

# Pengenalan Pneumonia Pada Anak Menggunakan Jaringan Syaraf Tiruan *Extreme Learning Machine*

*Ilham Habibullah Akbar*  
Departemen Ilmu Komputer / Informatika  
Universitas Diponegoro  
Semarang, Indonesia  
ilhamhakbar@gmail.com

*Priyo Sidik Sasongko*  
Departemen Ilmu Komputer / Informatika  
Universitas Diponegoro  
Semarang, Indonesia  
priyosidiksasongko@lecturer.undip.ac.id

**Abstrak**— Pneumonia adalah penyakit infeksi saluran pernapasan akut pada paru-paru yang menjadi penyebab utama kematian anak di bawah 5 tahun di seluruh dunia. Citra rontgen dada merupakan salah satu cara yang dapat digunakan untuk mendiagnosis pneumonia. Radiologi terkadang menemui kesulitan pada saat pengenalan pneumonia karena citra rontgen sering terlihat samar-samar dan dapat bertumpukan dengan gejala penyakit lain. Pengembangan teknologi pengenalan pneumonia anak dapat membantu mempermudah serta mempercepat proses dalam mendiagnosis penyakit pneumonia sehingga dapat menekan angka kematian akibat penyakit pneumonia pada anak. Penelitian ini membahas pengenalan pneumonia pada anak dengan menggunakan Grey Level Cooccurrence Matrix (GLCM) sebagai metode ekstraksi fitur dan Extreme Learning Machine (ELM) sebagai metode pengenalannya. Pelatihan dan pengujian ELM dilakukan dengan metode k-fold cross validation dengan nilai  $k=10$ . Hasil penelitian menggunakan parameter semua sudut ( $0^\circ, 45^\circ, 90^\circ, 135^\circ$ ) pada ekstraksi fitur GLCM menghasilkan akurasi total sebesar 0.9728 dengan sensitivity sebesar 0.9886 dan specificity sebesar 0.9574. Sehingga berdasarkan hasil penelitian yang didapat, metode ELM memiliki kinerja yang lebih baik dalam mengenali citra pneumonia pada anak.

**Kata kunci**— *Extreme Learning Machine, Pengenalan Rontgen, Gray Level Co-occurrence Matrix.*

## I. PENDAHULUAN

Pneumonia adalah penyakit yang terjadi akibat peradangan atau infeksi pada paru-paru yang disebabkan oleh bakteri, virus, dan jamur. Rongga paru-paru pada penderita pneumonia tidak dapat berfungsi dengan baik karena terisi oleh nanah, lendir, atau cairan lainnya. Oksigen yang seharusnya dapat mencapai darah menjadi terhambat [1].

Pneumonia menjadi penyebab utama kematian anak-anak di seluruh dunia. Setiap tahun lebih dari 2 juta anak meninggal di seluruh dunia akibat penyakit ini [1]. Menurut Survei Kesehatan Rumah Tangga (SKRT) pada tahun 2001 pneumonia menjadi penyebab kematian 5 dari 1000 bayi per tahun di Indonesia. Artinya terdapat 300 bayi meninggal setiap hari atau satu bayi meninggal setiap 5 menit. Pneumonia dapat dideteksi melalui beberapa cara seperti pencarian pada citra rontgen dada, tes darah secara lengkap, tingkat pengendapan sel darah merah, dan level dari C-reactive protein [2].

Citra rontgen dada memiliki peranan penting pada proses diagnosis pneumonia. Citra rontgen dada dapat meningkatkan akurasi dari diagnosis, menjelaskan kelainan anatomi dengan baik, mempengaruhi cara penanganan penyakit, dan dapat beroperasi dengan aman pada pasien-pasien yang lemah [3]. Namun radiologi terkadang menemui

kesulitan saat melakukan pengenalan pneumonia pada rontgen dada. Hal ini disebabkan karena citra rontgen sering terlihat samar-samar dan dapat bertumpukan dengan gejala penyakit lain [4]. Bantuan teknologi dalam pengenalan pneumonia pada citra rontgen dada dapat membantu radiologi dalam mengambil keputusan serta mempercepat proses diagnosis pneumonia. Selain itu diagnosis pneumonia yang dibantu oleh komputer dapat membantu menangani masalah pada daerah yang memiliki keterbatasan ahli.

Salah satu metode yang dapat digunakan untuk pengenalan citra adalah Jaringan Syaraf Tiruan Extreme Learning Machine (JST ELM). Parameter yang digunakan pada hidden layer pada JST ELM didapatkan secara acak. Hal tersebut memberikan keuntungan JST bukan hanya pada kecepatan learning namun juga pada kinerja model pada umumnya [5]

## II. TINJAUAN PUSTAKA

### A. Pneumonia

Pneumonia adalah infeksi yang menyerang sistem pernafasan bawah yang secara anatomi terletak di bawah pita suara. Infeksi ini dapat disebabkan oleh bakteri, virus, jamur, paparan zat kimia, kerusakan paru-paru, maupun pengaruh tidak langsung dari penyakit lain. Streptococcus dan Mycoplasma pneumonia merupakan bakteri yang sering menyebabkan pneumonia, sedangkan virus yang menyebabkan pneumonia adalah adenoviruses, rhinovirus, influenza virus, respiratory syncytial virus (RSV) dan parainfluenza virus [2].

Tanda gejala pneumonia pada anak dapat beragam mulai dari ringan dan sedang hingga kondisi parah yang memerlukan perawatan. Pasien yang dirujuk dengan pneumonia dapat memiliki gejala seperti demam, sesak atau kesulitan bernafas, batuk, mengi atau sakit pada bagian dada. Cara yang akurat untuk mendiagnosis pneumonia adalah dengan rontgen dada. The National Institute for Health and Clinical Excellence (NICE) memberikan anjuran kepada pasien bahwa rontgen dada hanya perlu dilakukan jika pasien tersebut sudah dirawat di rumah sakit [6].

Perawatan pasien pneumonia dapat dilakukan di rumah atau di rumah sakit setelah dilakukan analisis terhadap tingkat keparahan (*severity assessment*). Secara umum perawatan pasien yang dilakukan di rumah memiliki perbedaan dengan perawatan pasien di rumah sakit. Orang tua dari pasien yang dirawat di rumah harus diberikan informasi mengenai cara perawatan yang baik. Perawatan pasien di rumah sakit memiliki langkah yang lebih kompleks. Pasien harus menjalani serangkaian terapi yaitu terapi oksigen, terapi cairan dan fisioterapi. Pasien yang

didiagnosis dengan penyakit pneumonia wajib melakukan pengobatan antibiotik.

Meningkatnya kualitas dari layanan kesehatan masyarakat sangat membantu pencegahan penyakit pneumonia. Cara pencegahan lain yang dapat dilakukan adalah dengan vaksinasi. Pada tahun 2003 WHO mencatat ada 2 juta kematian yang dicegah oleh imunisasi

**B. Citra Digital**

Citra digital merupakan keluaran suatu sistem perekaman yang disimpan berbentuk matriks dalam himpunan berhingga (diskrit) nilai digital yang tersusun dari pixel (picture elements). Nilai diskrit citra digital dapat direpresentasikan dengan  $f(x, y)$ , dimana  $x$  dan  $y$  adalah koordinat posisi piksel berada sedangkan  $f$  menunjukkan intensitas (derajat keabuan) pada koordinat  $(x, y)$ [7].

Berdasarkan warnanya citra digital dapat dibagi menjadi citra warna, citra keabuan (grayscale) dan citra biner. Citra keabuan 8bit memiliki kemungkinan warna 28 warna, dengan 0 (minimum) hingga 255 (maksimum). Citra biner adalah citra yang setiap titik atau pikselnya bernilai 0 atau 1 dengan representasi warna 0 (hitam), dan 1 (putih) [8].

**C. Pengenalan Pola**

Pola adalah suatu entitas terdefinisi yang dapat diidentifikasi melalui ciri-cirinya (features). Ciri atau feature tersebut digunakan untuk membedakan suatu pola dengan pola lainnya [7]. Contoh hubungan dan pola dapat dilihat pada Tabel 1.

Tabel 1: Contoh Hubungan Pola dan Ciri

Pola	Ciri
Huruf	Tinggi, tebal, titik sudut, lengkungan garis, dll
Suara	Amplitudo, frekuensi, nada, intonasi, warna, dll
Tanda tangan	Panjang, kerumitan, tekanan, dll
Sidik jari	Lengkungan, jumlah garis, dll


**D. Jaringan Syaraf Tiruan**

Jaringan syaraf tiruan, disingkat JST (atau *Artificial Neural Network* disingkat ANN), adalah model tiruan dari cara kerja pembelajaran otak manusia yang direpresentasikan ke dalam suatu program komputer dengan cara melakukan peniruan terhadap aktivitas-aktivitas yang terjadi di dalam sebuah jaringan syaraf biologis [9]. Sama seperti otak manusia, jaringan syaraf tiruan dibangun atas neuron-neuron dimana setiap neuron-nya memiliki hubungan satu sama lain. Neuron-neuron tersebut mentransformasikan informasi menuju ke neuron-neuron lain lewat sambungannya. Hubungan antar neuron tersebut disebut bobot. Tiap bobot menyimpan informasi dalam bentuk suatu nilai tertentu yang dihantarkan dari output suatu neuron ke dalam input neuron lain yang tersambung. Kemudian bobot-bobot yang diterima oleh input neuron ini diproses oleh suatu fungsi perambatan yang menjumlahkan nilai-nilai semua bobot yang diterima oleh input neuron. Hasil penjumlahan bobot tadi dibandingkan dengan suatu nilai ambang (threshold) menggunakan fungsi aktivasi yang terdapat di setiap neuron. Apabila hasil penjumlahan bobot melewati nilai ambang, maka neuron diaktifkan.

**E. Extreme Learning Machine**

ELM merupakan salah satu JST umpan maju (*Feed-Forward Neural Network – FFNN*) yang hanya mempunyai satu *hidden layer* pada arsitektur jaringannya atau biasa disebut *Single Hidden Layer Feedforward Neural Networks*

(SLFNs). ELM dibuat untuk mengatasi permasalahan pada JST sebelumnya seperti kecepatan *learning*, *overfitting* atau *local minima*. Parameter-parameter yang digunakan pada ELM seperti *input*, *weight* dan *hidden bias* dipilih secara acak sehingga hasil yang didapatkan memiliki performa yang baik dan proses pembelajaran berjalan dengan sangat cepat [5]. Struktur arsitektur ELM dapat dilihat pada Gambar 1.

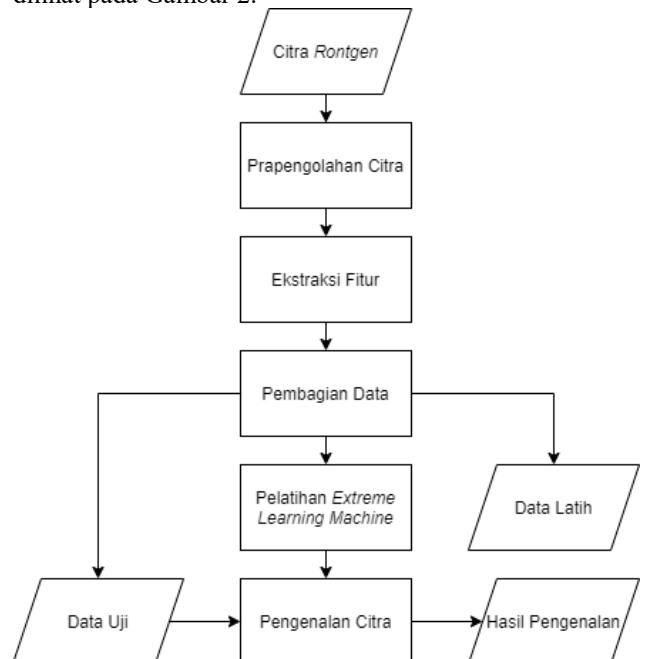


Gambar. 1. Struktur arsitektur ELM

Jaringan syaraf tiruan terbentuk dari *neurons* (nodes) yang saling terhubung. Node-node tersebut memiliki bobot yang menunjukkan pengaruh dari hubungan antar setiap node ketika dikalikan dengan nilai input. Proses *training* bertujuan untuk mendapatkan nilai-nilai bobot yang digunakan.

**III. METODE PENELITIAN**

Penelitian dibagi menjadi 6 tahapan yaitu pengumpulan data, prapengolahan citra, ekstraksi fitur, pembagian data, pelatihan dan pengujian. Gambaran umum penelitian dapat dilihat pada Gambar 2.



Gambar. 2. Blok Proses Tahapan-tahapan Penyelesaian Masalah

**A. Pengumpulan Data**

Data yang digunakan dalam penelitian ini diperoleh dari website kaggle. Dataset merupakan citra rontgen dari balita

berumur satu hingga lima tahun yang melakukan pemeriksaan rutin di Guangzhou Women and Children's Medical Center, Guangzhou. Data berjumlah 2680 citra yang terbagi menjadi 1340 citra normal dan 1340 citra pneumonia. Citra yang digunakan memiliki ukuran yang berbeda-beda dan disimpan dalam format \*.JPEG.

B. Prapengolahan Citra

Sebelum dilakukan proses pengenalan, seluruh citra yang ada pada dataset terlebih dahulu melalui proses prapengolahan. Citra yang digunakan Proses ini bertujuan untuk mengolah citra yang dapat diproses secara tepat dan sesuai dengan komputasi pengenalan pola yang dilakukan. Prapengolahan terdiri dari beberapa tahap yaitu *resizing*, *grayscale*, *contrast stretching* dan *image sharpening*.

Dataset terdiri dari citra yang memiliki ukuran dan dimensi yang beragam. Citra pada dataset rata-rata memiliki dimensi baris dan kolom dengan ukuran lebih dari 1000 pixels. Untuk memberikan hasil yang konsisten dan meringankan proses komputasi maka dilakukan pengecilan ukuran citra atau *resizing*. Seluruh citra diubah ukuran pixel barisnya menjadi 512 pixels dan ukuran kolom menjadi 512 pixels menggunakan metode interpolasi bilinear.

Ada beberapa citra dalam dataset yang masih bertipe RGB. Proses ekstraksi fitur menggunakan GLCM membutuhkan citra yang memiliki tingkat keabuan (*grayscale*). Oleh karena itu dilakukan proses *grayscale* untuk mengubah citra RGB menjadi citra keabuan. Salah satu cara untuk mengubah citra RGB menjadi *grayscale* adalah dengan mengalikan matriks R, matriks G, dan matriks B kemudian menjumlahkan hasilnya kedalam sebuah matriks S baru. Rumus yang digunakan pada proses *grayscale* dapat dituliskan sebagai berikut:

$$S=0.30(R)+0.59(G)+0.11(B). \tag{1}$$

Citra yang dihasilkan oleh proses *grayscale* belum memiliki kontras yang sesuai dengan kriteria. Ada objek-objek yang seharusnya tampak namun memiliki kontras yang rendah. Ada pula objek yang tidak terlalu dibutuhkan namun memiliki kontras yang tinggi. Oleh karena itu perlu dilakukan pengaturan kontras. Pengaturan kontras dilakukan untuk memunculkan karakteristik yang dibutuhkan dalam ekstraksi fitur. Pengaturan kontras dilakukan dengan menggeser sebuah jendela yang disebut kernel sepanjang citra dan mengatur jendela tersebut dengan rumus:

$$I_p(x,y)=255*[I_o(x,y)-min]/(max-min) \tag{2}$$

Objek yang dikenali pada citra rontgen terkadang memiliki tepi yang kurang jelas sehingga tersamarkan dengan objek lain. Untuk mengatasi masalah ini perlu dilakukan proses *image sharpening*. Salah satu cara yang cukup sering digunakan dalam penajaman citra adalah *unsharp masking*. Rumus dari *unsharp masking* adalah sebagai berikut:

$$g\_mask(x,y)=f(x,y)-f^-(x,y) \tag{3}$$

$$g(x,y)=f(x,y)+k*g\_mask(x,y) \tag{4}$$

C. Ekstraksi Fitur GLCM

Agar dapat diolah menggunakan JST ELM maka diperlukan ekstraksi fitur dari citra yang ada pada dataset kedalam bentuk matriks. Salah satu metode yang dapat digunakan adalah *co-occurrence matrix*. Ciri yang akan diekstrak adalah *Contrast*, *Correlation*, *Homogeneity*, dan *Energy*. Proses ekstraksi fitur menggunakan GLCM adalah sebagai berikut:

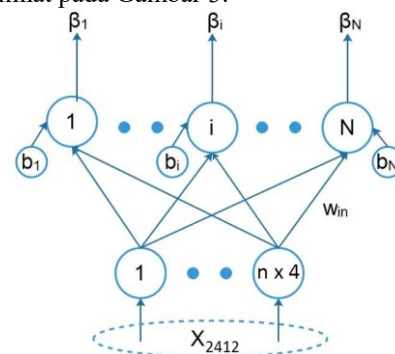
- Bentuk *co-occurrence matrix* yang memiliki hubungan spasial  $d=1$  dan sudut  $0^\circ, 45^\circ, 90^\circ, \text{ dan } 135^\circ$ .
- Transpose setiap *co-occurrence matrix*.
- Buat matriks simetris dengan menambahkan *co-occurrence matrix* dan transpose *co-occurrence matrix*.
- Normalisasi *co-occurrence matrix* simetris.
- Ekstraksi ciri fitur *contrast*, *correlation*, *energy* dan *homogeneity*.

D. Pembagian Data

Dataset yang digunakan dalam proses pengenalan terdiri dari dua unsur yaitu kelas dan fitur. Kelas yang digunakan yaitu normal dan *pneumonia*. Pada awal kolom setiap baris dataset diberi label 1 untuk kelas normal dan 0 untuk kelas pneumonia. Kemudian kolom selanjutnya diisi dengan hasil ekstraksi fitur GLCM. Hasil dari perhitungan *contrast*, *correlation*, *energy*, dan *homogeneity* disusun secara berurutan setelah label kelas. Skenario ekstraksi fitur GLCM yang digunakan dapat bermacam-macam sesuai dengan kombinasi sudut maupun fitur yang digunakan.

E. Pelatihan

Langkah awal dari proses pelatihan pada JST ELM dimulai dari memasukkan *input* berupa *dataset*. Model arsitektur pelatihan JST ELM yang dipakai pada penelitian ini dapat dilihat pada Gambar 3.




Gambar. 3. Arsitektur Pelatihan ELM 6

Berikut ini penjelasan dari langkah-langkah pada proses pelatihan ELM:

- Input data latih yang sudah dibagi menggunakan *k-fold* sehingga proses input dilakukan sejumlah dengan *fold* yang telah ditentukan. *Dataset* berukuran  $2412 \times 1 + (n \times 4)$  (2412 adalah jumlah citra yang digunakan pada data latih. 1 merupakan label kelas dan *n* adalah jumlah sudut yang digunakan).
- Inisialisasi *input weight (w)* dan *bias hidden neuron (b)*. *Input weight (w)* yaitu matriks berukuran  $2412 \times 1 + (n \times 4)$  yang diinisialisasi secara acak dengan nilai antara -1 hingga 1. *Bias hidden neuron (b)* yaitu matriks berukuran  $2412 \times 1$  dengan inisialisasi acak antara 0 hingga 1.
- Inisialisasi *hidden neuron*.
- Memperbarui *output hidden layer (H)*.
- Menghitung *output weight (beta)*.

### F. Pengujian

Pengujian dilakukan setelah mendapatkan model ELM dari proses pelatihan. Model terdiri dari input weight ( $w$ ), bias hidden neuron ( $b$ ), dan output weight ( $\beta$ ). Model arsitektur pengenalan JST ELM yang digunakan pada penelitian ini dapat dilihat pada Gambar 4.



Gambar. 4. Arsitektur Pengujian ELM

Berikut adalah tahap-tahap dari proses pengujian ELM:

1. Menginisialisasi variabel-variabel yang tersimpan dalam ELM model hasil proses pelatihan yaitu input weight ( $w$ ), bias hidden neuron ( $b$ ), output weight ( $\beta$ ), dan jumlah hidden neuron yang didapat dari proses pelatihan.
2. Menghitung nilai  $H$  yang diperoleh dari matriks data uji dengan matriks bobot yang ditranspose kemudian ditambah dengan *bias*.
3. Menghitung hasil prediksi dengan mengalikan matriks  $H$  dengan matriks *output weight* ( $\beta$ )

## IV. HASIL DAN PEMBAHASAN

### A. Skenario Pengujian

Pengujian ini digunakan untuk mencari arsitektur ELM yang optimal dengan mengubah sudut yang digunakan pada ekstraksi fitur GLCM. Arsitektur dengan kinerja yang optimal adalah arsitektur yang menghasilkan akurasi, *sensitivity* dan *specificity* pengujian terbaik dengan waktu yang relatif rendah.

Analisis performa dari klasifikasi dilakukan menggunakan tiga parameter statistik akurasi, *sensitivity* dan *specificity*. Ketiga parameter tersebut dapat dihitung menggunakan rumus (5), (6) dan (7) secara urut.

$$\text{Akurasi} = (TN + TP) / (TN + FP + FN + TP) \quad (5)$$

$$\text{Sensitivity} = TP / (TP + FN) \quad (6)$$

$$\text{Specificity} = TN / (TN + FP) \quad (7)$$

dimana  $TP$  adalah *true positive*,  $TN$  adalah *true negative*,  $FP$  adalah *false positive* dan  $FN$  adalah *false negative*. Keempat nilai tersebut didapatkan melalui *confusion matrix*. Dari rumus (13) dan (14), dapat diketahui bahwa *sensitivity*

mengukur prediksi tes positif pada sample yang memiliki penyakit sedangkan *specificity* mengukur prediksi tes negatif pada sample yang tidak memiliki penyakit.

Proses pengujian pada penelitian ini menggunakan kombinasi dari 4 sudut yang ada pada ekstraksi fitur GLCM ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ ). Terdapat total 15 kombinasi sudut. Kombinasi sudut yang digunakan dapat dilihat pada Gambar 4.1. Parameter ekstraksi fitur GLCM lainnya adalah *pixel distance* dan deskriptor. *Pixel distance* yang digunakan pada ekstraksi fitur GLCM adalah  $d = 1$  [10]. Sedangkan deskriptor yang digunakan yaitu *contrast*, *correlation*, *energy*, dan *homogeneity* [11]. Parameter yang digunakan pada proses klasifikasi yaitu *hidden neuron* dengan jumlah  $2/3$  dari ukuran *input layer* ditambah ukuran *output layer*, dan fungsi aktivasi *sigmoid*.

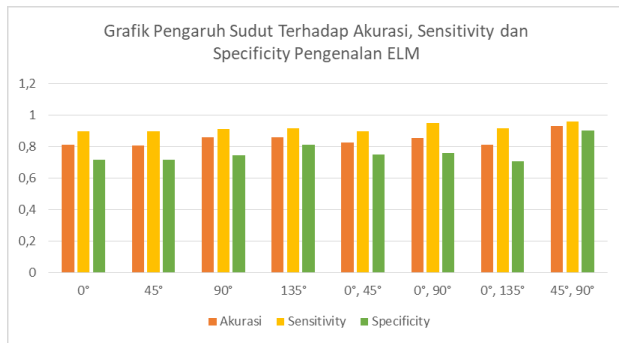
### B. Pembahasan Skenario Pengujian

Parameter terbaik arsitektur *Extreme Learning Machine* berdasarkan nilai akurasi tertinggi (0,8990), yaitu menggunakan kombinasi semua sudut pada ekstraksi fitur GLCM. Kombinasi sudut ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ) juga menghasilkan nilai *specificity* tertinggi (0,8731). Nilai *sensitivity* terbaik terdapat pada kombinasi sudut ( $90^\circ$ ,  $135^\circ$ ) yaitu sebesar (0,9357). Secara umum arsitektur yang dihasilkan memiliki waktu pengenalan yang baik dengan rata-rata 0,06148 detik. Waktu pengenalan dengan nilai terbaik terdapat pada kombinasi sudut ( $45^\circ$ ,  $135^\circ$ ) yaitu 0,0313 detik. Selisih waktu pengenalan dari setiap kombinasi sudut relatif rendah dengan selisih kurang dari 0,1 detik. Berdasarkan hasil pengujian pengujian dapat dijelaskan analisis performa model yang dihasilkan sebagai berikut:


- Akurasi, Sensitivity dan Specificity

Model ELM yang menggunakan sudut tunggal pada ekstraksi fitur GLCM menghasilkan nilai *sensitivity* yang cukup tinggi yaitu 0,8986 hingga 0,9149. Hal ini berarti model mampu memprediksi dengan pasien yang memiliki penyakit pneumonia. Namun *specificity* yang dihasilkan masih memiliki nilai kurang optimal dengan nilai tertinggi yaitu 0,8111 pada penggunaan sudut  $135^\circ$ . Penggunaan sudut tunggal belum mampu memprediksi dengan baik pasien yang tidak memiliki penyakit pneumonia.

Model ELM dengan kombinasi beberapa sudut pada ekstraksi fitur GLCM secara umum menghasilkan nilai akurasi keseluruhan yang lebih baik. Penggunaan kombinasi dua sudut ( $90^\circ$  dan  $135^\circ$ ) menghasilkan model ELM dengan *sensitivity* terbaik yaitu 0,9901. Namun nilai akurasi yang lebih baik didapatkan pada penggunaan seluruh sudut yang menghasilkan *sensitivity* sebesar 0,9886 dan *specificity* sebesar 0,9574 dengan nilai akurasi sebesar 0,9728. Grafik perbandingan pengaruh sudut terhadap akurasi, *sensitivity* dan *specificity* dapat dilihat pada Gambar 5. dan Gambar 6.



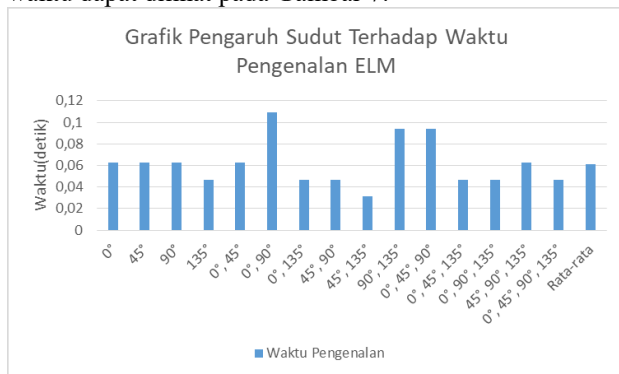
Gambar. 5. Grafik Pengaruh Sudut Terhadap Akurasi ELM



Gambar. 6. Grafik Pengaruh Sudut Terhadap Akurasi ELM (lanjutan)

• Waktu Pengujian

Waktu pengujian ELM pada 15 kombinasi sudut ekstraksi fitur GLCM menghasilkan waktu rata-rata 0.06148 detik. Dari hasil pengujian dapat dilihat bahwa jumlah sudut yang digunakan tidak berpengaruh terhadap waktu pengujian. Grafik perbandingan pengaruh sudut terhadap waktu dapat dilihat pada Gambar 7.



Gambar. 7. Grafik Pengaruh Sudut Terhadap Waktu Pengujian ELM

V. PENUTUP

Penelitian ini telah berhasil membangun sebuah model yang dapat mengenali pneumonia pada citra *rontgen* paru-paru anak. Proses pengenalan citra dimulai dengan tahap prapengolahan untuk memperbaiki kualitas citra, yang kemudian dilakukan ekstraksi fitur dengan GLCM. Fitur yang sudah dipilih dikenali menggunakan metode JST ELM. Model jaringan yang dipakai adalah dengan  $n \times 4$  input neuron,  $\frac{2}{3}n + 2$  hidden neuron, dan 2 output neuron, dimana  $n$  adalah jumlah sudut yang digunakan sesuai skenario pengujian. Akurasi terbaik pengujian adalah sebesar 0,8990 didapatkan ketika menggunakan parameter sudut (0°, 45°, 90°, dan 135°) pada ekstraksi fitur GLCM dengan penggunaan parameter lain yaitu deskriptor *contrast*, *correlation*, *energy* dan *homogeneity* serta *pixel distance*

sebesar 1 piksel. Model menghasilkan rata-rata waktu komputasi sebesar 0.06148 detik.

UCAPAN TERIMA KASIH

Peneliti mengucapkan terimakasih kepada Departemen Ilmu Komputer / Informatika, Universitas Diponegoro yang telah memberikan kesempatan untuk dapat melaksanakan penelitian ini.

DAFTAR PUSTAKA

- [1] Wardlaw, T. M., Johansson, E. W. & Hodge, M. J., 2006. *Pneumonia: the forgotten killer of children.* s.l.:Unicef.
- [2] McIntosh, K., 2002. Community-acquired pneumonia in children. *New England Journal of Medicine*, pp. 429-437.
- [3] Snow, N., Kathleen, T. B. & Terrence, P. H., 1990. Thoracic CT Scanning in Critically III Patients: Information Obtained Frequently Alters Management. *Chest*, pp. 1467-1470.
- [4] Scott, J. A. et al., 2012. The Definition of Pneumonia, the Assessment of Severity, and Clinical Standardization in the Pneumonia Etiology Research for Child Health Study. *Clinical Infectious Disease*, pp. S109-S116.
- [5] Huang, G.-B., Zhu, Q.-Y. & Siew, C.-K., 2004. Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks. *IEEE International Joint Conference on Neural Networks*, Volume 2, pp. 985-990.
- [6] Harris, M. et al., 2011. British Thoracic Society guidelines for the management of community acquired pneumonia in children: update 2011. *Thorax*, Volume 66, pp. ii1-ii23.
- [7] Munir, R., 2004. *Pengolahan Citra Digital dengan Pendekatan Algoritmik*. Bandung: Informatika.
- [8] Padmavathi, K. & Thangadurai, K., 2016. Implementation of RGB and grayscale images in plant leaves disease detection-comparative study. *Indian Journal of Science and Technology*, Volume 9(6), pp. 1-6.
- [9] Kusumadewi, S., 2003. *Artificial Intelligence*. 1st ed. Puspitaningrum, D., 2006. *Pengantar Jaringan Syaraf Tiruan*. 1st ed. Yogyakarta: ANDI.
- [10] Singh, V. P. et al., 2016. Mammogram classification using selected GLCM features and random forest classifier. *International Journal of Computer Science and Information Security*, Volume 14(6), p. 82
- [11] Tankasala, S. P. et al., 2011. Biometric recognition of conjunctival vasculature using GLCM features. *International Conference on Image Information Processing*, pp. 1-6