

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pasien adalah orang yang memiliki kelemahan fisik atau mentalnya kemudian menyerahkan pengawasan dan perawatannya, menerima dan mengikuti pengobatan yang ditetapkan oleh tenaga kesehatan atau para medis yang berada pada rumah sakit. Rumah sakit merupakan institusi yang menyelenggarakan pelayanan kesehatan perorangan yang menyediakan pelayanan salah satunya rawat inap. Rumah Sakit Umum Daerah (RSUD) Dr. H. Moh. Anwar Kabupaten Sumenep adalah badan pelayanan kesehatan milik pemerintah yang memberikan pelayanan kesehatan bagi masyarakat Kabupaten Sumenep.

Ketersediaan sumber daya merupakan faktor penting yang harus diperhatikan, karena kurangnya sumber daya dapat mengurangi kepedulian dan kualitas pelayanan terhadap pasien. Sumber daya yang ada khususnya sumber daya material harus dipersiapkan atau direncanakan untuk menjaga kualitas dari pelayanan pihak rumah sakit. Saat ini pihak Rumah Sakit RSUD Dr. H. Moh. Anwar Kabupaten Sumenep sering mengalami kesulitan dalam melakukan persiapan dan perencanaan. Ketidakpastian jumlah Pasien rawat inap di masa mendatang pada RSUD Dr. H. Moh. Anwar Kabupaten Sumenep menyebabkan pihak perencanaan kesulitan untuk memprediksi berapa jumlah pasien yang akan datang sehingga sering terjadi sumber daya yang telah di sediakan tidak sesuai dengan yang dibutuhkan.

Pada Penelitian sebelumnya Nabillah Dewi, Imam Cholissodin, Edy Santoso memecahkan permasalahan prediksi dengan menerapkan metode *Extreame Learning Machine* yaitu mengenai Prediksi Jumlah Kriminalitas di Kabupaten Probolinggo dengan data tahun 2012 hingga 2017 diperoleh arsitektur jaringan maksimum yaitu jumlah fitur sebanyak 7, dengan rasio perbandingan 80%:20%, dan jumlah *neuron* pada *hidden layer* sebanyak 7 serta aktivasi *sigmoid biner*. Nilai *error* yang rendah dihitung menggunakan tingkat kesalahan *Mean Square Error* yaitu sebesar 0,037662[1].

Pada Penelitian yang dilakukan oleh Rio Bayu Afrianto, Handayani Tjandrasa, dan Isye Ariesianti menggunakan metode *Backpropagation* dalam prediksi

pergerakan harga saham. Pada penelitian ini didapatkan hasil yang kurang baik. Hal ini terbukti dengan hasil RMSE yang didapatkan minimal sebesar 0.22 dan akurasi terbaik sebesar 62.18. [2].

Penelitian terkait juga dilakukan oleh Mladenovic dkk. Yang membahas tentang prediksi pertumbuhan ekonomi berdasarkan perdagangan, *impor* dan *ekspor* yang menghasilkan tingkat prediksi pada *Extreme Learning Machine* dengan nilai RMSE 0.4289 lebih tinggi dibandingkan dengan algoritma *Back Propagation* dengan nilai RMSE 1.2883[3].

Oleh Karena itu, penulis melakukan penelitian untuk memprediksi jumlah pasien rawat inap menggunakan metode *Extreme Learning Machine* dengan harapan dapat menjadi solusi dari permasalahan RSUD Dr. H. Moh Anwar Kabupaten Sumenep.

1.2 Perumusan Masalah

Ada 3 poin penting di dalam perumusan masalah, yaitu apa masalahnya, apa solusi yang digagas pada pertanyaan penelitiannya.

1.2.1 Masalah Penelitian

Ketidakpastian jumlah pasien rawat inap di masa mendatang pada RSUD Dr. H. Moh. Anwar Kabupaten Sumenep menyebabkan pihak perencanaan kesulitan untuk memprediksi berapa jumlah pasien yang akan datang sehingga sering terjadi sumber daya yang telah disediakan tidak sesuai dengan yang dibutuhkan.

1.2.2 Metode Usulan

Diusulkan menggunakan metode *Extreme Learning Machine*. Pemilihan Metode *Extreme Learning Machine* untuk mendapatkan komputasi yang cepat.

1.2.3 Pertanyaan Penelitian

Berdasarkan permasalahan dan metode yang telah dijelaskan di atas, didapatkan pertanyaan yaitu bagaimana tingkat *error* yang dihasilkan metode *Extreme Learning Machine* pada prediksi jumlah pasien rawat inap?

1.3 Tujuan Dan Manfaat

1.3.1 Tujuan Penelitian

Mengacu pada latar belakang serta rumusan masalah di atas maka tujuan dari penelitian ini adalah untuk memprediksi jumlah pasien rawat inap menggunakan metode *Extreme Learning Machine*.

1.3.2 Manfaat

Hasil dari penelitian ini dapat membantu pihak rumah sakit dalam melakukan persiapan dan perencanaan mengenai sumber daya yang terdapat pada RSUD Dr. H. Moh. Anwar Kabupaten Sumenep

1.4 Batasan - Batasan

Batasan masalah sebagai berikut :

1. Data yang digunakan adalah data RSUD Dr. H. Moh Anwar Kabupaten Sumenep
2. Data yang digunakan merupakan data pasien rawat inap
3. Data yang digunakan adalah data pasien rawat inap setiap hari pada tahun 2019 (365 Data) data diambil per tanggal 12 Januari 2020

1.5 Sistematika Skripsi

Sistematika penulisan buku dalam skripsi ini adalah sebagai berikut :

BAB I : PENDAHULUAN

Pada bab ini menjelaskan tentang latar belakang penelitian, perumusan masalah, tujuan, manfaat, metode penelitian, serta sistematika penulisan.

BAB II : STUDI PUSTAKA

Bab ini membahas mengenai landasan semua teori yang digunakan dalam penyusunan dan pembuatan penelitian.

BAB III : ANALISA DAN PERANCANGAN SISTEM

Pada bab ini menjelaskan tentang rancangan sistem dan keseluruhan sistem yang dibuat beserta rancangan alur flowchart pada tiap-tiap proses sistem.

BAB IV : IMPLEMENTASI SISTEM

Meliputi hasil yang telah dicapai dari penelitian ini dan implementasi sistem berdasarkan perancangan, sehingga dapat ditarik suatu kesimpulan.

BAB V : PENUTUP

Pada bab penutup ini menjelaskan tentang kesimpulan dari hasil uji coba yang telah dilakukan serta saran yang menjadi masukan dalam pengembangan penelitian berikutnya.

BAB II

TINJAUAN PUSTAKA

2.1 Prediksi


Prediksi adalah suatu proses memperkirakan secara sistematis tentang sesuatu yang mungkin terjadi di masa yang akan datang berdasarkan informasi masa lalu maupun data atau sumber informasi sekarang yang dimiliki, agar kesalahannya dapat diperkecil maka 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. [1]

Pengertian prediksi sama dengan ramalan atau perkiraan. Menurut kamus besar bahasa Indonesia, prediksi adalah hasil dari kegiatan memprediksi atau meramal atau memperkirakan nilai pada masa yang akan datang dengan menggunakan data masa lalu. Prediksi menunjukkan apa yang akan terjadi pada suatu keadaan tertentu dan merupakan *input* bagi proses perencanaan dan pengambilan keputusan.

Dilihat dari cara memperolehnya, peramalan dapat menggunakan cara kualitatif dan cara kuantitatif. Pada dasarnya, teknik kualitatif lebih menitik beratkan intuisi atau pendapat para pakar sehingga cara ini sering disebut teknik intuisi (*judgemental technique*). Sedangkan metode peramalan secara kuantitatif berdasarkan pada metode-metode matematik. Dalam prakteknya, teknik kualitatif dan teknik kuantitatif sering digunakan secara beriringan dan saling menunjang. Prediksi jumlah pasien adalah suatu proses memperkirakan secara sistematis jumlah pasien pada waktu yang akan datang berdasarkan data yang diperoleh pada saat itu dengan pertimbangan data masa lalu. Waktu yang dimaksud disini dapat dipresentasikan sebagai (jam, hari, minggu, bulan, tahun). Tetapi pada penelitian ini jangka waktu yang digunakan adalah hari, karena untuk meningkatkan akurasi prediksi.

2.2 Arsitektur Jaringan Saraf Tiruan

Jaringan Saraf Tiruan (JST) atau disebut juga *artificial neural network* memiliki perbedaan pendekatan dari pada metode AI umumnya. Dari struktur otak manusia metode ini didapatkan yaitu melihat cara kerja syaraf otak manusia sehingga dapat diimplementasikan menggunakan pemrograman komputer yang mampu menyelesaikan beberapa proses perhitungan sekaligus ketika proses pembelajaran berjalan.[4] Dalam JST ini sama seperti otak manusia yang memiliki beberapa *neuron* yang saling memiliki hubungan satu-sama lain. *Neuron-neuron* tersebut mentransfer informasi- informasi yang diterima oleh satu neuron ke *neuron* yang lain. Informasi yang dibawa oleh *neuron* tersebut disimpan pada suatu nilai tertentu yang disebut bobot.[5] Pada umumnya arsitektur JST dibagi beberapa *layer*, yaitu *input layer* (masukan), *hidden layer* (tersembunyi), dan *output layer* (hasil keluaran). Masing-masing lapisan memiliki jumlah *neuron* yang berbeda. Arsitektur JST digambarkan sesuai dengan gambar berikut:



Gambar 2.1 Gambar Jaringan Syaraf Tiruan

Pada jaringan syaraf, *neuron-neuron* dikumpulkan dalam lapisan-lapisan (*layer*) yang disebut dengan lapisan *neuron*. Terdiri dari 3 lapisan yaitu lapisan *input*, lapisan tersembunyi dan lapisan *output*

2.3 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang digunakan pada jaringan saraf untuk mengaktifkan atau tidak mengaktifkan *neuron*. Karakteristik yang harus dimiliki oleh fungsi aktivasi jaringan perambatan balik antara lain harus kontinu,

terdiferensialkan, dan tidak menurun secara monotonis (*monotonically non-decreasing*)[6]. Lebih lanjut, untuk efisiensi komputasi, turunan fungsi tersebut mudah didapatkan dan nilai turunannya dapat dinyatakan dengan fungsi aktivasi itu sendiri. Fungsi aktivasi yang dianalisis adalah *sigmoid biner* dan *sigmoid bipolar*.

Fungsi aktivasi *sigmoid biner* memiliki nilai pada range 0 sampai 1. Ditunjukkan dengan persamaan berikut:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

Fungsi aktivasi *sigmoid bipolar* hampir sama dengan fungsi *sigmoid biner*, hanya saja *output* dari fungsi ini memiliki range antara 1 sampai -1, didefinisikan dengan persamaan sebagai berikut :

$$f(x) = \frac{1+e^{-x}}{(1+e^{-x})} \quad (2.2)$$


2.4 Epoch

Epoch menandakan satu siklus algoritma *machine learning* ‘belajar’ dari seluruh set data *training*. Satu *epoch* berarti sebuah algoritma *machine learning* telah ‘belajar’ dari data *training* secara keseluruhan. Dalam jaringan saraf tiruan, proses pembelajaran yang berulang-ulang bertujuan untuk mencapai konvergensi nilai bobot. Karena nilai *epoch* yang sesuai tidak bisa diketahui, maka pada penelitian ini diujikan beberapa nilai *epoch* untuk mencapai nilai akurasi yang optimum.[7]

2.5 Algoritma *Extreme Learning Machine*

Extreme Learning Machine merupakan salah satu metode pelatihan yang termasuk pada jaringan saraf tiruan dan termasuk metode pelatihan terawasi. Metode-metode JST yang telah ada memiliki kelemahan dalam hal *learning speed* karena semua parameter pada jaringan di tentukan secara *iterative* dengan menggunakan suatu metode pembelajaran. Parameter yang dimaksud adalah bobot *input* dan bias yang menghubungkan antara *layer* satu dengan *layer* yang lain. Pada metode ELM, bobot *input* dan bias mula mula ditentukan akhir menggunakan *Moore-Penrose Generalized Invers*. Matriks yang digunakan dalam perhitungan bobot akhir adalah matriks yang beranggotakan jumlah atau keluaran masing-

masing *input* ke *layer* tersembunyi. Sehingga ELM memiliki *learning speed* yang cepat.[8]



Gambar 2.2 Gambar Struktur Metode *Extreme Learning Machine*

Langkah-langkah perhitungan dengan metode *Extreme Learning Machine* yaitu :

1. Pembagian data *training* dan data *testing*
2. Desain Arsitektur jaringan : Arsitektur jaringan yang akan digunakan terdiri dari 3 *layer* yaitu *input layer*, *hidden layer* dan *output layer*.
3. Normalisasi Data

Proses perhitungan perubahan *value* pada suatu nilai atau data khusus dalam rentang *value* yang khusus pula disebut dengan normalisasi data. Proses ini dilakukan apabila terjadi rentang atau jarak nilai masukan tidak sama. Proses untuk mendapatkan suatu nilai normalisasi yang kecil harus mengubah masukan data menjadi nilai keluaran yang kecil. *Min-Max Normalization* digunakan dalam proses normalisasi data ini. Metode ini tentu saja mempunyai kelebihan yaitu seimbang data setelah normalisasi dan sebelum dilakukan normalisasi[9]. Persamaan untuk normalisasi data.

$$x = \frac{0.8 * (x_p - \min(x_p))}{(\max(x_p) - \min(x_p))} + 0.1 \quad (2.3)$$

Dimana : x_p = data sebelum di normalisasi
 x = data hasil keluaran
 $\min(x_p)$ = dataset dengan nilai terkecil
 $\max(x_p)$ = dataset dengan nilai terbesar

4. Proses Pelatihan (*Training*)

Proses *training* dilakukan untuk memperoleh *output weight* optimal atau memiliki tingkat kesalahan yang rendah. Tujuan dari proses *training* yaitu untuk mengembangkan model ELM. Berikut langkah-langkah *training* yang diproses sebagai berikut:

- Langkah 1 : Inisialisasi *input weight* dan *bias* yang diinisialisasi secara acak dengan menggunakan fungsi aktivasi *sigmoid biner* rentang [0,1]
- Langkah 2 : Jika kondisi penghentian belum terpenuhi, maka lakukan langkah 3 sampai langkah 7

Fase I : Propagasi Maju (*feedforward*)

- Langkah 3 : Setiap unit *input* ($x_1, \dots, x_n$) menerima sinyal input dan meneruskan sinyal tersebut pada seluruh unit lapisan di atasnya (unit *hidden*).
- Langkah 4 : Keluaran di *hidden layer* dihitung menggunakan fungsi aktivasi. Pada langkah pertama ini dihitung keluaran *hidden layer*

$$G(w_i, x_i, b_i) = (\sum_{k=1}^n w_i x_i + b_i) \quad (2.4)$$

Dimana : $G(w_i, x_i, b_i)$ = Hasil *output* dari *hidden layer*
 x = Data *training*
 w = bobot *input*
 b = nilai bias

Selanjutnya hitung *output* dari lapisan dengan fungsi aktivasi *sigmoid biner*:

$$F(x) = \frac{1}{1 + e^{-G(w_i, x_i, b_i)}} \quad (2.5)$$

- Langkah 5 : Menghitung matriks H dengan ukuran $n \times m$.

$$H = \begin{pmatrix} g(w_{11}x_1 + b_1) & g(w_{12}x_1 + b_2) & g(w_{13}x_1 + b_3) & g(w_{14}x_1 + b_4) & g(w_{15}x_1 + b_5) & g(w_{16}x_1 + b_6) \\ g(w_{21}x_2 + b_1) & g(w_{22}x_2 + b_2) & g(w_{23}x_2 + b_3) & g(w_{24}x_2 + b_4) & g(w_{25}x_2 + b_5) & g(w_{26}x_2 + b_6) \\ g(w_{31}x_3 + b_1) & g(w_{32}x_3 + b_2) & g(w_{33}x_3 + b_3) & g(w_{34}x_3 + b_4) & g(w_{35}x_3 + b_5) & g(w_{36}x_3 + b_6) \\ g(w_{41}x_4 + b_1) & g(w_{42}x_4 + b_2) & g(w_{43}x_4 + b_3) & g(w_{44}x_4 + b_4) & g(w_{45}x_4 + b_5) & g(w_{46}x_4 + b_6) \\ g(w_{51}x_5 + b_1) & g(w_{52}x_5 + b_2) & g(w_{53}x_5 + b_3) & g(w_{54}x_5 + b_4) & g(w_{55}x_5 + b_5) & g(w_{56}x_5 + b_6) \\ g(w_{61}x_6 + b_1) & g(w_{62}x_6 + b_2) & g(w_{63}x_6 + b_3) & g(w_{64}x_6 + b_4) & g(w_{65}x_6 + b_5) & g(w_{66}x_6 + b_6) \end{pmatrix}$$

Setelah mendapatkan matriks H dengan ukuran $n \times m$, selanjutnya hitung H^+ yang merupakan matriks *Moore-Penrose generalized Invers* dari matriks H yang akan digunakan pada pencarian nilai bobot antara *hidden layer* dan *output layer*, persamaan H^+ sebagai berikut:

$$H^+ = (H^T H)^{-1} H^T \quad (2.6)$$

Dimana : H^+ = matriks *Moore Penrose*

H = matriks fungsi aktivasi *sigmoid*

H^T = matriks transpose fungsi aktivasi *sigmoid*

$(H^T H)^{-1} H^T$ = matriks *inverse* perkalian antara *output layer* menggunakan fungsi aktivasi dengan transpose H

Kemudian mencari nilai bobot ke *output layer* (β)

$$\beta = H^+ t_i \quad (2.7)$$

Dimana : β = Hasil matriks dari *output weight*

H^+ = Hasil matriks dari *moore-penrose pseudo invers*

t_i = target dari proses *training*.

f. Langkah 6 : Menghitung nilai *output* dengan menggunakan persamaan:

$$y = g(x) \cdot \beta \quad (2.8)$$

Dimana : y = matriks dari *output layer*

$g(x)$ = Matriks dari *output hidden layer* yang sudah di hitung dengan fungsi aktivasi

β = Matriks dari *output weight*

Langkah 7 : Menghitung nilai *Error* disetiap unit *output*

$$E = \|y - t_j\| \quad (2.9)$$

Dimana : E = Nilai *Error*

y = matriks dari *output layer*

t_j = nilai target

Fase II : Perubahan bobot dan bias

g. Langkah 8 : menghitung penjumlahan kesalahan pada *hidden layer* (δ_{net_j})

$$(\delta_{net_j}) = E * \beta \quad (2.10)$$

Dimana : δ_{net_j} = kesalahan pada *hidden layer*

E = Nilai *Error*

B = Matriks dari *output weight*

Menghitung faktor kesalahan pada *hidden layer* (δ_j)

$$\delta_j = \delta_{net_1} \cdot g(x_1) (1 - g(x_1)) \quad (2.11)$$

Dimana : δ_j = faktor kesalahan *hidden layer*

δ_{net_j} = kesalahan pada *hidden layer*

$g(x_1)$ = Matriks dari *output hidden layer* yang sudah di hitung dengan fungsi aktivasi

Menghitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit tersembunyi (*hidden*)

$$W_{j(\text{baru})} = W_{j(\text{lama})} + \alpha \delta_j x_i \quad (2.12)$$

Dimana : $W_{j(\text{baru})}$ = Nilai Bobot Baru

$W_{j(\text{lama})}$ = Nilai Bobot Lama

α = *learning rate*

δ_j = faktor kesalahan pada *hidden layer*

x_i = nilai *input*

h. Langkah 9 : Memeriksa kondisi penghentian, iterasi yang ada proses *training* akan berhenti jika iterasi = iterasi maksimal yang di inginkan

i. Langkah 10 : Simpan bobot dan bias optimal atau sesuai.

5. Denormalisasi data

Denormalisasi data penting untuk dilakukan agar data hasil prediksi dengan jaringan syaraf ELM dapat dilihat secara mudah dalam nilai yang sama dengan asalnya untuk interval [0,1] menggunakan persamaan berikut :

$$x = \frac{(x_p - 0.1)(\max\{x_p\} - \min\{x_p\})}{0.8} + \min\{x_p\} \quad (2.13)$$

2.6 Evaluasi

Hasil yang dikeluarkan pada lapisan *output* akan dibandingkan dengan nilai target dan dihitung menggunakan *Mean Square Error*.. Proses perhitungan akan berhenti jika sudah mencapai *epoch* maksimal[10].

Rumus untuk menghitung:

$$MSE = \sum_{t=1}^n \frac{(X_t - F_t)^2}{n} \quad (2.14)$$

Dimana : X_t = Nilai Aktual

F_t = Nilai Prediksi

n = banyaknya data

2.7 Penelitian Terkait

Penelitian yang dilakukan oleh Nabilah Dewi, dkk bertujuan untuk memperoleh prediksi jumlah kriminalitas menggunakan *Extreme Learning Machine*. Berdasarkan implementasi dan pengujian yang dilakukan menggunakan data kriminalitas Polres Kabupaten Probolinggo tahun 2012 hingga 2017, diperoleh jumlah fitur sebanyak 7 serta fungsi aktivasi *sigmoid biner*. Nilai *error* yang rendah dihitung menggunakan tingkat kesalahan *Mean Square Error* yaitu sebesar 0,037662.[1]

Penelitian lain yang dilakukan oleh Anneta Shifa Ichwani dan Helmie Arif Wibawa untuk prediksi angka kejadian Demam Berdarah Dengue (DBD). Berdasarkan Faktor Cuaca Menggunakan Metode *Extreme Learning Machine* (Studi Kasus Kecamatan Tembalang). Hasil penelitian menunjukkan bahwa model ELM dapat menghasilkan MSE pengujian terendah sebesar 0,0116 dan waktu pelatihan kurang dari 1 detik.[11]

Penelitian yang dilakukan oleh Raditya Lucky Riswanto, dkk bertujuan untuk prediksi jumlah penderita penyakit demam berdarah di kota Semarang menggunakan jaringan syaraf tiruan *Backpropagation*. Arsitektur *Backpropagation* menggunakan dua belas *neuron layer input*, satu *layer* tersembunyi dengan jumlah *neuron* yang dapat diubah-ubah dan satu *neuron* pada *layer output*. Pengujian menghasilkan MAPE terkecil yaitu 4,48 pada alfa 0,7 dan jumlah *neuron* tersembunyi sebanyak 50 *neuron* dengan nilai akurasi 95,52%.[12]

Penelitian selanjutnya dilakukan oleh Adyan Nur Alfiyatin, dkk. Pada penelitian ini dilakukan pengujian menggunakan metode *Extreme Learning Machine* mendapatkan nilai kesalahan sebesar 0.0202008, lebih kecil dibandingkan dengan metode *backpropogation* sebesar 1.16035821. Hal tersebut membuktikan bahwa metode ELM sangat cocok digunakan untuk prediksi.[13]

Penelitian lain yang dilakukan oleh Nirza Maulidya Ashar, dkk. Pada penelitian ini dilakukan pengujian menggunakan 7 *hidden neuron*, 5 fitur, dan persentase perbandingan 80% data *training* 20% data *testing* menghasilkan hasil MSE sebesar 0.00372 dengan selisih $\pm 1\%$ dari data aktual untuk memprediksi jumlah produksi pipa yang layak pada PT. KHI Pipe Indonesia menggunakan metode *Extreme Learning Machine*. [14]

Penelitian selanjutnya dilakukan oleh Svetlana Sokov-Mladenovic, dkk. Pada penelitian ini dilakukan perbandingan akurasi antara metode *Backpropagation* dengan *Extreme Learning Machine* untuk memprediksi pertumbuhan ekonomi berdasarkan jasa *ekspor* dan *impor* barang, jasa perdagangan barang terhadap pertumbuhan ekonomi. Sehingga didapatkan nilai akurasi menggunakan RMSE 0.4289 untuk metode *Extreme Learning Machine* dan 1.2883 untuk metode *Backpropagation*. [3]

Tabel 2.1 Penelitian Terkait

Peneliti, Tahun	Metode/kasus	Kelebihan	Kekurangan
Nabillah Dewi, Imam Cholissodin, Edy Santoso 2018	Prediksi Jumlah Kriminalitas Menggunakan <i>Extreme Learning Machine</i>	Menggunakan arsitektur yang maksimum yaitu jumlah fitur sebanyak 7, perbandingan rasio data 80%:20%, jumlah neuron pada <i>hidden layer</i>	Pada peneitian ini hanya menggunakan satu parameter saja, sehingga disarankan untuk mendampah parameter lain seperti faktor-

		sebanyak 7 dan fungsi aktivasi <i>sigmoid biner</i> mendapatkan Nilai <i>Mean Square Error (MSE)</i> terendah sebesar 0,037662	faktor dalam jumlah kriminalitas untuk menghasilkan prediksi yang lebih objektif.
Anneta Shifa Ichwani, He Imie Arif Wibawa 2019	Prediksi Angka Kejadian Demam Berdarah Dengue (DBD) Berdasarkan Faktor Cuaca Menggunakan <i>Extreme Learning Machine</i>	Memiliki nilai MSE sebesar 0,0116 pada <i>n</i> split 13 dan jumlah <i>layer</i> tersembunyi sebanyak 6 serta waktu pelatihan yang kurang dari 1 detik	Dalam penelitian ini, digunakan tiga prediktor cuaca, yaitu suhu udara, kelembapan, dan curah hujan serta angka kejadian demam berdarah
Raditya Lucky Riswanto 2014	Prediksi jumlah penderita penyakit demam berdarah di kota Semarang menggunakan jaringan syaraf tiruan <i>Backpropagation</i>	Pengujian menghasilkan MAPE terkecil yaitu 4.48 pada alfa 0.7 dan jumlah <i>neuron</i> tersembunyi sebanyak 50 <i>neuron</i> dengan nilai akurasi 95.52 persen.	Pelatihan Jaringan Syaraf Tiruan <i>Backpropagation</i> menunjukkan dua pelatihan paling cepat dengan durasi waktu 19 menit yang tergolong lama

Adyan Nur Alfiyatin 2019	Penerapan <i>Extreme Learning Machine</i> untuk peramalan laju inflasi di indonesia	Pada penelitian ini dilakukan pengujian menggunakan metode <i>Extreme Learning Machine</i> mendapatkan nilai kesalahan sebesar 0.0202008, lebih kecil dibandingkan dengan metode <i>backpropogation</i> sebesar 1.16035821. Hal tersebut membuktikan bahwa metode ELM sangat cocok digunakan untuk prediksi.	Penentuan jumlah neuron pada <i>hidden layer</i> masih harus manual oleh sebab itu peneliti menyarankan untuk menggunakan metode optimasi dengan tujuan untuk membuat kinerja ELM lebih efektif dan efisien
Nirza Maulidya Ashar, dkk 2018	Memprediksi jumlah produksi pipa yang layak pada PT. KHI Pipe Indonesia menggunakan metode <i>Extreme Learning Machine</i>	Menghasilkan hasil MSE sebesar 0.00372 dengan selisih $\pm 1\%$ dari data aktual	Diharapkan digabungkan dengan metode optimasi untuk memperoleh hasil prediksi yang lebih optimal

Sokov-Mladenovic, dkk. 2016	<i>Economic growth forecasting by artificial neural network with extreme learning machine based on trade, import and export parameter</i>	Hasil simulasi mengungkapkan bahwa model JST dengan algoritma pembelajaran ELM mampu memprediksi PDB dengan baik. Algoritma ELM dapat digunakan secara efektif dalam aplikasi PDB dan khususnya dalam estimasi PDB.	
--------------------------------	---	---	--