

Prediksi Penjualan Seblak menggunakan Algoritme *Extreme Learning Machine* di Seblak Malabar

Fadhilillah Ikhsan¹, Budi Darma Setiawan², Tibyani³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹fadhilillahikhsan@gmail.com, ²s.budidarma@ub.ac.id, ³tibyani@ub.ac.id

Abstrak

Seblak Malabar merupakan salah satu bisnis di Kota Malang yang bergerak di bidang makanan. Keunikan cita rasa yang khas dan keanekaragaman variasi menu yang berbeda-beda membuat makanan tersebut diminati oleh banyak pelanggan. Namun, karena pengaruh dari beberapa faktor, seperti perubahan cuaca dan persaingan pasar yang semakin ketat, membuat penjualan Seblak Malabar mengalami fluktuasi. Hal tersebut menimbulkan beberapa permasalahan baru, yaitu permasalahan dalam memaksimalkan keuntungan dan menjaga stabilitas bahan baku. Dari beberapa permasalahan tersebut, prediksi penjualan yang akan datang merupakan solusi yang diusulkan peneliti karena memiliki peran yang sangat penting dalam mengambil suatu keputusan. Data yang digunakan untuk prediksi penjualan mengacu pada data penjualan sebelumnya. Data tersebut bersifat *time series* karena disusun berdasarkan waktu. Prediksi data *time series* merupakan permasalahan yang sangat kompleks sehingga dibutuhkan suatu metode yang mampu menghasilkan prediksi berdasarkan pergerakan pola data sebelumnya. Algoritme *Extreme Learning Machine* (ELM) pada Jaringan Saraf Tiruan (JST) *feedforward network* diusulkan peneliti karena memiliki kinerja yang sangat baik dalam memprediksi data yang bersifat *time series*. Dari hasil penelitian yang dilakukan, algoritme ELM mampu menghasilkan *Mean Average Percentage Error* (MAPE) sebesar 1,7548%. Hasil MAPE yang kurang dari 10% menunjukkan bahwa algoritme ELM dapat digunakan untuk prediksi penjualan Seblak Malabar.

Kata kunci: prediksi penjualan, *time series*, Jaringan Saraf Tiruan, *Extreme Learning Machine*, *Mean Average Percentage Error*

Abstract

Seblak Malabar is a business in Malang running on food sector. The typical uniqueness of flavor and the diversity of menu which make the food attract many customers. However, because of the impact of some factors, such as weather change and tighter market trend, makes Seblak sale run into the fluctuation. It makes some new problems; those are problem in maximizing the profit and maintaining the stability of logistics. From those problems, the upcoming selling prediction is a solution offered by the researcher because it has an important role to make a decision. The data used for this prediction refers to the previous sale data. That data is time series because it is arranged based on the time. Time series data prediction is very complex problem so that it is needed a method which is able to produce a prediction based on previous data pattern movement. Extreme Learning Machine Algorithm in Artificial Neural Network (ANN) feedforward network is suggested by the researcher because it has very good performance in predicting time series data. From the research conducted, ELM algorithm is able to produce Mean Average Percentage Error (MAPE) up to 1.7548%. MAPE score less than 10% indicates that ELM algorithm can be used to predict the sale of Seblak Malabar.

Keywords: sale prediction, *time series*, Artificial Neural Network, *Extreme Learning Machine*, *Mean Average Percentage Error*

1. PENDAHULUAN

Seblak Malabar merupakan seblak pertama yang ada di Kota Malang. Usaha ini mulai

berdiri pada tahun 2015 oleh alumni mahasiswa Universitas Brawijaya Fakultas Perikanan dan Ilmu Kelautan Angkatan 2013. Keunikan dari Seblak Malabar, yaitu memiliki cita rasa yang khas dan keanekaragaman variasi makanan yang

berbeda-beda. Aneka ragam *topping* yang digunakan menjadi pembeda Seblak Malabar dengan seblak lainnya sekaligus menjadi andalan bagi Seblak Malabar untuk menarik banyaknya pelanggan. Namun, karena dipengaruhi oleh beberapa faktor yang terjadi, seperti perubahan cuaca dan persaingan pasar yang semakin ketat, membuat penjualan Seblak Malabar mengalami fluktuasi. Hal tersebut menimbulkan beberapa permasalahan baru, yaitu permasalahan dalam memaksimalkan keuntungan, mengatur jumlah produksi bumbu seblak, menjaga stabilitas bahan baku, dan merancang strategi pemasaran yang tepat untuk meningkatkan jumlah penjualan.

Dari beberapa masalah tersebut, prediksi penjualan yang akan datang merupakan solusi yang diusulkan peneliti karena memiliki peran yang sangat penting untuk mengambil suatu keputusan. Dengan melakukan prediksi penjualan yang akan datang, maka produksi bumbu seblak yang dihasilkan dapat lebih optimal karena mampu menyesuaikan dengan banyaknya porsi seblak yang akan terjual. Jika hal ini terjadi, maka keuntungan yang didapatkan dari hasil penjualan akan lebih maksimal dan kualitas dari produksi bumbu seblak tetap terjaga. Kemudian, prediksi penjualan juga dirasakan pada bagian logistik dimana stok bahan baku akan tetap terjaga sehingga tidak mengganggu proses produksi bumbu seblak. Selain itu, prediksi penjualan juga dirasakan pada bagian *marketing* dimana strategi pemasaran akan menjadi lebih akurat jika strategi ini dirancang menggunakan data yang dapat dijadikan sebagai acuan. Prediksi penjualan yang akan datang menentukan strategi pemasaran yang akan dilakukan.

Prediksi penjualan mengacu pada data penjualan sebelumnya. Data tersebut bersifat *time series* karena disusun berdasarkan waktu. Prediksi data *time series* merupakan permasalahan yang sangat kompleks (Singh & Balasundaram, 2007) sehingga dibutuhkan suatu metode yang mampu menghasilkan prediksi berdasarkan pergerakan pola data sebelumnya. Algoritme ELM pada Jaringan Saraf Tiruan (JST) *feedforward network* diusulkan peneliti karena memiliki kinerja yang sangat baik dalam memprediksi data yang bersifat *time series* (Singh & Balasundaram, 2007). Algoritme ELM juga memiliki kecepatan pembelajaran yang sangat cepat dan mampu menghasilkan prediksi dengan akurasi sebaik algoritme lainnya (Wang, et al., 2008). Hal tersebut telah dilakukan uji

coba pada penelitian prediksi pergerakan laju kapal yang membandingkan algoritme ELM dengan algoritme *Backpropagation Neural Network* (BPNN). Dari hasil penelitian tersebut, algoritme ELM menghasilkan nilai *Mean Square Error* (MSE) sebesar $3,3847e-004$ dengan waktu komputasi yang dibutuhkan sebanyak $0,0677$ seconds, sedangkan algoritme BPNN menghasilkan nilai MSE sebesar $0,0210$ dengan waktu komputasi yang dibutuhkan sebanyak $0,4577$ seconds. Hasil tersebut menunjukkan bahwa tingkat kesalahan dan waktu komputasi yang dihasilkan algoritme ELM lebih baik daripada algoritme BPNN (Huixuan, Yuchao & Zhang, 2015). Selain itu, terdapat penelitian lain yang menggunakan algoritme ELM untuk melakukan prediksi penjualan, yaitu prediksi penjualan mie pada studi kasus Kober Mie Setan Malang. Hasil dari penelitian tersebut menghasilkan nilai MSE sebesar $0,0171$. Nilai MSE kurang dari 10% menunjukkan bahwa algoritme ini cukup bagus untuk melakukan prediksi penjualan (Giusti, Widodo, & Adinugroho, 2018).

Berdasarkan hasil penelitian sebelumnya, algoritme ELM digunakan oleh peneliti sebagai solusi dalam menyelesaikan permasalahan yang terjadi di Seblak Malabar. Penelitian ini diharapkan dapat dijadikan sebagai alat bantu untuk mengontrol produksi bumbu seblak, persiapan bahan baku, dan merancang strategi pemasaran yang tepat pada usaha Seblak Malabar.

2. DASAR TEORI

2.1. Prediksi

Prediksi memiliki peran yang sangat penting untuk menentukan hasil yang terkait pada sebuah peristiwa yang akan terjadi sehingga dapat disiapkan dengan baik (Mosabeth, Furqon, & Wihandika). Prediksi yang dilakukan pada penelitian ini termasuk dalam prediksi jangka pendek karena prediksi hanya dapat dilakukan untuk satu hari ke depan.

2.2. Seblak Malabar

Seblak Malabar merupakan seblak pertama yang ada di Kota Malang. Seblak Malabar memiliki cita rasa yang khas dan keanekaragaman variasi makanan yang berbeda-beda. Variasi makanan pada Seblak Malabar terdiri dari empat paket. Setiap paket memiliki cita rasa yang sama. Namun, yang

membedakan adalah jenis *topping*-nya. Umumnya bahan utama Seblak Malabar terdiri atas kerupuk basah, kwitaw, mie, dan telur. Jika ingin bervariasi, kita dapat memesan *topping* sesuai dengan keinginan. Aneka ragam *topping* yang digunakan menjadi andalan Seblak Malabar untuk menarik banyaknya pelanggan.

2.3. Fungsi Aktivasi

Fungsi aktivasi ditugaskan untuk memproses sebuah *input neuron* yang masuk kemudian menentukan *output* berdasarkan *input neuron* tersebut dan meneruskannya kepada *output neuron*. Pada dasarnya, fungsi aktivasi terbagi menjadi dua jenis, yaitu fungsi aktivasi *linear* dan *nonlinear*. Karena penelitian ini menggunakan data acak, maka jenis fungsi aktivasi yang dapat digunakan adalah fungsi aktivasi *nonlinear*. Jenis fungsi aktivasi ini mampu mengenali bentuk variasi data sehingga cocok untuk menghitung nilai yang tidak dapat dipastikan, seperti prediksi. Berikut beberapa macam fungsi aktivasi *nonlinear* (Srimuang & Intarasothonchun, 2015).

1. Fungsi Sigmoid Biner

Perhitungan fungsi *sigmoid biner* ditunjukkan pada Persamaan (1).

$$H = \frac{1}{1 + \exp(-H_{init})} \quad (1)$$

2. Fungsi Sine

Perhitungan fungsi *sine* ditunjukkan pada Persamaan (2).

$$H = \sin(x) \quad (2)$$

3. Fungsi Sigmoid Bipolar

Perhitungan fungsi *sigmoid bipolar* ditunjukkan pada Persamaan (3).

$$H = \frac{1 - \exp(-H_{init})}{1 + \exp(-H_{init})} \quad (3)$$

Keterangan:

- H = Output pada fungsi aktivasi
- exp = Basis bilangan logaritma atau biasa disebut dengan bilangan *euler*, bilangan ini memiliki nilai pembulatan sebesar 2,71828183
- H_{init} = Input pada fungsi aktivasi
- $\sin(x)$ = Fungsi *sin* dengan *input* x

2.4. Normalisasi Data

Normalisasi data digunakan untuk mengurangi rentang data pada data yang

mempunyai perbedaan nilai yang jauh dengan nilai lainnya. *Min-Max Normalization* merupakan salah satu perhitungan normalisasi data yang digunakan untuk mengatasi perbedaan nilai pada data yang sangat bervariasi. Perhitungan normalisasi data untuk *Min-Max Normalization* dapat dilihat di Persamaan (4) (Mustaffa & Yusof, 2011).

$$X_n = \frac{(X_0 - X_{min})}{(X_{max} - X_{min})} \quad (4)$$

Keterangan:

- X_n = Nilai yang telah dinormalisasi
- X_0 = Nilai yang akan dinormalisasi
- X_{max} = Nilai maksimum yang diambil dari keseluruhan data
- X_{min} = Nilai minimum yang diambil dari keseluruhan data

2.5. Denormalisasi Data

Denormalisasi data digunakan untuk mengembalikan data normalisasi ke dalam bentuk aslinya. Berikut adalah perhitungan denormalisasi data ditunjukkan pada Persamaan (5) (Mustaffa & Yusof, 2011).


$$X_0 = X_n \cdot (X_{max} - X_{min}) + X_{min} \quad (5)$$

Keterangan:

- X_n = Nilai yang telah didenormalisasi
- X_0 = Nilai yang akan didenormalisasi
- X_{max} = Nilai maksimum yang diambil dari keseluruhan data
- X_{min} = Nilai minimum yang diambil dari keseluruhan data

2.6. Jaringan Saraf Tiruan (JST)


JST merupakan cabang dari *artificial intelligence* yang mengadaptasi mekanisme kerja saraf pada otak manusia dengan meniru kemampuannya dalam belajar untuk menyelesaikan suatu masalah melalui perhitungan komputasi (Humaini, 2015). Prinsip kerja JST mengambil cara kerja yang dilakukan pada jaringan saraf otak sehingga JST memiliki beberapa *neuron* yang sama dengan jaringan saraf otak manusia. Setiap *neuron* saling memberikan informasi kepada *neuron* lainnya. Untuk menyalurkan informasi tersebut dibutuhkan bobot (*weight*) sebagai perantara (Fikriya, Irawan & Soetrisno, 2017). Berikut adalah struktur *neuron* pada JST ditampilkan pada Gambar 1.



Gambar 1. Struktur Jaringan Saraf Tiruan
 Sumber: (Giusti, Widodo & Adinugroho, 2018)

2.7. Extreme Learning Machine (ELM)

Algoritme ELM termasuk bagian dari JST *feedforward network*. Umumnya, arsitektur JST *feedforward network* memiliki tiga pendekatan utama pada pembelajarannya, yaitu *gradient base*, *standard optimization method based*, dan *least square based* (Huang, Ding, & Zhou, 2010). Algoritme ELM menggunakan pendekatan *least square based* untuk melakukan pembelajaran yang mana pendekatan tersebut bekerja dengan melakukan generalisasi sehingga algoritme ELM dapat melakukan pembelajaran dengan sangat cepat. Pendekatan ini juga disebut *generalized single-hidden layer feedforward networks*. Tidak seperti pendekatan pembelajaran *gradient base* yang membutuhkan pembelajaran yang sangat lama karena parameter yang terdapat pada jaringan tersebut ditentukan secara berulang-ulang dan sering terjebak pada *local minima* (Huang et al, 2004). Untuk mengetahui lebih lanjut, arsitektur JST *feedforward network* yang digunakan peneliti pada algoritme ELM ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Algoritme Extreme Learning Machine
 Sumber: (Abadi, Musyafa & Soeprijanto, 2014)

Pada prosesnya, algoritme ELM mempunyai dua tahapan, yaitu tahap pembelajaran atau tahap *training* dan tahap pengujian atau tahap *testing*. Berikut adalah

penjelasan untuk setiap tahap pada algoritme ELM (Fachrony, Cholissodin & Santoso, 2018).

2.7.1. Proses Training

Tahap *training* pada algoritme ELM dengan menggunakan bias dapat dijelaskan sebagai berikut.

1. Menentukan bobot W_{jk} dan bias b secara acak dalam rentang yang telah ditentukan. Inisialisasi nilai bobot yang diberikan pada matriks bobot W_{jk} yang berkisar antara $[-0.5, 0.5]$ sedangkan *input* bias yang diberikan pada matriks b berkisar antara $[-1, 1]$.

2. Menghitung nilai H_{init}

Berikut rumus untuk menghitung H_{init} ditunjukkan pada Persamaan (6).

$$H_{init} = X.W^T + bias \tag{6}$$

Keterangan:

- H_{init} = Matriks H_{init}
- x = Matriks data *training*
- W^T = Matriks hasil *transpose* bobot

3. Menghitung *hidden layer* (H)

Proses perhitungan *hidden layer* pada tahap *training* disesuaikan pada Persamaan (1).

4. Menghitung *H dagger* (H^\dagger)

Proses perhitungan ini ditunjukkan pada Persamaan (7).

$$H^\dagger = (H^T.H)^{-1}.H^T \tag{7}$$

Keterangan:

- H^\dagger = Matriks *H dagger*
- H^T = *Transpose* matriks H pada *hidden layer*
- $(H^T.H)^{-1}$ = *Inverse* matriks

5. Menghitung *output weight* ($\hat{\beta}$)

Proses perhitungan ini ditunjukkan pada Persamaan (8).

$$\hat{\beta} = H^\dagger.Y \tag{8}$$

Keterangan:

- β = Matriks *ouput weight* pada *hidden layer*
- H^\dagger = Matriks *H dagger*
- Y = Matriks data target

2.7.2. Proses Testing

Tahap *testing* pada algoritme ELM menggunakan bobot, bias, dan $\hat{\beta}$ yang dihasilkan pada tahap *training*.

1. Menghitung nilai H_{init}

Proses perhitungan H_{init} pada tahap *testing* disesuaikan pada Persamaan (6).

2. Menghitung *hidden layer* (H)

Proses perhitungan *hidden layer* pada tahap *testing* disesuaikan pada Persamaan (1).

3. Menghitung *output layer* (\hat{Y})

Proses untuk mendapatkan data baru melalui perhitungan *output layer* ditunjukkan pada Persamaan (9).

$$\hat{Y} = H \cdot \hat{\beta} \tag{9}$$

Keterangan:

- \hat{Y} = Matriks *output layer* sebagai hasil generalisasi nilai baru
- H = Matriks *hidden layer*
- $\hat{\beta}$ = Matriks *output weight* pada *hidden layer*

2.8. Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengukur tingkat kesalahan berdasarkan kedekatan nilai prediksi yang dihasilkan dengan data data target. Perhitungan MAPE untuk evaluasi nilai baru hasil prediksi ditunjukkan pada Persamaan (10) (Mohammadi, et al., 2015).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_{i.pred} - P_{i.meas}}{P_{i.meas}} \right| \times 100\% \tag{10}$$

Keterangan:

- $P_{i.pred}$ = Nilai prediksi hasil denormalisasi
- $P_{i.meas}$ = Nilai dari data target
- n = Jumlah data uji/*testing* yang digunakan

Pada perhitungan nilai MAPE, penilaian kinerja sebuah model pembelajaran terbagi menjadi empat kategori. Berikut adalah kategori penilaian MAPE ditunjukkan pada Tabel 1. (Chang et al., 2007).

Tabel 1. Kriteria Nilai MAPE

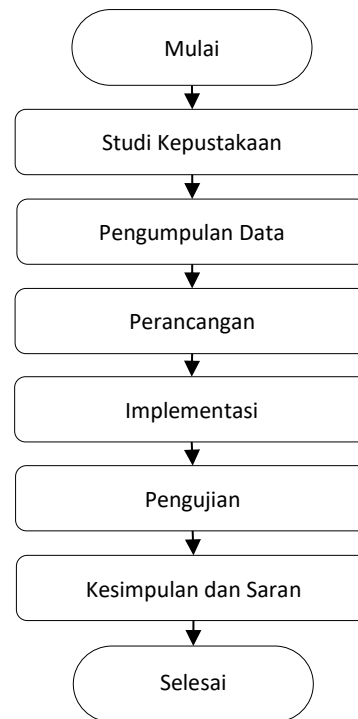
Nilai MAPE	Status
< 10%	Sangat bagus
10 – 20%	Bagus
20 – 50%	Cukup bagus
> 50%	Buruk

3. METODOLOGI PENELITIAN

3.1. Strategi Penelitian

Strategi penelitian dapat dikaitkan dengan

metodologi penelitian untuk menentukan tahap-tahap yang perlu ditempuh pada proses penelitian sehingga penelitian yang dilakukan memiliki bobot sesuai dengan konteks permasalahan yang dibahas. Berikut adalah beberapa strategi penelitian yang ditempuh pada penelitian digambarkan pada Gambar 3.



Gambar 3. Diagram Alir Metodologi Penelitian

3.2. Data Penelitian


Data yang digunakan merupakan data penjualan seblak yang diambil selama selama 2 bulan mulai dari tanggal 1 November 2018 sampai dengan tanggal 29 Desember 2018. Jumlah data penjualan yang berhasil dikumpulkan sebanyak 59 data. Data tersebut bersifat *time series* karena disusun berdasarkan waktu.

4. HASIL DAN PEMBAHASAN

Bagian ini akan membahas evaluasi hasil prediksi yang telah didapatkan. Setiap parameter diuji sebanyak lima kali percobaan. Pengujian pertama diuji menggunakan parameter yang telah ditentukan secara manual. Lalu, pengujian selanjutnya diuji menggunakan parameter terbaik yang menghasilkan rata-rata tingkat kesalahan terendah dari hasil uji coba sebelumnya. Berikut adalah pengujian parameter algoritme ELM.

4.1. Pengujian Persentase Jumlah Data Training

Pengujian ini menggunakan 5 fitur, 5 neuron, dan fungsi sigmoid biner.

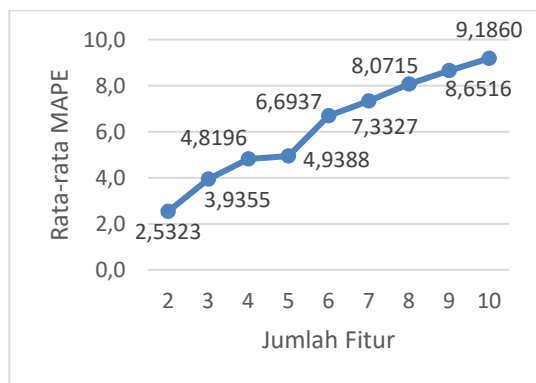


Gambar 4. Hasil Pengujian Persentase Jumlah Data Training

Dari beberapa jenis perbandingan yang telah diuji coba, perbandingan jumlah data yang mampu menghasilkan tingkat kesalahan terendah adalah 80%:10% dengan nilai error rate mencapai 4,3841%. Berdasarkan grafik pada Gambar 4, terjadi peningkatan tingkat kesalahan yang stabil mulai dari jumlah perbandingan 80%:10% sampai 20%:10%. Hal ini menunjukkan bahwa semakin berkurangnya persentase jumlah data training membuat hasil pembelajaran sulit untuk mengenali pola data yang lain sehingga menghasilkan prediksi dengan tingkat kesalahan yang lebih besar.

4.2. Pengujian Jumlah Fitur

Pengujian ini menggunakan persentase jumlah data terbaik dari hasil uji coba sebelumnya, yaitu 80%:10%. Kemudian, 5 neuron, dan fungsi sigmoid biner.



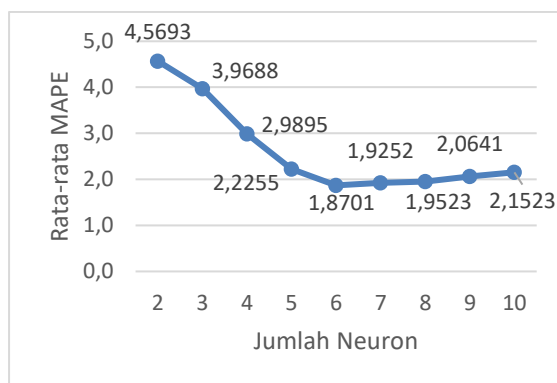
Gambar 5. Grafik Hasil Pengujian Jumlah Fitur

Dari beberapa uji coba yang telah dilakukan, banyaknya fitur yang mampu

menghasilkan tingkat kesalahan terendah adalah dua fitur dengan nilai error rate mencapai 2,5323%. Berdasarkan grafik pada Gambar 5, hasil pengujian banyaknya fitur menunjukkan peningkatan nilai error mulai dari fitur ke-2 sampai dengan fitur ke-10. Hal tersebut terjadi karena semakin bertambahnya fitur yang digunakan, maka faktor untuk menentukan data target juga semakin bertambah. Jumlah faktor yang semakin meningkat membuat sistem tidak dapat mengenali pola data dengan baik sehingga menghasilkan prediksi dengan tingkat kesalahan yang lebih besar.

4.3. Pengujian Jumlah Neuron

Hasil pengujian sebelumnya yang menghasilkan tingkat kesalahan terendah digunakan pada pengujian ini. Persentase data training dan fitur terbaik dari hasil uji coba sebelumnya, yaitu 80%:10% dan 2 fitur serta parameter yang telah ditetapkan diawal, yaitu fungsi aktivasi sigmoid biner.



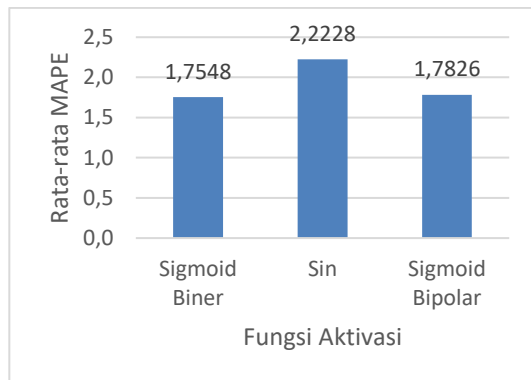
Gambar 6. Grafik Hasil Pengujian Jumlah Neuron

Dari beberapa uji coba yang telah dilakukan, banyaknya neuron yang mampu menghasilkan tingkat kesalahan terendah adalah enam neuron dengan nilai error rate mencapai 1,8701%. Berdasarkan grafik pada Gambar 6, terjadi penurunan yang stabil mulai dari neuron ke-2 sampai dengan neuron ke-6. Hal tersebut terjadi karena semakin bertambahnya neuron yang digunakan, maka jaringan yang dibentuk pada proses pembelajaran juga semakin bertambah sehingga sistem mampu mengenali pola data dengan baik dan mampu menghasilkan prediksi dengan tingkat kesalahan yang lebih kecil.

4.4. Pengujian Fungsi Aktivasi

Parameter terbaik dari hasil uji coba sebelumnya digunakan pada pengujian ini,

parameter tersebut, yaitu 80%:10% jumlah perbandingan data, 2 fitur, dan 6 *neuron*.



Gambar 7. Grafik Hasil Pengujian Fungsi Aktivasi

Dari beberapa jenis fungsi yang telah diuji coba, fungsi yang mampu menghasilkan tingkat kesalahan terendah adalah *sigmoid biner* dengan nilai *error rate* mencapai 1,7548%. Berdasarkan grafik pada Gambar 7, fungsi *sigmoid biner* memiliki tingkat kesalahan terendah dari fungsi lainnya. Hal ini menunjukkan bahwa pola pergerakan yang dihasilkan pada fungsi *sigmoid biner* mendekati pola pergerakan pada data target sehingga mampu menghasilkan prediksi dengan tingkat kesalahan yang lebih kecil.

5. KESIMPULAN

Berdasarkan hasil dan pembahasan dari pengujian yang telah dilakukan, terdapat beberapa kesimpulan yang diperoleh, sebagai berikut.

Algoritme ELM pada prediksi penjualan Seblak Malabar menghasilkan parameter yang optimal dengan melakukan pengujian untuk setiap parameter secara bertahap. Perbandingan parameter jumlah data *training* yang menghasilkan rata-rata tingkat kesalahan terendah adalah 80%:10% dengan nilai *error* mencapai 4,3841%. Kemudian, parameter fitur yang menghasilkan rata-rata tingkat kesalahan terendah adalah 2 fitur dengan nilai *error* mencapai 2,5323%. Lalu, untuk parameter *hidden neuron* yang menghasilkan rata-rata tingkat kesalahan terendah adalah 6 *neuron* dengan nilai *error* mencapai 1,8701%. Dan parameter fungsi aktivasi yang menghasilkan rata-rata tingkat kesalahan terendah adalah *sigmoid biner* dengan nilai *error* mencapai 1,7548%. Hasil pengujian pada setiap parameter menunjukkan hasil yang lebih baik dari pengujian sebelumnya. Hal tersebut menunjukkan bahwa parameter pada pengujian sebelumnya telah

mencapai batas kesalahan terendah yang mampu dicapai dari parameter tersebut.

Dari hasil pengujian parameter sebelumnya, rata-rata tingkat kesalahan terkecil yang mampu dicapai pada algoritme ELM untuk prediksi penjualan Seblak Malabar adalah 1,7548%. Berdasarkan Tabel 2, nilai MAPE yang kurang dari 10% menunjukkan bahwa rata-rata tingkat kesalahan yang dihasilkan algoritme ELM termasuk dalam kategori penilaian yang sangat bagus sehingga algoritme tersebut dapat digunakan untuk prediksi penjualan Seblak Malabar.

6. DAFTAR PUSTAKA

- Abadi, I. and Soeprijanto, A., 2014, November. Extreme learning machine approach to estimate hourly solar radiation on horizontal surface (PV) in Surabaya-East java. In Information Technology, Computer and Electrical Engineering (ICITACEE), 2014 1st International Conference on (pp. 372-376). IEEE.
- Chang, P.-C., Wang, Y.-W. & Liu, C.-H., 2007. The Development of a Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting. Expert Systems with Applications, Volume 32, pp. 88 - 89.
- Fachrony, A., Cholissodin, I. & Santoso, E., 2018. Implementasi Algoritme Extreme Learning Machine (ELM) untuk Prediksi Beban Pemanasan dan Pendinginan Bangunan. Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, 2(9), pp.3043–3049.
- Fikriya, Z.A., Irawan, M.I. & Soetrisno, 2017. Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital. 6(1).
- Giusti, A., Widodo, A.W. & Adinugroho, S., 2018. Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. 2(8), pp.2972–2978.
- Huang, G. Bin, Ding, X., & Zhou, H., 2010. Optimization method based extreme learning machine for classification. *Neurocomputing*, 74(1–3), 155–163. <https://doi.org/10.1016/j.neucom.2010.02.019>.

- Huang, G. Bin, Zhu, Q. Y., & Siew, C. K., 2004. Extreme learning machine: A new learning scheme of feedforward neural networks. *IEEE International Conference on Neural Networks - Conference Proceedings*, 2, 985–990. <https://doi.org/10.1109/IJCNN.2004.1380068>.
- Huixuan, F., Yuchao, W. & Zhang, H., 2015. Ship Rolling Motion Prediction Based on Extreme Learning Machine. Chinese Control Conference, pp.3468–3472.
- Humaini, Q. (2015). Jaringan Syaraf Tiruan Extreme Learning Machine (ELM) Untuk Memprediksi Kondisi Cuaca. 1–86.
- Mohammadi, K. et al., 2015. Predicting The Wind Power Density Based Upon Extreme Learning Machine. *Energy*, Volume 86, pp. 232-239.
- Mosabeth, C., Furqon, M.T. & Wihandika, R.C., 2018. Prediksi Harga Pasar Daging Sapi Di Kota Malang Dengan Menggunakan Metode Extreme Learning Machine (ELM). 2(12), pp.6362–6369.
- Mustaffa, Z. & Yusof, Y., 2011. A comparison of normalization techniques in predicting dengue outbreak. *International Conference on Business and Economics Research*, 1, pp.345–349.
- Singh, R. and Balasundaram, S., 2007. Application of extreme learning machine method for time series analysis. *International Journal of Intelligent Technology*, 2(4), pp.256-262.
- Srimuang, W., & Intarasothonchun, S., 2015. Classification Model of Network Intrusion using Weighted Extreme Learning Machine. 12th International Joint Conference on Computer Science and Software Engineering (JCSSE), 190-194.
- Wang, G., Zhao, Yi., & Wang, Di., 2008. Aprotein Secondary Structure Prediction Framework Based On The Extreme Learning Machine. *Journal Neurocomputing*, 262-268.