

# PENGENALAN CACAT PENGELASAN (*WELD DEFECT*) MENGUNAKAN ANALISIS MULTI RESOLUSI BERBASIS *WAVELET* DAN JARINGAN NEURAL BUATAN

Adhi Harmoko S.

Program Ekstensi Departemen Fisika FMIPA Universitas Indonesia, Depok 16424  
email : adhi\_hs@fisika.ui.ac.id

## ABSTRAK

Telah dikembangkan Sistem Pengenalan Cacat pada Pengelasan Metal dengan menggunakan analisis multi resolusi sebagai ekstraksi ciri dan jaringan neural buatan sebagai pengklasifikasinya. Input citra merupakan film Sinar-X dari teknik radiografi beberapa pengelasan metal yang telah didigitalisasi. Ekstraksi ciri menggunakan wavelet dan 14 ciri Harralick untuk mengenali pola tekstur dalam citra. Sedangkan jaringan neural buatan yang digunakan adalah Back Propagation dan Probabilistic Neural Network. Pengklasifikasi pengenalan cacat akan dikelompokkan menjadi 8 kelas berdasarkan jenis cacat yaitu : kelas 1 (normal), kelas 2 (distributed porosity), kelas 3 (incomplete penetration), kelas 4 (burn through), kelas 5 (cluster porosity), kelas 6 (excessive cap), kelas 7 (excessive penetration) dan kelas 8 (incomplete fusion). Hasil akurasi pengenalan terbaik untuk citra yang belum diketahui jenis cacatnya mencapai 83% untuk perbandingan data pelatihan dan data pengujian 1 : 1.

**Kata kunci:** Weld Defect, Multiresolution Analysis, Wavelet, Pattern Recognition, Probabilistic Neural Network, Back Propagation.

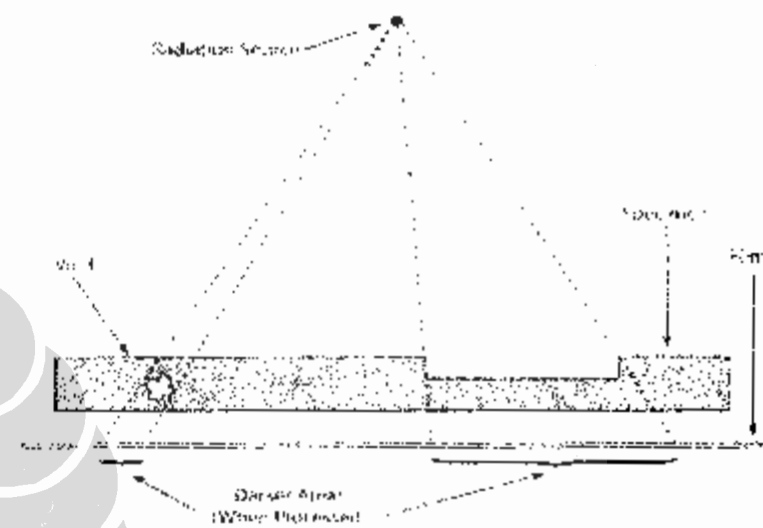
Makalah diterima [25 Januari 2004]. Revisi akhir [3 Maret 2004].

## 1. PENDAHULUAN

Penggunaan Sinar-X sebagai alat penguji produk-produk yang dihasilkan industri telah dimulai sejak awal abad 20. Karena itu sinar-X merupakan alat pengujian tak merusak (*Non-destructive test*) telah banyak digunakan secara luas pada saat ini. Sampai hari ini, terdapat beberapa penelitian untuk mengoptimalkan teknik pengujian, terutama pada pengembangan sistem otomatisasi analisis citra radiografi sehingga sistem tersebut mampu mengidentifikasi dan mengklasifikasi cacat (*defect*) di dalam citra radiografi [1].

Metode radiografi umumnya digunakan pada industri petroleum, petro kimia, nuklir dan pembangkit tenaga untuk menginspeksi kualitas sambungan las-lasan dan cetakan. 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.




Gambar 1. Pengujian tak merusak dengan menggunakan Sinar-X

Kegunaan otomatisasi proses analisis radiografi digital adalah untuk mereduksi waktu analisis dan mengeliminasi aspek subyektifitas dalam menganalisis yang dilakukan oleh seorang inspektor. Cara ini mampu meningkatkan reliabilitas dalam penginspeksian karena dilakukan oleh program komputer. 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].

Salah satu aplikasi teknik radiografi adalah pengujian tak merusak pada welding (pengelasan) sambungan metal untuk mengetahui kualitas welding tersebut. Terdapat beberapa jenis *welding defect* dengan penyebab yang berbeda-beda pula. Setiap negara mempunyai standar sendiri untuk menentukan jenis dan tingkat keamanan cacat tersebut. Beberapa istilah weld defect diantaranya adalah distributed porosity, cluster porosity, linear porosity, worm hole, continuous undercut, linear slag, incomplete penetration, inclusion, cracks, lack of penetration, lack of fusion, longitudinal crack, dan lain sebagainya. Untuk standar negara Inggris (IIW) dikelompokkan menjadi 5 tingkat keamanan, tingkat keamanan paling rendah (tidak ada cacat atau cacat masih aman digunakan) sampai cacat yang paling parah.

PERPUSTAKAAN PUSAT  
UNIVERSITAS INDONESIA



Gambar 2. Contoh Welding Defect jenis Centerline Surface Crack

Berikut ini adalah beberapa metode yang telah dipublikasikan dalam 15 tahun terakhir tentang pendeteksian dan pengklasifikasi otomatis welding defect

### 1.1. Metode Gayer

Metode yang diusulkan [3] dapat disimpulkan dalam dua tahapan, yaitu 1) Pencarian cepat untuk potensi cacat dalam citra sinar-X. Asumsi bahwa cacat akan lebih kecil dibandingkan struktur reguler dari daerah pengujian, potensi cacat diklasifikasikan pada daerah citra yang mempunyai frekuensi tertinggi. Spektrum citra sinar-X ditentukan dengan bantuan FFT (*Fast Fourier Transformation*), yang dihitung baris per baris atau kolom per kolom dengan ukuran *window*  $32 \times 32$ . Ketika jumlah frekuensi tertinggi dari *window* lebih besar dari nilai batas yang diberikan, keseluruhan *window* dianggap potensial cacat. 2) Identifikasi dan lokalisasi cacat yang sebenarnya. Dua buah algoritma dibuat dengan baik disini. Algoritma pertama digunakan untuk *matching* antara potensial cacat dengan jenis cacat, yang disimpan di dalam *library* sebagai *template*. Ketika kemiripan antara potensial cacat dengan *template* yang ditemukan besar, potensi cacat diklasifikasikan sebagai cacat. Algoritma kedua mengestimasi bebas cacat dari citra sinar-X dengan pemodelan interpolasi fungsi spline tanpa memperhatikan daerah yang mempunyai potensi cacat. Citra asli dan citra bebas cacat dibandingkan. Cacat diidentifikasi ketika perbedaan yang besar terjadi pada citra input original.

### 1.2. Metode Lawson dan Parker

Mengusulkan bahwa *artificial neural network* (ANN) digunakan untuk pendeteksian otomatis pada citra sinar-X. Metode ini menghasilkan sebuah citra biner dari citra uji dimana setiap pixel sama dengan 0 ketika ciri struktur reguler dan sama dengan 1 jika cacat dideteksi. Hal ini memerlukan pembelajaran terarah (*supervised learning*) pada *multi-layer perceptron network* (MLP) dimana percobaan dibuat untuk mendapatkan pendeteksian dari data pelatihan. Algoritma *back propagation* digunakan untuk menentukan bobot dalam MLP [4].

Mereka menggunakan satu dari dua layer tersembunyi dalam topografi jaringan pada ANN, dimana signal input berhubungan pada *window*  $m \times m$  nilai keabuan dalam citra sinar-X. Signal output adalah pixel pada pusat citra dalam citra biner. Karena fungsi nilai batas untuk neuron adalah sigmoidal dalam metode ini, nilai batas digunakan untuk mendapatkan signal output biner.

Pendeteksian yang diinginkan dalam data pelatihan didapatkan dengan prosedur segmentasi berdasarkan pada adaptif ambang batas. Selama eksperimen pada lima citra sinar-X, menunjukkan bahwa deteksi dengan menggunakan ANN unggul pada metode segmentasi dengan menggunakan adaptif ambang batas.

### 1.3. Pengenalan cacat dengan menggunakan ciri bentuk

Sebuah metode untuk pengenalan otomatis pada welding defect telah dipresetasikan oleh Sofia dan Redouane [5]. Pendeteksian mengikuti metodologi pengenalan pola. 1) Segmentasi, daerah pada pixel ditemukan dan diisolasi dari citra sinar-X dengan menggunakan algoritma *watershed* dan operasi morfologikal (erosi dan dilasi) 2) ekstraksi ciri, daerah diukur dan mengkuantisasi karakteristik bentuk (variasi dimenasi dan sumbu utama dari inersia berdasarkan pada moment invarian)i, 3) klasifikasi, ciri yang telah diekstraksi pada setiap daerah dianalisis dan diklasifikasi dengan menggunakan *k-nearest neighbour classifier*. Menurut mereka, metode ini kuat dan mencapai nilai pengenalan yang baik.

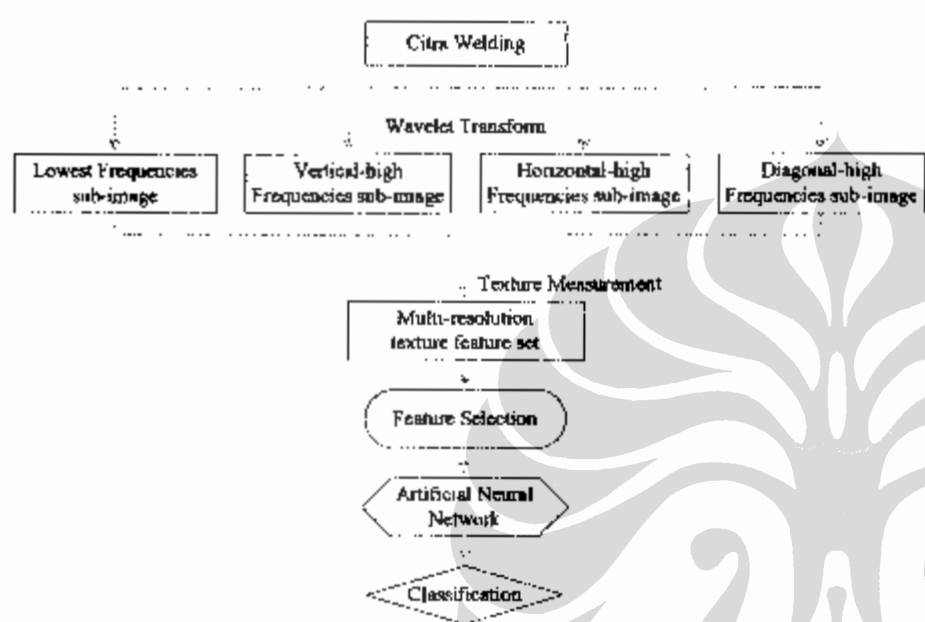
Wu dan Linders [6] menggunakan *Gray Level Cooccurrence Matrix* (GLCM) bersamaan dengan wavelet standar untuk penelitian citra radar. Wu dan Linders melakukan perbandingan tiga metode pemilihan ciri untuk memilih ciri yang paling baik dalam mengklasifikasikan jenis hutan. Pada penelitiannya, pertama-tama wavelet Haar diaplikasikan pada sebuah citra SAR berukuran  $10004 \times 4096$  piksel, dan diperoleh empat buah citra LL, LH, HL, dan HH yang masing-masing berukuran  $5002 \times 2048$ . Terhadap keempat citra ini diterapkan metode GLCM untuk setiap arah sehingga diperoleh 208 citra ciri. Terhadap 208 citra kemudian dilakukan seleksi ciri untuk mendapatkan ciri terbaik menggunakan tiga metode, yaitu *fuzzy partition*, *stepwise regression analysis*, dan *principal component analysis*. Fokus penelitian ini adalah penggunaan metode seleksi ciri yang terbaik [9].

Oleh karena itu, penelitian ini bermaksud mengembangkan sistem pengenalan *welding defect*. Penelitian ini menggunakan *Gray Level Cooccurrence Matrix* (GLCM) bersamaan dengan wavelet standar untuk pengolah citra radiografi sinar-X dan menggunakan jaringan saraf buatan untuk mengklasifikasikan *welding defect* sesuai dengan jenis cacatnya. Jaringan saraf buatan yang digunakan adalah *Back Propagation* dan sebagai perbandingan akan digunakan pula *Probabilistic Neural*

Network (PNN) yang dikenal mempunyai waktu pelatihan sangat singkat serta mempunyai tingkat generalisasi yang baik [7]. Hal-hal tersebut dilakukan untuk mendapatkan sistem pengenalan welding defect yang memiliki tingkat pengenalan tinggi. Dilakukan pula perbandingan kinerja JNB BP dan PNN, manakah yang mampu memberikan hasil yang terbaik.

## 2. SISTEM PENGENALAN WELD DEFECT

Skema umum yang menggambarkan sistem pengenalan weld defect diperlihatkan pada Gambar 3. Sistem pengenalan tersebut digunakan untuk dapat mengenali ada atau tidak cacat didalam proses pengelasan, apabila terdapat cacat, kemudian ditentukan jenis cacatnya.



Gambar 3. Sistem Pengenalan Welding Defect

Citra welding merupakan citra bentuk digital yang didigitalisasi dari film sinar-X dengan menggunakan kamera digital. Citra input merupakan citra dengan ukuran piksel sama dengan  $360 \times 180$ . Jumlah citra welding yang digunakan sebanyak 432 buah. Sebagian citra ini akan digunakan sebagai data pelatihan dan sisanya akan digunakan sebagai data pengujian.

Proses komputasi dimulai dengan mendekomposisi citra welding menjadi 4 sub citra dengan menggunakan transformasi wavelet dan kemudian mengekstraksi ciri tekstur dari setiap sub citra tersebut. Ciri tekstur ini dapat disebut ciri tekstur multi resolution karena diukur dari resolusi sub citra yang berbeda. Pada tahap ini akan didapatkan set ciri awal.

Tahap selanjutnya adalah menurunkan atau mengurangi set ciri multi resolution yang sangat besar menjadi set baru yang lebih kecil dengan menggunakan analisis *principal component analysis*. Hasil dari tahap ini adalah suatu set ciri baru dengan jumlah yang lebih kecil dari semula.

Tahapan selanjutnya menggunakan Jaringan Neural Buatan untuk mengklasifikasikan kedalam kelompok normal (tidak ada cacat) atau kedalam kelompok jenis cacat


tertentu (distributed porosity, incomplete penetration, burn through, cluster porosity, excessive cap, excessive penetration, incomplete fussion). Jaringan neural buatan yang digunakan disini adalah *Backpropagation* dan *Probabilistic Neural Network*.

### 2.1. Wavelet Haar

Wavelet Haar adalah wavelet yang paling sederhana [8] dapat didefinisikan oleh

$$\psi(t) = \begin{cases} 1 & 0 \leq t < \frac{1}{2} \\ -1 & \frac{1}{2} \leq t < 1 \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

Wavelet Haar mempunyai kekurangan dalam domain frekuensi, yaitu lokalisasinya dalam domain frekuensi tidak baik. Tetapi dalam domain waktu, wavelet Haar dapat berfungsi dengan baik. Wavelet Haar memiliki basis yang orthonormal dan anti simetrik. Gambar 4 berikut menunjukkan wavelet Haar dan spektrum frekuensinya.



Gambar 4. Wavelet Haar dan spektrum frekuensinya

*Scaling function* untuk wavelet Haar adalah sebagai berikut

$$\phi(t) = \begin{cases} 1 & 0 \leq t \leq 1 \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

Maka dengan mudah untuk melihat bahwa  $\phi(t)$  memenuhi dua scaling function berikut

$$\phi(t) = \phi(2t) + \phi(2t - 1) \quad (3)$$

dan  $\psi$  dapat dibentuk oleh  $\phi$  menurut persamaan berikut

$$\psi(t) = \phi(2t) - \phi(2t - 1) \quad (4)$$


persamaan 2 sampai 4 secara grafik dapat dilustrasikan seperti pada Gambar 5.



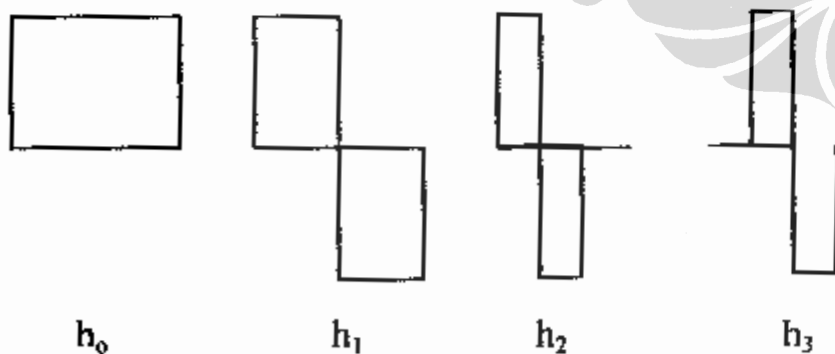
Wavelet Haar dapat dijelaskan dalam ruang vektor 4 dimensi dengan vektor-vektor basis sebagai berikut

$$h_0 = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}, h_1 = \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix}, h_2 = \begin{bmatrix} 1 \\ -1 \\ 0 \\ 0 \end{bmatrix}, h_3 = \begin{bmatrix} 0 \\ 0 \\ 1 \\ -1 \end{bmatrix} \quad (5)$$

Apabila vektor-vektor tersebut digambarkan dalam bentuk signal akan terbentuk seperti pada Gambar 6.



Gambar 5. Scalling Function Haar dan Wavelet Haar  
(a)  $\phi(2t)$ ; (b)  $\phi(2t-1)$ ; (c)  $\phi(t)$ ; (d)  $\psi(t)$



Gambar 6. Sinyal basis Wavelet Haar

## 2.2. Pengukuran Multiresolusi

Empat sub citra telah dihasilkan oleh transformasi wavelet, permasalahan selanjutnya adalah bagaimana mengekstrasi ciri dari setiap sub citra ini. Sejumlah pendekatan pada masalah pengukuran ciri telah dikembangkan selama beberapa tahun. Dalam studi ini, ciri-ciri co-occurrence

telah dipilih sebagai pengukuran ciri karena ini telah digunakan secara luas [6].

Ciri co-occurrence diturunkan dari sebuah matriks angular nearest-neighbour Gray-level co-occurrence, yang nilainya dihitung untuk hubungan variasi angular dan jarak antara pasangan pixel tetangganya pada sebuah window. Persamaan yang mendefinisikan sebuah set dari 14 pengukuran ciri co-occurrence diperkenalkan oleh Haralick. Persamaan itu adalah momen angular kedua, kontras, korelasi, varian, momen perbedaan invers, rata-rata jumlah, variasi jumlah, entropi jumlah, entropi, perbedaan varian, perbedaan entropi dan pengukuran informasi dari hubungan I dan II. Ciri ini dikatakan menjadi ciri co-occurrence.

## 2.3. Ciri Tektur Harralick

Matrik co-occurrence  $P_{kl}$  didefinisikan sebagai berikut. Elemen matriks  $P_{kl}(i,j)$  pada suatu window adalah berapa kali derajat keabuan  $i$  dan  $j$  terjadi dalam dua buah piksel dengan jarak dan arah yang diberikan oleh vektor  $(k,l)$  atau  $(-k,-l)$  dibagi dengan  $N_T$ . Dimana  $N_T$  adalah jumlah pasangan piksel yang terdapat dalam  $P_{kl}$ . Untuk menurunkan ukuran matriks co-occurrence  $N_x \times N_x$ , derajat keabuan dapat direduksi dari 256 menjadi 8 derajat keabuan [2]. Dari matrik co-occurrence yang terbentuk, beberapa ciri tektur dalam dihitung. Ke-14 ciri tektur Haralick didefenisikan sebagai berikut untuk  $p(i,j) := P_{kl}(i,j)$ :

angular second moment  $f_1 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} [p(i,j)]^2 \quad (6)$

contrast  $f_2 = \sum_{n=0}^{N_x-1} n^2 \sum_{i=1}^{N_x} \sum_{\substack{j=1 \\ |i-j|=n}}^{N_x} p(i,j) \quad (7)$

correlation  $f_3 = \frac{1}{\sigma_x \sigma_y} \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} (ij \cdot p(i,j) - \mu_x \mu_y)^2 \quad (8)$

sum of squares  $f_4 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} (i-j)^2 p(i,j) \quad (9)$

inverse difference moment  $f_5 = \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} \frac{1}{1+(i-j)^2} p(i,j) \quad (10)$

sum average  $f_6 = \sum_{i=2}^{2N_x} i \cdot p_{x+y}(i) \quad (11)$

sum entropy  $f_7 = -\sum_{i=2}^{2N_x} p_{x+y}(i) \log[p_{x+y}(i)] \quad (12)$

sum variance  $f_8 = \sum_{i=2}^{2N_x} (i-f_7) p_{x+y}(i) \quad (13)$

$$\text{entropy} \quad f_9 = - \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} p(i, j) \log[p(i, j)] \quad (14)$$

$$\text{difference variance} \quad f_{10} = \text{var}(p_{x+y}) \quad (15)$$

$$\text{difference entropy} \quad f_{11} = - \sum_{i=0}^{N_x-1} p_{x-y}(i) \log[p_{x-y}(i)] \quad (16)$$

$$\text{information measure of correlation 1} \quad f_{12} = \frac{f_9 - HXY1}{\max(HX, HY)} \quad (17)$$

$$\text{information measure of correlation 2} \quad f_{13} = \sqrt{1 - \exp[-2(HXY2 - HXY)]} \quad (18)$$

$$\text{maximal correlation coefficient} \quad f_{14} = \sqrt{\lambda_2} \quad (19)$$

dimana  $\mu_x, \mu_y, \sigma_x$  dan  $\sigma_y$  adalah rata-rata dan standar deviasi untuk  $p_x$  dan  $p_y$  dan

$$p_x = \sum_{j=1}^{N_x} p(i, j) \quad p_y = \sum_{i=1}^{N_x} p(i, j) \quad (20)$$

$$p_{x+y}(k) = \sum_{i=1}^{N_x} \sum_{\substack{j=1 \\ i+j=k}}^{N_x} p(i, j) \quad k = 2, 3, \dots, 2N_x \quad (21)$$

$$p_{x-y}(k) = \sum_{i=1}^{N_x} \sum_{\substack{j=1 \\ |i-j|=k}}^{N_x} p(i, j) \quad k = 0, 1, \dots, 2N_x - 1 \quad (22)$$

$$HX = - \sum_{i=1}^{N_x} p_x(i) \log[p_x(i)] \quad (23)$$

$$HY = - \sum_{j=1}^{N_x} p_y(j) \log[p_y(j)] \quad (24)$$

$$HXY1 = - \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} p(i, j) \log[p_x(i) p_y(j)] \quad (25)$$

$$HXY2 = - \sum_{i=1}^{N_x} \sum_{j=1}^{N_x} p_x(i) p_y(j) \log[p_x(i) p_y(j)] \quad (26)$$

dengan  $\lambda_2$  adalah nilai eigen Q kedua terbesar

$$Q(i, j) = \sum_{k=1}^{N_x} \frac{p(i, k) p(j, k)}{p_x(i) p_y(k)} \quad (27)$$

### 2.4. Principal Component Analysis

Dalam studi ini, digunakan metode *Principal Component Analysis* (PCA) untuk menemukan sebuah sub set dari

sekumpulan ciri tekstur multi resolusi 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 [6]. 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.

### 3. HASIL EKSPERIMEN

Telah dilakukan beberapa variasi setting eksperimen dengan menggunakan 432 citra dengan 8 kelas klasifikasi. Variasi setting eksperimen dilakukan untuk mencari parameter-parameter yang mampu menghasilkan nilai akurasi data maksimal.

Pada tabel 1 dapat dilihat hasil pengujian variasi jarak piksel vektor matriks coocurrence dengan menggunakan Back Propagation. Pada eksperimen tersebut menggunakan parameter-parameter sebagai berikut :

- ❖ Neuron lapisan tersembunyi : 20 16
- ❖ Jumlah epoch maksimum : 2500
- ❖ Persen PCA = 2%
- ❖ Data Pelatihan : Data Pengujian = 1 : 1
- ❖ Fungsi Transfer : tan-sigmoid
- ❖ Algoritma Pelatihan : Levenberg – Marquardt

Pada eksperimen tersebut dilakukan dua pendekatan cara pengambilan data pelatihan dan pengujian. Metode yang pertama adalah random atau acak, dimana telah ditentukan perbandingan jumlah data pelatihan dengan jumlah data pengujian namun dalam pemilihan datanya dilakukan secara acak. Sedangkan metode kedua penentuannya telah ditentukan oleh suatu indeks tertentu yang dibangkitkan secara acak namun pada setiap proses selanjutnya tetap menggunakan indeks tersebut.

Persen akurasi pada tabel 1 adalah kemampuan sistem mengklasifikasikan dengan benar sesuai dengan targetnya. Vektor N merupakan vektor matrik co-occurrence, yang

divariasikan sesuai dengan bilangan tersebut. Ukuran maksimum dari vektor ini tergantung dari ukuran citra input. Apabila citra input mempunyai ukuran piksel kecil maka vektor co-occurrence juga harus lebih kecil atau minimal sama.

**Tabel 1. Variasi Matriks Co-occurrence dengan menggunakan Back Propagation**

No	N	%Train	%Test	Keterangan
1	[10 0]	100	59	random
		100	62	tetap
2	[20 0]	100	41	random
		100	56	tetap
3	[50 0]	100	49	random
		100	51	tetap
4	[100 0]	100	58	random
		100	50	tetap
5	[0 10]	100	22	random
		100	34	tetap
6	[0 20]	100	63	random
		100	42	tetap
7	[0 50]	100	63	random
		100	47	tetap
8	[0 100]	100	41	random
		100	57	tetap

Hasil terbaik diberikan oleh vektor co-occurrence sama dengan [10 0], yaitu untuk pemilihan data yang tetap (telah ditentukan di awal), dimana sistem ini mampu mengklasifikasi 100% benar untuk data pelatihan dan 62% benar untuk data pengujian yang belum diketahui.

Sistem pengenalan dengan menggunakan JNB BP masih belum stabil. Apabila pengujian dilakukan beberapa kali, belum tentu menghasilkan nilai yang sama. Hal ini disebabkan data pelatihan masih belum mampu menggambarkan keadaan yang sebenarnya dari data *weld defect*. Akibatnya membuat nilai akurasi untuk data yang sama dengan kondisi yang sama, bila diulang akan memberikan nilai yang berbeda. Ada 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. Dari kondisi tersebut, untuk mengetahui apakah memang tingkat pengenalan cacat pengelasan dengan menggunakan MRA sudah benar-benar diperoleh hasil yang maksimal. Oleh karena itu sistem pengenalan cacat pengelasan akan diuji dengan menggunakan JNB yang lain. PNN merupakan alternatif yang cukup baik untuk mencapai tujuan tersebut.. Jaringan tersebut dikenal mempunyai waktu pelatihan yang singkat karena sifatnya hanya melewatkan data masukan sekali

jalan (*one-pass*). Berbeda dengan JNB BP yang harus melewatkan data masukan berulang-ulang (*multi-pass*) untuk mencapai tingkat kesalahan minimum, hal tersebutlah yang membuat JNB BP mempunyai waktu pelatihan yang cukup lama.

Pada tabel 2 dapat dilihat hasil pengujian variasi jarak piksel vektor matriks co-occurrence dengan menggunakan Probabilistic Neural Network. Pada eksperimen tersebut menggunakan parameter-parameter sebagai berikut :

- ❖ Persen PCA = 2%
- ❖ Spread = 0,03
- ❖ Data Pelatihan : Data Pengujian = 1 : 1

Pendekatan yang sama seperti dengan yang telah dilakukan sebelumnya dalam penentuan data pelatihan dan pengujian. Kedua metode pengambilan atau pemilihan data pelatihan dan pengujian juga dilakukan.

**Tabel 2. Variasi Matriks Co-occurrence dengan menggunakan Probabilistic Neural Network**

No	N	%Train	%Test	Keterangan
1	[10 0]	100	82.87	random
		100	75.46	tetap
2	[20 0]	100	78.07	random
		100	74.07	tetap
3	[50 0]	100	81.48	random
		100	77.78	tetap
4	[100 0]	100	81.48	random
		100	77.78	tetap
5	[0 10]	100	78.24	random
		100	76.85	tetap
6	[0 20]	100	74.07	random
		100	75.93	tetap
7	[0 50]	100	79.17	random
		100	74.07	tetap
8	[0 100]	100	74.54	random
		100	75.46	tetap

Bila dibandingkan dengan eksperimen sebelumnya, eksperimen dengan menggunakan PNN ini memberikan hasil yang stabil dan waktu prosesnya jauh lebih cepat dibandingkan dengan menggunakan JNB BP. Apabila menggunakan JNB BP proses pelatihan dan pengujian bisa menghabiskan waktu sampai 1 jam, sedangkan untuk PNN hanya membutuhkan tidak lebih dari 2 detik untuk proses pelatihan dan pengujian.

Hasil pengujian di atas yang menggunakan PNN memperlihatkan tingkat pengenalan yang lebih baik dari sebelumnya dengan menggunakan JNB BP. Hasil terbaik diberikan oleh vektor co-occurrence sama dengan [10 0], yaitu untuk pemilihan data secara random, dimana sistem ini mampu mengklasifikasi 100% benar untuk data pelatihan dan 83% benar untuk data pengujian yang belum diketahui.

#### 4. KESIMPULAN

Dalam tulisan ini, telah diteliti sebuah pendekatan untuk mendeteksi *weld defect* berdasarkan ekstraksi ciri dengan menggunakan wavelet Haar dan gray level co-occurrence matrix. Vektor co-occurrence matrix terbaik untuk sistem tersebut adalah [10 0], dimana vektor tersebut mempunyai jarak 10 piksel dan pada arah 0°. Jaringan Saraf Tiruan yang mampu memberikan akurasi terbaik dan pemrosesan tercepat adalah Probabilistic Neural Network, yang mampu mengklasifikasikan cacat sampai dengan 83%. Studi awal ini membuat sebuah kontribusi dalam memecahkan permasalahan dalam sistem pengenalan *weld defect*.

#### REFERENSI

- [1] 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.
- [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] Gayer, A, Saya, A, Shiloh, A., Automatic recognition of welding defects in real-time radiography, *NDT International*, 23(4):131–136, 1990.
- [4] Lawson, S.W, Parker, G.A, Intelligent segmentation of industrial radiographic images using neural networks, *In Machine Vision Applications and Systems Integration III*, Proc. of SPIE, volume 2347, pages 245–255, November 1994.
- [5] Silva, R.R, Siqueira, M.H.S, Calôba, L. P, Rebello, J.M.A, Radiographic pattern recognition of welding defects using linear classifier, *Insight, Journal of the British Institute of Non-destructive Testing*, 43(10): 669–674, 2001.
- [6] 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.
- [7] Trianto, Adi, Ekstraksi ciri pada data suara menggunakan spektra orde tinggi dan kuantisasi vektor untuk identifikasi pembicara menggunakan Jaringan Neural Buatan, *Tesis Program Pasca Sarjana Ilmu Komputer*, Universitas Indonesia, 2000
- [8] Tang Y Y, Yang L H, *Wavelet Theory and Its Application to Patern Recognition*, Singapore, World Scientific, 2000
- [9] 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