

Prediksi Jumlah Kriminalitas Menggunakan Metode *Extreme Learning Machine* (Studi Kasus Di Kabupaten Probolinggo)

Sema Nabillah Dewi¹, Imam Cholissodin², Edy Santoso³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹semanabillah888@gmail.com, ²imamcs@ub.ac.id, ³edy144@ub.ac.id

Abstrak

Tingkat kejahatan di Indonesia semakin merajalela. Ambisi masyarakat akan memiliki harta kekayaan dari jalan yang tidak wajar dengan melakukan tindak kriminalitas. Kriminalitas merupakan tindakan yang melanggar aturan undang-undang yang dapat meresahkan masyarakat. Setiap masyarakat memiliki resiko menjadi korban tindak kriminalitas. Semakin besar resiko yang dimiliki masyarakat menandakan semakin tidak amannya suatu daerah. Namun, tidak bisa dipastikan jumlah tindak kriminalitas dari waktu ke waktu karena jumlahnya yang tidak menentu. Hal ini menyebabkan pihak kepolisian mengalami kesulitan untuk mengatasi masalah tindak kriminalitas. Prediksi yang tepat dan akurat dapat membantu meminimalisir tindak kriminalitas yang akan terjadi. Penelitian ini bertujuan untuk memperoleh prediksi jumlah kriminalitas menggunakan metode *Extreme Learning Machine*. Berdasarkan implementasi dan pengujian yang dilakukan menggunakan data kriminalitas Polres Kabupaten Probolinggo tahun 2012 hingga 2017 diperoleh arsitektur jaringan yang maksimum yaitu jumlah fitur sebanyak 7, perbandingan rasio data yaitu 80%:20%, dan jumlah *neuron* pada *hidden layer* sebanyak 7 serta fungsi aktivasi sigmoid biner. Nilai *error* yang rendah dihitung menggunakan tingkat kesalahan *Mean Square Error* (MSE) yaitu sebesar 0,037662.

Kata Kunci: *extreme learning machine, kriminalitas, mean square error (MSE)*

Abstract

The crime rate in Indonesia is highly increased. A lot of people want to become wealthy in a wrong way by committing a crime. Criminality is an act that violates the rules of the law that can disturb the public. Every society has a risk of becoming a victim of crime. The greater the risk that the community has, the more unsafe their area is. However, the number of criminal acts can't be ensured from time to time due to the uncertain number. This causes the police will having a trouble in resolving the criminal acts. A proper and accurate prediction can help minimizing criminal acts that will be happened. This research is intended to get predicted numbers of criminality using *Extreme Learning Machine* method (ELM). Based on the implementation and testing done by using crime data of Probolinggo District Police in 2012 until 2017, obtained the maximum network architecture that is the number of features as much as 7, the comparison of data ratio is 80%: 20%, and the number of neurons in the hidden layer as much as 7 and the binary sigmoid activation function. The low error value is calculated using the *Mean Square Error* (MSE) error rate and the result is 0.037662.

Keywords: *extreme learning machine, criminality, mean square error (MSE)*

1. PENDAHULUAN

Dewasa ini kriminalitas di Indonesia semakin merajalela. Kompleksitas masyarakat modern membutuhkan berbagai macam kebutuhan materil yang melimpah dan disertai ambisi-ambisi sosial yang tidak konstruktif. Keinginan dalam memiliki harta kekayaan yang diperoleh dari jalan yang tidak wajar,

mendorong seseorang maupun kelompok melakukan tindak kejahatan. Kriminalitas atau kejahatan adalah suatu bentuk tindakan yang melanggar aturan undang-undang yang telah ditetapkan oleh pemerintahan dan menyimpang dari norma-norma sosial serta meresahkan masyarakat (Kartono, 1999). Beberapa bentuk tindak kriminal yaitu pencurian, penganiayaan, tindak asusila, pembunuhan, penipuan, korupsi

dan lain sebagainya. Dilansir dari catatan Badan Pusat Statistik (BPS) tercatat bahwa jumlah tindak kriminalitas di Jawa Timur mengalami peningkatan yang sangat drastis selama periode 2014-2015. Probolinggo merupakan salah satu dari 38 Kabupaten/Kota di Jawa Timur yang memiliki jumlah kriminalitas cukup tinggi. Di Kabupaten Probolinggo pada tahun 2016 terdapat 982 kasus kejahatan yang dilaporkan dan mengalami kenaikan hingga 24,84% dari tahun sebelumnya (Kepolisian Resort Kabupaten Probolinggo, 2017).

Selama ini jumlah kriminalitas pada Kabupaten Probolinggo jumlahnya berbeda setiap bulannya. Hal tersebut membuat pihak kepolisian mengalami kesulitan dalam memprediksi tingkat kriminalitas dari waktu ke waktu, karena datanya cenderung *fluktuatif* (dinamis). Menurut Kasubaghumas Polres Kabupaten Probolinggo, AKP Ida Bagus, faktor yang mendorong seseorang atau kelompok melakukan tindak pidana yaitu disebabkan oleh kondisi lingkungan sekitar yang mengalami perubahan yang sangat cepat, menurunnya norma-norma dan sanksi sosial yang memberikan pengaruh buruk yang mengacu terjadinya disorganisasi dalam masyarakat. Untuk meminimalisir tingkat kriminalitas, pihak kepolisian membutuhkan metode khusus yang disertai perhitungan-perhitungan dalam memprediksi jumlah kriminalitas. Sehingga pihak kepolisian memperoleh prediksi yang akurat dan efektif dalam menentukan jumlah kriminalitas. Maka dari itu diperlukan suatu metode komputasi untuk memprediksi jumlah kriminalitas.

Penelitian sebelumnya dalam memecahkan permasalahan prediksi dengan menerapkan metode *Extreme Learning Machine* (ELM) yaitu mengenai peramalan jumlah kunjungan pasien yang dilakukan pada bagian Poli Gigi di Rumah Sakit DR. Wahidin Sudiro Husodo Mojokerto. Penelitian ini menggunakan 116 data testing dengan dievaluasi beberapa kali, kemudian diuji coba berdasarkan fungsi aktivasi sigmoid. Sehingga diperoleh nilai akurasi optimal dari hasil peramalan dan tingkat kesalahan yang rendah yaitu sebesar 0,027 (Fardani, et al., 2015).

Oleh karena itu, penulis melakukan penelitian untuk memprediksi jumlah kriminalitas menggunakan metode ELM dengan harapan dapat menjadi solusi dari permasalahan tindak kriminalitas dan dapat membantu penulis untuk mengetahui jumlah kriminalitas di suatu

daerah serta menghasilkan ramalan atau prediksi yang lebih efektif, khususnya di Kabupaten Probolinggo.

2. TINJAUAN PUSTAKA

2.1 Prediksi

Prediksi adalah suatu perkiraan sistematis mengenai sebuah proses tentang apa yang mungkin terjadi di periode selanjutnya berdasarkan sumber informasi periode sebelumnya dan saat ini yang diperoleh untuk memperkecil suatu kesalahan (Mendome, et al., 2016). Secara umum hasil prediksi berkaitan erat dengan ketidakpastian, sehingga harus memperhitungkan faktor akurasi yang tidak akan selalu memperoleh hasil prediksi dengan akurasi 100%. Dengan adanya perbedaan waktu maka prediksi mempunyai peran penting untuk menentukan kapan akan terjadi suatu peristiwa sehingga dapat mempersiapkan segala tindakan yang dibutuhkan.

2.2 Kriminalitas

Kriminalitas merupakan suatu bentuk tindakan yang melanggar aturan undang-undang yang telah ditetapkan oleh pemerintahan dan menyimpang dari norma-norma sosial serta meresahkan masyarakat (Kartono, 1999). Secara kriminologi berbasis sosiologis, kriminalitas diartikan sebagai pola tingkah laku yang dapat meresahkan maupun merugikan masyarakat sebagai korban kejahatan. Adapun beberapa bentuk tindak kriminalitas yang sering terjadi yakni pencurian, penganiayaan dan pembunuhan.

2.3 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan atau yang biasa dikenal dengan istilah *Artificial Neural Network* (ANN) merupakan salah satu bagian dari *machine learning*. Jaringan syaraf tiruan memiliki kemiripan dengan kondisi otak manusia yang terbentuk dari sebagian besar *neuron* yang mempunyai hubungan sangat erat antara *neuron-neuron* yang ada (Siang, 2009). *Neuron-neuron* tersebut memiliki peranan penting dalam mengolah informasi dan meneruskannya kepada *neuron-neuron* lain. Hubungan antar *neuron* ini disebut bobot (*weight*). Dalam jaringan syaraf tiruan terdapat tiga lapisan yakni Lapisan Masukan (*Input Layer*), Lapisan Tersembunyi (*Hidden Layer*), dan Lapisan Keluaran (*Output Layer*).

Dalam jaringan syaraf tiruan terdapat fungsi aktivasi yang dapat digunakan untuk menentukan *output* suatu *neuron* dengan berargumen *net input*. *Net input* terdiri dari kombinasi linier *input* beserta bobotnya (Siang, 2009). Fungsi ini memiliki tujuan untuk memodifikasi *output* kedalam rentang nilai tertentu. Berikut ini adalah fungsi aktivasi yang sering digunakan dalam jaringan syaraf (Kusumadewi, 2003) yaitu:

a) Fungsi *sigmoid biner*

Fungsi *sigmoid biner* memiliki interval *output* 0 sampai 1 dengan membentuk kurva S yang dapat menghasilkan *output* lebih cepat. Fungsi *sigmoid biner* dapat dirumuskan seperti Persamaan 1.

$$f(x) = \frac{1}{1+e^{-x}} \tag{1}$$

Dimana,

$f(x)$ = Fungsi aktivasi sigmoid biner.
 e^{-x} = Eksponensial pangkat minus data ke- x .

b) Fungsi *sigmoid bipolar*

Sama halnya dengan fungsi *sigmoid biner*, hanya saja fungsi *sigmoid bipolar* memiliki rentang nilai antara -1 dan 1. Fungsi *sigmoid bipolar* dapat dirumuskan seperti Persamaan 2.

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \tag{2}$$

2.4 Extreme Learning Machine

Extreme Learning Machine (ELM) merupakan sekumpulan metode pembelajaran yang diawasi. Metode ini adalah metode baru dari Jaringan Syaraf Tiruan atau *Artificial Neural Network* (ANN) yang pertama kali dicetuskan oleh Huang (2004). ELM melambangkan bagian dari jaringan syaraf tiruan *feedforward* dengan *Single Hidden Layer Feedforward neural Networks* (SLFNs) (Mahdiyah, et al., 2015). Metode ELM menggunakan Proses Pelatihan (*training*) dan Proses Uji coba (*testing*) sehingga dapat memperoleh hasil peramalan atau prediksi yang diinginkan. Model ELM secara matematis lebih efektif dan sederhana dari jaringan syaraf tiruan *feedforward*. Model matematis dari ELM untuk N jumlah sampel yang berbeda (x_i, t_i) adalah sebagai berikut.

$$x_i = [x_{i1}, x_{i2}, \dots, x_{il}]^T \in \mathbf{R}^l$$

$$T = [x_{i1}, x_{i2}, \dots, t_{iN}]^T \in \mathbf{R}^N$$

$$X = [x_1, x_2, \dots, x_N]^T \in \mathbf{R}^N$$

Keterangan:

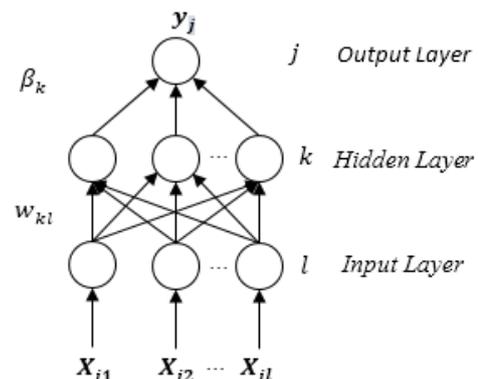
x_i = data ke- i

t_i = target data ke- i

X = keseluruhan data yang telah dinormalisasi

N = jumlah data

Konfigurasi sederhana algoritma ELM dapat dijelaskan pada Gambar 1.



Gambar 1 Struktur *Extreme Learning Machine*

Langkah-langkah perhitungan metode ELM dibagi menjadi dua proses yaitu proses pelatihan (*training*) dan proses uji coba (*testing*).

a) Proses *Training*

Proses *training* dilakukan guna memperoleh *output weight* optimal atau memiliki tingkat kesalahan yang rendah. Tujuan dari proses *training* adalah untuk mengembangkan model ELM. Tahapan pada proses *training* adalah sebagai berikut:

1. Inisialisasi seluruh bobot (*input weight*) diatur dengan bilangan *random* yang kecil dari -1 hingga 1.
2. Keluaran di *hidden layer* dihitung dengan cara mengalikan masukan berupa data sejumlah N yang merupakan normalisasi data dalam bentuk matriks (X) dengan matriks *input weight* $j \times k$ yang diperoleh secara *random*, dimana j adalah jumlah *hidden* neuron dan k adalah jumlah *input* node. Perhitungan keluaran di *hidden layer* dapat dilihat pada Persamaan 3. Selanjutnya hitung keluaran *hidden layer* (H_{init}) dengan menggunakan fungsi aktivasi yang ditunjukkan pada Persamaan 1 untuk fungsi *sigmoid biner* dan Persamaan 2 untuk fungsi *sigmoid bipolar*.

$$H_{init} = X \cdot w^T \tag{3}$$

Dimana,

H_{init} = Matriks keluaran *hidden layer*
 X

= Matriks normalisasi data tanpa target
 w^T

= Matriks *transpose input weight*

- Setelah memperoleh keluaran *hidden layer* dengan fungsi aktivasi ($H(x)$). Kemudian menghitung H^+ yang merupakan *Moore Penrose Generalized Invers* yaitu untuk menghitung nilai invers dari matriks $H(x)$ dengan fungsi aktivasi (Mahdiyah, et al., 2015). Berikut ini Persamaan 4 dalam menghitung nilai *output weight*..

$$\beta = H^+T \tag{4}$$

Dimana,

β = Matriks *output weight*
 H^+ = Matriks *Moore Penrose Generalized Invers* dari matriks H
 T = Matriks target

b) Proses *Testing*

Setelah proses *training*, diperoleh *output weight* yang optimal dari JST dengan metode ELM. Tujuan dari proses *testing* adalah mengevaluasi potensi metode ELM dalam hal prediksi. Tahapan pada proses *testing* adalah sebagai berikut:

- Inisialisasi *input weight* (diperoleh dari proses *training*)
- Semua keluaran di *hidden layer* dihitung dengan fungsi aktivasi ($H(x)$) menggunakan Persamaan 3.
- Menghitung keluaran hasil prediksi yang dihitung menggunakan Persamaan 5.

$$y = H(x).\beta \tag{5}$$

Keterangan:

y = *Output layer* yang merupakan hasil prediksi

β = Matriks *output weight*

$H(x)$ = Keluaran di *hidden layer* dihitung dengan fungsi aktivasi

- Menghitung nilai *error* pada *output layer* yang dapat dilihat pada Persamaan 6.

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} = \frac{\sum_{i=1}^n (y_i - t_i)^2}{n} \tag{6}$$

Keterangan:

n = Jumlah data uji

e_i = *Error*

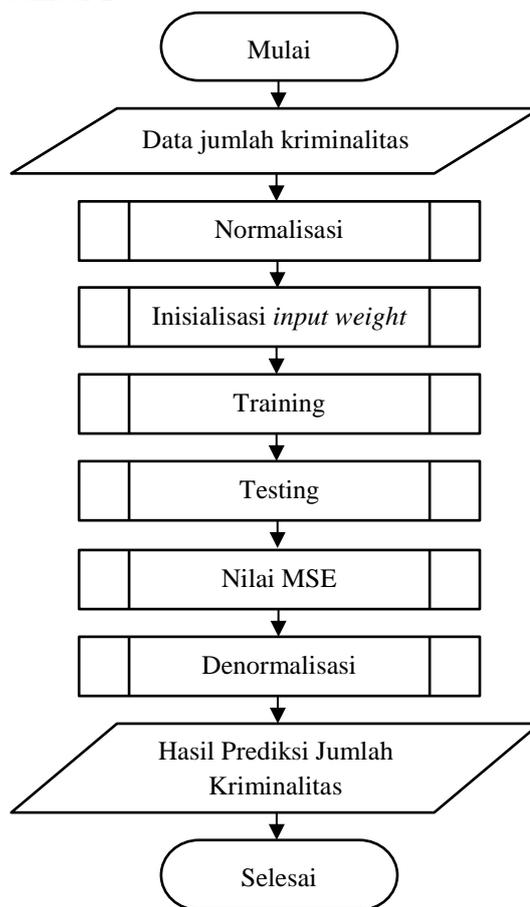
y_i = Nilai *output* (prediksi)

t_i = Nilai aktual

3. PERANCANGAN & IMPLEMENTASI

Data yang digunakan merupakan data sekunder berupa data jumlah kriminalitas dari

tahun 2012 hingga 2017 sebanyak 68 data yang diperoleh dari Polres Kabupaten Probolinggo. Sebelum dilakukan implementasi terlebih dahulu diperlukan sebuah alur pada proses perancangan dalam sistem prediksi jumlah kriminalitas menggunakan metode *Extreme Learning Machine* (ELM). Berikut merupakan diagram alir proses ELM yang ditunjukkan pada Gambar 2.

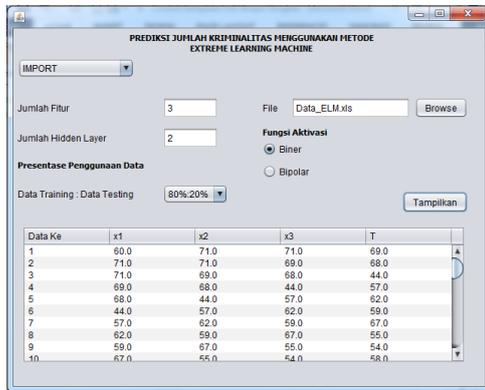


Gambar 2 Diagram Alir Proses *Extreme Learning Machine*

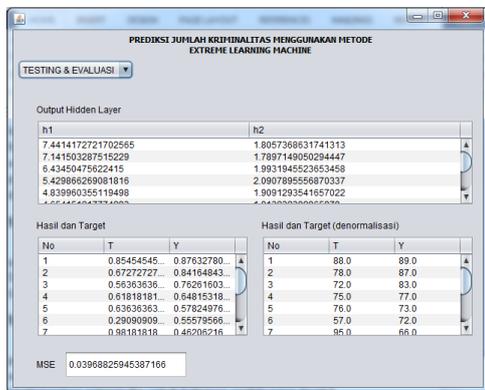
Tahapan-tahapan dari proses metode *Extreme Learning Machine* dari Gambar 1 yakni pertama menerima masukan berupa data jumlah kriminalitas, kedua melakukan proses normalisasi terhadap data masukan, ketiga inisialisasi *input weight* yang dilakukan secara random dengan range [-1,1], keempat melakukan proses *training* ELM, kelima melakukan proses *testing* ELM. Kemudian mencari nilai MSE dan melakukan proses denormalisasi. Keluaran dari sistem berupa hasil prediksi jumlah kriminalitas.

Implementasi antarmuka yang digunakan pada prediksi jumlah kriminalitas terbagi menjadi 5 halaman yakni halaman *import* data yang ditunjukkan pada Gambar 3, halaman

normalisasi data, halaman *weight*, halaman *training*, serta halaman *testing* dan evaluasi ditunjukkan pada Gambar 4.



Gambar 3 Halaman *Import Data*

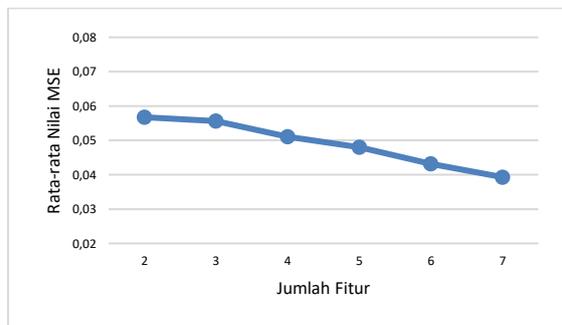


Gambar 4 Halaman *Testing dan Evaluasi*

4. PENGUJIAN DAN ANALISIS

Pengujian ini dilakukan dengan menguji keakuratan tingkat kriminalitas sesuai data *testing* yang diperoleh dengan hasil *output* sistem. Pengujian yang dilakukan pada penelitian ini berupa variasi fitur data, rasio data, fungsi aktivasi, dan jumlah *neuron* pada *hidden layer*.

4.1 Hasil Pengujian MSE Terhadap Variasi Fitur Data

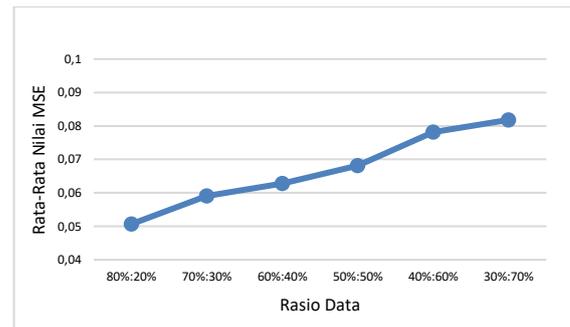


Gambar 5 Grafik MSE Terhadap Variasi Fitur Data

Dari Gambar 5 dapat diketahui bahwa perolehan rata-rata nilai MSE terendah

ditunjukkan pada variasi fitur sebanyak 7 fitur yang memiliki nilai 0,039299. Hal ini dapat disimpulkan bahwa semakin banyak masukan jumlah fitur maka hasil prediksi yang dihasilkan cenderung yang terbaik, karena selain fitur juga bergantung pada objek yang digunakan untuk memprediksi dan menghasilkan pola data yang lebih baik.

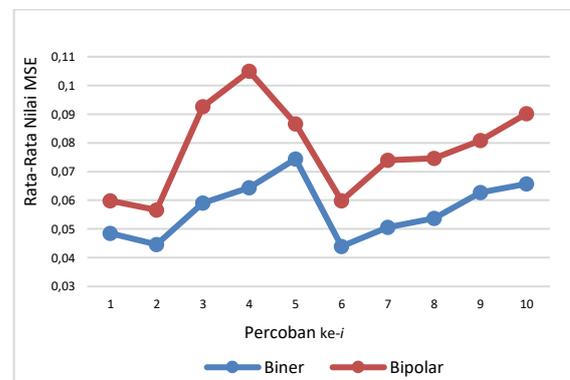
4.2 Hasil Pengujian MSE Terhadap Rasio Data



Gambar 6 Grafik MSE Terhadap Rasio Data

Dari Gambar 6 diketahui bahwa perolehan rata-rata nilai MSE sebesar 0,050670 yang terletak pada pengujian rasio perbandingan 80%:20%. Nilai *error* yang dihasilkan tersebut mengalami penurunan cukup signifikan. Hal ini terjadi karena pengaruh data dan nilai *input weight* yang ditentukan secara *random*. Oleh sebab itu banyaknya data *training* dan data *testing* sangat berpengaruh pada perolehan nilai *error*. Semakin banyak data pelatihan (*training*) yang dilakukan maka perolehan nilai *error* semakin baik.

4.3 Hasil Pengujian MSE Terhadap Fungsi Aktivasi

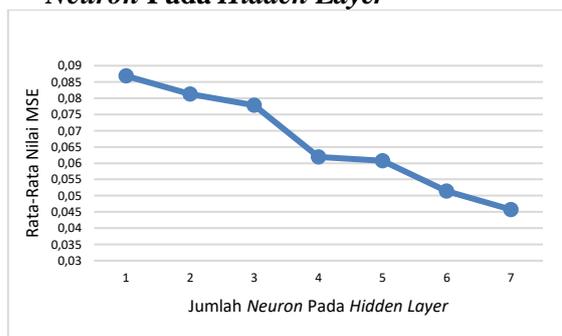


Gambar 7 Grafik MSE Terhadap Fungsi Aktivasi

Dari Gambar 8 diketahui bahwa perolehan rata-rata nilai MSE sebesar 0,056762 yang terletak pada fungsi aktivasi sigmoid biner. Walaupun rata-rata nilai MSE fungsi aktivasi

sigmoid biner tidak jauh berbeda dengan rata-rata nilai MSE fungsi aktivasi sigmoid bipolar, akan tetapi fungsi aktivasi sigmoid biner yang memiliki akurasi lebih baik. Hal itu dikarenakan nilai yang dihasilkan dari fungsi aktivasi sigmoid biner sangat berpengaruh pada pencapaian target prediksi.

4.4 Hasil Pengujian MSE Terhadap Jumlah Neuron Pada Hidden Layer



Gambar 9 Grafik MSE Terhadap Jumlah Neuron Pada Hidden Layer

Dari Gambar 9 diketahui bahwa rata-rata nilai MSE mengalami penurunan yang cukup jauh. Hal ini dapat disimpulkan bahwa semakin banyak masukan jumlah *hidden layer* maka semakin kecil rata-rata nilai MSE. Hasil pengujian diperoleh rata-rata nilai MSE terbaik ditunjukkan pada jumlah *hidden layer* 7 yaitu sebesar 0,045752.

5. KESIMPULAN & SARAN

Berdasarkan hasil pengujian dan analisis pada penelitian prediksi jumlah kriminalitas menggunakan metode *Extreme Learning Machine* maka diperoleh beberapa kesimpulan sebagai berikut:

1. Implementasi metode ELM dapat dilakukan untuk memprediksi jumlah kriminalitas dengan mendefinisikan jumlah *hidden layer* dan nilai *input weight* yang menghasilkan keluaran dengan perolehan nilai *error* terkecil.
2. Nilai *Mean Square Error* (MSE) terendah yang dihasilkan sebesar 0,037662 dengan simpangan rata-rata jumlah kriminalitas sebesar 4,2 dari perolehan arsitektur yang maksimum yaitu jumlah fitur sebanyak 7, perbandingan rasio data yaitu 80%:20%, jumlah *neuron* pada *hidden layer* sebanyak 7 dan fungsi aktivasi sigmoid biner.

Beberapa saran yang dapat diberikan pada penelitian mengenai prediksi jumlah

kriminalitas menggunakan metode *Extreme Learning Machine* (ELM) adalah sebagai berikut:

1. Untuk penelitian mendatang, peneliti dapat melakukan penambahan beberapa parameter lain seperti faktor-faktor dalam jumlah kriminalitas untuk menghasilkan prediksi yang lebih objektif. Semakin banyak parameter faktor terjadinya tindak kejahatan, maka akan memperoleh hasil yang lebih baik.
2. Peneliti dapat melakukan pengembangan metode ELM yang di-*hybrid* dengan beberapa metode pelatihan lain dari jaringan syaraf tiruan seperti *Backpropagation* (BP), *Learning Vector Quantitation* (LVQ), *Support Vector Machine* (SVR), *Radial Basis Function* (RBF), dan metode pelatihan lainnya untuk meningkatkan kemampuan jaringan dalam mengenali pola jumlah kriminalitas serta meningkatkan hasil yang diperoleh dari penelitian sebelumnya.

6. DAFTAR PUSTAKA

- Fardani, D. P., Wuryanto, E. & Werdiningsih, I., 2015. Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus: Poli Gigi RSU DR. Wahidin Sudiro Husodo Mojokerto). *Journal of Information Systems Engineering and Business Intelligence*, Volume 1, p. 33.
- Huang, G., Zhu, Q. & Siew, C., 2004. *Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks*. Budapest, Hungary: Nayang Avenue.
- Kartono, K., 1999. *Patologi Sosial*. Jakarta: Raja Grafindo Persada.
- Kusumadewi, S., 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta: Graha Ilmu.
- Mahdiyah, U., Irawan, M. I. & Imah, E. M., 2015. Study Comparison Backpropagation, Support Vector Machine, And Extreme Learning Machine For Bioinformatics Data. *Ilmu Komputer dan Informasi*, pp. 53-59.
- Mendome, K., Nainggolan, N. & Kekenusa, J., 2016. Penerapan Model ARIMA dalam Memprediksi Jumlah Tindak Kriminalitas di Wilayah POLRESTA Manado Provinsi

Sulawesi Utara. *Jurnal MIPA UNSRAT*,
Volume 5(2), p. 114.

Siang, J. J., 2009. *Jaringan Syaraf Tiruan dan
Pemrogramannya Menggunakan Matlab*.
Yogyakarta: Andi.