

## Digitalisasi Pengenalan Cacat Pengelasan dengan Bantuan Komputer

Adhi Harmoko S<sup>1</sup>, Benyamin Kusumoputro<sup>2</sup>

<sup>1</sup>Departemen Fisika FMIPA-UI Kampus Baru Depok 16424

<sup>2</sup>Fakultas Ilmu Komputer UI Kampus Baru Depok 16424

adhi\_hst@fisika.ui.ac.id, kusumo@cs.ui.ac.id

### Abstrak

Telah dikembangkan sistem otomatisasi pengenalan cacat pada pengelasan metal berbasis ciri tekstur sebagai pengekstraksi ciri dan jaringan neural buatan sebagai pengklasifikasinya. Sebuah film sinar-X hasil proses radiografi dua buah metal yang disambung dengan teknik pengelasan menjadi input sistem otomatisasi ini. Film Sinar-X didigitalisasi terlebih dahulu kemudian diproses dengan menggunakan komputer agar didapatkan informasi jenis cacat dalam pengelasan. Ekstraksi ciri tekstur Harralick menjadi basis pengolahan citra film sinar-X agar dapat diketahui karakter yang dimiliki oleh citra radiografi. Jaringan Neural Buatan BackPropagation digunakan sebagai sistem pengklasifikasi jenis cacat. Hasil akurasi pengenalan terbaik untuk citra yang belum diketahui jenis cacatnya mencapai 82,87 % untuk perbandingan data pelatihan dan data pengujian 1 : 1.

### Abstract

An automation system for welding defect recognition in metal weld has been developed. The recognition method base on texture feature as feature extraction and neural network as classifier. The input of automatic systems is an X-ray film developed from radiographic technique. The films were digitalized before processing the defect information using computer. For extracting the feature of X-ray films image was used Harralick texture. Back Propagation Neural Network is used to classify the output welding defect automatic systems. The best result is about 82.87% using training testing paradigm 1 : 1.

*Keywords : Weld Defect, Image Processing, Neural Network, Texture Extraction*

## 1. PENDAHULUAN


Sistem otomatisasi telah banyak dikembangkan pada hampir sebagian besar piranti/komponen dalam dunia industri. Dengan implementasi sistem otomatisasi tersebut, tentu akan meningkatkan produktivitas dan efisiensi sebuah proses produksi. Salah satu sistem otomatisasi yang berkembang pada saat ini adalah Sistem Otomatisasi Pengenalan Cacat Pengelasan untuk mendeteksi kualitas proses pengelasan sambungan dua material dengan menggunakan metode radiografi [1].

Kegunaan otomatisasi proses analisis radiografi digital adalah untuk mereduksi waktu analisis dan mengeliminasi aspek subyektifitas dalam menganalisis yang dilakukan oleh seorang inspektor. Otomatisasi analisis radiografi terdiri atas beberapa tahapan, yaitu : digitalisasi film radiografi, pemrosesan citra digital, ekstraksi ciri dan pengenalan cacat dengan menggunakan alat pengenalan pola (*pattern recognition*) [2].

Radiografi adalah metode pengujian tak merusak yang menggunakan penetrasi dan ionisasi untuk mendeteksi kerusakan internal dengan sensitivitas tinggi berupa diskontinuitas beberapa milimeter dari sebuah sambungan dengan prinsip kelurusan sinar datang. Metode radiografi umumnya digunakan pada industri petroleum, petro kimia, nuklir dan pembangkit tenaga untuk menginspeksi kualitas sambungan pengelasan (*welding*) dan cetakan (*casting*). Penggunaan spesial metode ini juga pada industri peralatan perang untuk menginspeksi alat peladak, alat perang dan rudal. Radiografi juga memainkan peranan penting dalam penjaminan kualitas (*Quality Assurance*) pada komponen yang memerlukan kesesuaian dengan suatu standar, spesifikasi dan kode perancangan [3].

Pada penelitian ini, penulis menjelaskan sistem otomatisasi pengenalan cacat pengelasan dengan menggunakan ciri tekstur untuk mengklasifikasikan cacat pengelasan di dalam industri radiografi. Beberapa jenis cacat pengelasan yang akan dikenali dalam sistem ini

yaitu : normal (tanpa cacat), distributed porosity, incomplete penetration, burn through, cluster porosity, excessive cap, excessive penetration, incomplete fusion.



Gambar 1. Jenis cacat pengelasan cluste porosity pada penelitian ini.

Pada gambar 1 dipellihatkan salah satu jenis cacat yaitu cluster porosity, yang digunakan pada penelitian ini. Daerah yang berada dalam kotak adalah posisi cacat yang akan dideteksi.

## 2. METODE PENELITIAN

Kata Tekstur walaupun telah umum digunakan pada kehidupan sehari-hari, namun sampai saat ini belum ada definisi yang disepakati tentang tekstur. Gonzales menyatakan, bahwa walaupun belum ada definisi formal untuk tekstur, secara intuitif tekstur dapat dikatakan sebagai deskriptor yang memberikan informasi tentang kehalusan, kekasaran dan keteraturan [4]. Sedangkan Tomita menjelaskan makna tekstur sebagai pola visual homogen yang kita lihat ketika kita memperhatikan permukaan bahan pakaian, kulit kayu atau batu-batuan [5].

Gray Level Co-occurrence Matrix merupakan metode paling umum digunakan dalam menganalisis tekstur dan telah digunakan sejak tahun 1970 [6]. Ide dari metode tersebut adalah membuat ciri-ciri yang bersifat homogen dari suatu tekstur. Hal ini dilakukan karena mengklasifikasikan sesuatu yang homogen jauh lebih mudah daripada mengklasifikasikan tekstur. Yang dimaksud dengan ciri disini adalah sifat-sifat yang mampu membedakan suatu tekstur dengan tekstur yang lainnya, seperti derajat keacakan, homogenitas, korelasi dan lain sebagainya. Ciri-ciri ini diperoleh dengan melakukan transformasi terlebih dahulu terhadap suatu daerah bertekstur menjadi matriks co-occurrence.

Matriks co-occurrence merupakan matriks yang berisi informasi tentang seberapa sering atau berapa frekuensi kemunculan suatu nilai keabuan berada berdampingan dengan nilai keabuan yang lain. Berdampingan disini dapat dilihat dari dua sudut pandang, pertama dari sudut pandang arah, seperti berdampingan secara horizontal ( $0^\circ$ ), vertikal ( $90^\circ$ ),

diagonal ( $45^\circ$  atau  $135^\circ$ ). Dan kedua dari sudut pandang jarak, seperti berdampingan atau boleh diselingi dengan satu atau lebih piksel diantaranya.

Dalam perumusannya, matriks co-occurrence pada jarak  $d$  dan sudut  $\theta$  dapat dituliskan seperti pada persamaan 1.

$$p(i, j; d, \theta) = \# \begin{cases} (x, y), (x', y') \in D \times D \\ d = |i(x, y) - (x', y')| \\ \theta = \angle(x, y), (x', y') \\ I(x, y) = i, I(x', y') = j \end{cases} \quad (1)$$

Dimana  $p(i, j; d, \theta)$  adalah matriks co-occurrence, # merupakan fungsi "jumlah dari"  $(x, y)$  dan  $(x', y')$  yang merupakan koordinat piksel citra,  $D$  adalah domain derajat keabuan,  $d$  adalah jarak antara dua piksel,  $\theta$  adalah sudut.

Pengukuran nilai tekstur didasarkan pada 4 persamaan Haralick [7] yang didefinisikan sebagai berikut untuk  $p(i, j) = P_{ij}(i, j)$ :

Angular second moment :

$$f_1 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} [p(i, j)]^2 \quad (2)$$

Correlation :

$$f_2 = \frac{1}{\sigma_x \sigma_y} \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} (ij \cdot p(i, j) - \mu_x \mu_y)^2 \quad (3)$$

Invers difference moment :

$$f_3 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} \frac{1}{1 + (i-j)^2} p(i, j) \quad (4)$$

Entropy :

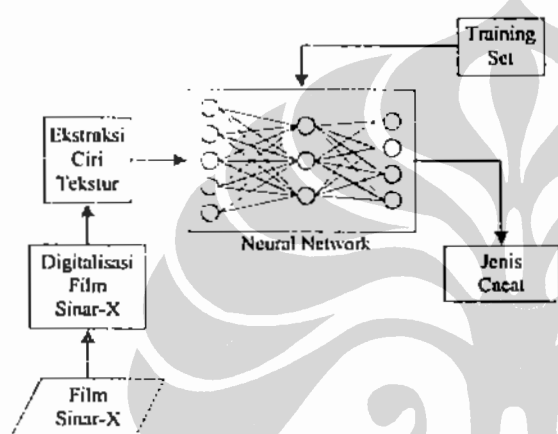
$$f_4 = - \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} p(i, j) \log[p(i, j)] \quad (5)$$

Dalam studi ini, digunakan metode *Principal Component Analysis* (PCA) untuk menemukan sebuah sub set dari sekumpulan ciri tekstur asli sehingga ciri yang mempunyai pengaruh besar dipilih sebagai input pengklasifikasi.

*Principal Component Analysis* sering digunakan secara luas pada aplikasi *remote sensing* untuk mereduksi dimensi [8]. Penggunaan tradisional dari metode ini meliputi pencarian untuk mengganti kolom  $m$  dari baris ciri dengan kolom baru  $n$ . Untuk beberapa set data, penggabungan dua ciri dapat menghasilkan kekuatan baru untuk membedakan dibandingkan dengan sebelumnya. Tetapi, ciri yang berlebihan tidak dapat diidentifikasi oleh pemakaian ini karena ciri aslinya telah ditransformasi menjadi ciri baru. Metode ini didasarkan pada pencarian dan pembuangan ciri yang berhubungan dengan bobot terbesar dalam eigenvektor dari eigenvalue terkecil.

PCA adalah sebuah cara mengidentifikasi pola dalam data dan mengekspresikan data dengan cara memperhatikan kemiripan dan perbedaannya. Ketika pola dalam data menjadi sulit untuk ditemukan dalam data dengan dimensi yang besar, PCA merupakan alat yang tangguh untuk menganalisis data tersebut. Keuntungan utama PCA adalah mampu menemukan pola dalam data dan meng-compress data dengan cara mereduksi jumlah dimensi tanpa harus kehilangan banyak informasi.

Pada gambar 2 diperlihatkan skematik sistem otomatisasi pengenalan cacat dengan menggunakan komputer sebagai sistem pengolah informasi untuk mendapatkan informasi mengenai kualitas pengelasan.



Gambar 2. Skematik sistem otomatisasi pengenalan cacat pengelasan

Pada tahap pertama adalah proses digitalisasi film sinar-X. Film radiografi dari didigitalisasi dengan menggunakan kamera digital di dalam ruang gelap dengan menggunakan latar belakang lampu inspeksi film radiografi tanpa menggunakan flash kamera, pada jarak 30 cm sejajar film. Output proses ini adalah sebuah citra berbasis RGB dan disimpan dalam format JPG tanpa proses kompresi.


Tahap kedua adalah ekstraksi ciri tektur dengan menggunakan komputer Pentium IV 2,6 GHz berbasis teknologi Hyper Threading. Ekstraksi ciri tektur dimulai dengan melakukan kuantisasi derajat keabuan, hal ini dilakukan karena citra input merupakan citra standar dari kamera digital dengan format jpg.. Setelah itu dibentuk satu buah matrik co-occurrence dari satu buah citra input. Kemudian dilakukan proses perhitungan tektur. Pada tahap ini akan didapatkan sebuah set ciri awal. Selanjutnya adalah menurunkan/mengurangi set ciri dengan menggunakan analisis *principal component*.

Tahap ketiga adalah menggunakan Jaringan Neural Buatan untuk mengklasifikasikan kedalam kelompok

normal atau kedalam kelompok jenis cacat tertentu). Jaringan neural buatan yang digunakan disini adalah *Backpropagation*.

### 3. HASIL DAN PEMBAHASAN

Ekstraksi ciri diawali dengan mengkuantisasi citra input RGB menjadi citra dalam 256 derajat keabuan. Langkah selanjutnya membentuk matriks co-occurrence dengan beberapa variasi window pada setiap citra. Dengan pemilihan empat jenis orientasi ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  dan  $135^\circ$ ) pada 4 pengukuran akan didapat sebuah set data yang terdiri atas 16 baris diekstraksi dari setiap citra. Set data ini digunakan sebagai set data awal. Set data ini terdiri atas 16 ciri (gambar 3).



Gambar 3. Pengukuran Ciri dengan menggunakan GLCM.

Set data awal yang terdiri atas 16 ciri selanjutnya dilakukan pemilihan ciri dengan menggunakan PCA. Pada eksperimen ini digunakan nilai 2% untuk PCA.

Untuk mengetahui hasil pengenalan cacat pengelasan pada penelitian ini diperlukan persiapan data masukan untuk proses pembelajaran dan data masukan untuk proses pengujian. Pemilihan data pembelajaran dan data pengujian merupakan salah satu penentu keberhasilan sistem pengenalan. Apabila dapat dipilih satu set data pembelajaran yang mampu mewakili keseluruhan keadaan sistem pengenalan maka akan diperoleh nilai pengenalan tinggi. Untuk mendapatkan set data yang mewakili keseluruhan keadaan sistem pengenalan tentunya bukanlah merupakan hal mudah.


Pada penelitian ini digunakan tiga jenis pemilihan data, yaitu sebagai berikut:

- Random penuh
- Semi random
- Pilih


Persentase pengenalan atau akurasi dinyatakan sebagai nilai perbandingan antara jumlah data citra yang berhasil dikenali oleh jaringan dengan jumlah total data pengujian (8 kelas) seperti pada persamaan 6.

$$\% \text{Akurasi} = \frac{\text{Jumlah Data Terklasifikasi Benar}}{\text{Jumlah Data Total}} \times 100\% \quad (6)$$

Hasil pengenalan cacat pengelasan pada data pengujian dengan menggunakan JNB BP dapat dilihat pada gambar 4 dengan variasi jarak piksel sedangkan pada gambar 5 dapat dilihat hasil pengujian pada pengurangan derajat keabuan.



Gambar 4. Hasil Pengujian dengan variasi jarak piksel



Gambar 5. Hasil Pengujian dengan variasi derajat keabuan

Dari data di atas memperlihatkan sistem pengenalan cacat pengelasan otomatis dengan menggunakan JNB BP dapat dikatakan cukup baik. Namun nampak terlihat belum adanya pola yang teratur antara hubungan jarak piksel dan derajat keabuan terhadap nilai maksimum pengenalan. Selain itu sistem ini belum mampu memberikan hasil yang stabil, hal ini dibuktikan pula pada pengulangan lebih dari 2 kali eksperimen pembelajaran JNB BP dengan parameter dan set data sama, dapat dihasilkan nilai pengenalan yang berbeda-beda. Terdapat banyak faktor yang menyebabkan hal ini terjadi, salah satunya adalah data input pembelajaran belum mampu memenuhi kebutuhan informasi minimal sistem pengenalan, artinya data pembelajaran yang diberikan belum mencukupi keseluruhan permasalahan yang akan diselesaikan.

Kemampuan JNB dalam pengenalan masih dapat diperbaiki dengan mengubah parameter-parameter yang mempengaruhinya. Misalkan adalah komposisi jumlah neuron pada lapisan tersembunyi, jumlah ini mungkin saja dapat diperbanyak, namun memperbanyak jumlah

neuron akan memperlama waktu komputasi pembelajaran jaringan. Pada tabel 1 diperlihatkan waktu komputasi untuk setting eksperimen yang kami lakukan. Waktu tersebut dihitung pada komputer Pentium IV 2,6 GHz berbasis teknologi Hyper Threading dengan DDR 1 GHz.

Tabel 1. Waktu komputasi pembelajaran JNB Back Propagation.

Jarak Piksel	Waktu (sekon)
1	4776
2	6090
5	6828
10	5975
20	7762
50	1347
100	2476

Tabel 2. Waktu komputasi ekstraksi ciri tekstur.

Derajat Keabuan	Waktu (sekon)
8	0,171
16	0,250
32	0,422
64	1,250
256	24,047

Dengan konfigurasi neuron 20 pada lapisan tersembunyi pertama dan 16 neuron pada lapisan tersembunyi kedua, waktu komputasi dapat dilihat pada tabel 1 membutuhkan waktu yang cukup lama, rata-rata 1 jam 30 menit. Belum ditambah waktu untuk mengekstraksi ciri, yaitu waktu yang diperlukan untuk mendapatkan 1 set ciri sebagai input pengklasifikasi JNB BP. Waktu komputasi ekstraksi ciri sangat tergantung dengan derajat keabuan, semakin besar derajat keabuan akan semakin lama waktu komputasinya, seperti pada tabel 2.

Maka untuk melakukan proses pembelajaran sistem otomatisasi ini memerlukan komputer dengan kemampuan komputasi yang tinggi.

#### 4. KESIMPULAN

Dalam tulisan ini, telah dilakukan penelitian sebuah sistem otomatisasi untuk mendeteksi cacat pengelasan berbasis ciri tekstur *Gray Level Co-occurrence matrix* (GLCM). Film sinar-X standar IIW telah dijadikan sebagai input sistem pengenalan. Film sinar-X telah

didigitalisasi terlebih dahulu dengan menggunakan kamera digital. Ciri tekstur diekstrak dengan menggunakan empat persamaan Harralick pada matrik co-occurrence. Jaringan Neural Buatan *Back Propagation* telah digunakan sebagai pengklasifikasi output pengenalan berupa delapan kelompok jenis cacat pengelasan. Tingkat pengenalan sistem terbaik mampu mencapai 82.87% pada derajat keabuan 8 dan jarak piksel 5. Penelitian ini membuat sebuah kontribusi dalam memecahkan permasalahan dalam sistem otomatisasi pengenalan *weld defect*.

#### DAFTAR ACUAN

- [1] Nafaa, N., Redouane, D., Amar, B., "*Weld defect extraction and Classification in radiographic testing based Artificial Neural Network*", Laboratoire du Traitement du Signal et de Image Centre de Soudage et de Contoler
- [2] Mery, D., "*Processing Digital X-ray Images and Its Applications in the Automated Visual Inspection of Aluminum Casting*", 3rd Pan American Conference for Nondestructive Testing – PANNDT, Rio de Janeiro – RJ, June 2003.
- [3] Antonio Alves de Carvalho, Raphael Carlos de Sá Brito Suita, Romeu Ricardo da Silva, João Marcos Alcoforado Rebello, "*Evaluation of the Relevant Features of Welding Defects in Radiographic Inspection*", *Materials Research*, Vol. 6. No. 3, 427-432, 2003.
- [4] Gonzales, R.A., Woods, R.E., "*Digital Image Processing*", Addison-Wesley Publishing Company, Inc., 1973
- [5] Tomita, F., Tsuji, S., "*Computer Analysis of Visual Textures*", Kluwer Academic Publisher, 1990
- [6] Cahyati, Dina, "*Klasifikasi citra radar berdasarkan ciri tekstur Gray Level Cooccurrence Matrix (GLCM) Semivariogram dan Wavelet*", Tesis, Program Pasca Sarjana Ilmu Komputer, Universitas Indonesia, 2003
- [7] Harralick, R.M., "Statistical and Structural Approaches to Texture", *Proceedings of the IEEE*, vol. 67, no 5, 1979.
- [8] Wu, D, J. Linders, "*Comparison of three different methods to select feature for discriminating forest cover types using SAR Imaginary*", *International Journal of Remote Sensing*, Vol 21, No 10, 2089-2099, 2000

