

Дормидошина Дарья Андреевна,
Технический директор , АО «ЦКБ «Дейтон»
Dormidoshina Daria A.,
Technical Director , JSC «CDO «Deyton»

Рубцов Юрий Васильевич,
Генеральный директор , АО «ЦКБ «Дейтон»
Rubtsov Yuriy V.,
General Director , JSC «CDO «Deyton»

ОБЗОР И АНАЛИЗ МЕТОДОВ ИЗВЛЕЧЕНИЯ ИЗОБРАЖЕНИЙ ДЕФЕКТОВ В АВТОМАТИЧЕСКОМ ОПТИЧЕСКОМ КОНТРОЛЕ КАЧЕСТВА ИЗДЕЛИЙ ЭЛЕКТРОННОЙ ТЕХНИКИ

Аннотация. Извлечение изображений дефектов используется на этапе обработки изображений в системах автоматического обнаружения дефектов оптическим методом в процессах контроля качества изделий электронной техники. Тем не менее, вопрос о том, как эффективно извлекать необходимые проблемные места на изображении поверхности изделий, остается сложной проблемой. В представленной статье, проведен обзор и анализ результатов исследований в этой области. Примененные методы в статье обсуждаются с точки зрения обработки изображений, извлечения информации о дефектах. Также рассматриваются результаты исследований, в которых использованы технологии искусственного интеллекта для обнаружения дефектов. В статье выделены современные тенденции и возможные будущие направления исследований для создания более совершенных систем автоматизированного оптического контроля качества изделий электронной техники. Цель настоящей статьи – предоставить исследователям и разработчикам основу для категоризации различных методов и помочь им найти ранее опубликованные работы, которые соответствуют их потребностям.

Abstract. Defect image extraction is used in image processing in automated optical defect detection systems for quality control of electronic products. However, how to effectively extract critical areas from surface images remains a challenging issue. This article provides a review and analysis of research in this area. The methods used are discussed in terms of image processing and defect information extraction. Research using artificial intelligence technologies for defect detection is also considered. Current trends and potential future research directions for developing more advanced automated optical quality control systems for electronic products are highlighted. The purpose of this article is to provide researchers and developers with a framework for categorizing various methods and helping them find previously published work that meets their needs.

Ключевые слова: Автоматический оптический контроль, алгоритмы обработки изображений, изделия электронной техники, машинное обучение, компьютерное зрение.

Keywords: Automatic optical inspection, image processing algorithms, electronic products, machine learning, computer vision.

Введение

Обнаружение дефектов в изделиях электронной техники (ИЭТ) является сложной задачей из-за малого размера, разнообразия и несбалансированных образцов на изображениях дефектов. Начиная с ручного контроля и заканчивая современными подходами к обнаружению на основе машинного обучения (МО) задача обнаружения дефектов была важнейшей частью в процессах изготовления ИЭТ, сборки простых узлов или сложной радиоэлектронной аппаратуры (РЭА) с применением ИЭТ.



Ручной контроль подвержен ошибкам, требует много времени и других ресурсов. Люди-инспекторы могут подвергаться воздействию опасных сред на производстве. В последние годы растет необходимость в обнаружении все более сложных и микроскопических дефектов в ИЭТ. Например, в аэрокосмической и автомобильной промышленности ИЭТ с дефектами в производственных процессах отбраковываются, поскольку незначительный дефект может привести к полному отказу РЭА на более поздней или конечной стадии.

На различных этапах производственного процесса изготовления ИЭТ или РЭА, обеспечение качества и мониторинг обнаружения дефектов всегда помогают обеспечить корректирующие меры. Однако это также исключает потерю времени на исправление дефектов, которые могут быть обнаружены на более поздних этапах производства. Более того, автоматический контроль качества (автоматический оптический контроль, АОИ) становится особенно важным при массовом производстве ИЭТ.

Исследователями используется мера сходства для сравнения геометрических размеров элементов ИЭТ, спроецированных из моделей САПР, с геометрическими размерами на реальных изображениях. Это сравнение позволяет обнаруживать и связывать данные, а также обрабатывать данные для задач инспекции ИЭТ. Исследователями разработана модель ранжирования и принятия решений для выбора подходящей технологии.

Исследователями предлагаются методы обработки изображений для улучшения изготовления изделий, классификации изображений и МО для обнаружения дефектов ИЭТ. В разработанных исследователями методах используются алгоритмы извлечения признаков и реализации байесовского классификатора, а также алгоритмов деревьев решений.

Среди других активных исследовательских методологий за последние десятилетия можно назвать применение глубоких нейронных архитектур для достижения улучшенного идеального баланса между производительностью и точностью. Благодаря оптимальным алгоритмам обучения, реализованным исследователями в таких системах как ResNet, AlexNet, GoogLeNet и VGGNet, было показано значительное улучшение по сравнению со старыми традиционными методами.

Производительность подходов к обнаружению дефектов нуждается в дальнейшей оптимизации и валидации. Определено, что вычислительные нагрузки существенно высоки при попытках обучения обнаружению дефектов с использованием локального центрального процессора компьютера. Обучающая часть этих подходов имеет решающее значение, поскольку она потребляет много ресурсов с точки зрения процессорного времени, памяти и т. д. Под обучением понимается задача компьютерной памяти при подготовке к распознаванию дефектов.

Хотя ручной осмотр для обнаружения дефектов поверхности бывает удовлетворительным, все равно требуется больше времени, в зависимости от конкретного эксперта в данной области. Для этой цели более ранние модели обработки изображений и обнаружения дефектов, основанные на глубоком обучении, адаптированы Google Cloud Machine Learning Engine, что показывает достаточно удовлетворительные результаты.

Извлечение изображений дефектов является этапом обработки для многих задач АОИ, в которых для обеспечения высокой скорости вычислений многие алгоритмы извлечения разделяют изображение на области правильной формы, такие как прямоугольные области или окружности, и извлекают особенности изображения для последующих процессов. Тем не менее, признаки, полученные из областей правильной формы, часто терпят неудачу и приводят к сбою обнаружения и потере данных из-за слабой репрезентативной способности областей правильной формы.

По сравнению с правильными областями формы, произвольные области формы могут не только сохранять больше информации, такой как цвет, яркость и текстура, но и захватывать



больше границ изображений дефектов. Поскольку области произвольной формы имеют много преимуществ, существует также множество результатов исследований, в которых области произвольной формы используются для выделения особенностей, например, классификация видов. Тем не менее, требуется много времени для извлечения областей произвольной формы, что неприемлемо для некоторых АОИ с высокими требованиями к реальному времени.

Несмотря на то, что в последние годы было предложено множество новых алгоритмов извлечения изображений с дефектами, процесс по-прежнему остается очень сложным. Например, несмотря на то, что глубокие сети успешно применяются в задачах классификации, в которых доминирует одна модальность, их производительность неизбежно сталкивается с трудностями в сложных сценах, которые необходимо точно классифицировать из-за ограниченности информационного разнообразия.

Исследователи предложили базовое решение вышеупомянутой проблемы, разработав общую мультимодальную структуру. Были тщательно исследованы сверточные нейронные сети (СНС) и графовые сверточные сети (ГСН) с точки зрения классификации изображений. Из-за построения матрицы смежности для всех данных, традиционные ГСН обычно страдают от огромных вычислительных затрат, особенно в задачах обнаружения микродефектов на сложных поверхностях.

Методы обнаружения микродефектов в инфракрасном освещении, основанные на обучении, в настоящее время в значительной степени опираются на магистральную сеть классификации. По этой причине была исследована и предложена простая и эффективная структура «U-Net in U-Net». Ее применение принесло значимые результаты.

Таким образом, множество требований к обнаружению дефектов, привело к значительному числу методов и алгоритмов, обзор и анализ которых представлен в настоящей статье.

Применение алгоритмов связанных компонентов

Алгоритм связанных компонентов является общепринятой техникой извлечения изображения с дефектами, которая рассматривает каждый пиксель как узел в графе. Метка связанного компонента (CCL – Connected Component Labelling) может быть использована после этого шага в задачах инспекции дефектов для маркировки найденных мест определенными классами.

Чан и др. в [1] применили алгоритм связанных компонентов для определения дефектов светодиодов на бинарной карте изображения. Алгоритм был применен после сегментации пикселей как 1 и 0 в бинарном изображении, имеющем такой же размер, как оригинальное изображение, с использованием нейронной сети Хопфилда. Алгоритм связанных компонентов проверяет каждый пиксель изображения, чтобы сравнить его с соседними пикселями. Эта процедура повторяется до тех пор, пока все чипы не будут распознаны. Ои и др. в [2] предложили комплексный процесс дата-майнинга с использованием алгоритма сегментации и обнаружения для извлечения общих изображений с дефектами.

Предложенный метод был разработан для точного и автоматического извлечения значимых характеристик изображений. Он может быть реализован как в онлайн, так и в офлайн режимах. Алгоритм связанных компонентов использовался для простого соединения соседних 1 (которые представляют собой дефектные места) и 0 (которые представляют не дефектные места) в бинарном изображении. В конце были использованы морфологические операции для удаления шума на изображении. Это исследование достигло 90% точности в обнаружении. Более того, разработанные алгоритмы помогают сократить количество ложных срабатываний более чем на 90% по сравнению с использованием только алгоритма сегментации.

Подобное исследование также было проведено Си и др. в [3], где были сгенерированы четыре дефектные модели с помощью подходов алгоритма связанных компонентов и морфологических операций.



Уджесингхе и др. в [4] использовали аналогичный подход при инспекции дефектов в жидкокристаллических дисплеях. Полученные изображения бинаризируются и пиксели изображения классифицируются как дефектные и недефектные в соответствии с определенным порогом, связанным с интенсивностью. Затем определялись границы дефектных и недефектных областей, группируя каждый класс пикселей вместе. Эта техника повторялась, пока все области были классифицированы. Использование этого подхода не только оценивает конкретное дефективное местоположение, но и позволяет определить величину каждого дефекта и количество дефектов в единичном образце.

Применение вектора признаков

Синдагип и Сривастава в [5] использовали два подхода к извлечению признаков, чтобы выделить микро- и макродефектные характеристики видеопанелей и сгенерировать вектор признаков, который должен использоваться в качестве входных данных для классификатора. Благодаря преимуществам вычислительной эффективности и значимости текстур, модифицированная версия локальных бинарных мест на изображении была рассмотрена как один из подходов к извлечению признаков. В алгоритме используется оператор три на три для сравнения каждого центрального пикселя с его восьмью соседними пикселями, чтобы сгенерировать бинарный код, который можно преобразовать в десятичное значение. Соседние пиксели, значения которых меньше значения центрального пикселя, устанавливаются в логический 0, в противном случае они устанавливаются в логический 1. Затем сгенерированный бинарный код, полученный из значений соседних пикселей, заменяет значение центрального пикселя. В модифицированной версии алгоритма определяется мера однородности, которая соответствует количеству переходов между ноль и единица.

Шаблоны, имеющие уровень однородности ниже определенного порога, обозначаются как однородные. В процессе оценки этого метода было замечено, что он хорошо работает с макродефектами, такими как вмятины и выпуклости, но неэффективен для микродефектов, таких как царапины и пятна. Поэтому для обнаружения микродефектов была интегрирована другая техника извлечения признаков, называемая локальными отношениями выбросов и вливания.

Применение метода оборачиваемости и региональной обработки изображений

Лин и др. в [6] рассмотрели метод извлечения изображений дефектов на основе сегментации, называемый оборачиванием, для локализации дефектных ярких деталей в светоразделительной пластине жидкокристаллической панели. Сначала всё изображение сканируется для нахождения яркой точки. Затем АОИ сканирует верхнюю часть к краю точки. Расстояние между нижними и верхними краями рассчитывается, и центральная точка оценивается делением расстояния пополам. Измеренная центральная точка соответствует центру яркой точки. В этом случае предлагается метод оборачивания окружности, при котором последовательность сканирования следует против часовой стрелки от одного угла к противоположному углу, пока все яркие точки не будут отмечены. Затем были применены определенные измерения для оценки качества ярких точек. Однако процедура классификации не была явной. Кроме того, не было обсуждения времени вычисления, необходимого для достижения точности.

Кубота и др. в [7] использовали метод регионального роста для извлечения особенностей формы дефекта полупроводниковой пластины. Их алгоритм начинается с извлечения точек локального минимума в квадратной области пикселей, расположенной в центре пикселя вопроса, называемой областью соседства. Если значение локальной минимальной точки находится в заранее определенном диапазоне, то эта точка принадлежит указанной области. Более того, они извлекли характеристики кривизны поверхности дефекта. Затем создали вектор признаков на основе извлеченных характеристик и подали его на нейронную сеть для классификации.



Хсей и Чен в [8] использовали несколько методов извлечения признаков на основе анализа подконтуров для определения возможной дефектной точки полупроводниковых пластин. Затем они применили метод минимальной площади прямоугольника для объединения дефектных точек в кластеры. Однако они не указали, как задать количество кластеров и как использовать функции кластеризации для разделения различных типов рисунков дефектов [9].

Панг в [10] предложил исследование для обнаружения дефектов припойной пасты в местах пайки, сначала создавая 3D профиль для представления блока припойной пасты. Использовалась техника сегментации, чтобы разделить блок на четыре края и поверхность верхней зоны. Весь блок припойной пасты рассматривался как другой регион. Глобальный классификатор был использован для оценки качества всей области блока и определения наличия дефекта. Для подачи данных в этот классификатор использовались две характеристики: объем и соотношение сторон. Однако блок паяльной пасты все еще мог быть дефектным, если он проходит глобальный классификатор. Это связано с тем, что деформированный блок паяльной пасты может иметь такой же объем и соотношение сторон, как и нормальный. Поэтому были созданы дополнительные пять локальных классификаторов, соответствующих пяти сегментированным регионам. Для четырех краев были рассмотрены те же характеристики, такие как стандартное отклонение контурных линий и площадь края, которые подаются на четыре классификатора.

При этом стандартное отклонение высоты верхнего края и площадь верхней поверхности паянного соединения были выбраны в качестве признаков для классификатора извлечения изображения дефектов. Наконец, была реализована логическая операция «И» (конъюнкция, представляет собой операцию, которая возвращает истину только в том случае, если оба операнда (входные значения) также являются истинными) между выходами локальных классификаторов и глобального классификатора, если дефект обнаруживается в одном из них, это означает, что дефект обнаружен. Несмотря на достижение 100% уровня обнаружения в этом исследовании, они не упомянули природу выбранных классификаторов. Более того, поскольку в этом исследовании было выбрано в общей сложности шесть классификаторов, было важно упомянуть время, необходимое для классификации.

Методы на основе морфологии

Ляо и др. в [11] предложили подход на основе морфологии для генерации простых и сложных образцов полупроводниковых пластин с определенной степенью сходства по сравнению с образцами. В этом процессе использовалось несколько морфологических операций, включая дилатацию (преобразование множеств, растяжение, расширение, когда все пиксели меняют значение интенсивности), эрозию, сдвиг позиции, изменение плотности и вращение с вариациями. Сгенерированные данные затем отправлялись классификатору, чтобы определить тип дефекта.

Лин и Лю в [12] предложили систему быстрого позиционирования и инспекций для микросхем в корпусе с шариковыми выводами BGA. Сначала были применены техники обнаружения краев и пороговой обработки для нахождения границ областей подушек и отверстий, затем использовался метод наименьших квадратов, с помощью которого находятся центры отверстий и подкладок. Затем сдвиг выравнивания проверяется с использованием четырех образцовых изображений, где центры отверстий и подкладок этих образцов сравниваются друг с другом. Были использованы определенные пороги, чтобы определить, принимаются ли изменения, возникающие в результате процесса сравнения. К сожалению, в этом исследовании не было представлено информации об эффективности предложенного метода с точки зрения точности распознавания и вычислительного времени.



Дэн и др. в [13] исследовали прозрачные дефекты поляризаторов из полимеров, с помощью выпуклой линзы. Они применили подход дилатации и эрозии, чтобы идентифицировать исследуемые дефекты и извлечь их особенности. Они были связаны с местоположением, формой и размером дефектов. Несмотря на наличие АОИ с относительно низким временем обнаружения (1,6 секунды) и учитывая тот факт, что обнаружение смоделированных дефектов было согласовано с экспериментальными результатами, в этом исследовании не рассматривался алгоритм классификации дефектов. Кроме того, нерегулярные дефекты можно смоделировать с помощью линз неправильной формы, но это не было подтверждено экспериментально. При этом, они не показали необходимость использования такой смоделированной техники. Позже в [14, 15] применены аналогичные подходы; однако в них рассматривались простые для обнаружения дефекты.

Получили развитие работы, в которых используются ранее сформированные специализированные методы обнаружения дефектов поверхности [16–22]. Например, алгоритм обнаружения пятен, представлен в [20]. Обнаружение дефектов с использованием метода гистограмм на основе признаков, представлено в [21].

Методы на основе глубокого машинного обучения

Методы, основанные на обучении, представляют собой лучшую альтернативу заранее запрограммированным методам обнаружения признаков благодаря своей устойчивости к вариациям. Классические методы МО для извлечения признаков могут обеспечить такую устойчивость. Эти методы, основанные на обучении, используют опорные векторы [23, 24], К-ближайших соседей, байесовский алгоритм [25], нейронные сети [26], деревья решений [27]. Эти методы учитывают статистические вариации дефектов на изображениях для определения желаемых дефектов. Одним из основных недостатков таких методов является необходимость разработки точных моделей для изучения закономерностей в дефектах, и они могут быть недостаточно устойчивыми к вариациям фона, освещения, сложности дефектов и т. д.

В последнее время глубокое МО показало исключительную эффективность в обнаружении дефектов на изображениях и в извлечении их признаков. Оно доказало свою устойчивость к фону, освещению, цвету, форме, размерам и интенсивности при обнаружении закономерностей на изображениях. Это особенно важно при обнаружении сложных дефектов поверхности в промышленных условиях. Более того, дефекты необходимо не только обнаруживать, но и определять их точный размер и тип.

Извлечение их признаков на основе глубокого МО обеспечивает гибкость сети для обнаружения индивидуальных дефектов на основе набора данных. Более того, параметры, изученные для одной нейронной сети, могут быть использованы для аналогичных сетей и достижения высокой эффективности обнаружения поверхностных дефектов. Более того, нет необходимости в написании специального кода для обучения различных типов дефектов. Размеченные данные для различных дефектов с соответствующей сетью обеспечивают значительно гибкий механизм обнаружения дефектов, как описано в нескольких работах, обсуждаемых в данной статье.

Извлечения изображений дефектов – это метод или процесс для выявления аномалий, которые представляют собой дефекты в наборах данных. Его часто рассматривают как приложение неконтролируемого обучения [28].

Аномалии – это неожиданные события, которые показывают отклонения от нормальных данных. В последнее время исследователи все чаще используют глубокое обучение для обнаружения аномалий. Обнаружение аномалий на основе глубокого обучения можно разделить на три метода: контролируемое, полуконтролируемое и неконтролируемое обнаружение аномалий [29]. Контролируемое обнаружение аномалий содержит как бездефектные, так и дефектные образцы, которые помечены в обучающем наборе. В этом



случае показатели обнаружения могут быть очень высокими, поскольку все обучающие данные помечены. Однако контролируемое обнаружение аномалий не является самым эффективным подходом из-за дисбаланса классов в наборах данных.

При полуконтролируемом обнаружении аномалий обучающий набор данных включает только помеченные нормальные образцы. Этот метод также называют одноклассовой классификацией. Основная идея заключается в обучении и установке дискриминационной границы, которая содержит бездефектные образцы и рассматривает любые образцы за пределами границы как аномалии. Метод полезен, поскольку не приходится иметь дело с получением большого количества дефектных образцов, а модель строится только с использованием нормальных образцов. Однако точность обнаружения аномалий этим методом ниже, чем у контролируемого обнаружения аномалий. В таких исследованиях, как [30–33], применяются различные подходы глубокого обучения в полуконтролируемом обнаружении аномалий. По сравнению с другими, полуконтролируемое обнаружение аномалий, представленное в [33], показывает более четкие границы решений вокруг выбросов.

Если размеченные данные недоступны, используют неконтролируемое обнаружение аномалий. При этом существует несколько предположений. Первое заключается в том, что большинство образцов в наборе данных являются нормальными (не дефектными). Предполагается, что дефектные экземпляры встречаются в наборе данных редко. Второе предположение заключается в том, что аномальные экземпляры должны демонстрировать заметные отклонения от стандартных экземпляров в наборе данных. При этих предположениях метод изучает внутренние характеристики набора данных, чтобы отделить аномалии от нормальных образцов. В [34] авторы демонстрируют обнаружение аномалий, основанное на неконтролируемом обучении и глубоких генеративно-сопоставительных сетях (GAN). Авторы использовали только полезные данные для обучения GAN, и построенная сеть тестируется как на неизвестных без дефектов, так и на аномальных данных. Другой пример неконтролируемого обнаружения аномалий в [35]. Здесь авторы представляют метод, называемый описанием данных с помощью глубоких опорных векторов, который обучает глубокую нейронную сеть, одновременно минимизируя объем гиперсферы, содержащей сетевые представления нормальных данных. Глубокие опорные векторы выполняют это сопоставление и происходит преобразование нейронной сети с весами. Результат алгоритма показывает, что данные, выходящие за пределы гиперсферы, могут быть классифицированы как аномалии.

Классификация набора данных разделяет образцы на две группы: нормальные и дефектные. По сравнению с методом обнаружения аномалий, метод целевого обнаружения дефектов используется для обнаружения определенного типа дефекта путем установки его в качестве цели. Сначала идентифицируется целевой дефект, а затем определяется его местоположение на изображении. Это делается с помощью контролируемого обучения, поскольку конкретная цель должна быть помечена как дефект. Для обучения модели используется большое количество дефектных образцов. Тип дефекта и объем полученных данных при этом влияют на сложность вычислений.

По сравнению с контролируемым обнаружением аномалий, которое дает положительные результаты после обучения на хороших образцах, целевое обнаружение дефектов обучает модель или глубокую нейронную сеть на дефектных образцах. Процесс сбора данных может быть трудоемким из-за необходимости использования значительного количества дефектных образцов. Например, в обычных промышленных условиях и на производственной линии количество бездефектных образцов обычно значительно превышает количество дефектных. Таким образом, получение большого количества образцов с



определенным дефектом может занять время, и такой сценарий может быть неидеальным. Тем не менее, он хорошо работает, когда данные о дефектах легко доступны.

Заключение

В настоящей статье представлены результаты исследований, выполнен анализ методов и алгоритмов извлечения изображений дефектов в АОИ ИЭТ с целью решения проблем нерационального выделения положительных и отрицательных выборок и потери информации о микродефектах. Для достижения этой цели необходимо обнаружение дефектов на основе автоматизированного назначения образцов, которое оптимизирует обнаружение дефектов в АОИ и значительно улучшит обнаружение микродефектов. Такой подход оптимизирует проанализированные в статье методы и алгоритмы.

Глубокое МО набирает популярность в АОИ. В данной статье представлены три различных подхода в результатах исследований. Первый подход основан на определении области действия различных задач АОИ в зависимости от контекста и требований приложения. Этот подход помогает определить и понять различные типы задач обнаружения дефектов. Второй подход рассматривает результаты исследований с точки зрения МО и объясняет, почему определенные подходы к обучению полезны для решения определенных видов задач. Наконец, подход с точки зрения системной архитектуры объясняет различные типы подходов, используемых для локализации и классификации дефектов с точки зрения системной архитектуры. Обнаружение дефектов поверхности на основе изображений с использованием глубокого МО является быстро развивающейся областью и представляет уникальные проблемы по сравнению с другими задачами анализа изображений и обнаружения дефектов.

Извлечение фрагментов изображений является распространенной задачей в распознавании дефектов и их анализе. Большая часть проанализированных в статье исследований сосредоточена на областях, ограниченных прямыми границами. В то время как классические алгоритмы извлечения областей с дефектами доказали свою способность работать во многих АОИ, дальнейшие направления исследований требуют обобщения такой задачи для случая, когда извлекаемые области ограничены произвольным числом изогнутых границ.

Список литературы:

1. C.-Y. Chang, C.-H. Li, S.-Y. Lin, and M. Jeng, «Application of two hopfield neural networks for automatic four-element LED inspection» IEEE Trans. Syst., Man, Cybern. C, Appl. Rev., vol. 39, no. 3, pp. 352–365, May 2009.
2. M. P.-L. Ooi, E. K. J. Joo, Y. C. Kuang, S. Demidenko, L. Kleeman, and C. W. K. Chan, «Getting more from the semiconductor test: Data mining with defect-cluster extraction» IEEE Trans. Instrum. Meas., vol. 60, no. 10, pp. 3300–3317, Oct. 2011.
3. L. Xie, R. Huang, N. Gu, and Z. Cao, «A novel defect detection and identification method in optical inspection» Neural Comput. Appl., vol. 24, nos. 7–8, pp. 1953–1962, Jun. 2014.
4. R. E. Wijesinghe, K. Park, Y. Jung, P. Kim, M. Jeon, and J. Kim, «Industrial resin inspection for display production using automated fluid-inspection based on multimodal optical detection techniques» Opt. Lasers Eng., vol. 96, pp. 75–82, Sep. 2017.
5. V. A. Sindagi and S. Srivastava, «Domain adaptation for automatic OLED panel defect detection using adaptive support vector data description» Int. J. Comput. Vis., vol. 122, no. 2, pp. 193–211, Apr. 2017.
6. C.-S. Lin, W.-Z. Wu, Y.-L. Lay, and M.-W. Chang, «A digital image-based measurement system for a LCD backlight module» Opt. Laser Technol., vol. 33, no. 7, pp. 499–505, Oct. 2001.



7. T. Kubota, P. Talekar, X. Ma, and T. S. Sudarshan, «A nondestructive automated defect detection system for silicon carbide wafers» *Mach. Vis. Appl.*, vol. 16, no. 3, pp. 170–176, May 2005.
8. H.-W. Hsieh and F.-L. Chen, «Recognition of defect spatial patterns in semiconductor fabrication» *Int. J. Prod. Res.*, vol. 42, no. 19, pp. 4153–4172, Oct. 2004.
9. C.-H. Wang, S.-J. Wang, and W.-D. Lee, «Automatic identification of spatial defect patterns for semiconductor manufacturing» *Int. J. Prod. Res.*, vol. 44, no. 23, pp. 5169–5185, Dec. 2006.
10. T.-W. Hui and G. K.-H. Pang, «Solder paste inspection using region- based defect detection» *Int. J. Adv. Manuf. Technol.*, vol. 42, nos. 7–8, pp. 725–734, Jun. 2009.
11. C.-S. Liao, T.-J. Hsieh, Y.-S. Huang, and C.-F. Chien, «Similarity searching for defective wafer bin maps in semiconductor manufacturing» *IEEE Trans. Autom. Sci. Eng.*, vol. 11, no. 3, pp. 953–960, Jul. 2014.
12. C.-S. Lin and L. W. Lue, «An image system for fast positioning and accuracy inspection of ball grid array boards» *Microelectron. Rel.*, vol. 41, no. 1, pp. 119–128, Jan. 2001.
13. Y.-L. Deng, S.-P. Xu, and W.-W. Lai, «A novel imaging-enhancement- based inspection method for transparent aesthetic defects in a polymeric polarizer» *Polym. Test.*, vol. 61, pp. 333–340, Aug. 2017.
14. Y.-L. Deng, S.-P. Xu, H.-Q. Chen, Z.-H. Liang, and C.-L. Yu, «Inspection of extremely slight aesthetic defects in a polymeric polarizer using the edge of light between black and white stripes» *Polym. Test.*, vol. 65, pp. 169–175, Feb. 2018.
15. C. Yu, P. Chen, X. Zhong, X. Pan, and Y. Deng, «Saturated imaging for inspecting transparent aesthetic defects in a polymeric polarizer with black and white stripes» *Materials*, vol. 11, no. 5, p. 736, May 2018.
16. Adhish Anitha Vilasan, Stephan Jäger, Noah Klarmann. «AI-Driven Multi-Stage Computer Vision System for Defect Detection in Laser-Engraved Industrial Nameplates». *Computer Science, Computer Vision and Pattern Recognition*, 2025.
17. Nian Wang, Yue Chen, Weiang Li, Liyang Zhang, Jinghong Tian, «FAD-Net: Automated Framework for Steel Surface Defect Detection in Urban Infrastructure Health Monitoring». *Big Data Cogn. Comput.* 9(6), 2025.
18. Tsai, D.-M., and Huang, T.-Y., «Automated surface inspection for statistical textures». *Image and Vision computing*, 21 (4), 2003.
19. Samarawickrama, Y. C., and Wickramasinghe, C. D., «Matlab based automated surface defect detection system for ceramic tiles using image processing». 6th National Conference on Technology and Management (NCTM), IEEE, 2017.
20. Elbehriy, H., Hefnawy, A., and Elewa, M., «Surface defects detection for ceramic tiles using image processing and morphological techniques». 2005.
21. Iivarinen, J., «Surface defect detection with histogram-based texture features». In *Intelligent robots and computer vision xix: Algorithms, techniques, and active vision*, Vol. 4197, International Society for Optics and Photonics, 2000.
22. Jie, L., Siwei, L., Qingyong, L., Hanqing, Z., and Shengwei, R., «Real time rail head surface defect detection: A geometrical approach». *IEEE International Symposium on Industrial Electronics*, IEEE, 2009.
23. Jia, H., Murphey, Y. L., Shi, J., and Chang, T.-S., «An intelligent real time vision system for surface defect detection». In *Proceedings of the 17th International Conference on Pattern Recognition*, Vol. 3, IEEE, 2004.



24. Xue-Wu, Z., Yan-Qiong, D., Yan-Yun, L., Ai-Ye, S., and Rui-Yu, L., «A vision inspection system for the surface defects of strongly reflected metal based on multiclass svm». *Expert Systems with Applications*, 38(5), 2011.
25. Shanmugamani, R., Sadique, M., and Ramamoorthy, B., «Detection and classification of surface defects of gun barrels using computer vision and machine learning». *Measurement*, 60, 2015.
26. Li, Q., Wang, M., and Gu, W., «Computer vision based system for apple surface defect detection». *Computers and electronics in agriculture*, 36 (2-3), 2002
27. Pastor-López, I., Santos, I., Santamaría-Ibirika, A., Salazar, M., de la Pena-Sordo, J., and Bringas, P. G., «Machine-learning-based surface defect detection and categorization in high-precision foundry». *7th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, IEEE, 2012.
28. Varun Chandola, Arindam Banerjee, V. K., «Anomaly detection: A survey». *ACM Journals*, 2009.
29. Chalapathy, R., and Chawla, S., «Deep learning for anomaly detection: A survey». 2019.
30. Kiran, B., Thomas, D., and Parakkal, R., «An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos». *Journal of Image*, vol. 4. 2018.
31. Wulsin, D., Blanco, J., Mani, R., and Litt, B., «Semi-supervised anomaly detection for eeg wave-forms using deep belief nets». *Ninth International Conference on Machine Learning and Applications*, pp. 436–441. 2010.
32. Song, H., Jiang, Z., Men, A., and Yang, B., 2017. «A hybrid semi-supervised anomaly detection model for high-dimensional data». *Journal of Computational Intelligence and Neuroscience*, 2017.
33. Ruff, L., Vandermeulen, R. A., Gornitz, N., Binder, A., Muller, E., Muller, K.-R., and Kloft, M., «Deep semi-supervised anomaly detection». *Ar Xiv preprint arXiv: 1906.02694*. 2019.
34. Schlegl, T., Seebock, P., Waldstein, S. M., Schmidt-Erfurth, U., and Langs, G., 2017. «Unsupervised anomaly detection with generative adversarial networks to guide marker discovery». In *Information Processing in Medical Imaging*, M. Niethammer, M. Styner, S. Aylward, H. Zhu, I. Oguz, P.-T. Yap and D. Shen, eds., Springer International Publishing, 2017
35. Ruff, L., Vandermeulen, R., Goernitz, N., Deecke, L., Siddiqui, S. A., Binder, A., Müller, E., and Kloft, M., 2018. «Deep one class classification». In *Proceedings of the 35th International Conference on Machine Learning*, J. Dy and A. Krause, eds., Vol. 80 of *Proceedings of Machine Learning Research*, PMLR, 2018.

