

## PERBANDINGAN KINERJA CNN LeNet 5 DAN EXTREME LEARNING MACHINE PADA PENGENALAN CITRA TULISAN TANGAN ANGKA

**Desti Fitriati**

Teknik Informatika Universitas Pancasila  
desti.fitriati@univpancasila.ac.id

### ABSTRAK

Pengenalan pola merupakan hal penting untuk mengkategorikan sebuah objek pada citra. Pengkategorian dengan jumlah data banyak relatif memberikan kesulitan pada manusia. Untuk itu diperlukan sebuah metode yang tepat agar sistem yang dibuat dapat mengelompokkan citra sesuai kelasnya. Metode *Convolutional Neural Network Lecunn Network 5* (CNN LeNet 5) dan *Extreme Learning Machine* (ELM) merupakan metode yang diunggulkan pada banyak penelitian beberapa tahun terakhir. Karena keunggulannya, penelitian ini melakukan percobaan pada data sederhana dimana citra yang digunakan adalah tulisan tangan angka yang hanya diolah melalui proses binerisasi dan menjadikan hasil tersebut sebagai masukan metode klasifikasi. Penelitian ini menggunakan dua jenis data, yaitu data primer yang diambil langsung dari berbagai lokasi di Palembang Indonesia. Sedangkan data sekunder diambil melalui basis data publik MNIST. Hasil percobaan menunjukkan bahwa CNN LeNet 5 lebih unggul dalam hal akurasi yaitu mencapai 98,04% untuk 10.000 data sekunder MNIST dan 78,14% untuk 700 data primer. Sedangkan metode ELM lebih unggul dalam hal komputasi waktu yang mencapai 0,00078 mili detik.

*Kata kunci : Pengenalan pola, Tulisan Tangan Angka, CNN LeNet 5, ELM*

### 1. PENDAHULUAN

Pada dasarnya pola adalah sebuah cara yang dapat digunakan untuk memberikan penandaan atau ciri terhadap sebuah objek. Untuk itu pola perlu dicari agar sebuah objek dapat dikenali berdasarkan kategori atau kelasnya. Pengelompokan sebuah objek dengan jumlah kelas yang sedikit tidak memberikan kesulitan yang berarti. Akan tetapi, pengelompokan dalam jumlah yang besar relatif sulit dan cukup memakan waktu bagi manusia. Sebagai contoh, manusia relatif mengalami kesulitan jika diberikan 100 citra tanda tangan dan mengelompokkannya berdasarkan tanda tangan asli dan palsu. Berdasarkan hal tersebut maka diperlukan sebuah alat atau sistem klasifikasi untuk mempermudah pekerjaan manusia.

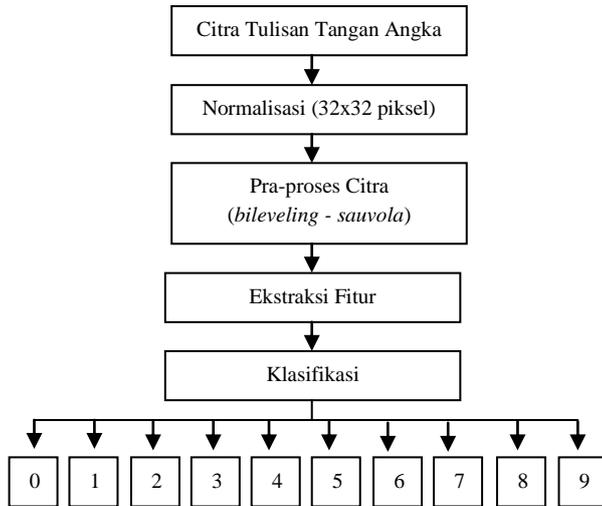
Dalam beberapa tahun terakhir ada banyak metode klasifikasi citra dengan kekurangan dan kelebihan masing-masing. Seperti Algoritma Propagasi Balik yang dinilai unggul karena mampu memberikan hasil klasifikasi hingga mencapai 90% pada beberapa jenis bidang diantaranya diterapkan dibidang finansial dan pengenalan pola. Pencapaian tersebut diperoleh karena pengguna bisa mengatur maksimal eror yang diinginkan, misal eror 0,1 yang berarti akurasi yang diinginkan adalah 99%. Karena adanya proses pencapaian eror yang diinginkan maka ada masalah tambahan yaitu lambatnya proses komputasi klasifikasi. Berangkat dari permasalahan tersebut, maka muncul metode klasifikasi baru yang diunggulkan memiliki komputasi 1000 kali lebih cepat dari metode propagasi balik yaitu *Extreme Learning Machine*

(ELM) [1]. Inti dari metode ini adalah belajar tanpa iterasi, sehingga proses belajar dari metode ini sangat cepat (ekstrem).

Pada beberapa penelitian, metode ELM cukup tangguh yaitu dapat menghasilkan akurasi pengenalan pola yang hampir sama dengan yang diperoleh metode propagasi balik [1]. Hal ini dapat dilihat pada penelitian Fitriati yang melakukan klasifikasi citra retina tergolong normal dan abnormal untuk penyakit diabetik retinopati dan menghasilkan akurasi sebesar 97,5% [2]. Tidak hanya itu, penelitian yang dilakukan oleh Murdoko dan Saparudin juga melakukan klasifikasi citra daun tanaman menggunakan metode ELM dengan nilai akurasi terbesar 92,9 % untuk 32 kelas dan menggunakan 4 fitur tekstur *Gray Level Coocurrence Matrix* (GLCM) yaitu energi, kontras, homogenitas, dan korelasi [3]. Disisi lain metode *Convolutional Neural Network* dengan arsitektur LeNet 5 (CNN LeNet 5) mampu menghasilkan akurasi hingga 98% dengan hanya menggunakan fitur biner sederhana. Berdasarkan hal tersebut, peneliti ingin menguji dan membandingkan kinerja ELM dan CNN LeNet 5. Penelitian ini ingin menguji apakah metode ELM unggul pula dalam mengklasifikasi data biner sederhana pada citra tulisan tangan angka.

Secara umum sistem klasifikasi citra terdiri dari beberapa proses seperti pra-proses, deteksi, segmentasi, ekstraksi fitur, dan klasifikasi citra [4]. Namun pada penelitian ini hanya menggunakan beberapa alur saja yang dianggap sudah mencukupi untuk keseluruhan proses. Adapun alur metode

usulan pada penelitian ini seperti Gambar 1.1 berikut :



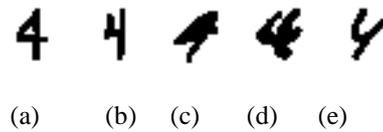
Gambar 1.1 Metode Usulan

## 2. Analisis Pola Tulisan Tangan Angka

Pola angka yang ditulis dengan tangan memiliki bentuk yang tidak pasti atau tidak konsisten bila dibandingkan dengan pola angka yang dicetak dengan mesin. Bahkan untuk satu orang yang sama akan menghasilkan pola yang berbeda-beda untuk angka yang sama. Keunikan inilah yang membuat pola angka tulisan tangan lebih sulit dikenali dibandingkan dengan pola angka yang dihasilkan oleh mesin. Ketidakkonsistenan penulisan sebuah pola angka dapat disebabkan oleh beberapa hal berikut :

1. Ketidakkonsisten ini disebabkan karena tidak ada bentuk dan ukuran yang pasti bagi setiap orang untuk menuliskan sebuah pola angka. Contohnya apabila ada dua orang yang menuliskan angka empat maka akan dihasilkan pola yang berbeda seperti angka empat yang tertutup dan angka empat yang terbuka pada bagian atasnya serta angka empat yang berukuran kecil dan angka empat yang berukuran besar;
2. Ketidakkonsistenan ini disebabkan karena berbagai bentuk perubahan atau distorsi yang mungkin timbul pada sebuah pola angka seperti adanya penebalan, kemiringan, pergeseran, dan penekanan;
3. Ketidakkonsistenan ini disebabkan karena faktor psikologis penulis seperti menulis terburu-buru dan cara menggunakan alat tulis yang berbeda sehingga menghasilkan bentuk tulisan yang menebal karena tinta yang meluber.

Untuk itu berikut akan diberikan beberapa contoh variasi bentuk distorsi agar dapat memperjelas penjelasan di atas.



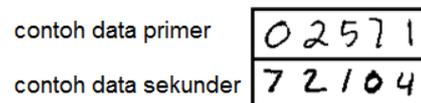
Gambar 2.1 Variasi Bentuk Distorsi Angka yang Ditulis Tangan

- (a) Bentuk angka empat yang tertutup
- (b) Bentuk angka empat yang ditekan
- (c) Bentuk angka empat yang ditulis terburu-buru
- (d) Bentuk angka empat yang menebal
- (e) Bentuk angka empat yang miring

## 3. METODE PENELITIAN

### A. Data Penelitian

Penelitian ini menggunakan dua jenis data, yaitu data primer dan data sekunder. Data primer terdiri dari 700 citra angka tulisan tangan berukuran 34x34 piksel dengan format RGB. Data primer diambil dari tulisan tangan angka masyarakat Palembang, Indonesia. Sedangkan data sekunder diambil dari basis data publik MNIST dengan jumlah data sebanyak 60.000 citra yang digunakan untuk data pembelajaran dan 10.000 citra digunakan untuk data pengujian. Gambar pada basis data MNIST berukuran 28x28 piksel dengan format *grayscale*. Semua data yang digunakan terlebih dahulu dinormalisasi menjadi ukuran 32x32 piksel menyesuaikan lebar lapisan LeNet 5. Gambar 3.2 berikut adalah contoh citra yang digunakan.



Gambar 3.1 Contoh Tulisan Tangan Angka

### B. Pra-pengolahan Citra Digital

Teknik *bilevel sauvola* merupakan salah satu teknik yang mengubah gambar skala keabuan menjadi gambar biner. Dalam penerapannya, teknik ini mampu menghasilkan pengenalan sebesar 95,8% [5]. *Sauvola* merupakan algoritma ambang batas yang memanfaatkan ambang batas lokal adaptif. Asumsikan bahwa citra abu-abu dimana  $g(x,y) \in [0,255]$  menjadi intensitas piksel di lokasi  $(x,y)$ . Teknik lokal adaptif ambang batas bertujuan untuk menghitung ambang batas  $T(x,y)$  untuk setiap piksel, sehingga :

$$o(x,y) = \begin{cases} 0 & \text{jika } g(x,y) \leq t(x,y) \\ 255 & \text{yang lainnya} \end{cases} \quad (1)$$

Pada metode ini, ambang batas  $t(x,y)$  dihitung menggunakan rata-rata  $m(x,y)$  dan standar deviasi  $s(x,y)$  dengan intensitas piksel berukuran  $w \times w$  :

$$t(x, y) = m(x, y) * \left[ 1 + k \left( \frac{s(x,y)}{R} - 1 \right) \right] \quad (2)$$

Keterangan :

- R : nilai maksimum standar deviasi (R = 128 untuk citra abu-abu)
- m(x,y) : rata-rata lokal
- s(x,y) : standar deviasi yang mengadaptasi nilai ambang batas berdasarkan pada lingkungan lokal piksel
- k : parameter yang mengambil nilai-nilai positif dalam kisaran [0,2, 0,5].

### C. Ekstraksi Fitur

Operasi ambang batas (*Thresholding*) adalah proses perubahan citra keabuan menjadi citra biner yang terdiri dari 2 warna yaitu hitam dan putih dimana objek dilambangkan dengan piksel hitam (0) dan latar belakang dilambangkan dengan piksel putih (255). Fitur yang digunakan sebagai masukan adalah seluruh piksel citra hasil *bilevel* yang berjumlah 1024 (berasal dari 32x32 piksel). Untuk skenario tambahan digunakan pula fitur area sebagai penjumlahan piksel bernilai 0 (objek citra).

### D. Extreme Learning Machine

Metode pembelajaran dari 2 dekade terakhir masih banyak yang *berdasarkan gradient-descent/pendekatan iterasi* [1]. Salah satu contohnya adalah *Backpropagasi Neural Network*. akan tetapi, metode ini masih memiliki kekurangan dimana meskipun hasil akurasi yang diperoleh diakui sudah cukup baik, namun terkadang terjadi *overfitting*, berhenti di local minima, dan membutuhkan waktu yang lama untuk belajar. Untuk mengatasi masalah performansi dari *Single-hidden Layer Feedforward Networks* (SLFNs), maka *Extreme Learning Machine* (ELM) dibentuk.

*Extreme Learning Machine* (ELM) merupakan sebuah algoritma pembelajaran yang memanfaatkan arsitektur *Single-hidden Layer Feedforward Networks* (SLFNs). Metode ini memiliki struktur yang hampir sama dengan SLFNs, namun dengan perhitungan komputasi yang berbeda. Metode ini merupakan perbaikan dari SLFNs dimana SLFNs memiliki kelemahan dalam hal proses komputasi yang lama. Inti dari metode ini adalah belajar tanpa iterasi. Sehingga proses belajar dari metode ini cepat (ekstrim). Secara matematis, ELM dimodelkan seperti yang telah di jelaskan oleh G-B.Huang [1]. Secara ringkas Tabel 2.1 berikut memberikan penjelasan mengenai komponen matriks ELM.

Tabel 3.1 Matriks Komponen ELM

Matriks [ baris, kolom]	
	$T = [ T_{11} \quad \dots \quad T_{1N} ]$
	T[1, banyak_sampel]

$X = \begin{bmatrix} x_{11} & \dots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nN} \end{bmatrix}$ X[banyak_fitur, banyak_sampel]	
$b = \begin{bmatrix} b_1 \\ \vdots \\ b_L \end{bmatrix}$ b[banyak_node_hidden, 1]	$H = \begin{bmatrix} h_{11} & \dots & h_{1N} \\ \vdots & \ddots & \vdots \\ h_{L1} & \dots & h_{LN} \end{bmatrix}$ H[banyak_node_hidden, banyak_sampel]
$W = \begin{bmatrix} w_{11} & \dots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{L1} & \dots & w_{LN} \end{bmatrix}$ W[banyak_node_hidden, jumlah_fitur]	$\beta = \begin{bmatrix} \beta_{11} & \dots & \beta_{1n} \\ \vdots & \ddots & \vdots \\ \beta_{L1} & \dots & \beta_{LN} \end{bmatrix}$ $\beta$ [banyak_node_hidden, jumlah_fitur]

Keterangan :

- L : jumlah *node hidden*
- N : jumlah fitur
- X : Sampel
- W : bobot input
- H : bobot input
- $\beta$  : bobot *output*
- B : bias
- Y : *output*

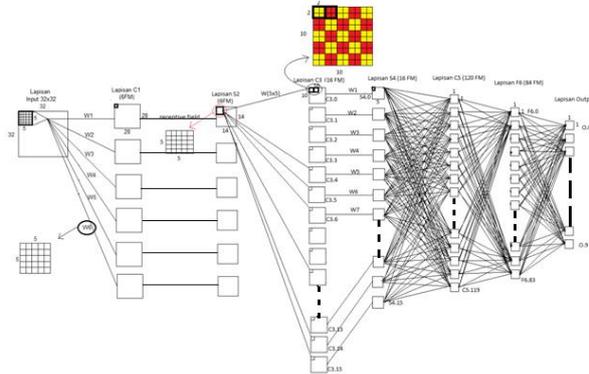
### E. CNN LeNet 5

*Convolutional Neural Network* (CNN) merupakan perbaikan dari Jaringan Saraf Umpam Maju Berlapis Banyak dalam menangani masukan dua dimensi [6]. CNN terinspirasi dari sistem biologis visual manusia yang menggabungkan ekstraksi fitur dan tahap pengklasifikasian [7]. Jaringan ini merupakan hasil pemodelan struktur retina manusia. Jaringan ini secara khusus dirancang untuk mengenali bentuk dua dimensi dengan tingkat invarian yang tinggi meliputi ragam bentuk, perubahan ukuran dan distorsi [8].

Arsitektur CNN memiliki kemampuan implisit untuk mengekstraksi fitur secara otomatis. Dalam hal ini lapisan masukan adalah gambar mentah, lapisan keluaran mewakili kelas pemenang sebagai penggolong, dan lapisan lainnya bertanggung jawab untuk fitur ekstraksi atau pemetaan serta tugas sub-sampling. Agar dapat tahan terhadap distorsi, perubahan ukuran, dan pergeseran, CNN menggunakan tiga ide arsitektur yaitu bidang reseptif lokal (*receptive field*), bobot bersama (*sharing weight*), sub-sampling spasial atau *temporal subsampling* [9].

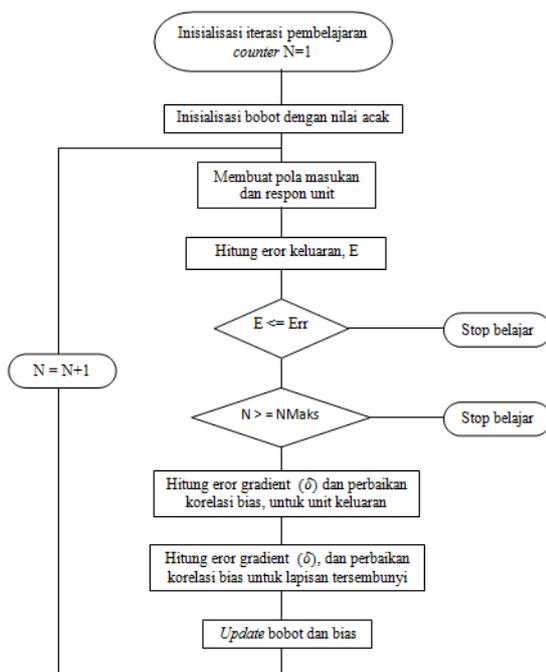
Sedangkan LeNet 5 adalah suatu jaringan berlapis banyak berbasis CNN yang diperkenalkan oleh Yann LeCun. LeNet 5 merupakan pengembangan dari LeNet-LeNet sebelumnya,

dimana LeNet 5 memiliki jumlah parameter bebas atau jumlah lapisan yang lebih banyak dari pendahulunya. Pertambahan jumlah parameter ini disebabkan oleh makin majunya kecepatan atau teknologi dari komputer sehingga mampu untuk melakukan perhitungan matematis secara lebih cepat [10]. Gambar 3.2 berikut adalah arsitektur CNN LeNet 5 yang digunakan pada penelitian ini.



Gambar 3.2 Arsitektur CNN LeNet 5

Kemampuan LeNet 5 untuk menolak karakter yang bukan angka ini dimungkinkan dengan penggunaan *Radial Basis Unit* pada lapisan keluaran dan penggunaan suatu lapisan  $F_6$  yang mencerminkan gambar suatu kelas angka. Nilai dari masing-masing unit pada lapisan keluaran akan mencerminkan jarak dari masing-masing kelas terhadap gambar masukan yang masuk pada sistem. Gambar 3.2 berikut adalah Alur Algoritma Propagasi Balik tipe iterative yang penulis gunakan untuk implementasi CNN LeNet 5.



Gambar 3.2 Alur Algoritma Propagasi Balik Tipe Iteratif

## F. Teknik Evaluasi Hasil

Seperti yang telah dijelaskan sebelumnya bahwa kesimpulan yang diperoleh dari pemrosesan berupa pendekatan. Hal ini akan menyebabkan ada perbedaan antara kesimpulan sebenarnya dengan kesimpulan yang diperoleh. Perbedaan tersebut dinamakan kesalahan atau kekeliruan dari jaringan saraf tiruan. Besarnya kekeliruan atau kesalahan pemrosesan ditentukan oleh fungsi kesalahan. Secara matematis, hal tersebut dituliskan sebagai berikut :

$$E = \frac{1}{2} \sum_{p=1}^P Y_{Dp}^2 \quad (3)$$

Keterangan :

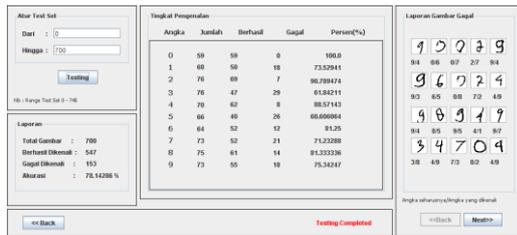
- E : total galat (*minimum square error*)
- $Y_{Dp}$  : keluaran sebenarnya (*actual output*) dari neuron ke-j untuk masukan p
- P : jumlah pola masukan

## 4. HASIL DAN ANALISIS

### A. Hasil

Berdasarkan alur metode usulan, yang menjadi masukan pada tahap klasifikasi adalah citra ukuran 32x32 piksel hasil normalisasi dari proses binerisasi menggunakan teknik *sauvola*. Adapun pengujian ini memiliki beberapa skenario percobaan yaitu pengujian berdasarkan kenaikan jumlah data dan waktu komputasi yang diperoleh, serta pemilihan akurasi yang baik berdasarkan *error train* untuk CNN LeNet 5 dan jumlah *hidden neuron* yang baik untuk ELM.

Pengujian oleh CNN LeNet 5 dan ELM dilakukan dengan menggunakan parameter/bobot atau pengetahuan yang didapatkan dari proses pembelajaran. Bedanya, pada CNN LeNet 5 pengetahuan didapatkan berdasarkan nilai kesalahan pada saat pembelajaran atau *error train* (MSE). Pada praktiknya, pengetahuan yang memiliki tingkat akurasi yang paling baik yang akan digunakan sebagai parameter pengujian. Dalam hal ini pengujian dilakukan dengan menggunakan pengetahuan yang paling baik yaitu pengetahuan yang diperoleh dari *error train* sebesar 1,2%. Sedangkan parameter pada ELM diperoleh sekali (pembelajaran tanpa iterasi) sesaat setelah proses pelatihan selesai dilakukan. Tentunya parameter yang digunakan adalah parameter yang memiliki nilai akurasi pelatihan yang paling baik yaitu dengan jumlah *neuron hidden* 90 dan fungsi aktivasi sinusoid. Gambar 4.1 dan Gambar 4.2 berikut adalah antarmuka perangkat lunak yang dibuat.



Gambar 4.1 Antarmuka Perangkat Lunak Pengujian



Gambar 4.2 Antarmuka Pengenalan Pola Galat

**SKENARIO 1 : Pengujian Berdasarkan Banyak Data**

Tabel 4.1 Perbandingan Akurasi Pengujian

Banyak Data Primer	Akurasi yang Dihasilkan (%)	
	CNN LeNet 5	ELM
100	81,0	26,34
200	76,5	23,12
300	77,66664	22
400	78,75	12,57
500	78,799995	12,28
600	78,333336	11,46
700	78,14286180	10,86
Banyak Data Sekunder	Akurasi yang Dihasilkan (%)	
	CNN LeNet 5	ELM
1.000	98,2995	36,42
2.000	97,35	26,14
3.000	96,73	22,23
4.000	97,05	20,09
5.000	97,11995	18,67
6.000	97,433334	18,05
7.000	97,58572	17,35
8.000	97,875	16,74
9.000	98,0	16,20
10.000	98,04	15,76

**SKENARIO 2 : Perbandingan Waktu Komputasi**

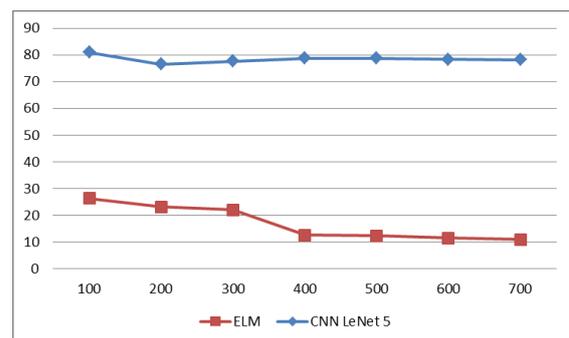
Tabel 4.2 Perbandingan Komputasi Waktu

Banyak Data Primer	Komputasi Waktu md (mili detik)	
	CNN LeNet 5	ELM
100	1066	0,0546

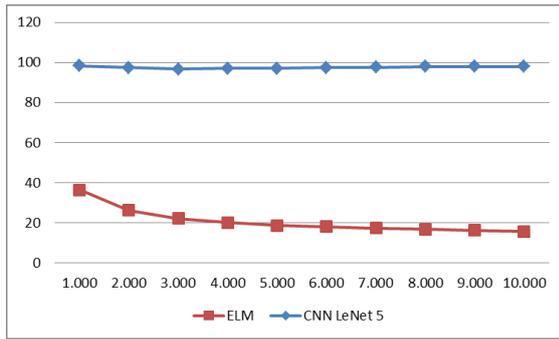
200	1058	0,003120
300	1084	0,0061
400	2031	0,00624
500	2051	0,00936
600	3018	0,00624
700	3058	0,00624
Banyak Data Sekunder	Komputasi Waktu md (mili detik)	
	CNN LeNet 5	ELM
1.000	5031	0,00312
2.000	13090	0,01716
3.000	37030	0,00078
4.000	45031	0,02496
5.000	90077	0,02652
6.000	53023	0,02496
7.000	38075	0,04056
8.000	44009	0,0889
9.000	46003	0,06396
10.000	90047	0,078

**B. Analisis Hasil**

Berdasarkan percobaan yang dilakukan diketahui bahwa nilai akurasi yang diperoleh ELM, baik menggunakan data primer maupun sekunder, mengalami penurunan untuk setiap penambahan jumlah data. Sedangkan akurasi yang diperoleh CNN LeNet 5 cenderung tidak menentu antara peningkatan dan penurunan akurasinya. Akan tetapi antara metode ELM dan CNN LeNet 5 diketahui bahwa dalam hal ini CNN LeNet 5 lebih unggul karena mampu mengenali pola tulisan tangan angka dengan tingkat kepercayaan sebesar 78,14% untuk data primer dan 98,04% untuk data sekunder. Hal ini dapat dilihat pada grafik Gambar 4.3 dan Gambar 4.4.



Gambar 4.3 Grafik Akurasi Data Primer



Gambar 4.4 Grafik Akurasi Data Sekunder

Grafik di atas menunjukkan bahwa terdapat perbedaan yang cukup jauh antara nilai akurasi yang diperoleh dari kedua metode ini. Diketahui bahwa CNN LeNet 5 mampu mencapai rentang 70% – 90%, sedangkan ELM berada pada rentang 10% – 30%. Jika dilihat dari data masukan dan struktur algoritma setiap metode, CNN LeNet 5 memiliki arsitektur yang cukup baik karena dapat menangkap setiap piksel masukan hingga membentuk sebuah kelas angka berukuran 12 x 7 piksel (direpresentasikan menjadi 84 peta fitur pada lapisan  $F_6$ ) yang berarti proses pembelajaran hanya fokus pada hal ini saja. Pembentukan 84 peta fitur dan penggunaan *Radial Basis Unit* (RBF) pada lapisan keluaran ini mampu menolak karakter yang bukan angka. Nilai dari masing-masing unit pada lapisan keluaran akan mencerminkan jarak dari masing-masing kelas terhadap gambar masukan yang masuk pada sistem. Sedangkan pada ELM, citra hasil bilevel langsung diproses per-pikselya tanpa ada lapisan lain yang menangkap objek secara khusus. Seperti yang diketahui ELM memanfaatkan arsitektur *Single-hidden Layer Feedforward Networks* (SLFNs) namun dengan perhitungan komputasi yang berbeda yaitu dengan memanfaatkan *invers* Moore-Penrose dari keluaran lapisan tersembunyi untuk melakukan perhitungan matrik kompleks dan matrik bebas.

Tidak hanya itu, tingkat akurasi yang dihasilkan dari pengujian *data set* yang berbeda membuktikan bahwa karakter tulisan tangan memiliki tingkat variasi yang tinggi dan tidak konsisten. Artinya budaya, lingkungan tempat tinggal, dan kebiasaan mempengaruhi karakter tulisan tangan seseorang.

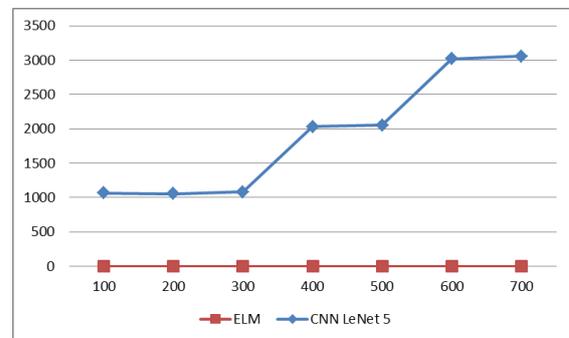
Gambar 3.1 pada pembahasan sebelumnya menunjukkan bahwa ada sedikit perbedaan dari karakter tulisan tangan angka kedua data, yaitu dari sisi ketebalan penulisan. Selain itu, Keanekaragaman hasil akurasi yang diperoleh dari sistem disebabkan oleh jumlah variasi gaya penulisan yang berbeda-beda pada setiap jumlah data yang diuji, sehingga hasil yang didapatkan selalu berubah-ubah. Oleh karena itu banyaknya

data yang diuji belum tentu mempengaruhi tingkat akurasi.

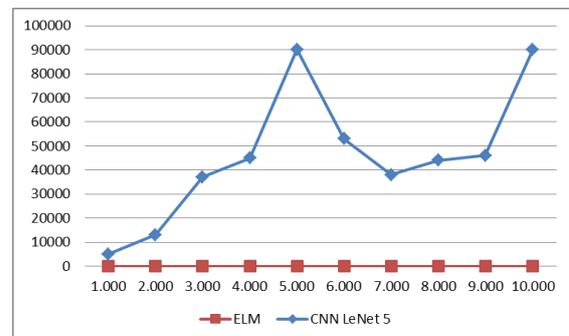
### Analisis Gambar Gagal Dikenali

Gambar yang gagal dikenali pada saat pengujian adalah gambar yang memiliki bentuk pola utama yang hampir sama dengan kelas angka yang lain sehingga bersifat ambigu. Namun ada beberapa kelas angka yang terlihat jelas namun gagal dikenali. Hal ini dikarenakan contoh gambar yang terdapat pada *training set* mungkin belum banyak memiliki variasi bentuk gaya tulisan seperti yang terdapat pada *testing set*. Apabila pada *training set* ditambahkan sedikit variasi gaya penulisan maka pengenalan angka tulisan tangan dapat meningkat.

### Analisis Komputasi Waktu



Gambar 4.5 Grafik Komputasi Waktu Data Primer



Gambar 4.6 Grafik Komputasi Waktu Data Sekunder

Gambar 4.5 dan Gambar 4.6 menunjukkan bahwa ELM lebih unggul dibandingkan CNN LeNet 5 dari sisi komputasi waktu. Hal ini terlihat jelas karena struktur ELM tidak ada perulangan sehingga proses perhitungan menjadi lebih cepat. Sedangkan arsitektur CNN LeNet 5 lebih kompleks karena harus menghitung sampai 3 lapisan dimana dalam tiap lapisan membutuhkan perhitungan lagi untuk setiap pemetaan konvolusi pikselnya. Tidak hanya itu, proses pembelajaran pula menggunakan sistem perulangan untuk mendapatkan akurasi sesuai nilai eror yang didefinisikan.

## 5. KESIMPULAN

Berdasarkan hasil pengujian dapat disimpulkan bahwa pengembangan sistem klasifikasi tulisan tangan angka menggunakan metode CNN LeNet 5 lebih unggul dalam hal akurasi yaitu mencapai 98,04% untuk 10.000 data sekunder MNIST dan 78,14% untuk 700 data primer. Sedangkan metode ELM lebih unggul dalam hal komputasi waktu yang mencapai 0,00078 mili detik. Hasil pengujian ditentukan oleh banyaknya data latih yang digunakan. Semakin banyak data latih maka akan meningkatkan nilai akurasi pengujianya. Penentuan jumlah *hidden node* berpengaruh besar dalam menghasilkan nilai akurasi ELM. Pada penelitian ini nilai *hidden node* yang dapat menghasilkan nilai akurasi terbesar adalah sebesar 90 dan dengan fungsi aktivasi sinusoid.

## DAFTAR PUSTAKA

- [1] G-B. Huang, Q-Y. Zhu, C-K. Siew. "Extreme Learning Machine : Theory and Applications", Elsevier Neurocomputing 70 , hal. 489-501, 2006.
- [2] Murdoko dan Saparudin. "Klasifikasi Citra Daun Tanaman Menggunakan Metode Extreme Learning Machine", Konferensi Nasional Informatika (KNIF), 2015.
- [3] Fitriati, Desti. "Neovascular Classification From Fundus Image Using Extreme Learning Machine for Screening Diabetic Retinopathy", The Second Indonesian-Japanese Conference on Knowledge Creation and Intelligent Computing (KCIC), hal. 73-78, 2013. ISBN : 978-602-9494-68-6.
- [4] Kamavisdar, P., Saluja, S., & Agrawal, S. "A Survey on Image Classification Approaches and Techniques", International Journal of Advanced Research in Computer and Communication Engineering, 2(1), 2013.
- [5] Shafait, F., D. Keysers, & T.M. Breuel. "Efficient Implementation of Local Adaptive Thresholding Techniques Using Integral Images", Proceedings of the 15th Document Recognition and Retrieval Conference (DRR-2008), Part of the IS&T/SPIE International Symposium on Electronic Imaging. January 26-31, San Jose, CA, USA volume 6815, SPIE, 1/2008, Accepted for publication.
- [6] Bouchain, David. "Character Recognition Using Convolutional Neural Networks", Statistical Learning Theory Conference, Institute for Neural Information Processing, University of Ulm, Germany. (Winter 2006/2007).
- [7] Ahranjany, S.S, F. Razzazi, & M.H. Ghassemian. "A Very High Accuracy Handwritten Character Recognition System for Farsi/Arabic Digits Using Convolutional Neural Networks", International Journal of Technology Information IEEE, 2010.
- [8] Mrazova, I, & M. Kukacka. "Hybrid Convolutional Neural Networks", The IEEE International Conference on Industrial Informatics (INDIN). Doc, Daejeon, Korea Juli 13-16-2008.
- [9] Zhao, Z, S. Yang, & X. Ma. "Chinese License Plate Recognition Using a Convolutional Neural Network", IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application (PACIIA), 2008.
- [10] Y. LeCun, L. Bottou, Y. Bengio, & P. Haffner. "Gradient-based learning applied to document recognition", Proceedings of the IEEE, 86(11):2278-2324, November, 1998.