

BAB II

TINJAUAN PUSTAKA

Pemeriksaan sambungan solder dengan AOI telah menjadi topik penelitian bertahun-tahun karena tingginya tuntutan industri akan kualitas produk yang dihasilkan. Czimmermann mengungkapkan bahwa pemeriksaan cacat pada sambungan solder dengan mengandalkan penglihatan manusia memiliki banyak kelemahan. Pemeriksaan cacat pada produk merupakan pekerjaan yang bersifat rutin dan dilakukan dalam waktu yang lama, hal ini menyebabkan kejenuhan yang akan berpengaruh terhadap hasil pemeriksaan. Pemeriksaan secara manual memerlukan waktu banyak waktu, biaya, dan sumber daya manusia [9]. AOI memberikan solusi bagi pemeriksaan kualitas sambungan solder karena kemampuannya mengumpulkan informasi dalam jumlah besar untuk keperluan penjaminan kualitas produk [8]. Chin dan Harlow menyampaikan enam argumen yang menunjukkan efisiensi penggunaan AOI dibandingkan dengan pemeriksaan kualitas secara manual. Adapun argumen yang disampaikan Chen dan Harlow antara lain:

- A. Membebaskan pekerja dari kebosanan akibat aktivitas rutin
- B. Mengurangi biaya kerja (upah) pada produksi
- C. Memungkinkan pemeriksaan pada area yang sulit dijangkau manusia
- D. mengurangi ketergantungan akan tenaga kerja dengan kemampuan yang tinggi
- E. memungkinkan perekaman data dan tindakan statistik untuk

membantu pengambilan keputusan

F. dapat menyesuaikan kecepatan inspeksi dengan kecepatan produksi

Argumen tersebut masih dapat berkembang seiring perkembangan teknologi AIO serta ruang lingkup permasalahan dan sudut pandang yang digunakan [7]

Salah satu contoh perkembangan teknologi AOI adalah penggunaan algoritma *deep learning* untuk klasifikasi. Penggunaan *deep learning* dalam AOI terbukti dapat meningkatkan kemampuan pemeriksaan dan waktu pemeriksaan yang cepat [20], [21]. AOI berbasis *deep learning* juga mampu memenuhi kriteria yang disampaikan Timm dan Barth yaitu memiliki ketepatan deteksi mendekati 100% dan jumlah alarm palsu mendekati nol [22]. Selama bertahun-tahun telah banyak penelitian yang dilakukan untuk menemukan algoritma yang tepat sehingga memenuhi syarat yang disarankan oleh Timm dan Barth. *Convolutional Neural Networks* (CNN) merupakan salah satu algoritma *deep learning* dengan performa yang paling baik jika dibandingkan algoritma klasifikasi lainnya [23]. CNN secara khusus dikembangkan untuk pengolahan informasi citra dimana *feature extraction* dan *pre-processing* tidak diperlukan karena termasuk ke dalam *hidden layer* dari algoritma ini.

Pengembangan selanjutnya dari penggunaan CNN dilakukan oleh Wu, [24] yang menerapkan *Region-based Convolutional Neural Network* (R-CNN) dimana metode yang diusulkan mampu melakukan segmentasi, penentuan posisi dan klasifikasi sambungan solder dalam satu waktu. Algoritma yang diusulkan memiliki struktur yang kompleks dan menggunakan banyak data latih sehingga

menuntut penggunaan komputer dengan kecepatan proses yang tinggi. Untuk mencukupi kebutuhan tersebut, sebuah komputer GPU dengan seri NVidia GTX 1080Ti digunakan. Zhang dan Shen [25] menerapkan algoritma Faster-RCNN yang merupakan pengembangan dari R-CNN pada deteksi cacat sambungan solder dan menghasilkan peningkatan akurasi yang cukup baik. Pengujian yang dilakukan pada algoritma ini menghasilkan tingkat akurasi sebesar 94% dan pada kondisi tertentu akurasi dapat mencapai 100%. Untuk mencukupi kebutuhan komputasi, digunakan *hardware* berupa Intel Core I7-8750h CPU dan Nvidia GTX 1050Ti 8G GPU. Penelitian lain yang dilakukan Li, [26] mengembangkan penerapan *Generator Adversarial Networks* (GAN) pada deteksi sambungan solder pada komponen *Integrated Circuit* (IC). GAN merupakan algoritma *deep learning* yang mampu melakukan ekstraksi fitur struktural secara efektif tanpa memerlukan supervisi. GAN tidak melakukan ekstraksi fitur struktural secara langsung, melainkan mempelajari distribusi data latennya dengan melakukan pemodelan secara tidak terawasi pada data yang diberikan. Oleh karena itu, GAN tidak memerlukan supervisi dalam bentuk label data ter-anotasi. Sifat *Unsupervised* memungkinkan GAN untuk menentukan *target of interest* pada citra dalam ukuran besar. Algoritma ini memiliki komputasi yang kompleks dengan data yang besar sehingga dalam penelitian tersebut digunakan komputer GPU Nvidia Quadro M4000 8 GB. Penelitian terkini dilakukan oleh Liao, [27] yang membandingkan beberapa algoritma *deep learning* antara lain *Faster R-CNN*, YOLO3, YOLO4, YOLO5, dan YOLO-X. Pengujian yang dilakukan menunjukkan bahwa YOLO-X memiliki performa tertinggi dengan *mean Average*

Precision (mAP) sebesar 94,19%. YOLO-X menggunakan arsitektur deep learning yang membutuhkan komputasi yang sangat intensif sehingga memerlukan GPU untuk menjalankannya. Meskipun demikian, penggunaan CPU pada YOLO-X masih dimungkinkan. Namun, deteksi objek pada CPU akan memerlukan waktu yang lebih lama dibandingkan dengan menjalankan YOLO-X pada GPU.

Deep Learning merupakan algoritma yang handal digunakan pada AOI seperti disampaikan pada penelitian [24],[25],[26],[27]. Namun, jika diamati dengan seksama, proses komputasi CNN memiliki struktur yang kompleks dan mendalam sehingga menimbulkan beberapa masalah, antara lain: diperlukan banyak citra untuk komparasi, memerlukan komputer dengan kemampuan tinggi (seperti parallel GPU), dan waktu pelatihan yang lama [28]. Penggunaan komputer GPU pada inspeksi sambungan solder dengan AOI pada dunia industri tentu tidak menjadi masalah karena tersedianya anggaran yang memadai untuk pengadaan jenis komputer tersebut. Namun, penggunaan GPU akan menimbulkan permasalahan bagi institusi dengan anggaran yang terbatas seperti pada sekolah vokasi. Untuk mengatasinya, Fonseka [19] mengusulkan sebuah algoritma baru yang dirancang untuk pemeriksaan sambungan solder berjenis THT dengan menggunakan segmentasi citra dan ekstraksi fitur. Klasifikasi yang dilakukan dengan menggunakan segmentasi dan ekstraksi fitur memiliki komputasi yang lebih sederhana daripada penggunaan *deep learning* sehingga tidak diperlukan GPU melainkan cukup menggunakan CPU. Namun demikian, metode yang diusulkan Fonseka, dkk [19] hanya mampu mendeteksi 4 tipe cacat. Disisi lain, Sankar mengungkapkan bahwa terdapat 19 jenis cacat pada sambungan solder [2].

Jenis-jenis cacat yang disampaikan oleh Sankar merupakan jenis cacat yang muncul pada sambungan solder dalam industri perakitan rangkaian elektronika. Namun, dalam penelitian ini hanya lima jenis cacat yang dipertimbangkan merujuk pada pedoman penilaian praktikum *soldering* di sekolah vokasi yang didasarkan pada SKKNI.

Penelitian mengenai pemeriksaan sambungan solder dengan menggunakan *Automatic Optical Inspection* telah banyak dilakukan sebelumnya. Namun demikian, penelitian yang dilakukan hanya diterapkan pada bidang industri perakitan rangkaian elektronika. Penerapan *Automatic Optical Inspection* pada bidang pendidikan vokasi belum banyak dilakukan sebelumnya. Dengan adanya permasalahan yang telah disampaikan pada bagian pendahuluan, maka diperlukan studi mengenai penggunaan AOI pada praktikum *soldering*. Algoritma yang diusulkan Fosenka dan Jayasinghe mampu mendeteksi cacat dengan akurasi cukup baik pada sambungan solder THT-PCB dengan menggunakan perangkat keras CPU sehingga dirasa cocok untuk diterapkan pada penelitian ini. Namun demikian, modifikasi perlu dilakukan pada algoritma Fosenka dan Jayasinghe sehingga dapat melakukan deteksi hingga 5 kelas cacat. Satu tipe cacat yang akan ditambahkan adalah “sambungan solder kusam” (*dull soldering*). *Dull soldering* dapat diamati dari tekstur permukaannya yang kusam [2], [29], [30]. Salah satu metode yang terbukti handal untuk melakukan analisis pada tekstur adalah *Gray Level Coocurance Matrix* (GLCM). Pada penelitian sebelumnya yang dilakukan oleh Uchida [13], GLCM digunakan untuk menganalisis struktur mikroskopis dari material solder. Ekstraksi fitur kontur dengan GLCM menghasilkan fitur dataset

yang dapat diolah menggunakan *Deep Learning*. Pendekatan analisis melalui ekstraksi fitur tekstur GLCM juga pernah diterapkan pada deteksi cacat sel Photovoltaic oleh Naveen, [31]. Fitur data GLCM yang diperoleh kemudian diklasifikasi dengan menggunakan model klasifikasi Random Forest. Model ini memiliki nilai akurasi yang lebih baik dari pada model yang diusulkan pada penelitian-penelitian sebelumnya yaitu sebesar 99.68%. Berdasarkan hasil penelitian [13],[31] dapat diketahui bahwa ekstraksi fitur tekstur GLCM memiliki performa yang baik pada analisis tekstur sambungan solder. Oleh karena itu dalam penelitian ini akan digunakan ekstraksi fitur tekstur dengan menggunakan GLCM.

Ekstraksi fitur tekstur menghasilkan dataset fitur yang masih memerlukan proses klasifikasi untuk menghasilkan keputusan deteksi. Dalam beberapa literatur, algoritma klasifikasi SVM memiliki performa yang paling baik jika dibandingkan dengan algoritma lain karena memiliki fitur hyperplane [12]. Penggunaan GLCM dan SVM pernah dilakukan untuk mendiagnosa penyakit daun pada cabai. Hasil pengujian terhadap model menunjukkan hasil dengan akurasi 88% [11]. Penelitian yang lainya menggunakan sepuluh fitur GLCM yang berbeda untuk diekstraksi dan dimasukkan sebagai input pada algoritma klasifikasi SVM. Metode yang diusulkan dilatih dan diuji dengan dataset yang dikumpulkan dari pusat analisis citra, Universitas Swedia. Hasil menunjukkan bahwa fitur dari GLCM dapat diklasifikasikan dengan metode machine learning SVM [32]. Dengan keberhasilan penerapan klasifikasi SVM pada ekstraksi fitur tekstur GLCM maka model klasifikasi SVM dipilih untuk diterapkan dalam penelitian ini.