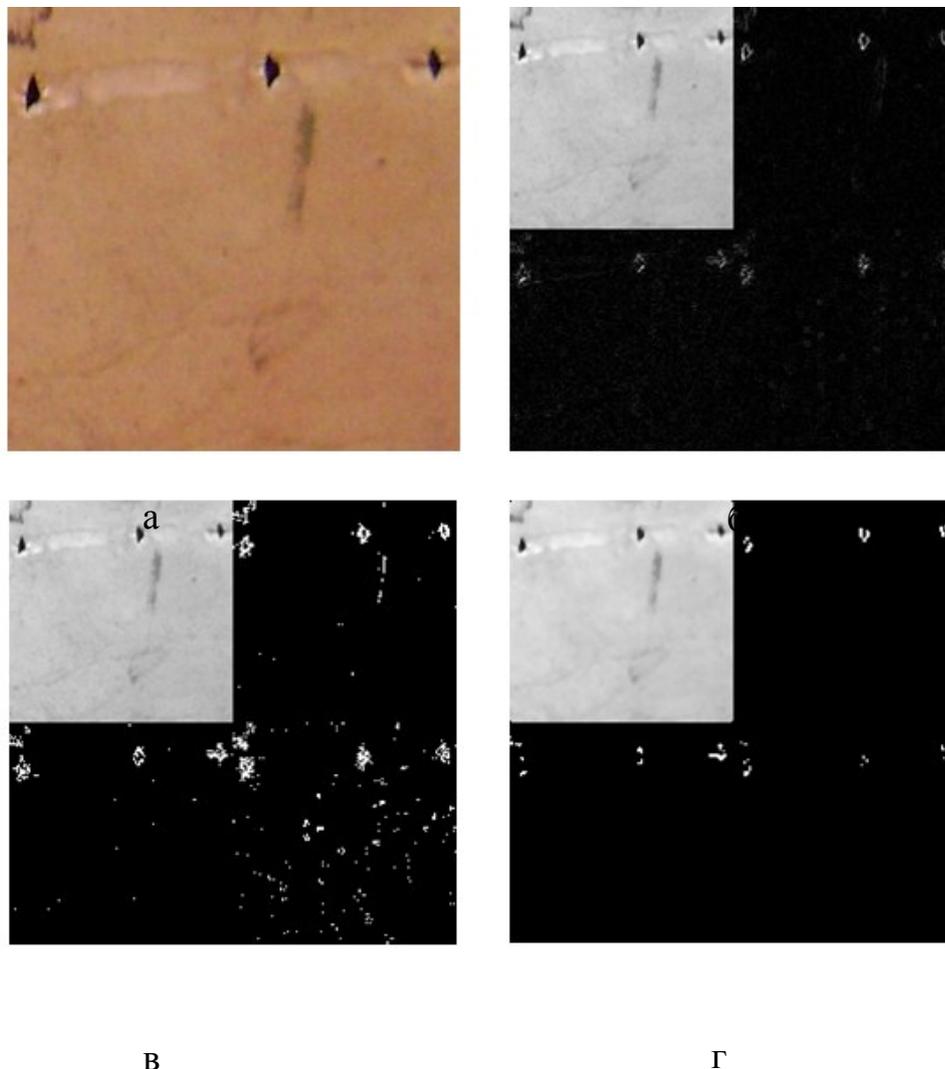


Рисунок 3.8 – Идентификация поверхностных дефектов (а – исходное изображение, б – результат вейвлет-преобразования, в – бинаризация без фильтров, г – бинаризация с использованием медианного фильтра)

Для определения минимального уровня разрешения для идентификации различных типов поверхностных дефектов исследована эффективность работы предложенного алгоритма ВР. Исследования проводились для неустранимого дефекта «Отверстие» и устранимого дефекта «Мягость». На рисунках 3.9, 3.10 представлены результаты работы алгоритма ВП (а – исходное изображение, б – результат ВП).

Анализ результатов показал, что для идентификации дефекта «Отверстие» достаточно одного уровня вейвлет-разложения изображения, а дефект «Мягкость» необходимо три уровня преобразования [47].

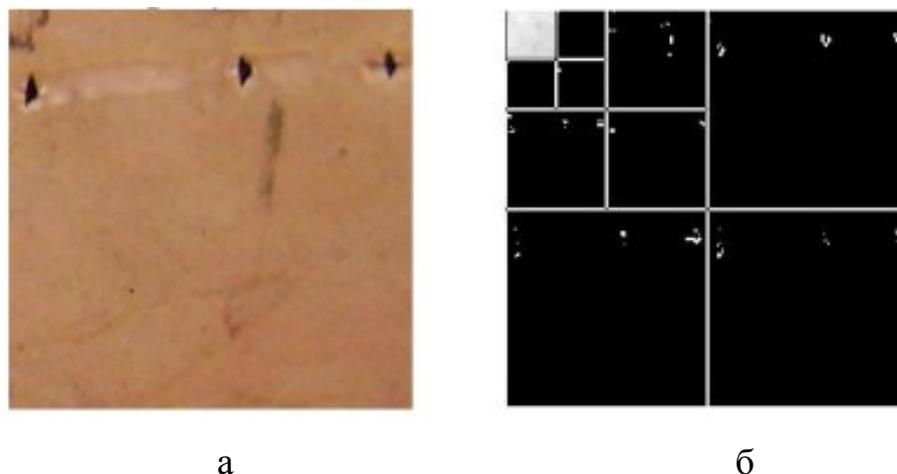


Рисунок 3.9 – Результат обнаружения для дефекта «Отверстие»

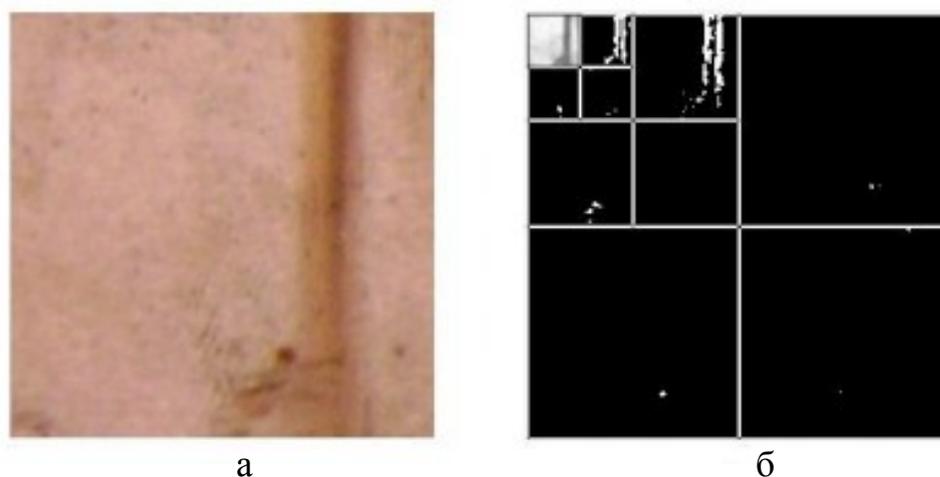


Рисунок 3.10 – Результат обнаружения для дефекта «Мягкость»

Поэтому, для обнаружения поверхностных дефектов достаточно трех уровней преобразования исходного изображения, причем неустраняемые дефекты выявляются после первого шага. На более высоких уровнях преобразования проявляются особенности текстурной компоненты изображения.

Таким образом, предложена методика идентификации поверхностных дефектов, отличающаяся от известных медианной фильтрацией ВК для устранения помех от технологической смазки с пороговой бинаризацией для определения

числа уровней вейвлет-разложения изображения, позволяющие идентифицировать поверхностные дефекты листового проката.

3.2.3 Методика ускорения работы медианного фильтра

Предложенная методика вейвлет-разложения (ВР) изображений позволяет идентифицировать дефекты листового проката. Для изображения размером 1.5 мегапикселя время работы такого алгоритма на компьютере с конфигурацией Intel Core i7 3.0 ГГц, 4 GB RAM составляет в среднем 1.1 секунды, что не позволяет применять алгоритм для обработки видеоряда (25 изображений 1024x1024 пикселя в секунду) в реальном времени. Существенную часть времени при этом занимает работа медианного фильтра (1.06 с.). Поэтому необходимо ускорение алгоритма медианной фильтрации для обнаружения дефектов в реальном времени. Реализация медианного фильтра при помощи гистограмм, предложенная в [16,117], позволяет сократить время работы медианного фильтра до 0.45 с.

Для ускорения работы алгоритма фильтрации ВК предложен алгоритм обнаружения, состоящий из трех основных этапов: двумерное вейвлет-преобразование до третьего уровня, применение медианного фильтра к ВК и определение ВК, больших, чем утроенное их СКО. Если величина ВК больше половины количества элементов в окне фильтра, тогда медиана больше, чем утроенное СКО. Реализованный таким образом медианный фильтр срабатывает за 0,1 с., что является недостаточным для работы алгоритма в реальном времени.

Для дальнейшего ускорения работы медианного фильтра применяется распараллеливание алгоритма обнаружения [111] в сочетании с использованием векторных команд процессора из набора SSE2. Технология SSE2 включает в архитектуру процессора восемь 128-битных регистров и набор инструкций, работающих с векторами значений [51, 66, 67].

На рисунке 3.11 представлен алгоритм фильтрации ВК при обнаружении дефектов с использованием векторных команд процессора.

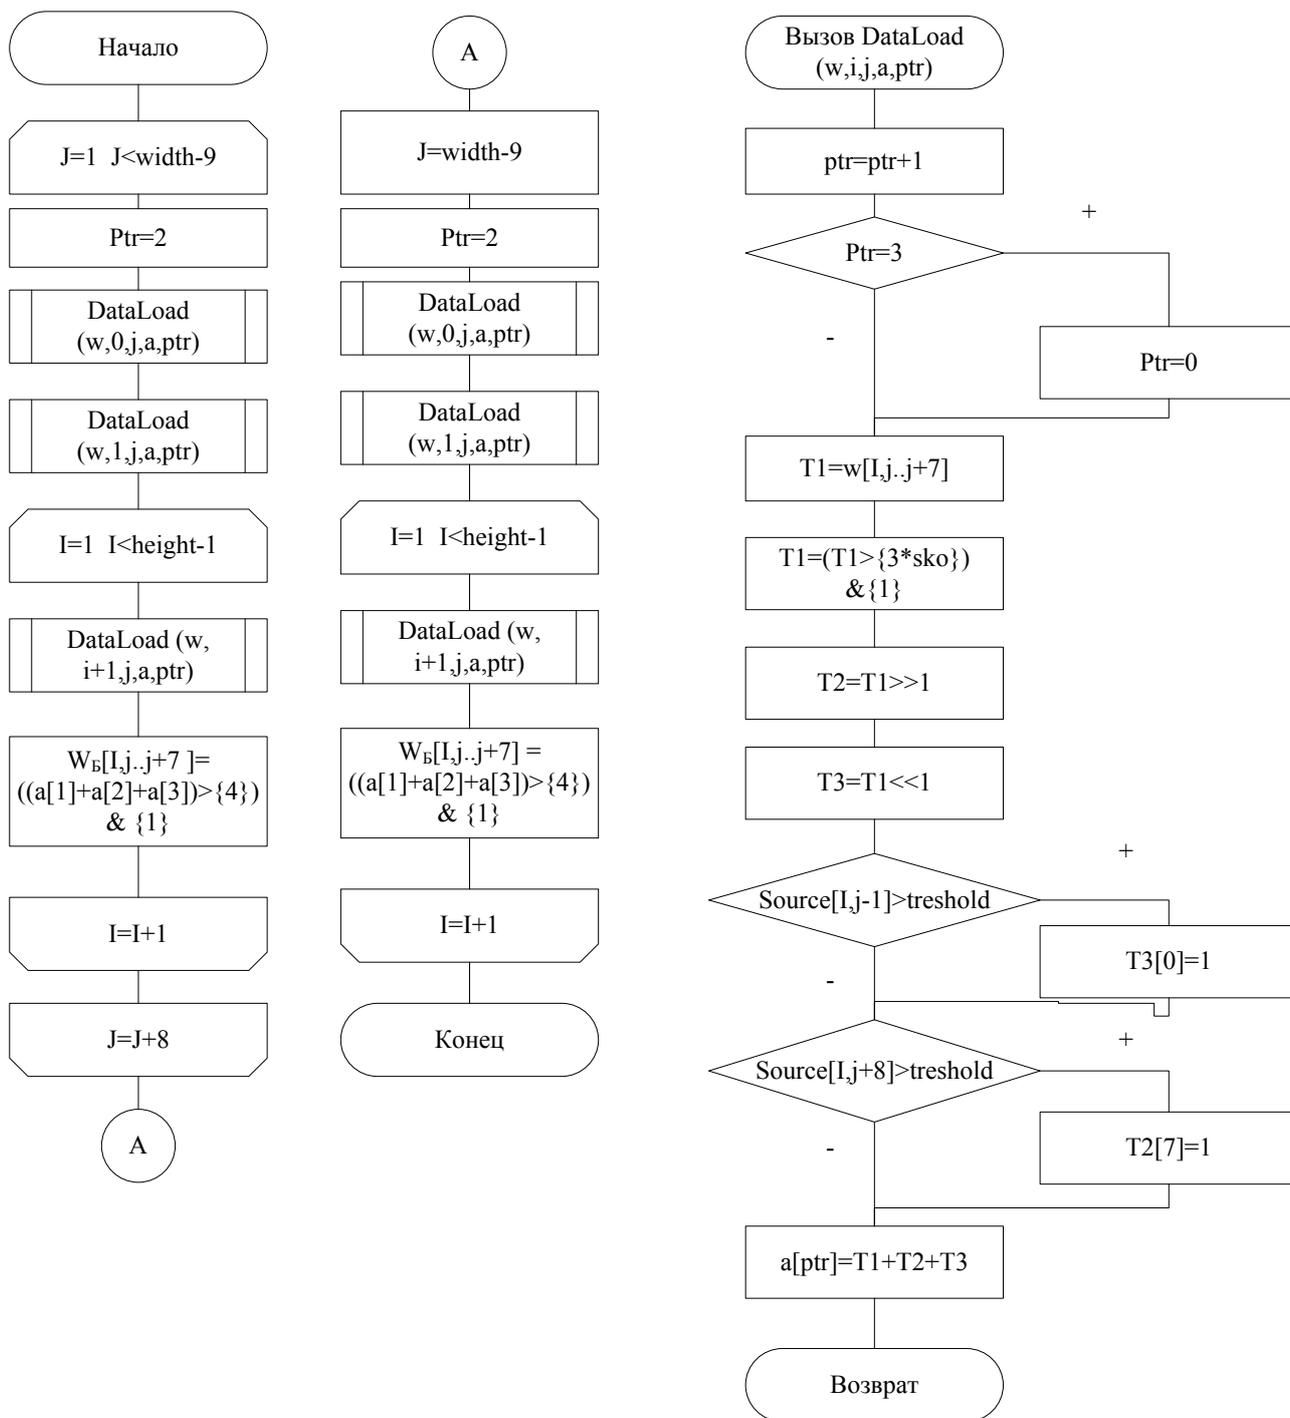


Рисунок 3.11 – Алгоритм фильтрации ВК при идентификации (обнаружении) дефектов на основе векторных команд процессора

Исследования проводились на компьютере с процессорами Intel Core i7 3.0 ГГц, 4 GB RAM для изображений 1.5 мегапикселя. Результаты работы различных вариантов реализаций фильтра приведены в таблице 3.1.

Таблица 3.1 – Результаты работы различных вариантов фильтрации

Реализация	Результат, с
С использованием сортировки	1.04
С использование гистограммы	0.45
С использованием сравнения медианы с утроенным СКО	0.1
С использованием векторных команд процессора	0.017
Сочетание ВКП и распараллеливания на два ядра	0.01

В результате распараллеливание на два ядра по технологии OpenMP [101] алгоритма медианной фильтрации позволяет осуществлять фильтрацию за 0.01с, что приемлемо для обнаружение дефектов в реальном времени.

Таким образом, предложенные алгоритмы идентификации позволяют распараллелить часть цифровой обработки изображений и, в сочетании с использованием векторных команд процессора, обеспечить идентификацию поверхностных дефектов в процессе производства.

3.2.4 Методика выделение областей поверхностных дефектов

В полученной матрице W_{BZ}^i (3.9) единицы соответствуют границе области дефекта. Полученные таким образом области значительно меньше по отношению к исходному изображения.

Для того чтобы восстановить границы области дефекта в масштабе исходного изображения, необходимо выполнить операцию слияния [101]:

$$Map(x, y) = \bigcup_{i=1}^3 \bigcup_{Z \in (LH, HL, HH)} w_{BZ}^i (\lfloor x / 2^i \rfloor, \lfloor y / 2^i \rfloor), \quad (3.11)$$

где $\lfloor \cdot \rfloor$ – округление в меньшую сторону.

В результате формируется матрица, отражающая область дефекта, в которой границе области соответствуют значения равные 1. Результат операции слияния представлен на рисунке 3.12(б).

Для объединения близкорасположенных частей границы дефекта в одну область используется операция утолщения границы по следующему правилу: если $Map(x,y)=0$ и существует $Map(x+m,y+n)=1$; $m \in -1,0,1$; $n \in -1,0,1$, то $Map(x,y):=2$.

Результат операции утолщения границы представлен на рисунке 3.12(в).

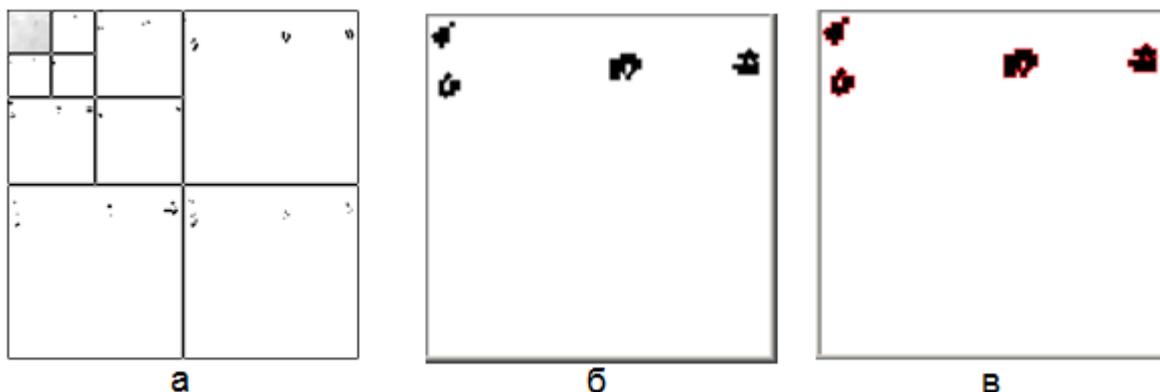


Рисунок 3.12 – Результаты операций бинаризации (а); слияния (б); утолщения границ (в)

С целью ограничения анализируемой ОД (карта дефектов) выделяются отдельные области на изображении (рисунок 3.13(а)):

1 Находится $Map(x,y) \neq 0$.

2 Начиная с этого элемента, выполняется поиск в ширину [44, 53, 111] для копирования объекта в отдельную матрицу М. На исходной карте дефектов объект при этом заполняется нулевыми значениями (стирается). Матрица М, в которую путем копирования выделяется объект, создается таким образом, чтобы крайние значения в матрице были равны нулю.

3 Повторяются пункты 1-2, пока на карте дефектов существуют элементы $Map(x,y) \neq 0$.

Далее отделяется текстурная компонента изображения от ОД. Для этого от крайнего пикселя $M(0,0)$ выполняется обход в ширину для значений равных 0 и их значение переопределяются на 3. Отсюда, можно разграничить пиксели с нулевым значением, расположенные вне ОД и внутри ОД.

Последним этапом методики формирования ОД является разделение границы дефекта и внутренней ОД (рисунок 3.13(б)). Выделение границы осуществляется по следующему принципу: если $M(x,y) = 3$ и существует $M(x+m,y+n)=1$; $m \in \{-1,0,1\}$; $n \in \{-1,0,1\}$, то $M(x,y)$ принимается равным 4.

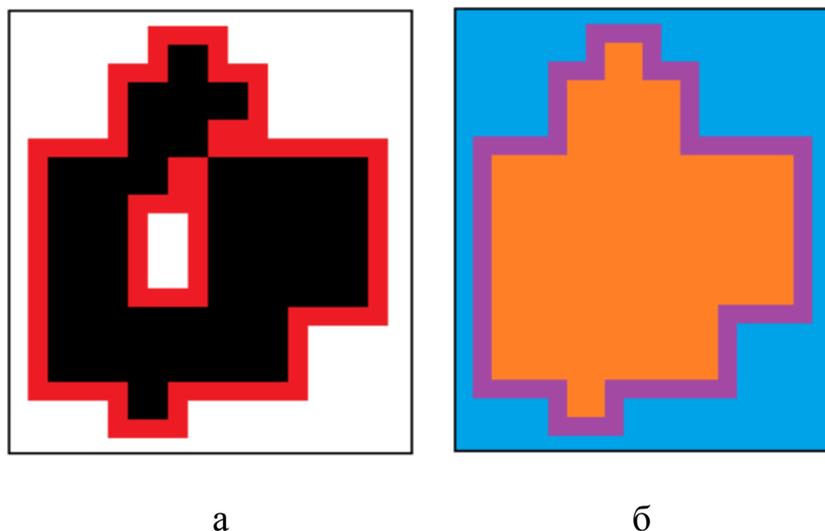


Рисунок 3.13 – Локализованный дефект (а); выделение границы и внутренней области дефекта (б)

Тогда внутреннюю ОД можно выделить по принципу: если $M(x,y) = 3$ и $M(x,y) = 4$, то $M(x,y)$ принимается равным 5.

Предложенная методика формирования ОД позволяет исключить текстурную компоненту модели изображения I (2.10) и определить пространственное положение дефекта.

Таким образом, предложена методика, позволяющая идентифицировать области дефектов по изображению и определить их пространственное положение.

3.3 Методика распознавания поверхностных дефектов

Критичным фактором при выборе метода распознавания поверхностных дефектов листового проката является скорость срабатывания алгоритма, так как распознавание должно производиться в процессе производства. Эффективное (в вычислительном отношении) использование распознающих алгоритмов пред-

полагает наличие некоторого аппарата оценки близости, не требующего сравнения распознаваемого объекта с каждым элементом обучающего набора. Одним из таких методов является метод окрестностей [29, 30]

3.3.1 Методика использования метода окрестностей в задаче распознавания поверхностных дефектов

В методе окрестностей степень выраженности каждого признака дефекта (объекта изображения) должна иметь 2^m градаций [29, 100], для чего выполняется отображение численных значений признаков на множество $\{0, 1, \dots, 2^m - 1\}$.

Отсюда, каждый распознаваемый объект $u = (u_1, \dots, u_N)$ можно интерпретировать как точку в гиперпространстве

$$D = \{u \in R^N : -2^{-1} \leq u_i \leq 2^m - 2^{-1}, 1 \leq i \leq N\}, \quad (3.12)$$

называемом пространством признаков (предполагается, что D охватывает любые возможные в задаче сочетания значений признаков).

Распознавание, т.е. указание принадлежности объекта к одному из классов Ω_v , осуществляется на основе принципа прецедентности или частичной прецедентности, т.е. путем оценки близости объекта к элементам заданного обучающего набора объектов, принадлежность которых к классам дефектов известна.

Первым шагом методика распознавания является построение системы окрестностей в пространстве D [29, 100]. Для этого необходимо выполнить:

1. Вводится вспомогательный гиперкуб

$$D_0 = \{u \in R^N : -2^{-1} \leq u_i \leq 2^{m+1} - 2^{-1}, 1 \leq i \leq N\}, \quad (3.13)$$

и набор отражений

$$g_n(u) = u - h_n, h_n = (2^{n-1}, \dots, 2^{n-1}) \quad (3.14)$$

порождающих набор образов

$$D_n = g_n(D_0), 1 \leq n \leq m + 1, \quad (3.15)$$

гиперкуба D_0 каждый из которых включает гиперкуб D , т.е.

$$D = D \cap D_n, 0 \leq n \leq m+1 \quad (3.16)$$

2. Вспомогательный гиперкуб D_0 делится на 2^N гиперкубов «первого разбиения» гиперплоскостями, параллельными координатным и проходящими через серединные точки его ребер, ортогональных к этим гиперплоскостям. Каждый из гиперкубов первого разбиения разбивается тем же приемом на 2^N гиперкубов второго разбиения. Последовательное разбиение продолжается до тех пор, пока не будут построены гиперкубы $m+1$ разбиения с длиной ребра, равной 1 [29, 100].

Необходимо отметить, что общее число подкубов l -го разбиения равно 2^{lN} и длины их ребер равны 2^{m+1-l} . Пример построенной системы окрестностей для случая $m=2, N=3$ представлен на рисунке 3.14.

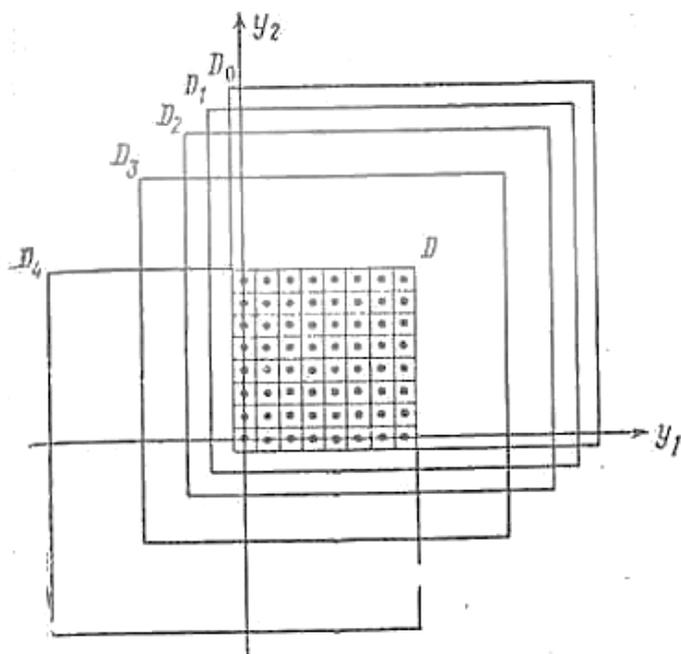


Рисунок 3.14 – Пример системы окрестностей для случая $m=2, N=3$

3.3.2 Особенности индексации подкубов и окрестностей

Для указания любого подкуба l -го разбиения, где $1 \leq l \leq m+1$, в [29] предлагается индексация подкубов на каждом уровне разбиения действительными числами x из интервала $[0,1]$ на основе кривых Пеано.

Однако при большом количестве признаков и числе градаций количество окрестностей на последних уровнях разбиения будет большим, чем 2^{64} . Соответственно, в программной реализации необходимо будет использовать так называемые «длинные числа», реализуемые через массивы значений, что приводит к значительному увеличению процессорного времени, необходимого для вычисления x [100].

В качестве альтернативы для индексации гиперкубов на каждом уровне разбиения можно использовать вектора значений $r=(r_1, \dots, r_N)$ [50]. Для этого необходимо выполнить деление отрезка $[-2^{-l}, 2^{m+1}-2^{-l}]$ на 2^l равных частей для каждого уровня разбиения l . Тогда для каждого уровня разбиения l получится упорядоченное множество отрезков. Такой подход при поиске требует выполнить большее количество сравнений, но не требует дополнительных вычислений

$$\begin{aligned} p_l = \{[a_i, b_i], a_i = -2^{-l} + (i-1) \cdot 2^{-(m+1)-l}, \\ b_i = -2^{-l} + i \cdot 2^{-(m+1)-l}, 1 \leq i \leq 2^l\}. \end{aligned} \quad (3.17)$$

В этом случае каждое из ребер любого из подкубов l -го разбиения соответствует одному из отрезков p_l . Вектор значений r для уровня разбиения l формируется по следующему принципу: если ребро гиперкуба, лежащее на оси координат признака y_j соответствует отрезку $[a_i, b_i]$, тогда $r_j=i$. Таким образом, подкуб l -го разбиения, соответствующий вектору r , будет обозначаться $D_0(l, r)$. Пример индексации окрестности представлен на рисунке 3.15.

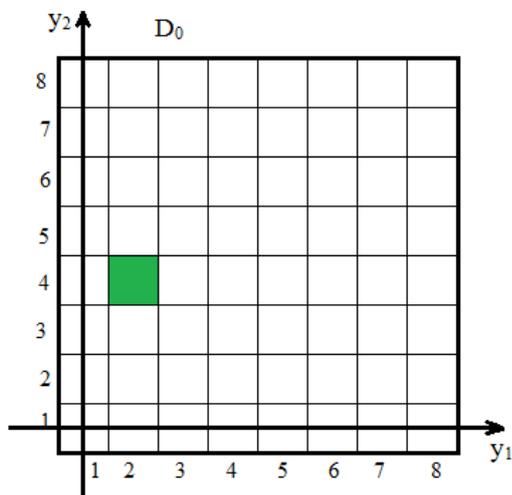


Рисунок 3.15 – Окрестность [2,4].

Отображения g_n из (3.13), порождающие сдвинутые образы D_n из (3.14) гиперкуба D_0 из (3.12), одновременно порождают и образы $D_n(l, z) = g_n(D_0(l, r))$ введенных элементов разбиения этого гиперкуба (рисунок 3.16). Принимается, что $D_0(0,0) = D_0, g_0(u) = u$ и вводится система окрестностей в пространстве D из (3.12) как набор непустых пересечений $D(l, r, n) = D \cap D_n(l, r)$, где $0 \leq l \leq m+1, 0 \leq n \leq m+1$.

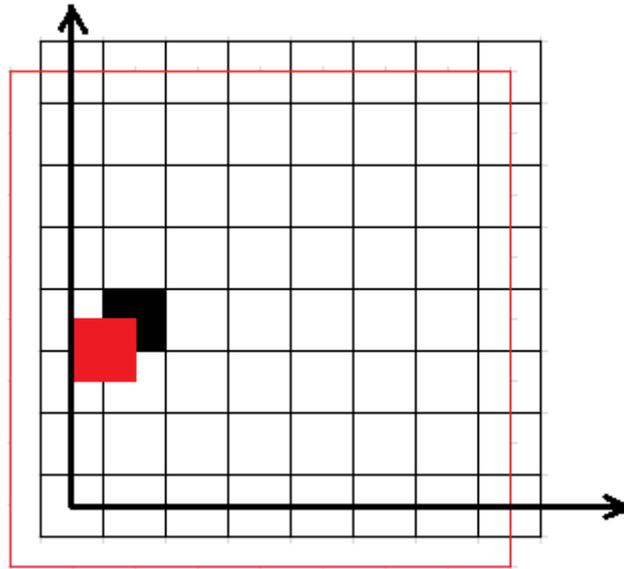


Рисунок 3.16 – Отображение окрестностей

Данная система окрестностей построена таким образом, что для любых двух точек x и y , для которых $\max(|x_i - y_i|) \leq 2^{m+1-l}$ на l -м разбиении существует хотя бы одна окрестность $D(l, z, n)$, содержащая точки x и y .

Полученная система окрестностей позволяет для любого распознаваемого объекта $u = (u_1, \dots, u_n)$ и уровня l определить соответствующую ему окрестность $D(l, r, 0)$. Для однозначного определения этой окрестности необходимо найти вектор z . Для этого в p_l осуществляется поиск отрезков $[a_i, b_i], 1 \leq i \leq 2^l$, такого, что $u_j \in [a_i, b_i]$ для каждого u_j . Вследствие того, что множество p_l является упорядоченным, нахождение соответствующего интервала можно вы-

полнить при помощи бинарного поиска [7,10,26]. При этом вектор r формируется на основе правила: если $u_j \in [a_i, b_i]$, то $r_j = i$.

Для определения соответствующих окрестностей $D(l, r, n)$, $1 \leq n \leq m + 1$, необходимо выполнить отображение g_n для множества признаков p_l

$$g_n(p_l) = \{[g_n(a_i), g_n(b_i), 1 \leq i \leq 2^l]\}. \quad (3.18)$$

После этого вектор z формируется аналогично случаю $n = 0$, за исключением того, что поиск отрезков осуществляется в отображении $g_n(p_l)$.

Таким образом, предложена система окрестностей в пространстве признаков для однозначной классификации дефектов в виде вектора и разработана методика определения классификационного вектора для распознаваемого объекта на каждом уровне разбиения в каждом из отображений вспомогательного гиперкуба.

3.4 Алгоритмизация процессов обучения и распознавания анализатора класса поверхностных дефектов

Нормирование признаков. Для использования метода окрестностей в задаче распознавания поверхностных дефектов необходимо признаки дефектов (2.16) нормализовать. Для каждого из изображений обучающей выборки рассчитываются величины признаков и определено их минимальное и максимальное значения. Для каждого из признаков отрезок $[\min, \max]$ разделен на $2m$ равных отрезков $[a_i, b_i]$, $0 \leq i \leq 2^m - 1$. Если соответствующее значение признака попадает в отрезок $[a_i, b_i]$, то его нормированное значение принимается равным i . Если значение признака меньше определенного минимального значения, то его нормированное значение принимается равным нулю. Если значение признака больше определенного максимального значения, то его нормированное значение принимается равным $2m-1$. Таким образом, выполняется отображение численных значений признаков на множество $\{0, 1, \dots, 2m-1\}$ [50].

Таким, образом, предложена методика отображения значений признаков на множество $\{0,1,\dots,2^m-1\}$, что позволяет использовать метод окрестностей, адаптированный для распознавания поверхностных дефектов.

Алгоритмизация обучения анализатора класса поверхностных дефектов. Разработана методика обучения анализатора класса дефектов на основе метода окрестностей, которая сводится к построению на основе набора образцов U для каждого уровня разбиения l , $0 \leq l \leq m+1$ и номера отображения n , $0 \leq n \leq m+1$ списка $List(l,n)$, содержащего объекты $\{r, \Omega_v\}$, упорядоченные по векторам r . При этом для векторов r^1 и r^2 принимается, что $r^1 = r^2$, если $r_i^1 = r_i^2, 1 \leq i \leq N$ и $r_i^1 < r_i^2$, если $\exists i : r_i^1 < r_i^2, 1 \leq i \leq N, \forall j < i, r_j^1 = r_j^2$ [50]. Матрица списков $List$ представлена в таблице 3.2.

Таблица 3.2 – Матрица списков $List$

Отображение гиперкуба, n	Уровень разбиения, l			
	1	2	...	$m+1$
1	$List_{1,1}$	$List_{1,2}$...	$List_{1,m+1}$
2	$List_{2,1}$	$List_{2,2}$...	$List_{2,m+1}$
...
$m+1$	$List_{m+1,1}$	$List_{m+1,2}$...	$List_{m+1,m+1}$

Схема алгоритма обучения анализатора класса поверхностных дефектов представлена на рисунке 3.17.

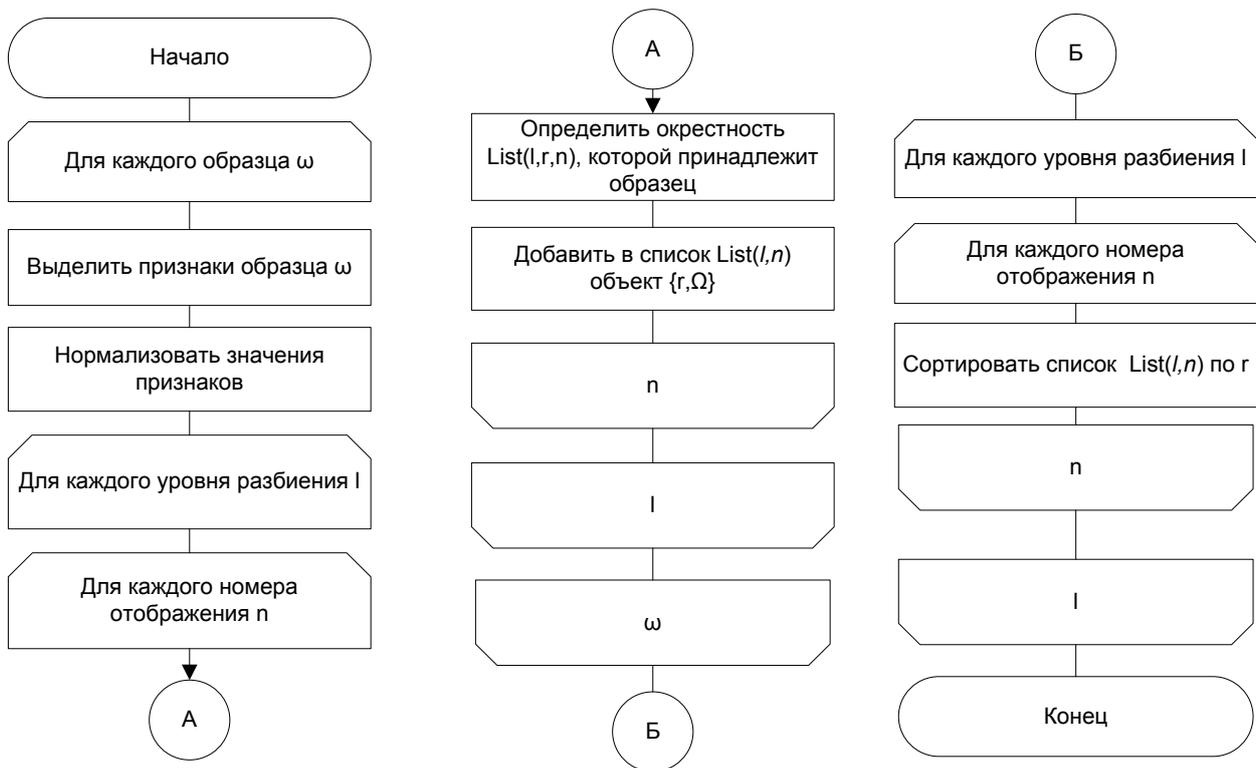


Рисунок 3.17 – Схема алгоритма обучения анализатора класс поверхностных дефектов

Таким образом, разработан алгоритм обучения анализатора класс поверхностных дефектов на основе использования адаптированного метода окрестностей.

Алгоритмизация распознавания анализатора класса поверхностных дефектов. Степень близости $L(u, u^j)$ объектов u и u^j будет характеризоваться максимальным значением номера разбиения l , $1 \leq l \leq m+1$, при котором существует некоторая окрестность $D(l, z, n)$, охватывающая узлы соответствующие этим объектам, т.е.

$$L(u, u^j) = \max \{ l : (\exists r, n), u, u^j \in D(l, r, n) \} \quad (3.19)$$

Тогда для распознавания объекта необходимо [29, 100]:

- 1) Найти максимальный уровень разбиения l , для которого существуют окрестности $D(l, r, n)$, охватывающие узлы, соответствующие распознаваемым

тому объекту и не менее чем s образцов (принято $s = 3$). Данный уровень разбиения обозначается, как $\tau(u)$.

2) Определить долю образцов γ_v , принадлежащих тем же окрестностям $D(l,r,n)$, которым принадлежит и распознаваемый объект, и относящихся к классу объектов Ω_v .

$$\gamma_v = \frac{\mu_v(u)}{\mu(u)}, \quad (3.20)$$

где $\mu(u)$ – количество образцов, принадлежащих тем же окрестностям $D(l,z,n)$, которым принадлежит и распознаваемый объект;

$\mu_v(u), 1 \leq v \leq q$ – количество образцов, принадлежащих тем же окрестностям $D(l,r,n)$, которым принадлежит и распознаваемый объект, и относящихся к классу объектов Ω_v .

3) Определить класс объекта на основе порогового решающего правила. В работе использовано следующее пороговое правило: объект ω относится к классу объектов Ω_v , если $\tau(u) \geq m - 2$ и $\gamma_v > 0.7$.

Укрупненная схема алгоритма распознавания поверхностных дефектов СКЗ представлена на рисунке 3.18.

Так как каждый из списков $List(l,n)$ является упорядоченным, можно выполнять поиск образцов, принадлежащих соответствующим окрестностям, при помощи известного алгоритма бинарного поиска.

Таким образом, выделены параметры распознавания, определено пороговое решающее правило и разработан алгоритм распознавания поверхностных дефектов листового проката на основе метода окрестностей.

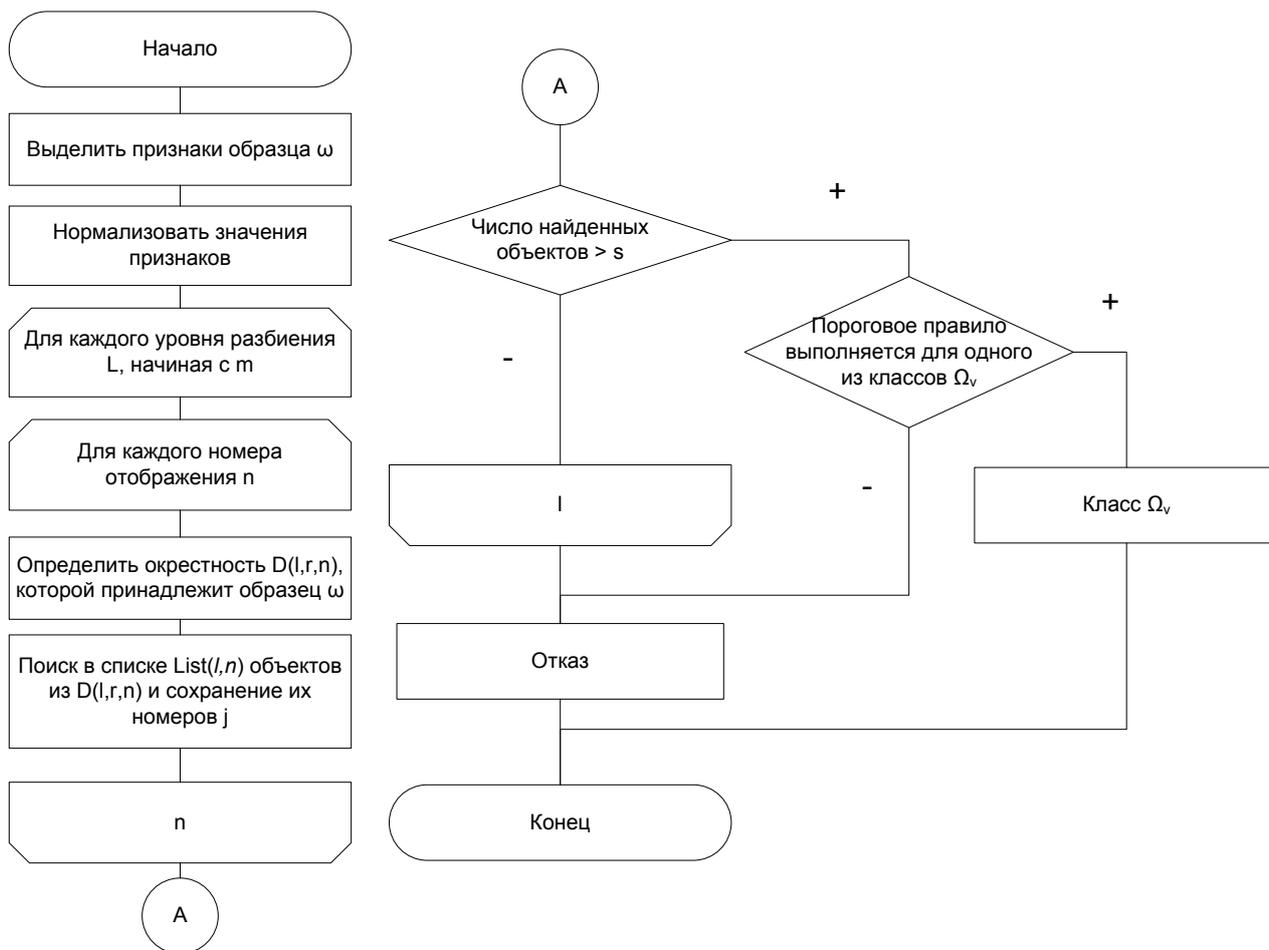


Рисунок 3.18 – Схема алгоритма распознавания дефектов

Выводы по разделу

1. Предложена методика формирования изображения проката с линейной видеокамеры, отличающаяся пропуском части кадров, содержащих дублирующую информацию, что позволяет СКЗ обнаруживать дефекты на потенциально возможных скоростях проката.

2. Исследованы основные методы фильтрации двумерных сигналов для подавления шумов в ВК и обоснован выбор в пользу медианного фильтра.

3. Разработана методика идентификации поверхностных дефектов, отличающаяся использованием медианного фильтра для подавления помех и бинаризацией матрицы ВК модели изображения по динамическому порогу, обеспечивающему пространственное выделение ОД для сокращения объема информации при решении задачи распознавания.

4. Предложена реализация алгоритма медианной фильтрации с использование векторных команд процессора и распараллеливание алгоритма на основе технологии OpenMP для повышения быстродействия.

5. Разработана методика и алгоритмы распознавания поверхностных дефектов листового проката в процессе производства, отличающаяся использованием метода окрестностей с векторной индексацией упорядоченного пространства признаков дефектов и бинарным поиском образцов для повышения быстродействия алгоритма распознавания.

4 РАЗРАБОТКА ПРОТОТИПА СИСТЕМЫ КОМПЬЮТЕРНОГО ЗРЕНИЯ РАСПОЗНАВАНИЯ ПОВЕРХНОСТНЫХ ДЕФЕКТОВ ЛИСТОВОГО ПРОКАТА

4.1 Разработка архитектуры высокопроизводительной системы распознавания поверхностных дефектов

Рассматривается процесс функционирования подсистемы СКЗ контроля качества продукции холодной обработки цветных металлов давлением. На вход системы поступают кадры с линейной камеры, установленной над полосой проката. На выходе подсистемы формируется информация о наличии дефектов, их положении на прокатном листе и определяется их класс.

Для понимания функций, которые должно выполнять прототип СКЗ, разработана функциональная модель с использованием графической нотации IDEF0 (рисунки 4.1 – 4.3) [103].

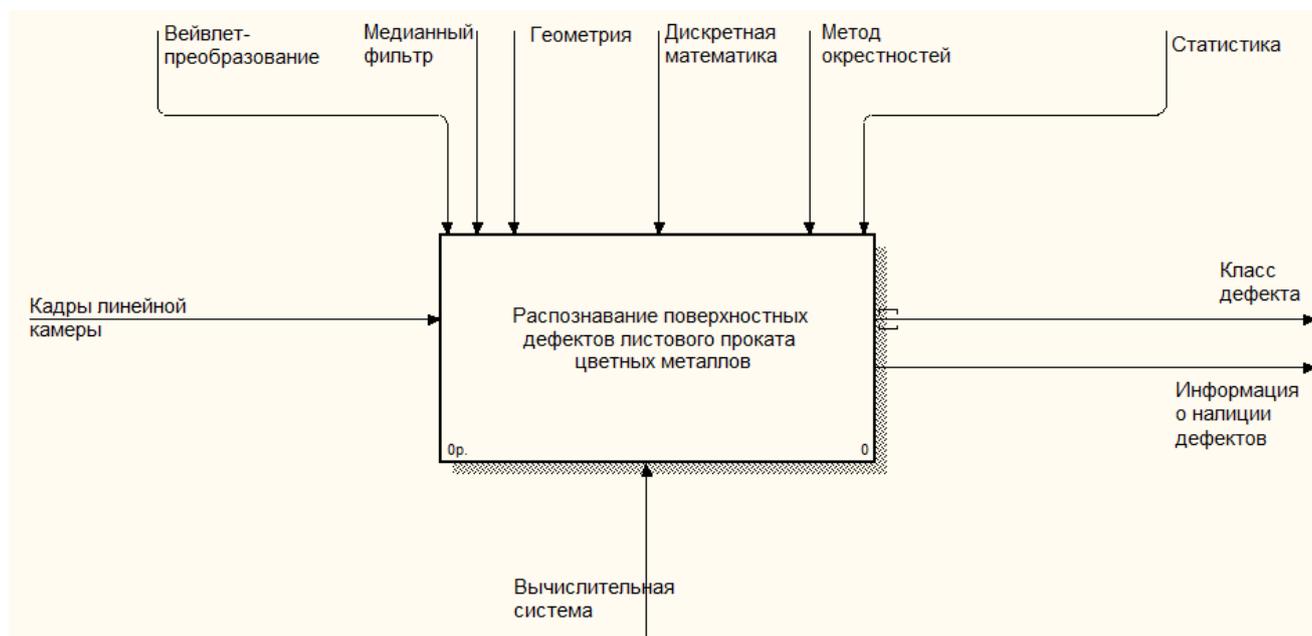


Рисунок 4.1 – Контекстная диаграмма СКЗ распознавания поверхностных дефектов листового проката в нотациях IDEF0

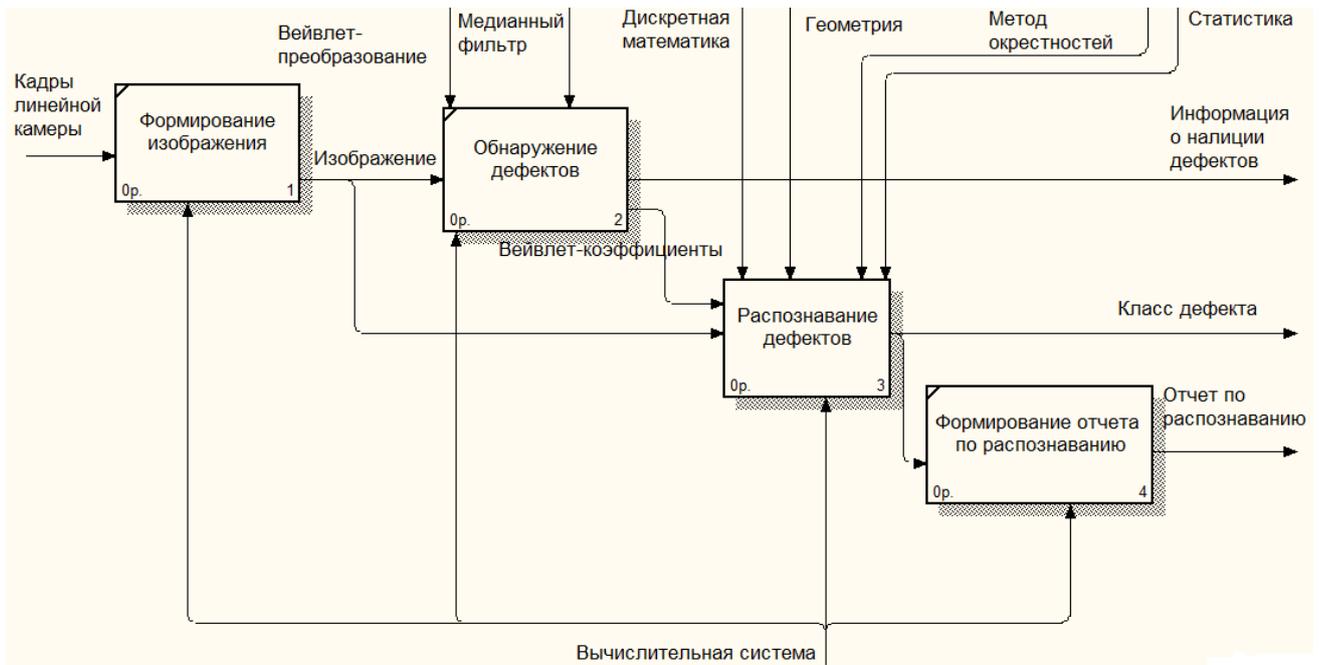


Рисунок 4.2 – Декомпозиция функциональной модели обнаружения (идентификации) и распознавания поверхностных дефектов листового проката

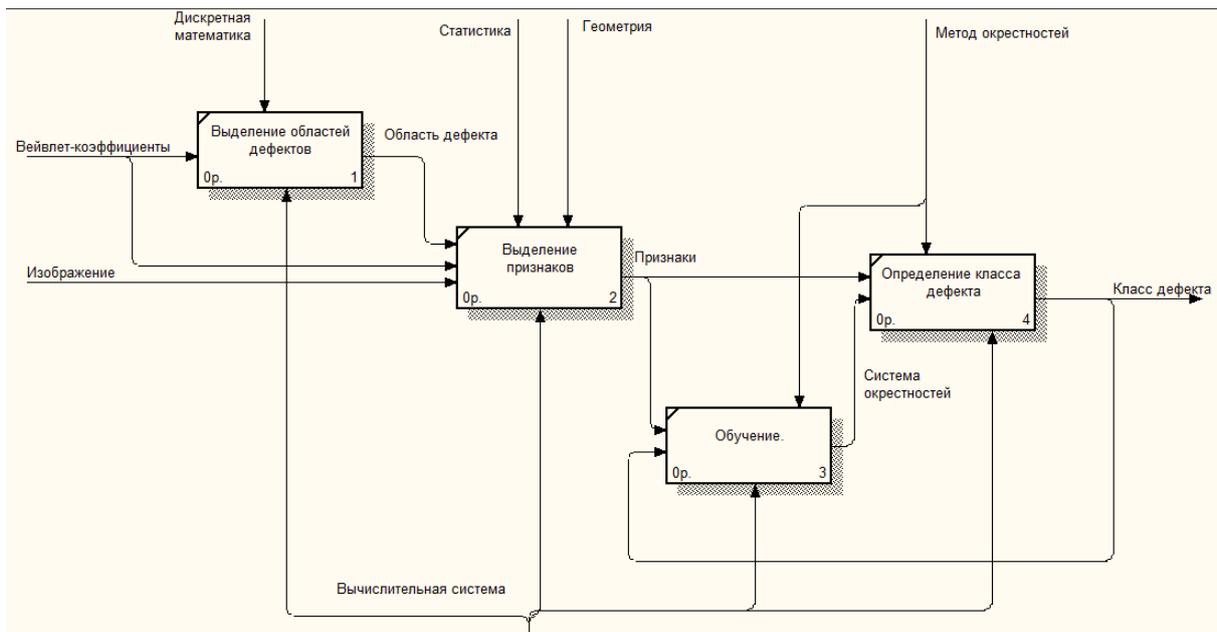


Рисунок 4.3 – Функциональная декомпозиция процесса распознавания поверхностных дефектов листового проката

Таким образом, разработана архитектура прототипа СКЗ контроля качества продукции холодной обработки цветных металлов давлением согласно ГОСТ 19.701-90 (рисунок 4.4) [104].

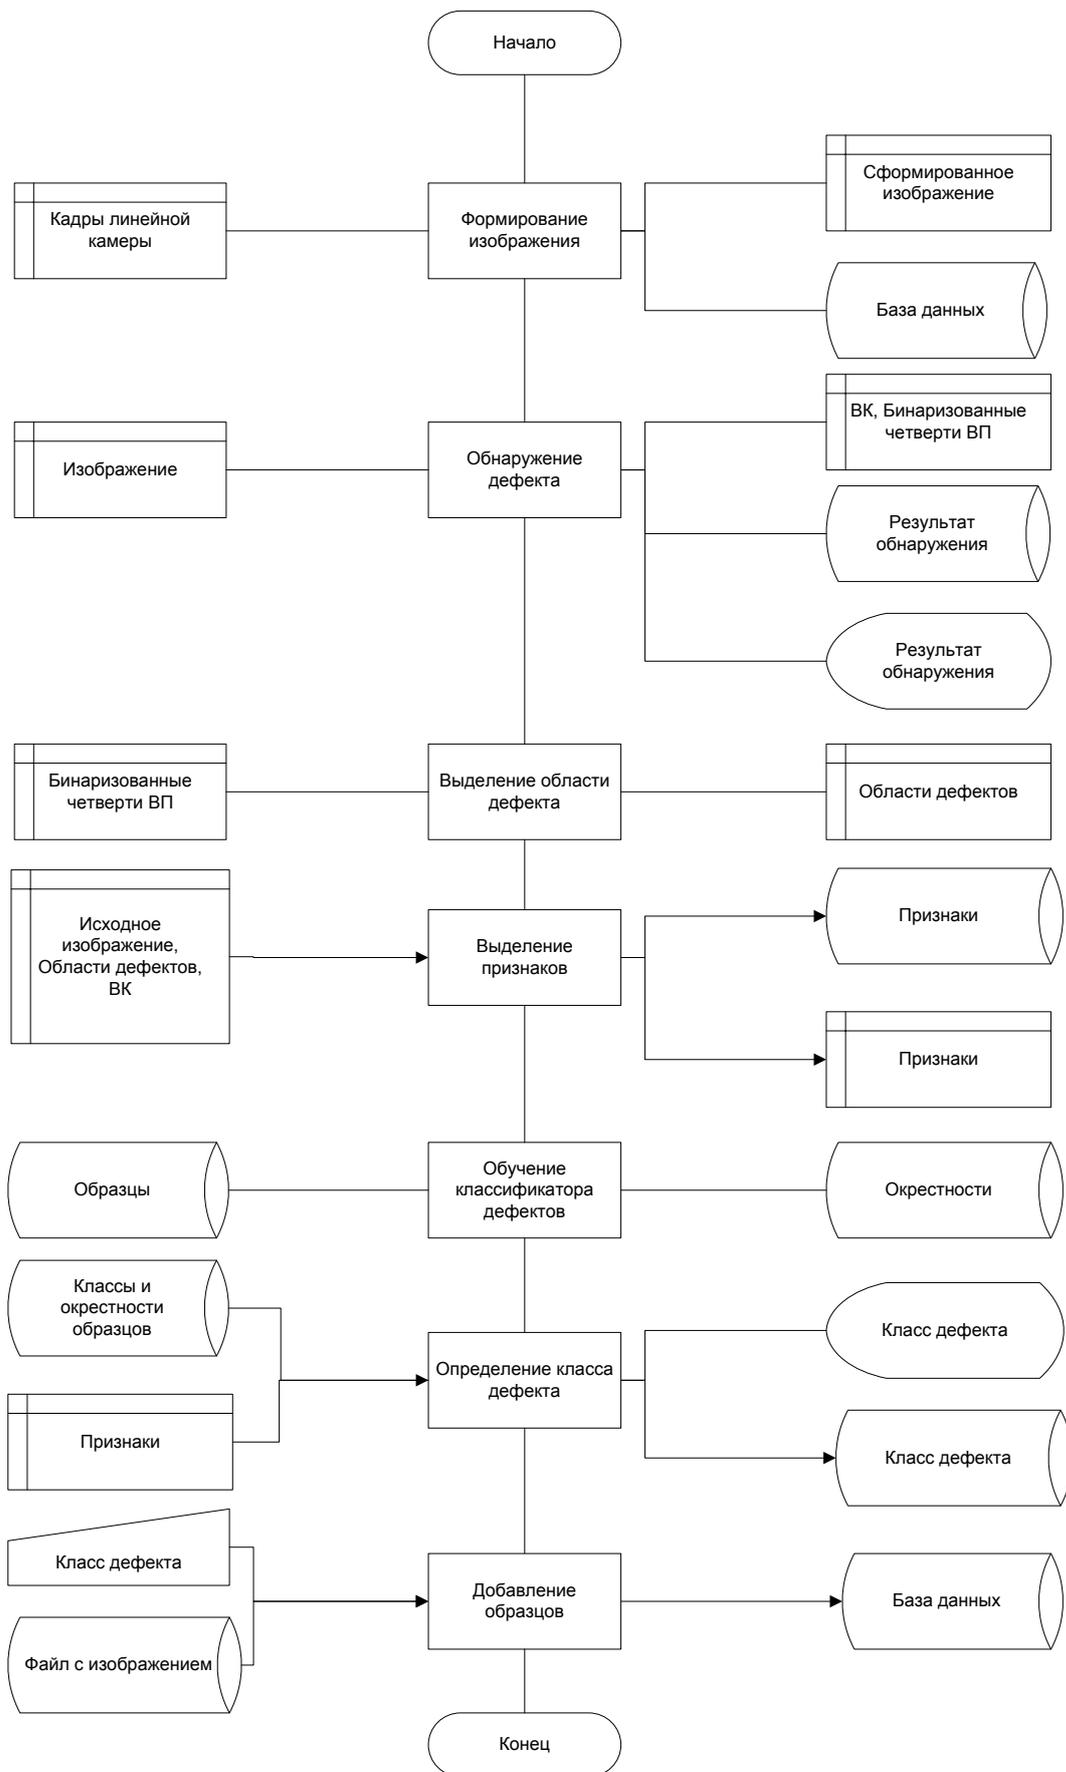


Рисунок 4.4 – Функциональная схема прототипа СКЗ контроля качества продукции металлопроката

4.2 Разработка модульной структуры системы компьютерного зрения

На основе контекстной диаграммы и функциональной схемы разработана структура программных модулей [67], представленная на рисунке 4.5.



Рисунок 4.5 – Схема взаимодействия модулей в процессе работы системы распознавания

Модуль формирования изображений накапливает кадры линейной камеры и формирует из них изображения размером 1024*1024 пикселя.

Модуль обнаружения поверхностных дефектов позволяет определить наличие дефектов в изображении.

Модуль выделения областей дефектов позволяет локализовать обнаруженные дефекты.

Модуль выделения признаков служит для расчета численных значений признаков дефектов.

Модуль определения класса дефекта позволяет определить класс дефекта по значениям признаков.

Модуль обучения служит для обучения классификатора на основе выборки изображений дефектов.

Модуль интеграции с клиентской частью служит для вывода информации об обнаруженных и распознанных дефектах оператору для принятия решений.

Архитектура программной системы имеет модульную структуру. При разработке использован метод нисходящего проектирования (функциональная декомпозиция) [40].

Спецификация модулей представлена в таблице 4.1

Таблица 4.1 – Спецификация модулей

Название	Назначение
MainWindow.cpp	Модуль служит для реализации главного окна программы
ImageLoader.cpp	Модуль, содержащий функции приема кадров линейной камеры и функции для формирования изображений 1024x1024 пикселя
DetectionParameters.cpp	Модуль, содержащий параметры обнаружения дефектов
WaveletTransform.cpp	Модуль, содержащий функции вейвлет преобразования.
MedianFilter.cpp	Модуль, содержащий функцию медианной фильтрации
Detection.cpp	Модуль, реализующий обнаружение дефектов на основе бинаризации по порогу.
ImageMap.cpp	Модуль, содержащий реализацию структуры, описывающей карту дефектов.
DefectObject.cpp	Модуль, содержащий реализацию структуры, описывающей отдельный дефект, а так же функции выделения признаков дефекта
ClassifierLearning.cpp	Модуль, реализующий функции обучения классификатора поверхностных дефектов
Recognition.cpp	Модуль, реализующий функции распознавания дефектов

Укрупненный алгоритм прототипа СКЗ оценки качества продукции холодной обработки цветных металлов давлением представлен на рисунке 4.6.



Рисунок 4.6 – Укрупненный алгоритм работы СКЗ контроля качества продукции холодной обработки цветных металлов давлением

На рисунке 4.7 представлен обобщенный алгоритм обработки сформированного изображения



Рисунок 4.7 – Алгоритм обработки сформированного изображения

Таким образом, решена задача алгоритмизации технической реализации приложений модульной структуры прототипа СКЗ распознавания поверхностных дефектов тонколистового проката.

4.3 Разработка базы данных

В результате анализа предметной области получено формализованное описание структуры данных для решения задач идентификации и распознава-

ния поверхностных дефектов листового проката [28, 51]. В таблице 4.2 представлены классы объектов предметной области [52] и их свойства.

Таблица 4.2 – Классы объектов предметной области и их свойства

Класс объектов/ Свойство	Ключ	Физические харак- теристики (тип, длина)	Опцио- наль- ность	Логические огра- ничения	Процессы
1	2	3	4	5	6
Видеопоток					
Код	УК1, ПК	Число,10	Д.б.	>0	генерация, просмотр
дата		Дата,10	Д.б.	ДД.ММ.ГГГГ	ВВ, О, П
Время		Время,10	Д.б.	ЧЧ:ММ:СС	ВВ, О, П
Название	УК2	Строка, 255	Д.б.		ВВ, О, П
Тип изображения					
Код	УК1, ПК	Число,10	Д.б.	>0	генерация, просмотр
Название	УК2	Строка, 255	Д.б.		ВВ, О, П
Изображение					
Номер	УК, ПК	Число, 10	Д.б	>0	генерация, просмотр
Номер в пото- ке		Число,10	Д.б	>0	ВВ, О, П
Дата		Дата	Д.б	ДД.ММ.ГГГГ	ВВ, О, П
Время		Время	Д.б	ЧЧ:ММ:СС	ВВ, О, П
Дефект					
Номер	УК, ПК	Число, 10	Д.б	>0	генерация, просмотр
X		Число, 10	Д.б	>0	ВВ, О, П
Y		Число,10	Д.б	>0	ВВ, О, П
Длина		Число, 10	Д.б	>0	ВВ, О, П
Ширина		Число,10	Д.б	>0	ВВ, О, П
Класс дефекта					
Код	УК1, ПК	Число,10	Д.б	>0	генерация, просмотр
Название	УК2	Строка, 255	Д.б		ВВ, О, П
Группа признаков					
Код	УК1, ПК	Число,10	Д.б	>0	генерация, просмотр
Название	УК2	Строка, 255	Д.б		ВВ, О, П
Признак					
Код	УК1, ПК	Число,10	Д.б	>0	генерация, просмотр
Название	УК2	Строка, 255	Д.б		ВВ, О, П
Значение признака					
Номер	УК, ПК	Число,10	Д.б	>0	генерация, просмотр
Значение		Число,10	Д.б		ВВ, О, П

В таблице использованы сокращения: УК – уникальный ключ; ПК – первичный ключ, Д.Б. – должно быть, ВВ – ввод, О, обновление, П - просмотр.

Инфологическая модель предметной области [52], построенная по методологии Ричарда Баркера [28], представлена на рисунке 4.8.



Рисунок 4.8 – Инфологическая модель предметной области

Таким образом, в результате анализа предметной области получено формализованное описание базы данных, состоящая из 8 связанных таблиц, нормализованная до 3-ей нормальной формы, целостность которой обеспечена ключевыми реквизитами, определен состав пользователей и описаны уровни доступа пользователей к разработанной базе данных. Построена концептуальная инфологическая модель предметной области.

4.4 Разработка интерфейса клиентской части

На основании предложенных моделей и алгоритмов разработан прототип СКЗ распознавания поверхностных дефектов листового проката. Вычислительные модули написаны на языке C++, интерфейсные модули написаны на языке C#. При разработке использовались методы библиотеки OpenCV [90]. В реальном времени система отображает текущее количество дефектов для прогона для каждого из типов дефектов.

Окно программы в реальном времени представлено на рисунке 4.9.

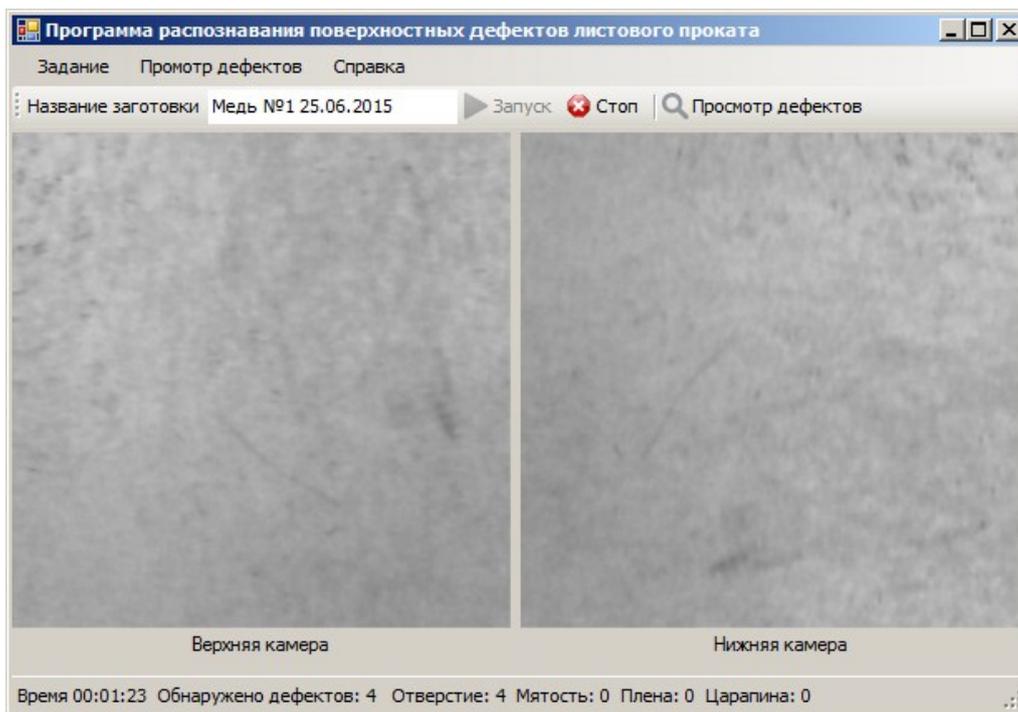


Рисунок 4.9 – Окно программы при работе в режиме реального времени

Сформированные изображения, содержащие дефекты, сохраняются в базе данных. Оператор стана имеет возможность просмотра обнаруженных дефектов. Для этого необходимо выбрать в главном меню программы пункт «Просмотр дефектов» или кнопку «Просмотр дефектов». При этом откроется окно выбора заготовок, представленное на рисунке 4.10.

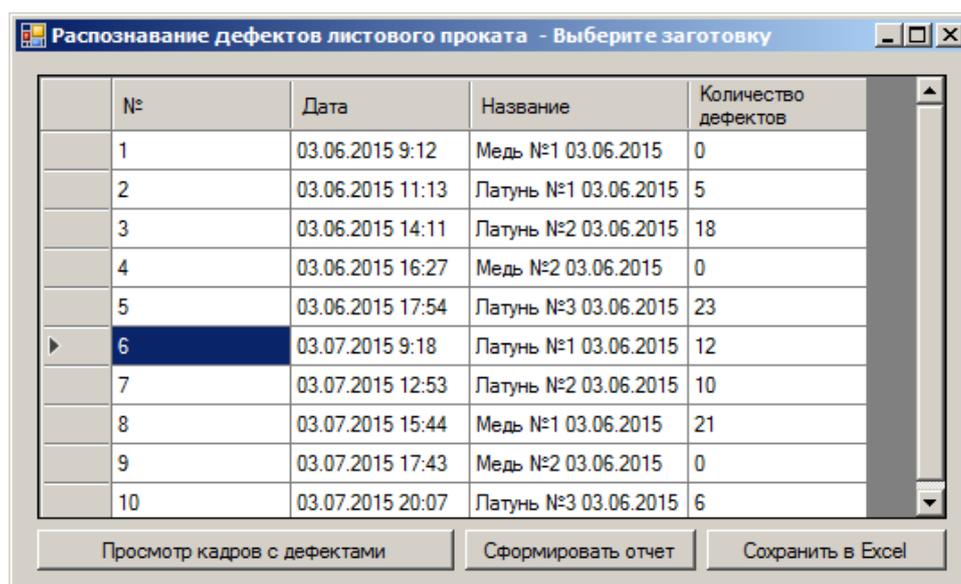


Рисунок 4.10 – Окно выбора заготовок

Информацию по заготовкам можно сохранить в виде файла MS Excel. Интерфейс программы позволяет сформировать отчет, выбрав необходимый промежуток времени, а также заготовки, в процессе проката которых обнаружены дефекты. Окно формирования отчета представлено на рисунке 4.11.

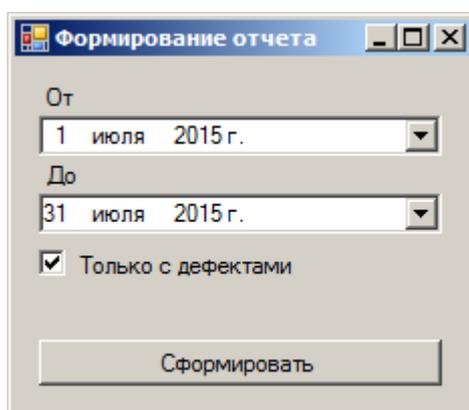
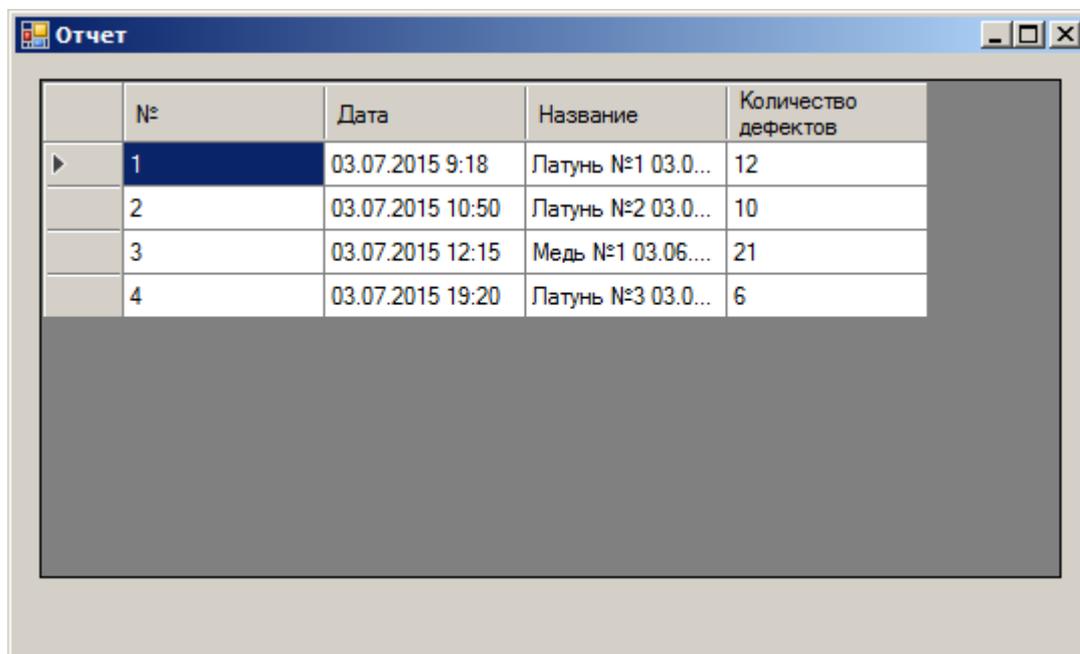


Рисунок 4.11 – Окно формирования отчета

Окно отчета представлено на рисунке 4.12.



№	Дата	Название	Количество дефектов
1	03.07.2015 9:18	Латунь №1 03.0...	12
2	03.07.2015 10:50	Латунь №2 03.0...	10
3	03.07.2015 12:15	Медь №1 03.06....	21
4	03.07.2015 19:20	Латунь №3 03.0...	6

Рисунок 4.12 – Окно отчета

Выбора заготовки через окно просмотра изображений с дефектами представлено на рисунке 4.13.



Рисунок 4.13 – Окно просмотра кадров с дефектами

В открывшемся окне можно просмотреть изображения с дефектами и выделенные области дефектов (см. рис. 4.14).

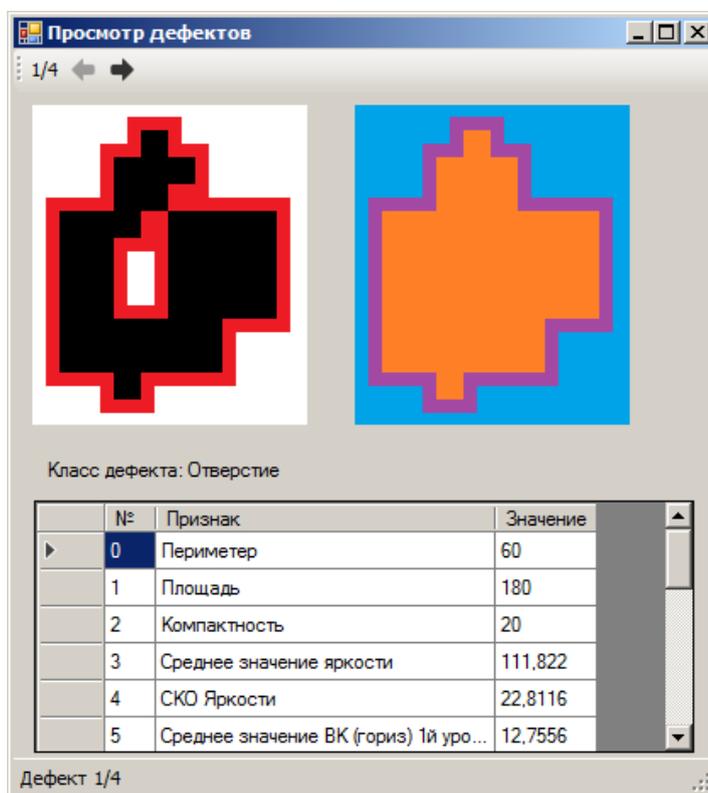


Рисунок 4.14 – Просмотр информации о дефекте

Программы обнаружения [66] и распознавания [67] зарегистрированы в государственном реестре программ для ЭВМ и баз данных (Приложения А, Б), тем самым завершена реализация интерфейса клиентской части программного интерфейса СКЗ контроля качества продукции холодной обработки цветных металлов давлением.

Таким образом, разработано информационное и программное обеспечение прототипа СКЗ контроля качества продукции холодной обработки цветных металлов давлением.

Выводы по разделу

1. Разработана архитектура прототипа СКЗ контроля качества продукции холодной обработки цветных металлов давлением, включающая базу данных, компонентов приложений: идентификации области дефектов, распознавания класса дефектов, интерфейсные приложения.

2. Разработана база данных, состоящая из 8 связанных таблиц, нормализованная до 3-ей нормальной формы, целостность которой обеспечена ключевыми реквизитами, определен состав пользователей и описаны уровни доступа пользователей к разработанной базе.

3. Разработан интерфейс клиентской части программного интерфейса СКЗ контроля качества продукции холодной обработки цветных металлов давлением.

4. Реализовано информационное и программное обеспечение прототипа СКЗ контроля качества продукции холодной обработки цветных металлов давлением.

5 Экспериментальные исследования прототипа системы компьютерного зрения

Методика проведения эксперимента включает следующие этапы [1]:

- формулировка целей исследования эффективности и методик её достижения;
- выбор существенных факторов (параметров);
- разработка и реализация плана эксперимента;
- обработка результатов эксперимента;
- формирование рекомендаций для дальнейших исследований.

5.1 Методика оценки эффективности системы компьютерного зрения

Целью экспериментального исследования является проверка эффективности предложенных методик идентификации и распознавания поверхностных дефектов тонколистового проката на основе компьютерного зрения.

Задачи экспериментального исследования:

- 1) экспериментальная проверка эффективности использования предложенной модели и методики принятия решений в задаче классификации;
- 2) выработка рекомендаций для дальнейших исследований.

Экспериментальный набор данных включает изображения поверхностных дефектов 4-х классов – «мятость», «царапина», «отверстие», «плена».

Известны метрики признаков эффективности алгоритмов классификации [1,2], позволившие определить показатели (признаки) эффективности классификации [52]:

N – общее число образцов в контрольной части выборки;

N_v – число образцов в контрольной части выборки, относящихся к классу Ω_v ;

FI_v – число образцов, относящихся к классу Ω_v , на которых не обнаружен дефект;

TR_v – число верно распознанных образцов, относящихся к классу Ω_v ;

FR_v – число ошибочно распознанных образцов, относящихся к классу Ω_v ;

OR_v – число образцов, относящихся к классу Ω_v , для которых получен отказ в распознавании;

FRC_v – число ошибочно распознанных образцов, отнесенных к классу Ω_v .

Критериями эффективности классификации приняты величины ошибок первого и второго рода.

Ошибка первого α (вероятность принять ошибочного решения относительно объекта класса Ω_v) и второго рода β (вероятность принять решения о принадлежности объекта к классу Ω_v , когда оно ложно) определяются [52]:

$$\alpha_v = \frac{FI_v + FR_v + OR_v}{N_v}, \quad (5.1)$$

$$\beta_v = \frac{FRC_v}{N - N_v}. \quad (5.2)$$

Данные величины характеризуют эффективность распознавания и не зависят от количества объектов в тестовом наборе.

На основе показателей TP и TN можно рассчитать меру полноты и точности распознавания. При экспериментальных исследованиях чаще оперируют не абсолютными показателями, а относительными (долями), выраженными в процентах. Так мера полноты r_v оценивает долю верного распознавания относительно всех объектов определенного класса. Мера точности p_v оценивает долю верных обнаружений относительно всех объектов. Данные меры рассчитывают по следующим зависимостям:

$$r_v = \frac{TR_v}{N_v}, \quad (5.3)$$

$$p_v = \frac{TR_v}{TR_v + FRC_v}. \quad (5.4)$$

Интегральным критерием эффективности классификации принята F-мера, зависящая от полноты и точности, определяется зависимостью:

$$F_v = \frac{2}{\frac{1}{r_v} + \frac{1}{p_v}}. \quad (5.5)$$

Кроме оценки точности распознавания необходимо проведение оценки быстродействия системы распознавания. Для этого экспериментально оценивается среднее время для каждого этапа классификации: время обнаружения дефектов $t_{обн}$, время выделения областей дефектов $t_{обл}$ (в том числе слияние, утолщение границ, локализация), время выделения признаков $t_{призн}$ и время распознавания $t_{расп}$ (на основе метода окрестностей). Суммарное среднее время на обработку одного изображения должно быть меньше или равно максимальному времени обработки одного изображения, что позволит проводить обработку в процессе производства.

Таким образом, определены показатели и критерии эффективности разработанных технических решений системы компьютерного зрения, предложена методика обработки результатов эксперимента.

5.2 Технология проведения эксперимента

Технология проведения эксперимента базируется на получении видеопотока проката с помощью установки на стане «КВАРТО 400 ŠKODA» видеокамеры Basler web ral2048 по схеме, представленной на рисунке 5.1.

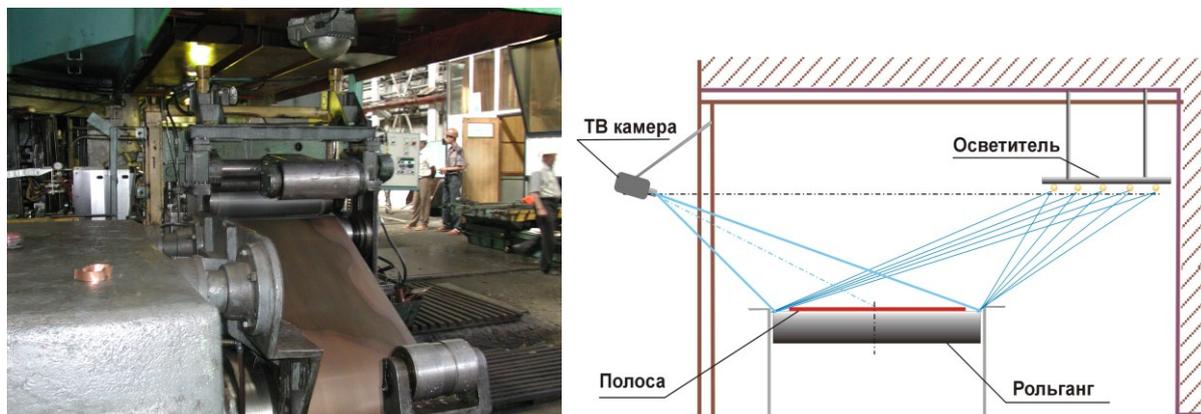


Рисунок 5.1 – Размещение и схема экспериментальной установки

Основой проведения эксперимента определен *метод тестовой выборки* [2, 38]. Идея данного метода заключается в том, что для осуществления тестирования из обучающей выборки выбирается 10-20% контрольных образцов, в то время как остальная часть используется для обучения. Такая выборка должна

быть сбалансирована, т.е. состоять из одинакового количества объектов, предназначенных для тестирования каждого класса.

Достоинством метода является то, что для оценки результата тестирования необходимо сделать всего одно обучение и одну проверку тестирования для каждого объекта из тестовой выборки. Недостатком является зависимость результатов тестирования от того, какие объекты попали в тестовую выборку. Например, если в тестовую выборку попали объекты, большинство которых находилось в обучающей выборке – результаты тестирования будут хорошими, в противном случае, если объекты в тестовой выборке окажутся специфическими, то результаты тестирования покажут низкий уровень правильно классифицируемых объектов и высокое количество ложно классификации.

Другой, более сложный и трудоемкий, метод *k-подмножеств* (*k-folds*) [2, 80]. Сущность метода заключается в разделении экспериментальной выборки на *k* равных частей. Причем распределение образцов дефектов по частям должно осуществляться равномерно (в каждую часть должно попадать одинаковое количество образцов для каждого из классов). Далее производится *k* итераций работы классификатора (обучение и тестирование). В ходе каждого итерации работы классификатора (*k-1*) часть участвует в обучении и одна в тестировании, при этом тестовая часть постоянно меняется. Алгоритм предложенной методики представлен на рисунке 5.2.

В результате каждого запуска системы классификации фиксировались: значения пяти вероятностных характеристик – ошибки I рода α и II рода β , сводная оценка качества классификации (F-мера), меры полноты и точности. По результатам всех тестов вычислялись средние значения всех величин. Результаты классификации зависят от разбиения на подмножества тестовых данных, но определение средних величин позволит достаточно точно оценить эффективность работы классификатора.

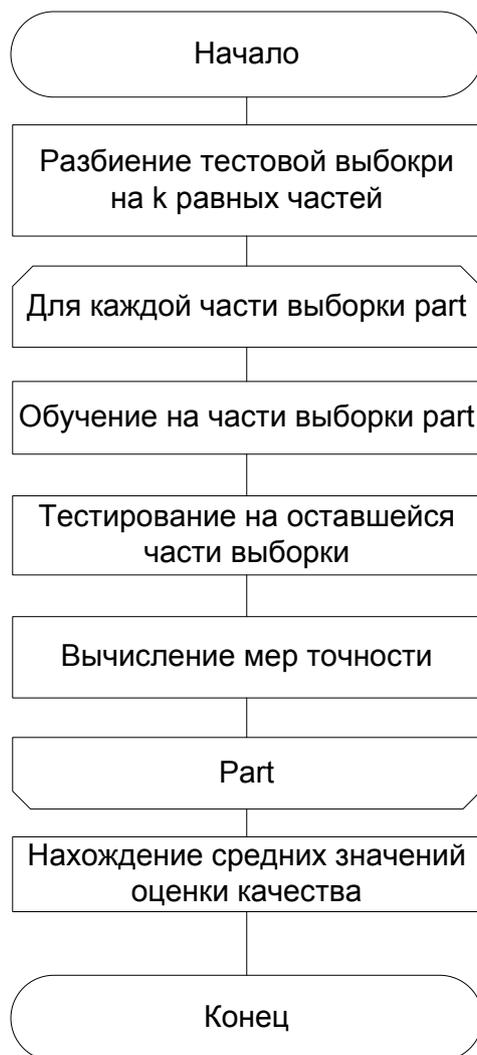


Рисунок 5.2 – Технология оценки результатов эксперимента методом k -подмножеств

Преимущество метода k -подмножеств заключается в возможности оценки эффективности при меньшем числе образцов, чем для метода тестовой выборки.

Таким образом, основой технологии экспериментальных исследований системы компьютерного зрения контроля качества продукции металлопроката становится на методе k -подмножеств.

5.3 Методика оценки погрешности метрик распознавания

Основой методики оценки погрешностей распознавания прототипа СКЗ при измерении признаков дефекта избран эксперимент.

В качестве датчика СКЗ использовалась матричная видеокамера «*Canon PowerShot SX 530 HS*». Данная камера позволяет фиксировать изображения размером 1280*1024 пикселей. Камера размещалась таким образом, что ширина прокатного листа (600 мм) соответствовала 1024 пикселям. Для анализа изображения формировались кадры размером 1024x1024 пикселя.

На оцифрованные изображения поверхности проката накладывались области дефекта. На основе выделенной области дефекта рассчитывались истинные значения метрик признаков. Для каждого дефекта проводилась серия из $n=10$ испытаний, рассчитывались значения метрик и систематическая и случайная погрешности классификации.

Для определения систематической погрешности для каждого из дефектов и для каждой из метрик признаков необходимо выполнить следующие вычисления [49]:

1 Расчет средних значений СКО метрик признаков u

$$\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i, \quad (5.6)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (u_i - \bar{u})^2}{n - 1}}, \quad (5.7)$$

где σ – среднее квадратическое отклонение;

u_i – результат i -го измерения из n измерений.

2 Расчет абсолютных систематическая ошибок метрик

$$\Delta_C = \bar{u} - u_0, \quad (5.8)$$

где u_0 – действительное значение измеряемой величины.

Относительная систематическая погрешность определяется как

$$\delta_C = \frac{\Delta_C}{u_0} \cdot 100\% . \quad (5.9)$$

3 Расчет абсолютной случайной погрешности метрик

$$\Delta_0 = K \cdot \sigma , \quad (5.10)$$

где K – коэффициент, зависящий от принятой доверительной вероятности и закона распределения результатов измерений (использован $K=1,96$ с доверительной вероятностью 95%).

Относительная случайная погрешность определяется как

$$\delta_0 = \frac{\Delta_0}{u_0} \cdot 100\% . \quad (5.11)$$

3 Расчет абсолютной суммарной погрешности

$$\Delta = \pm(|\Delta_C| + |\Delta_0|) . \quad (5.12)$$

5 Расчет относительной суммарной погрешности

$$\delta = \frac{\Delta}{u_0} \cdot 100\% .$$

Таким образом, предложен методический аппарат расчета погрешностей распознавания прототипа СКЗ при измерении и расчете признаков дефекта.

5.4 Результаты экспериментальной оценки эффективности системы компьютерного зрения

Результаты оценки погрешности изменения метрик распознавания поверхностных дефектов представлены в таблицах 5.1-5.3.

Таблица 5.1 – Относительные систематические погрешности измерения метрик распознавания

	Отверстие	Плена	Мягость	Царапина
Периметр, %	1,6	2,25	2,2	0,58
Площадь, %	0,36	0,72	2,07	0,34
Компактность, %	3,01	3,58	2,49	1,52
СЗ яркости, %	2,14	1,82	2,85	3,75
СКО яркости, %	4,61	1,79	4,13	5,42
СЗ ВК, %	6,67	6	4	3,95
СКО ВК, %	2,352941	2,22	1,46	0,71

Таблица 5.2 – Относительные случайные погрешности измерения метрик распознавания

	Отверстие	Плена	Мягость	Царапина
Периметр	17,33	14,05	14,78	8,94
Площадь	8,89	4,97	16,25	9,54
Компактность	26,31	22,95	17,8	9,57
СЗ яркости	13,7	16,19	7,75	9,9
СКО яркости	23,57	9,02	12,34	19,06
СЗ ВК	25,54	25,02	26,13	15,22
СКО ВК	22,41	15,09	14,78	13,49

Таблица 5.3 – Относительные суммарные погрешности измерения метрик распознавания

	Отверстие	Плена	Мятость	Царапина
Периметр	18,93	16,3	16,98	9,52
Площадь	9,25	5,69	18,32	9,88
Компактность	29,32	26,53	20,29	11,09
СЗ яркости	15,84	18,01	10,6	13,65
СКО яркости	28,18	10,81	16,47	24,48
СЗ ВК	32,20	31,02	30,13	19,18
СКО ВК	24,76	17,31	16,24	14,21

Полученные оценки погрешности измерения метрик поверхностных дефектов свидетельствуют о достоверности принятия решений в задаче распознавания.

Для определения требуемого аппаратного обеспечения СКЗ (количества процессоров) проведен эксперимент на базе компьютеров с процессорами Intel Core i7 3.0 ГГц. Компьютеры объединены сетью Ethernet со скоростью 1 Гбит/с.

Экспериментальная выборка образцов дефектов для оценки эффективности прототипа системы классификации состояла из изображений четырех классов дефектов («мятость», «отверстие», «царапина», «плена»). Всего исследовано 845 изображений различных дефектов (206 отверстий, 231 плена, 215 мятостей, 193 царапины).

Оценка быстродействия алгоритма обнаружения дефектов представлена в таблице 5.4.

Таблица 5.4 – Оценка ускорения алгоритма обнаружения дефектов

Реализация	Среднее время работы [с.]
Последовательный алгоритм	0,055
1 поток + ВКП	0,024
2 потока	0,032
4 потока	0,018
2 потока + ВКП	0,015
4 потока + ВКП	0,012
2 процесса (2 потока + ВКП)	0,014
4 процесса (4 потока + ВКП)	0,011

Из таблицы видно, что использование векторных команд процессора и распараллеливания вычислений на потоки по ядрам процессора (технология OpenMP) приводит к существенному повышению быстродействия алгоритма. Однако, распараллеливание алгоритма по узлам кластера не дает существенного повышения производительности. Это обусловлено значительными временными затратами на передачу информации между узлами кластера.

Вероятность верного обнаружения для каждого из классов исследованных дефектов представлена в таблице 5.5.

Таблица 5.5 – Вероятность верного обнаружения дефектов

Класс дефекта	Вероятность верного обнаружения, %
Отверстие	99,03
Плена	99,13
Мятость	98,6
Царапина	98,45

Из таблицы видно, что достоверность распознавания поверхностных дефектов тонколистового проката предложенными техническими решениями не хуже аналогов.

Проведена оценка быстродействия для этапа выделения областей дефектов проката. Результаты оценки быстродействия представлены в таблице 5.6.

Таблица 5.6 – Результаты оценки быстродействия выделения областей дефектов

Этап выделения области дефекта	Время, с.
Слияние	0,0002
Утолщение границ	0,0005
Локализация дефектов	0,0032
Итого	0,0045

Следовательно, среднее время, затрачиваемое на этап выделения признаков поверхностных дефектов, составляет 0,0006 с., что свидетельствует о возможности распознавания в процессе производства.

Проведен анализ зависимости ошибки первого рода α от значения параметра m , определяющего максимальный уровень разбиения гиперкубов. Результаты представлены в таблице 5.7.

Таблица 5.7 – Зависимости ошибки первого рода α от значения параметра m

Класс дефекта	m			
	4	5	6	7
Отверстие	0,4616	0,4616	0,1538	0,1602
Царапина	0,6154	0,5135	0,2744	0,2487
Мягость	0,3077	0,3077	0,0769	0,0884
Плена	0,6667	0,5	0,1667	0,1861

Из результатов эксперимента видно, что ошибка первого рода одинакова при $m=6$ и $m=7$. Поэтому в эксперименте принято $m = 6$.

Исследования влияние порогового значения γ_v на ошибку распознавания первого рода представлены в таблице 5.8.

Таблица 5.8 – Зависимости ошибки первого рода α от порогового значения γ_v

Класс дефекта	Значение порога			
	0,5	0,6	0,7	0,8
Отверстие	0,3515	0,1974	0,1602	0,1628
Плена	0,3715	0,2237	0,1861	0,2165
Мятость	0,2432	0,1499	0,0883	0,1437
Царапина	0,606	0,5377	0,2487	0,3547

Из таблицы видно, что ошибка первого рода достигает минимума при значении $\gamma_v = 0,7$. При дальнейшем увеличении γ_v повышается вероятность отказа, что приводит к увеличению ошибки первого рода.

Для полной оценки эффективности распознавания рассчитаны ошибка первого и второго рода, полнота, точность и f-мера для СКЗ контроля качества продукции холодной обработки цветных металлов давлением [52]. Результаты представлены в таблице 5.9.

Таблица 5.9 – Результаты оценки эффективности разработанной системы компьютерного зрения

Дефект	Ошибка первого рода	Ошибка второго рода	Полнота	Точность	F-мера
Отверстие	0,160194175	0,00312989	0,839806	0,988571	0,908136
Плена	0,186147186	0,01465798	0,813853	0,954315	0,878505
Мятость	0,088372093	0,00952381	0,911628	0,970297	0,940048
Царапина	0,248704663	0,004601227	0,751295	0,97973	0,85044

Результаты оценки эффективности системы компьютерного зрения свидетельствуют о достижении требуемых значений показателей распознавания.

Оценка быстродействия системы компьютерного зрения представлена в таблице 5.10.

Таблица 5.10 – Временные оценки основных этапов алгоритмов идентификации и распознавания

Этап	Ср. время работы, с
1. Обнаружение, с.	0,012
2. Выделение областей дефектов, в т.ч.	0,0045
Слияние, с.	0,0002
Утолщение границ, с.	0,0005
Локализация дефектов, с.	0,0032
3. Расчет значений признаков, с.	0,0006
4. Распознавание, с.	0,0029
Итого, с.	0,02

Полученные результаты обеспечивают возможность распознавания поверхностных дефектов тонколистового проката цветных металлов в процессе производства.

Таким образом, разработан прототип система компьютерного зрения, обеспечивающая распознавание дефектов класса «отверстие» с погрешностью 16 %, «плена» – 19 %, «мятость» – 9%, царапина – 25 %. Среднее время распознавания составляет 20 мс и является достаточным для работы при скоростях проката до 8 м/с.

5.5 Направления дальнейших исследований

Дальнейшие направления исследований в области цифровой обработки изображений и совершенствования СКЗ оценки качества продукции тонколистового проката, которые, по мнению авторов, являются актуальными, приведены в таблице 5.11.

Таблица 5.11 – Направления дальнейших исследований

Разработка методов устранения дефектов	Распознавание поверхностных дефектов листового проката, не рассмотренных в данной диссертации	Обнаружение и распознавание структурных дефектов	Обнаружение и распознавание дефектов в иных областях
Анализ физики возникновения поверхностных дефектов	Исследование эффективности распознавания поверхностных дефектов на основе, выделение новых признаков	Разработка моделей, алгоритмов и средств распознавания структурных дефектов	Исследование характерных для черной металлургии дефектов и выделение их признаков
Разработка методики и алгоритмов информационного и программного обеспечения технических средств устранения дефектов классов «мятость» и «царапина»			Развитие метода окрестностей для распознавания дефектов горячей обработки металлов
			Развитие метода окрестностей для распознавания дефектов в иных областях промышленности

Выводы по разделу

1 Определены показатели и критерии эффективности разработанных технических решений системы компьютерного зрения, предложена методика обработки результатов эксперимента.

2 Основой технологий экспериментальных исследований системы компьютерного зрения контроля качества продукции металлопроката выбран метод k-подмножеств.

3 Предложен методический аппарат расчета погрешностей распознавания прототипа СКЗ при измерении признаков дефекта.

4 Разработанный прототип система компьютерного зрения, обеспечивает распознавание дефектов класса «отверстие» с погрешностью 16 %, «пле-на» - 19 %, «мятость» – 9%, царапина – 25 %. Среднее время распознавания со-

ставляет 20 мс и является достаточным для работы при скоростях проката до 8 м/с.

5 Предложены направления дальнейших исследований в области развития систем компьютерного зрения для контроля качества продукции холодной обработки цветных металлов давлением.

Заключение

Таким образом, в результате проведенных исследований:

1. Определены технологические параметры процесса проката, влияющие на возникновение различных поверхностных дефектов, обоснованы классы поверхностных дефектов, имеющие существенные метрологические отличия, и определены метрики спектральных, геометрических и оптических признаков, на основе которых возможно распознавание поверхностных дефектов тонколистового проката цветных металлов. Предложена концепция совершенствования ОЭИИС оценки качества листового проката цветных металлов.

2. Модернизирована вейвлет-модель изображения проката для использования векторного процессора, обеспечивающая сокращения времени расчета спектральных признаков дефектов. Предложена модель дефекта для распознавания в виде вектора признаков, отличающаяся использованием в дополнение к спектральным признакам вейвлет-разложения изображения геометрических и оптических признаков обнаруженного дефекта.

3. Предложена методика формирования изображения путем накопления строк пикселей (кадров), полученных с линейной видеокамеры, отличающаяся пропуском строк пикселей, содержащих дублирующую информацию. Определено предельно допустимое время обработки одного кадра для обеспечения работы СКЗ в реальном масштабе времени. Предложена методика, позволяющая обнаруживать дефекты по изображению и определить его пространственные характеристики, отличающаяся использованием медианного фильтра для устранения шумов и бинаризации по динамическому порогу, а также выделением каждого обнаруженного дефекта в отдельную матрицу, что позволяет сократить время на расчет признаков дефектов. Разработан алгоритм принятия решений при распознавании поверхностных дефектов листового проката в процессе производства, отличающаяся использованием метода окрестностей с векторной индексацией пространства признаков области дефектов для повышения быстродействия распознавания.

4. Разработана система компьютерного зрения контроля качества продукции тонколистового проката, обеспечивающая распознавание дефектов класса «отверстие» с погрешностью – 16 %, «плена» – 19 %, «мятость» – 9 %, царапина – 25 %. Среднее время распознавания составляет 20 мс и является достаточным для работы при скоростях проката до 8 м/с.

Научная новизна исследований:

1. Обоснованы классы поверхностных дефектов, имеющие существенные метрологические отличия, выделены спектральные, геометрические и оптические признаки дефектов и их метрики, на основе которых возможно идентификации и распознавание поверхностных дефектов проката.

2. Разработана модель изображения поверхности проката, отличающаяся от известных представлением изображения проката в виде пакетов пикселей для увеличения быстродействия алгоритма обнаружения дефектов за счет использования векторных команд процессора и расширенным информационным полем классификации дефектов на основе спектральных, пространственных и оптических метрик признаков для повышения достоверности распознавания класса дефекта.

3. Разработана методика идентификации поверхностных дефектов, отличающаяся от известных использованием медианного фильтра для подавления помех и бинаризацией матрицы вейвлет-коэффициентов модели изображения по динамическому порогу для формирования области дефектов, сокращающей объем информации при решении задачи распознавания.

4. Разработана методика и алгоритмы распознавания поверхностных дефектов, отличающаяся от известных использованием метода окрестностей с векторной индексацией упорядоченного пространства признаков дефектов и бинарным поиском образцов для повышения быстродействия распознавания.

Практическая значимость исследований заключается в разработанном информационном и программном обеспечении прототипа системы компьютерного зрения контроля качества продукции холодной обработки цветных металлов давлением.

Достоверность результатов основывается на использовании апробированных методов исследования, корректном применении математического аппарата, согласованности новых результатов с известными теоретическими положениями.

Основные результаты прошли апробацию на 8 международных научных конференциях в период 2008-2017 годов.

По результатам исследований опубликовано 16 печатных работ, в том числе 9 публикации в сборниках материалов конференций международного уровня, 7 статей в журналах из Перечня ВАК, две из которых входят в базу Scopus.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Адлер, Ю.П. Планирование эксперимента при поиске оптимальных условий /Ю. П. Адлер, Е. В. Маркова, Ю. В. Грановский. – 2-е изд., доп. и перераб. – М.: Наука, 1976. – 280 с.
2. Айвазян, С.А. Прикладная статистика: классификации и снижение размерности: справ. изд. /С.А. Айвазян [и др.]; под ред. С. А. Айвазяна. – М.: Финансы и статистика, 1989. – 607 с
3. Алгоритм обучения по Байесу [Электронный ресурс] /Учеб.-науч. комплекс «Института прикладного системного анализа» МинОбрНауки Украины. – Режим доступа : <http://iasa.org.ua/lections/tpr/studying/bayes.htm>
4. Алексеев, Ю.Н. Введение в теорию обработки металлов давлением, прокаткой и резанием /Ю.Н. Алексеев – Харьков: изд. ХГУ, 1969. – 106 с.
5. Аленин, В.А. Способы повышения качества оценки фундаментальной матрицы /В.А. Аленин, О.Л. Куляс //Вестник Московского государственного областного университета. Серия: Физика-Математика. – 2011. – № 3. – С. 106-116
6. Алешин, Н.П. Ультразвуковая дефектоскопия: Справ. пособие /Н.П. Алешин, В.Г. Лупачев – Минск.: Выш. шк. – 1987. – 271с.
7. Амосов, А.А. Вычислительные методы для инженеров /А.А. Амосов, Ю.А. Дубинский, Н.П. Копченова – М.: Мир, 1998. – 495 с
8. Афонин, В.Л. Обработка нового поколения: Концепция проектирования /В.Л. Афонин [и др.] – М.: Машиностроение, 2004. – 256 с.
9. Бабкин, В. А. Повышение качества идентификации адаптивной системы управления /В.А. Бабкин, А.В. Щедринов //Автоматизация и современные технологии. – М.: Наука, 2006. № 9. – С. 42–46.
10. Бахвалов, Н.С. Численные методы /Н.С. Бахвалов, Н.П. Жидков, Г.Г. Кобельков – М.: Лаборатория Базовых Знаний, 2000. – 412 с.
11. Белов, М.П. Автоматизированный электропривод типовых производственных механизмов и технологических комплексов /М.П. Белов. – 3-е изд., испр. – М.: Издательский центр «Академия», 2007. – 576 с.

12. Белокуров, А. Стохастические модели в задачах анализа и обработки изображений /А. Белокуров, В. Сечко //Зарубежная радио-электроника. – 1994. – №2. – С. 21-38.
13. Боровиков, В.П. Искусство анализа данных /В.П. Боровиков – 2-е изд. – Санкт-Петербург: ПИТЕР, 2005. – 288 с.
14. Бугаев, Д.П. Распараллеливание алгоритма вейвлет-преобразования при выявлении поверхностных дефектов листового металла при обработке на прокатном стане //Высокопроизводительные параллельные вычисления на кластерных системах: сб. мат. VII Международной конференции-семинара. – Нижний Новгород, 2007. – С. 50-54.
15. Бугаев, Д.П. Выявление дефектов поверхности металла с помощью вейвлет-преобразования /Д.П. Бугаев, Н.А. Соловьев //Компьютерная интеграция производства и ИПИ-технологии: сб. мат. III ВНПК. – Оренбург: ГОУ ОГУ, 2007. – С. 115-118.
16. Бугаев, Д.П. Развитие АСУТП прокатного стана на основе выявления поверхностных дефектов металла методом вейвлет-преобразований видеоизображений /Д.П. Бугаев, Н.А. Соловьев //Спец. выпуск журнала «Известия Самарского научного центра Российской академии наук» . – 2009. – С.180-184.
17. Бугаев, Д.П. Модель учета физико-механических свойств металла в технологии холодного проката /Д.П. Бугаев, В.В. Паничев //Материалы IX ВНПК (с межд. участием). – Оренбург: ООО «Комус», 2010. – С. 39-41.
18. Бугаев, Д.П. Разработка программно-аппаратного комплекса выявления поверхностных дефектов металла на линии резки радиаторной ленты: Отчет о НИР (заключ.) / ФГБОУ ВПО «Оренбургский государственный университет»; рук. Н.А. Соловьев; исполн.: Д.П. Бугаев. – Оренбург: Изд. ОГУ, 2009. – 155 с.
19. Бугаев, Д.П. Повышение эффективности технологического процесса обработки цветных металлов давлением в условиях перехода к тонколистовому прокату: диссертация на соиск. уч. ст. канд. техн. наук – Оренбург – 2013. – 140 с.

20. Ванин, В.А. Приспособления для металлорежущих станков: учеб. пособие /В.А. Ванин, А.Н. Преображенский, В.Х. Фидаров – Тамбов: Изд-во Тамб. гос. техн. ун-та, 2007. – 316 с.
21. Васильева Л.Г. Преобразование Фурье и вейвлет-преобразование. Их свойства и применение /Л.Г.Васильева, Я.М. Жилейкин, Ю.И. Осипик //Вычислительные методы и программирование. – 2002. – Т. 3. – С. 172-175.
22. Васильев В.И. Распознающие системы: Справочник – 2-е изд. – Киев: Наукова думка, 1983. – 424 с.
23. Вапник, В. Н. Теория распознавания образов /В.Н. Вапник, А.Я. Червоненкис. – М.: Наука, 1974. – 416 с.
24. Вентцель, Е.С. Теория вероятностей /Е.С. Вентцель – 10-е изд., – М.: «Академия», 2005. – 576 с.
25. Виттих, В.А. Обработка изображений в автоматизированных системах научных исследований /В.А. Виттих, В.В. Сергеев, В.А. Сойфер – М.: Наука, 1982. – 218 с.
26. Вирт, Н. Алгоритмы + структуры данных = программы. – М.: «Мир», 1985. – 361 с.
27. Воеводин, В.В. Суперкомпьютерное образование: третья составляющая суперкомпьютерных технологий / В.В. Воеводин, В.П. Гергель //Вычислительные методы и программирование: новые вычислительные технологии – 2010. – Т. 11. – № 2. – С. 117–122.
28. Волкова, Т.В. Проектирование и создание БД: учебное пособие для ВУЗов /Т. В. Волкова. – Оренбург: ОГУ, 2006. – 140 с.
29. Гергель, В.П. Метод окрестностей в задачах распознавания /В.П. Гергель, Л.Г. Стронгин, Р.Г. Стронгин //Техническая кибернетика. – 1987. – №4. – С. 14-22
30. Гергель, В.П. Развитие системы суперкомпьютерного образования в России: текущие результаты и перспективы /В.П. Гергель, Л.Б. Соколинский, В.П. Демкин, Н.Н. Попова, А.В. Бухановский //Вестник Нижегородского университета им. Н.И. Лобачевского. – 2012. – № 4. – С. 268–274.

31. Гергель, В.П. Теория и практика параллельных вычислений. – М.: Бином. Лаборатория знаний. – 2007. – 424 с.
32. Гонсалес, Р. Цифровая обработка изображений /Р. Гонсалес, Р.Вудс. – М.: Техносфера. – 2005. – 1072 с.
33. ГОСТ 21014-88. Прокат черных металлов. Термины и определения дефектов поверхности.
34. ГОСТ 19.701-90. Схемы алгоритмов, программ, данных и систем. Условные обозначения и правила выполнения.
35. Горелик, А.Л. Методы распознавания /А.Л. Горелик, В.А. Скрипкин. – 4-е изд. – М.: Высшая школа, 2004. – 262 с.
36. Добеши, И. Десять лекций по вейвлетам. – Ижевск: РХД, 2001. – 464 с.
37. Деревецкий, Д.П. Прикладная теория дискретных адаптивных систем управления /Д.П. Деревецкий, А.Л. Фрадков – М.: Наука, 1981. – 216 с.
38. Дубров, А.М. Многомерные статистические методы: учебник /А. М. Дубров, В. С. Мхитарян, Л. Н. Трошин. – М.: Финансы и статистика, 2002. – 352 с.
39. Журавлёв, Ю.И. Распознавание. Классификация. Прогноз. Математические методы и их применение. Вып.2. – М.: Наука, 1989. – 242 с.
40. Зубкова, Т.М. Технология разработки программного обеспечения: учеб. пособие / Т. М. Зубкова. – Оренбург: ОГУ, 2017. – 202 с.
41. Мирошников, М.М. Теоретические основы оптикоэлектронных приборов /М.М. Мирошников. – Л.: Машиностроение, 1983. – 696 с.
42. Козлов, В.Н. Вычислительные методы синтеза систем автоматического управления /В.Н. Козлов, В.Е. Купринов, В.С. Заборовский – Л.: Изд-во ЛГУ, 1989. – 223 с.
43. Контроль качества листового проката тепловым методом [Электронный ресурс]. – Научно-производственная фирма АВЭК. – Режим доступа: http://www.avek.ru/info/kontrol_kachestva_listovogo_prokata_teplovym_metodom.

44. Кормен, Т.Х. Алгоритмы: построение и анализ /Т.Х. Кормен, Х.К. Томас, И.Л. Чарльз., Рональд Л.Р., Клиффорд Ш. – 2-е изд. – М.: «Вильямс», 2006. – С. 1296.
45. Крюков, В.В. Информационно-измерительные системы: учебное пособие /В.В. Крюков. – Владивосток: ВГУЭС, 2000. – 102 с.
46. Кузьмин, М.И. Автоматизация обнаружения поверхностных дефектов листового проката /М.И. Кузьмин, Н.А. Соловьев // «Перспектива». Сборник статей молодых ученых №15. – Оренбург: ООО ИПК «Университет», 2012. – С. 502-505.
47. Кузьмин, М.И. Алгоритм фильтрации вейвлет-коэффициентов изображений поверхностных дефектов в реальном времени на основе векторных команд процессора /М.И. Кузьмин, Н.А. Соловьев // Современные информационные технологии в науке, образовании и практике. Материалы X Всероссийской научно-практической конференции. Оренбург: ООО ИПК «Университет», 2012. – с. 74-77
48. Кузьмин, М.И. Систематизация методов моделирования изображений для распознавания поверхностных дефектов листового проката //Управление большими системами: материалы X Всероссийской школы-конференции молодых ученых, Уфимский государственный авиационный технический университет. – Уфа: УГАТУ, 2013. – Т. 3. – С. 149-152
49. Кузьмин, М.И. Метрологическое обеспечение выделения областей для решения задачи распознавания дефектов /М.И. Кузьмин, Н.А. Соловьев //Компьютерная интеграция производства и ИПИ-технологии: материалы VI Всероссийской научно-практической конференции. – Оренбург: ООО ИПК «Университет», 2013. – С. 152-156
50. Кузьмин, М.И. Особенности распознавания поверхностных дефектов проката на основе метода окрестностей / М.И. Кузьмин, Н.А. Соловьев // Современные информационные технологии в науке, образовании и практике: материалы X всероссийской научно-практической конференции. – Оренбург: ООО ИПК «Университет». – 2014. – С. 38-40.

51. Кузьмин, М.И. Программное обеспечение системы распознавания поверхностных дефектов проката цветных металлов /М.И. Кузьмин, Н.А. Соловьев, Л.А. Юркевская //Современные наукоемкие технологии. – 2016. – № 5, Ч. 1. – С. 46-51.

52. Кузьмин, М.И. Информационно-измерительная система распознавания поверхностных дефектов листового проката на основе метода окрестностей: диссертация на соиск. уч. ст. канд. техн. наук – Оренбург – 2016. – 140 с.

53. Левитин, А. В. Алгоритмы. Введение в разработку и анализ /А.В. Левитин. – М.: Вильямс, 2006 – 576 с.

54. Логунова, О.С. Математическое описание объектов нерегулярной формы на цветных изображениях /О.С. Логунова, В.В. Шакшин, С.М. Логунов //Автоматизация технологических и производственных процессов в металлургии. – 2009. – С. 52-54.

55. Логунова, О.С. Алгоритмы и программное обеспечение распознавания низкоконтрастных изображений при оценке качества стали /О.С. Логунова, П.П. Макарычев //Программные продукты и системы. – 2008. – № 3. – С. 79-81

56. Логунова, О.С. Исследование алгоритмов построения гистограмм и эквализации для изображений в металлургической промышленности /О.С. Логунова, И.А. Посохов //Кибернетика и высокие технологии XXI века: Мат. XI международной научно-технической конференции. – Воронеж: НПФ "Секвое", 2010. – С. 644-650

57. Мацко, И.И. Тенденция применения систем автоматизированного анализа изображений в металлургической промышленности /И.И.Мацко, И.А. Демьяненко, В.В. Павлов, О.С. Логунова /Инженерная поддержка инновации и модернизации. Материалы Международной конференции, посвященной 15-летию со дня создания РУО АИН. – М.: Академия инженерных наук им. А.М. Прохорова. – 2010. – С. 77-79

58. Местецкий, Л. М. Математические методы распознавания образов [Электронный ресурс]: курс лекций /Л. М. Местецкий. – М., – Режим доступа: <http://www.ccas.ru/frc/papers/mestetskii04course.pdf>.

59. Мински М. Фреймы для представления знаний.– 1979. – 576 с
60. Осовский, С. Нейронные сети для обработки информации /С.Осовский. – М.: Финансы и статистика. – 2002.
61. Патент 2426069 Российская федерация, МПК G01B11/30, B21C51/00. Способ неразрушающего контроля качества поверхности рельсов /Трофимов В.Б., Кулаков С.М. Заявитель и патентообладатель ГОУ ВО "Сибирский государственный индустриальный университет" – № 2010112763/28,; заявл. 01.04.2010 г.; опубл. 10.08.2011 г.
62. Переберин, А.В. О систематизации вейвлет-преобразований. //Вычислительные методы и программирование. – 2001. – Т.2., Р. 3. – С.15-40.
63. Прэтт, У. Цифровая обработка изображений. – М.: Мир, 1982. – 791 с.
64. Порфирьев, Л.Ф. Основы теории преобразования сигналов в оптико-электронных системах. – Л.: Машиностроения, 1989. – 400 с.
65. Свидетельство о государственной регистрации программы для ЭВМ. Defectoscope_wavelets / Д.П. Бугаев, Н.А. Соловьев. - №2009610915, дата поступления 3 февраля 2009 г., зарегистрирована в реестре программ для ЭВМ 10.02. 2009 г.
66. Св-во гос. рег. прогр. для ЭВМ № 2013612245, Российская Федерация. Программа идентификации поверхностных дефектов по изображениям цифрового видеопотока холоднокатанного листового проката в реальном времени «Defect Detector for Cold-Rolling Mill» / М.И. Кузьмин, Н.А. Соловьев, Д.А. Лесовой.– № 2012661665; дата поступления 27.12.2012; дата регистр. в Реестре программ для ЭВМ 19.02.2013 г. - Оpubл. 20.03.2013 г., Эл.бюл.№ 1.
67. Св.-во гос. рег. прогр. для ЭВМ № 2016612832, Российская Федерация. Программа распознавания поверхностных дефектов листового проката на основе метода окрестностей / М.И. Кузьмин, Н.А. Соловьев.– № 2016610177; дата поступления 12.01.2016; дата регистр. в Реестре программ для ЭВМ 10.03.2016 г. - Оpubл. 20.04.2016 г., Эл.бюл.№ 4.
68. Соловьев, Н.А. Концепция развития информационных технологий в теории интеллектуального управления //Сборник статей НПК «Опыт использо-

вания и проблемы внедрения инновации в науке, бизнесе и образовании». – Оренбург: ОГИМ, 2009. – С. 24-28.

69. Соловьев, Н.А. Идентификация дефектов листового проката на основе вейвлетной кросскорреляции изображений /Д.П. Бугаев, Н.А. Соловьев //Естественные и технические науки. – 2013. – №3. – С. 230-233.

70. Соловьев, Н.А. Идентификация поверхностных дефектов листового проката методом вейвлет-анализа изображений с управляемым разрешением /М.И. Кузьмин, Д.А. Лесовой, Н.А. Соловьев //Вестник Нижегородского университета им. Н.И. Лобачевского, 2013, №1(3). С. 84-91

71. Стокман, Д. Компьютерное зрение /Д. Стокман, Л. Шапиро. – М.: Бином. Лаборатория знаний, 2006. — 752 с.

72. Тарасов, В.В. Двух- и многодиапазонные оптико-электронные системы с матричными приемниками излучения /В.В. Тарасов, Ю.Г. Якушенков – М.: Логос, 2007. – 192 с.

73. Тимофеев, Б.С. Цифровое телевидение: учебное пособие /Б.С. Тимофеев. – Санкт-Петербург: СПбГУАП, 1998. – 49 с.

74. Ту, Д. Принципы распознавания образов /Д. Ту, Р. Гонсалес. – М.: Мир. – 1978. – 342 с.

75. Установка инспекции качества полосы [электронный ресурс]/ Режим доступа: http://www.dc.ru/activities/visual_control_systems /ustanovka_inspekicii_kachestva_polosy_prokata.

76. Фомин, Я. А. Распознавание образов: теория и применения /Я.А. Фомин. – 2-е изд. – М.: ФАЗИС, 2012. – 429 с.

77. Фомин, Я. А. Статистическая теория распознавания образов /Я.А. Фомин, Г.Р. Тарловский. – М.: Радио и связь, 1986. – 624 с.

78. Форсайт, Д. Компьютерное зрение. Современный подход. /Д.Форсайт, Д. Понс. – М.: Вильямс, 2004. – 928 с

79. Фу, К. Структурные методы в распознавании образов / К. Фу. – М.: Мир, 1977. – 319 с.

80. Хайкин, С. Нейронные сети: Полный курс /С. Хайкин. – 2 изд. – М.: «Вильямс», 2006. – 1104 с.
81. Хант, Э. Искусственный интеллект /Э. Хант – М.: Мир, 1978. – 558 с.
82. Хуанг Т.С. Быстрые алгоритмы в цифровой обработке изображений / Т.С. Хуанг. – М.: Радио и связь, 1984. – 224 с.
83. Черненко, С.А. Медианный фильтр [электронный ресурс]. – Режим доступа:http://www.logis-pro.kiev.ua/math_power_medianfilter_ru.html
84. Юркевская Л.А. Метод идентификации угроз безопасности информационных ресурсов АСУ на основе мультиразрешающего анализа /Н.А. Соловьев //Вестник Самарского государственного университета, серия «Технические науки», 2007, №2(20), ст.70-77.
85. Якушенков, Ю.Г. Теория и расчет оптико-электронных приборов /Ю.Г. Якушенков. – М.: Логос, 2011. – 568 с.
86. Яровой, Н.И. Адаптивная медианная фильтрация. [электронный ресурс]. – Режим доступа: <http://www.controlstyle.ru/articles/science/text/amf/>
87. DeFinds - система контроля качества поверхности листовых материалов [Электронный ресурс] /Режим доступа: <http://www.mallenom.ru/old/definds.php>.
88. UVB TECHNIK. SURFSCAN - Камерные измерительные системы [Электронный ресурс] /Режим доступа: <http://www.uvbtechnik.cz/ru/automatic-detection-of-strip-defects>.
89. Barker R. CASE Method: Entity Relationship Modelling. Reading. – MA: Addison-Wesley Professional, 1990. – P. 113-120.
90. Bradski, G. Learning OpenCV /G. Bradski, A. Kaehler. – O'Reilly Media Inc, 2008. – 555 p.
91. Chen P. The Entity-Relationship Model. Toward a Unified View of Data //ACM Transactions on Database Systems (TODS). – 1976. – Vol. 1. – P. 9-36.
92. Choi, D. Faulty Scarfing Slab Detection Using Machine Vision/ D. Choi, Y. Jeon, S. W. Kim //The 3rd International Conference on Machine Vision (ICMV 2010). – 2010. – P. 434-437.

93. Cong, J. Real-time surface defects inspection of steel strip based on difference image/ J. Cong, Y. Yan, H. Zhang, J. Li // International Symposium on Photoelectronic Detection and Imaging 2007: Related Technologies and Applications, edited by Liwei Zhou. – Proc. of SPIE Vol. 6625, 66250W. – 2008. – P. 45-49.
94. Darlinton, J. Guided Resource Organisation in Heterogeneous Parallel Computing / J. Darlinton, M. Ghanem, Y. Guo, H.W. To // Journal of High Performance Computing. – 1996. – T. 4(1). – P. 13–23.
95. Edler S.. Detection of holes and tears in cold rolled strip /S. Edler, A. Spie // Millenium steel 2005: Finishing processes, 2005. – P. 251-253
96. Industry news //Iron a Stell Engineer. 1985. – V. 62. – № 6. – P. 74-75.
97. Fog, A. Optimizing software in C++: An optimization guide for Windows, Linux and Mac platforms [электронный ресурс]. Режим доступа: http://www.agner.org/optimize/optimizing_cpp.pdf.
98. Huang, T.S. A fast two dimensional median filtering algorithm /T.S. Huang, G.J. Yang, G.Y. Tang //IEEE transactions on acoustics, speech and signal processing. – 1979. – Vol. ASSP-27. – № 1. – P. 13-18.
99. Hacquin, A. A three-dimensional semi-analytical model of rolling stand deformation with finite element validation /A. Hacquin, P. Montmitonnet, J.P. Guille-rault // European Journal of Mechanics. – 1998. – Vol. 17, № 1. – P. 79-106.
100. Kuzmin, M.I. Recognition of surface defects of cold-rolling sheets based on method of localities /Gergel V.P., Kuzmin M.I., Solovyov N.A., Grishagin V.A. //International Review of Automatic Control. – 2015. – Vol.8. – N 1. – P. 51–55.
101. Kuzmin, M.I. System of Computer Vision for Cold-Rolled Metal Quality Control /V. I. Batischev, M.I. Kuzmin, A.M. Pischukhin, N.A. Solovyov //International Review of Automatic Control (I.RE.A.CO.). –2016. – Vol. 9, N. 4. – P. 259-263.
102. Kumar, A. Texture Inspection for Defects Using Neural Networks and Support Vector Machines / A. Kumar, H.C. Shen // IEEE International Conference on Image Processing. – 2002. – P. 353–356

103. Kunzman, D.M. Programming Heterogeneous Systems / D.M. Kunzman, L.V. Kale // IEEE International Symposium on Parallel and Distributed Processing Workshops and Phd Forum. – 2011. P. 211–223.

104. Lee D. Wavelet Analysis: Theory and Applications [Электронный ресурс] //Hewlett-Packard Journal. – 1994. – Режим доступа: <http://www.hpl.hp.com/hpjournal/94dec/dec94a6a.pdf>.

105. Li, J. On-Line Seam Detection in Rolling Processes Using Snake Projection and Discrete Wavelet Transform /J. Li, J. Shi, T. Chang // Journal of Manufacturing Science and Engineering. – Vol. 129. – 2007. – P. 926-933

106. Lin, Z.C. Application of an elastic roller with slightly convex shape to the improvement of the flatness of a strip for cold rolling / Z.C. Lin, S.Y. Lee // Japan Society of Mechanical Engineers International Journal. – 1997. – Vol. 40, №4. – P. 459-469.

107. Matz, M. System V Application Binary Interface - AMD64 Architecture Processor Supplement [электронный ресурс] /M. Matz, J. Hubicka, A. Jaeger, M. Mitchell. – 2010. – Режим доступа: <https://courses.cs.washington.edu/courses/cse351/12wi/supp-docs/abi.pdf>.

108. McCallum, A. A Comparison of Event Models for Naïve Bayes Classification / A. McCallum, K. Nigam // AAAI-98: Workshop on Learning for Text Categorization. – 1998. – P. 8-18.

109. Mitchell J.F. Hot Strip Mill Thickness and Profile Measurement /J.F. Mitchell, K. S. Quinn // AISE Steel Technology. – 2001. – P. 35-44.

110. Medina, R. Surface Defect Detection on Rolled Steel Strips by Gabor Filters /R. Medina, F. Gayubo, L. González, D. Olmedo, J. Gómez, E. Zalama, J. Perán // VISAPP 2008 – International Conference on Computer Vision Theory and Applications. – 2008. – p. 479-485

111. Moore, E.F. The shortest path through a maze /In Proceedings of the International Symposium on the Theory of Switching. – Harvard University Press, 1959. – P. 285–292.

112. Pichler R. Recent developments by VAI in plate mill automation / R. Pichler, D. Auzinger, F. Parzer, K. Aistleitner // Steel Times International. – 2003. – P. 34-35.

113. Rafajlowicz, E. Local detection of defects from image sequences /E. Rafajlowicz, M. Wnuk, W. Rafajlowicz //International Journal of Applied Mathematics and Computer Science. – 2008. – Vol. 18. – No. 4. – pp. 581–592.

114. Systems Engineering Fundamentals. Defense Acquisition University Press [Электронный ресурс]. – 2001. – Режим доступа: http://ocw.mit.edu/courses/aeronautics-and-astronautics/16-885j-aircraft-systems-engineering-fall-2005/readings/sefguide_01_01.pdf.

115. The Basler raL2048-48gm [Электронный ресурс] /Basler AG. – Режим доступа: <http://www.baslerweb.com/en/products/cameras/line-scan-cameras/racer/ral2048-48gm>.

116. Tukey, J. W. Exploratory Data Analysis. – Addison-Wesley, Reading, Mass. – 1971. – P. 220–227.

117. Wu, G. Online surface inspection technology of cold rolled strips //Multimedia, Kazuki Nishi, InTech. – 2010. – P. 205-232.

Приложение А
(обязательное)
Свидетельство о государственной регистрации программы
для ЭВМ «Defectoscope_wavelets»



Приложение Б

(обязательное)

Свидетельство о государственной регистрации программы
для ЭВМ «Программа идентификации поверхностных дефектов»

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2013612245

Программа идентификации поверхностных
дефектов по изображениям цифрового видеопотока
холоднокатанного листового проката в реальном времени
«Defect Detector for Cold-Rolling Mill»

Правообладатель(ли): *Федеральное государственное бюджетное
образовательное учреждение высшего профессионального
образования «Оренбургский государственный университет» (RU)*

Автор(ы): *Кузьмин Михаил Иванович (RU), Соловьев Николай
Алексеевич (RU), Лесовой Дмитрий Андреевич (RU)*

Заявка № 2012661665

Дата поступления 27 декабря 2012 г.

Зарегистрировано в Реестре программ для ЭВМ

19 февраля 2013 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Б.П. Симонов



Приложение В
(обязательное)

**Свидетельство о государственной регистрации программы
для ЭВМ «Программа распознавания поверхностных дефектов»**

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2016612832

**Программа распознавания поверхностных дефектов
листового проката на основе метода окрестностей**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования «Оренбургский
государственный университет» (RU)*

Авторы: *Кузьмин Михаил Иванович (RU),
Соловьев Николай Алексеевич (RU)*



Заявка № **2016610177**

Дата поступления **12 января 2016 г.**

Дата государственной регистрации
в Реестре программ для ЭВМ **10 марта 2016 г.**

*Руководитель Федеральной службы
по интеллектуальной собственности*

Г.П. Ивлиев