

PERAMALAN PRODUKSI GULA PASIR MENGGUNAKAN *EXTREME LEARNING MACHINE* (ELM) PADA PG CANDI BARU SIDOARJO

Iga Permata Siwi¹, Imam Cholissodin², M. Tanzil Furqon³

¹Mahasiswa, ^{2,3}Dosen Pembimbing

Program Studi Teknik Informatika, Jurusan Teknik Informatika, Fakultas Ilmu Komputer
Universitas Brawijaya

Jl. Veteran, Malang 65145, Indonesia

Email: igapermatasiwi@gmail.com¹, imamcs@ub.ac.id², m.tanzil.furqon@gmail.com³

ABSTRAK

Gula merupakan salah satu kebutuhan pokok yang keberadaannya memegang peranan penting bagi masyarakat Indonesia. Selain itu gula juga menjadi salah satu yang dibutuhkan dalam suatu industri untuk dijadikan sebagai bahan baku seperti bahan baku untuk pembuatan tepung, makanan, serta industri pengolahan dan pengawetan makanan. Kebutuhan akan gula yang semakin meningkat didukung oleh gaya hidup masyarakat terutama dalam konsumsi sehari-hari. Akan tetapi, kenaikan konsumsi gula ini tidak diikuti dengan kenaikan tingkat produksi yang ada. Memperkirakan permintaan konsumen di masa datang dengan membuat perencanaan produksi selalu menjadi tantangan bagi suatu industri. Hal ini membuat peramalan memiliki peranan penting. Perencanaan yang efektif dan efisien harus didukung oleh sistem peramalan yang akurat. Oleh karena itu, pada penelitian ini penulis membuat sistem peramalan produksi gula dengan menerapkan metode *Extreme Learning Machine* (ELM). Metode ini merupakan salah satu metode pembelajaran baru dari jaringan syaraf tiruan. Hasil uji coba dalam penelitian ini menunjukkan bahwa metode ELM memiliki nilai *error* yang baik diukur dengan tingkat kesalahan *Mean Absolute Percentage Error* (MAPE). Berdasarkan hasil pengujian didapat nilai MAPE terbaik sebesar 0.74% dengan menggunakan perbandingan jumlah data *training* dan *testing* sebanyak 80% : 20%, *range input weight* [-1;1], jumlah *neuron* pada *hidden layer* sebanyak 12 dan menggunakan analisis fundamental.

Kata kunci: Gula, Produksi Gula, Peramalan, *Extreme Learning Machine*.

ABSTRACT

Sugar is one of the principal whose existance hold an important role for the Indonesian people. Other than that, sugar is also one that is needed in an industry to be used as raw materials such as raw materials for the manufacture of flour, meal, as well as industrial processing and food preservation. Demand for sugar is increasing supported by people's lifestyles, especially in daily consumption. However, the increase in sugar consumption is not accompanied by any increase in production levels. Estimating future consumer demand by make production planning has always been a challenge for an industry. This makes forecasting has an important role. Effective planning and efficient must be supported by accurate forecasting system. Therefore, in this study the authors make sugar production forecasting system by applying the method of Extreme Learning Machine (ELM). This method is one of the new learning method of the neural network. The trial results in this study show that this method has the good value error measured of ELM using Mean Percentage Absolute Error (MAPE). Based on the test result obtained that the best error MAPE is 0.74% by using a comparison of the amount of training and testing data as much as 80% : 20%, range input weight [-1;1], the number of neurons hidden layer is 12 and by using data of fundamental analysis.

Keywords : *Sugar, Sugar Production, Forecasting, Extreme Learning Machine.*

1. PENDAHULUAN

1.1. Latar Belakang

Gula merupakan salah satu kebutuhan pokok yang keberadaan memegang peranan penting bagi masyarakat Indonesia. Selain itu gula juga menjadi salah satu yang dibutuhkan dalam suatu industri untuk dijadikan sebagai bahan baku seperti bahan baku untuk pembuatan tepung, makanan, serta industri pengolahan dan pengawetan makanan. Kebutuhan akan gula yang

semakin meningkat didukung oleh gaya hidup masyarakat terutama dalam konsumsi sehari-hari. Permintaan konsumsi gula akan terus meningkat seiring dengan pertambahan jumlah penduduk. Kenaikan konsumsi gula di Indonesia ini tidak diikuti dengan kenaikan tingkat produksi yang ada. Produktivitas dan efisiensi industri gula di Indonesia yang semakin rendah dapat dilihat dari penurunan jumlah produksi gula yang dihasilkan perusahaan penghasil gula dan juga rendahnya

efisiensi manajemen dari setiap pabrik gula yang ada di Indonesia. Untuk dapat memenuhi kebutuhan masyarakat akan gula yang terus meningkat membuat Indonesia menjadi negara pengimpor gula setiap tahunnya.

Perencanaan produksi adalah aktivitas untuk menetapkan produk yang diproduksi, jumlah yang dibutuhkan, kapan produk tersebut harus selesai dan sumber-sumber yang dibutuhkan. Dalam kegiatan memproduksi gula, PT PG Candi Baru sudah melakukan perencanaan produksi untuk dapat mengoptimalkan strategi produksi. Namun perencanaan produksi ini masih dilakukan secara manual. Hal ini memungkinkan dalam memberikan kesalahan prediksi yang tinggi karena proses perencanaan produksi dilakukan berdasarkan subjektif yaitu dengan memperkirakan target produksi selanjutnya dengan menaikkan atau menurunkan target dari hasil produksi yang didapatkan sebelumnya. Dengan kemajuan teknologi saat ini, penulis bermaksud merancang sistem terkait prediksi untuk hasil produksi agar membantu mempermudah kinerja karyawan dalam pengambilan keputusan yang berhubungan dengan proses produksi.

Banyak metode telah dikemukakan untuk mendapatkan hasil ramalan yang akurat. Salah satunya adalah metode *Extreme Learning Machine* (ELM). ELM merupakan jaringan syaraf tiruan *feedforward* dengan satu *hidden layer* atau lebih dikenal dengan istilah *single hidden layer feedforward neural network* (SLFNs). Metode ELM memiliki kelebihan dalam *learning speed* serta mempunyai tingkat akurasi yang lebih baik dibanding dengan metode konvensional sehingga dengan menerapkan ELM diharapkan mampu menghasilkan ramalan yang lebih efektif.

1.2. Rumusan Masalah

Berdasarkan uraian latar belakang masalah yang telah dijelaskan, maka dapat dirumuskan permasalahan yang akan dijadikan objek penelitian yaitu sebagai berikut:

1. Bagaimana mengimplementasikan metode *Extreme Learning Machine* untuk peramalan produksi gula?
2. Berapa tingkat kesalahan peramalan (*forecast error*) yang diukur dengan perhitungan MAPE (*Mean Absolute Percentage Error*) pada hasil peramalan produksi gula menggunakan *Extreme Learning Machine*?

1.3. Batasan Masalah

Berdasarkan latar belakang masalah, berikut ini diberikan batasan masalah untuk menghindari melebarnya masalah yang akan diselesaikan:

1. Implementasi metode *Extreme Learning Machine*.
2. Data yang digunakan didapatkan dari PG Candi Baru Sidoarjo pada masa giling periode 2010-2015.
3. Adapun parameter yang digunakan adalah jumlah lama giling, rendemen tebu, luas areal tanaman tebu, jumlah pekerja dan jumlah bahan baku yang digunakan.
4. Perhitungan nilai *forecast error* pada penelitian ini menggunakan MAPE (*Mean Absolute Percentage Error*).
5. Fungsi aktivasi yang digunakan adalah fungsi aktivasi *sigmoid biner*.
6. Hasil akhir dari peramalan produksi gula ini tidak dibandingkan dengan metode peramalan lainnya.

2. TINJAUAN PUSTAKA

2.1. Definisi Gula

Gula merupakan suatu karbohidrat sederhana yang menjadi sumber energi utama dalam tubuh manusia serta menjadi salah satu kebutuhan pokok masyarakat yang paling banyak dicari. Keberadaan gula menjadi salah satu komoditi perdagangan utama yang paling banyak diperdagangkan dalam bentuk kristal sukrosa padat. Gula sebagai sukrosa diperoleh dari nira tebu, bit gula, atau aren. Proses untuk menghasilkan gula mencakup tahap ekstraksi (pemerasan) diikuti dengan pemurnian melalui distilasi (penyulingan).

2.2. Faktor-faktor yang Mempengaruhi Produksi Gula

Dalam pembuatan gula terdapat beberapa faktor yang mempengaruhi hasil dari produksi gula antara lain:

1. Bahan Baku Tebu

Tebu (*Saccharum officinarum*) sebagai bahan baku utama industri gula di Indonesia merupakan tanaman yang efisien. Mulai dari pangkal sampai ujung batang tebu mengandung air gula dengan kadar mencapai 20%. Air gula inilah yang akan dibuat kristal-kristal gula atau gula pasir. Gula sebagai hasil proses asimilasi disimpan oleh tanaman di dalam cairan sel tebu, cairan ini yang disebut dengan nira.

2. Luas Areal (Tanah)

Lahan adalah tanah yang digunakan untuk usaha pertanian. Penggunaan lahan sangat tergantung pada keadaan dan lingkungan lahan berada (Mohar, 2004). Lahan merupakan bagian dari faktor produksi karena dijadikan sebagai sarana produksi. Luas lahan pertanian pun dijadikan sebagai sesuatu yang penting dalam proses produksi ataupun dalam usaha pertanian. Dalam usaha tani misalnya, penguasaan lahan sempit sudah pasti kurang efisien dibanding lahan yang lebih luas. Semakin sempit lahan usaha, semakin tidak efisien usaha tani yang dilakukan (Mohar, 2004). Dalam produksi gula, luas areal tebu mampu mempengaruhi jumlah produksi gula. Semakin luas areal yang ditanami tebu maka tebu yang dihasilkan banyak dan jumlah produksi gula semakin meningkat. Jumlah produksi tebu yang baik dan berkualitas tinggi dipengaruhi oleh penggunaan dan pemanfaatan lahan tebu yang efektif dan tepat, baik dari sistem pengairan dan jenis varietas tanaman tebu yang ditanam. Hal tersebut akan berpengaruh pada produksi gula yang dihasilkan yaitu gula dengan jumlah yang tinggi serta kualitas yang baik.

3. Rendemen Tebu

Rendemen tebu merupakan kandungan yang terdapat pada tebu. Rendemen yang dihasilkan oleh tebu dipengaruhi oleh keadaan tanaman dan proses penggilingan di pabrik. Untuk mendapatkan rendemen yang tinggi, tanaman harus bermutu baik dan ditebang pada saat yang tepat serta harus diolah dengan baik (Napitupulu, 2013). Hubungan rendemen dengan gula sangat mempengaruhi, karena rendemen merupakan kandungan gula yang terdapat pada batang tebu dan dapat menentukan jumlah produksi gula yang dihasilkan. Semakin tinggi tingkat rendemen dalam tebu maka akan semakin tinggi pula jumlah gula yang dihasilkan.

4. Tenaga Kerja Manusia

Tenaga kerja merupakan pekerja yang membantu proses produksi pembuatan gula. Tenaga kerja pada PG Candi Baru dibedakan atas tiga bagian yaitu *staff*, *non-staff* dan pekerja PKWT. Pekerja *staff* dan *non-staff* adalah pekerja tetap. Sedangkan pekerja PKWT adalah pekerja musiman dengan sistem kontrak, artinya hanya bekerja pada saat musim giling saja.

5. Modal Biaya Produksi

Biaya produksi adalah biaya-biaya yang terjadi untuk mengolah bahan baku menjadi

produk jadi yang siap untuk dijual (Mulyadi, 2004). Menurut Mulyadi, unsur biaya dalam harga pokok produksi diklasifikasikan atas 3 (tiga) biaya, yaitu:

1. Biaya bahan baku (*Material Cost*)
2. Biaya tenaga kerja (*Labour Cost*)
3. Biaya *overhead* pabrik (*Factory Overhead Cost*).

6. Jam Mesin

Mesin merupakan salah satu faktor produksi yang digunakan dalam proses produksi gula. Berdasarkan sifat produksi gula yang kontinyu, apabila terjadi kerusakan atau kemacetan pada salah satu mesin maka akan mengakibatkan kemacetan pada proses produksi secara keseluruhan sehingga berapa lama jam mesin dapat beroperasi akan berpengaruh terhadap hasil yang didapatkan dari kegiatan produksi tersebut.

7. Lama Giling

Lama giling adalah waktu yang dibutuhkan untuk mengolah tebu menjadi gula dalam satu musim giling. Lama giling juga dipengaruhi oleh faktor jam mesin. Apabila salah satu mesin yang digunakan mengalami kerusakan atau kemacetan maka akan menentukan lama giling. Proses giling yang efektif adalah ditentukan dari tersedianya bahan baku tebu dan mesin giling dalam produksi gula.

2.3. Peramalan (*Forecasting*)

Dalam kehidupan sehari-hari, sering terjadi kesenjangan antara kebutuhan akan sesuatu hal di masa depan dengan peristiwa yang akan terjadi. Kesenjangan inilah yang menyebabkan pentingnya perencanaan dan peramalan. Peramalan juga dapat mempengaruhi proses pengambilan keputusan dalam kurun waktu beberapa jam, hari, bahkan tahunan sekalipun. Kemajuan ilmu pengetahuan telah mampu memberikan penjelasan yang teoritis, sehingga peramalan tidak hanya dianggap sebagai dugaan tanpa landasan yang kuat (Makridakis, 1999). Ada beberapa jenis teknik peramalan yang dilakukan, diantaranya:

1. Peramalan Teknikal

Peramalan ini menggunakan data historis untuk meramalkan nilai di masa yang akan datang dan kadang kala peramalan dilakukan hanya dengan pengamatan data tanpa menggunakan perhitungan statistik. Namun tidak jarang pula perhitungan statistik disertakan dalam ramalan. Jika data historis yang ada menampakkan pola yang *random*, maka peramalan teknis ini kurang begitu tepat untuk diterapkan. Peramalan secara teknis ini

juga terkadang kurang membantu untuk jangka waktu yang cukup lama walaupun secara umum peramalan teknikal memberikan konsistensi yang baik.

2. Peramalan Fundamental

Peramalan fundamental dilakukan berdasarkan hubungan fundamental seperti yang telah dijelaskan sebelumnya mengenai faktor-faktor yang mempengaruhi produksi gula, antara lain bahan baku tebu, luas areal, rendemen tebu, dan lain sebagainya.

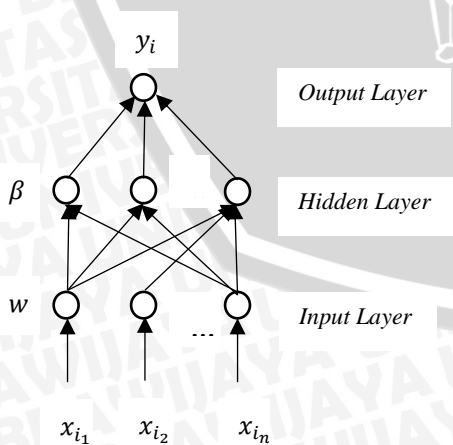
2.4. Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) merupakan metode pembelajaran baru dari jaringan syaraf tiruan. Metode ini pertama kali diperkenalkan oleh Huang *et al.* (2004). ELM merupakan jaringan syaraf tiruan *feedforward* dengan satu *hidden layer* atau lebih dikenal dengan istilah *single hidden layer feedforward neural network*.

Metode pembelajaran ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*. Huang *et al* mengemukakan dua alasan mengapa jaringan syaraf tiruan *feedforward* mempunyai *learning speed* rendah, yaitu:

1. Menggunakan *slow gradient based learning algorithm* untuk melakukan *training*.
2. Semua parameter pada jaringan ditentukan secara *iterative* dengan metode pembelajaran tersebut.

Pada ELM parameter-parameter seperti *input weight* dan *hidden bias* dipilih secara *random*, sehingga ELM memiliki *learning speed* yang cepat dan mampu menghasilkan *good generalization performance*. Gambar 1 merupakan struktur dari ELM.



Gambar 1 Struktur ELM

Metode *Extreme Learning Machine* (ELM) mempunyai model matematis yang berbeda dari jaringan syaraf tiruan *feedforward*. Model matematis dari ELM lebih sederhana dan efektif. Berikut model matematis dari ELM. Untuk N jumlah sampel yang berbeda (x_i, t_i) .

$$\begin{aligned} x_i &= [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n \\ x_t &= [x_{t1}, x_{t2}, \dots, x_{tn}]^T \in R^n \end{aligned} \quad (1)$$

Langkah-langkah perhitungan dengan metode ELM ini dibedakan menjadi 2 proses, yaitu proses *training* dan proses *testing*.

2.4.1. Proses Training

Sebelum digunakan sebagai *tool* peramalan, ELM harus melalui proses *training* terlebih dahulu. Tujuan dari proses ini adalah mendapatkan *input weight* dan *output weight* dengan tingkat kesalahan yang rendah. Langkah-langkah pada proses *training* ELM dijabarkan sebagai berikut:

1. Menghitung Keluaran pada Setiap *Hidden Layer* dengan Fungsi Aktivasi

Pada *input layer* akan diterima data sejumlah N yang akan diproses oleh *hidden layer*. Data sejumlah N merupakan data dalam bentuk matriks. Dalam proses ini, data sejumlah N akan dikalikan dengan *input weight* yang diperoleh secara *random* dengan ukuran matriks berupa jumlah *hidden layer* x jumlah *input layer*. Perhitungan keluaran *hidden layer* ini ditunjukkan pada Persamaan 2.

$$H = N * w^T \quad (2)$$

Keterangan:

H = matriks keluaran *hidden layer*

N = jumlah *input layer*

w^T = matriks *transpose input weight*

Hasil keluaran *hidden layer* akan diaktivasi dengan fungsi aktivasi. Fungsi aktivasi digunakan untuk memetakan nilai matriks keluaran *hidden layer*. Fungsi aktivasi yang digunakan pada penelitian ini adalah *sigmoid biner*. Fungsi ini sering digunakan untuk jaringan syaraf tiruan yang membutuhkan nilai *output* yang terletak pada interval 0 sampai 1. Fungsi *sigmoid biner* dapat dirumuskan pada Persamaan 3.

$$H(x) = \frac{1}{(1+e^{-x})} \quad (3)$$

2. Menghitung Matriks *Moore-Penrose Pseudo Inverse*

Matriks *moore-penrose pseudo inverse* didapatkan dari perkalian matriks *inverse* dan matriks *transpose* dari hasil keluaran *hidden layer* dengan fungsi aktivasi. Untuk menghitung

matriks *moore-penrose pseudo inverse* dapat dirumuskan pada Persamaan 4.

$$H^+ = (H^T H)^{-1} H^T \quad (4)$$

Keterangan:

H^+ = matriks *Moore-Penrose Pseudo Inverse*

H = matriks keluaran *hidden layer*

3. Menghitung *Output Weight*

Output weight merupakan hasil keluaran dari *hidden layer* dengan *output layer*. Untuk menghitung *output weight* dapat dirumuskan pada Persamaan 5.

$$\beta = H^+ T \quad (5)$$

$$\beta = \begin{pmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{pmatrix} \quad (6)$$

$$T = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix} \quad (7)$$

Keterangan:

β = matriks *output weight*

H^+ = matriks *Moore-Penrose Pseudo Inverse*

T = matriks target

4. Menghitung *Output Peramalan*

Output peramalan merupakan proses perkalian antara matriks keluaran *hidden layer* dengan matriks *output weight* yang ditunjukkan pada Persamaan 8.

$$O = H\beta \quad (8)$$

Keterangan:

O = *output peramalan*

H = matriks keluaran *hidden layer*

β = matriks *output weight*

2.4.2. Proses *Testing*

Urutan langkah-langkah pada proses *testing* sama seperti yang dilakukan pada proses *training*. Proses *testing* dilakukan berdasarkan *input weight* dan *output weight* yang didapatkan dari proses *training*. Selanjutnya adalah melakukan peramalan dengan ELM. Komposisi data yang digunakan adalah 80% dari total seluruh data untuk proses *training* dan 20% dari total seluruh data untuk proses *testing* (Zhang, 1997). Proses data *training* bertujuan untuk

mengembangkan model dari ELM, sementara untuk proses *testing* bertujuan untuk mengevaluasi kemampuan ELM sebagai *forecasting tool*.

2.5. Normalisasi Data

Dalam melakukan perhitungan pada peramalan produksi gula, perlu dilakukan proses *preprocessing* terlebih dahulu berupa normalisasi data. Hal ini bertujuan untuk standarisasi semua data yang digunakan dalam perhitungan sehingga data berada pada jarak tertentu (Patro et al, 2015). Proses normalisasi diperlukan karena untuk menghasilkan perhitungan yang digunakan menghasilkan *output* dengan *range* data [0,1] atau [-1,1]. Persamaan yang digunakan untuk normalisasi data ditunjukkan pada persamaan (9).

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (9)$$

Keterangan:

x = nilai data asli yang belum dinormalisasi

x_{min} = nilai minimum pada data set

x_{max} = nilai maksimum pada data set

2.6. Denormalisasi Data

Denormalisasi data adalah proses untuk mengembalikan nilai data menjadi nilai sebenarnya berdasarkan hasil peramalan. Berikut rumus denormalisasi yang dijabarkan pada Persamaan 10 yang didapat melalui *reverse* dari Persamaan 9.

$$x = (x'(x_{max} - x_{min})) + x_{min} \quad (10)$$

2.7. Nilai Evaluasi

Evaluasi dilakukan dengan mencari nilai *error Mean Absolute Percentage Error* (MAPE) dengan membandingkan selisih antara nilai ramalan dengan nilai aktual. Penjabaran rumus MAPE akan dijelaskan pada Persamaan 2.11 (Liu et al, 2008).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100 \quad (11)$$

Keterangan:

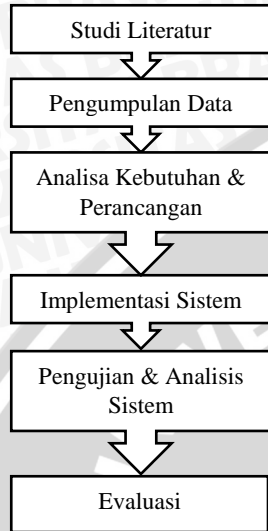
\hat{y}_i = nilai hasil ramalan

y_i = nilai aktual

Pendekatan MAPE berguna ketika ukuran atau besar variabel ramalan dianggap penting dalam mengevaluasi ketetapan ramalan, MAPE merupakan jenis pendekatan nilai *error* yang mudah dipahami oleh pengguna dari berbagai kalangan karena MAPE menggunakan nilai presentase untuk menyatakan *error* yang didapat, dimana presentase tersebut mencerminkan nilai *error* hasil ramalan dari nilai aktual yang sesungguhnya (Swanson et al, 2010)

3. METODOLOGI

Pada bab ini dibahas mengenai penjelasan dari setiap tahapan penyelesaian dari permasalahan yang diangkat pada penelitian ini.



Gambar 2 Diagram Alir Sistem

3.1. Pengumpulan Data

Pengumpulan data merupakan tahapan untuk mengumpulkan data-data yang akan digunakan dalam pengembangan dan pengujian sistem. Data-data yang dibutuhkan tersebut antara lain:

1. Data yang digunakan pada penelitian ini adalah data produksi gula dalam masa giling bulan Mei-Desember periode tahun 2010-2015 pada PG Candi Baru Sidoarjo.
2. Data produksi gula yang diolah meliputi data jumlah lama giling, rendemen tebu, luas areal tanaman tebu, jumlah pekerja, jumlah bahan baku yang diproduksi dan hasil produksi gula.
3. Pada penelitian ini data dibedakan menjadi dua, yaitu data latih (*training*) dan data uji (*testing*).
4. Data produksi gula yang didapat dibuat menjadi tiga data parameter yang berbeda, yaitu data parameter fundamental, teknikal dan gabungan antara fundamental dan teknikal

4. PERANCANGAN

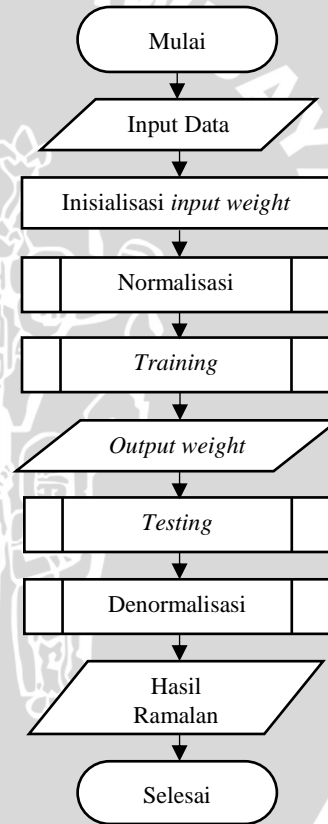
4.1. Formulasi Permasalahan

Permasalahan yang diselesaikan adalah peramalan produksi gula pasir dengan tujuan memprediksi produksi gula agar dapat memenuhi kebutuhan pasar, sehingga dapat menyeimbangkan

antara produksi dan konsumsi gula. Peramalan dilakukan dengan metode ELM yang memberikan hasil peramalan dengan tingkat akurasi yang lebih baik dibanding metode peramalan konvensional serta memiliki *learning speed* yang tinggi. Hasil peramalan dilihat berdasarkan tingkat kesalahan (*forecast error*). Semakin kecil nilai kesalahan maka data peramalan semakin akurat.

4.2. Diagram Alir Sistem

Diagram alir sistem merupakan gambaran dari alur proses sistem akan bekerja. Diagram alir sistem pada peramalan produksi gula pasir ini meliputi input data, normalisasi, *training*, *testing*, denormalisasi dan evaluasi. Diagram alir sistem ditunjukkan pada Gambar 3.



Gambar 2 Diagram Alir Sistem

5. PENGUJIAN DAN ANALISIS

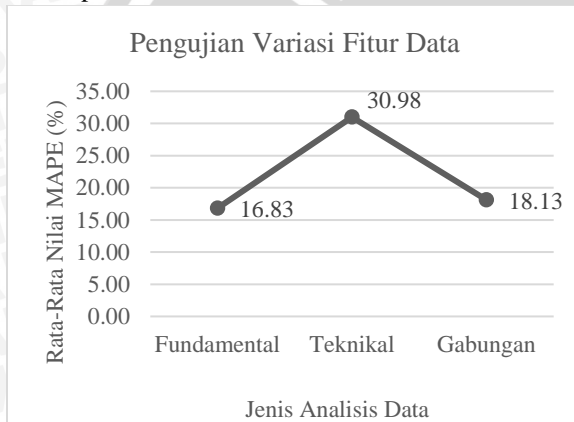
Bab ini berisi hasil pengujian dan analisis dari hasil uji coba yang telah dilakukan dalam peramalan produksi gula pasir menggunakan *Extreme Learning Machine* (ELM). Pada bab ini terdapat dua macam pengujian yang akan dilakukan, yaitu:

1. Pengujian variasi fitur data
2. Pengujian *range input weight*

3. Pengujian perbandingan jumlah data *training* dan data *testing*
4. Pengujian jumlah *neuron*

5.1. Hasil dan Analisa Uji Coba Variasi Data

Pengujian berdasarkan analisis data digunakan untuk mengetahui jenis data terbaik yang cocok digunakan untuk menghasilkan nilai kesalahan yang minimal pada peramalan produksi gula. Terdapat tiga jenis analisis data, yaitu fundamental, teknikal dan gabungan antara fundamental dan teknikal (data lengkap disertakan pada Lampiran A). Inisialisasi parameter yang digunakan pada pengujian ini adalah jumlah *hidden neuron* sebanyak 3, *input weight* dengan *range* [-1,1] (nilai *input weight* setiap kali percobaan disertakan pada Lampiran B) dan perbandingan data *training* dan data *testing* sebesar 80%:20%. Pengujian dilakukan sebanyak 10 kali percobaan. Hasil Pengujian variasi fitur data dapat dilihat pada Gambar 3.



Gambar 3 Grafik Pengujian Variasi Data


Analisis fundamental merupakan analisis yang menggunakan data faktor-faktor yang mempengaruhi produksi gula. Pada penelitian menggunakan analisis fundamental ini diambil lima faktor yang digunakan, yaitu jumlah bahan baku tebu, luas areal, rendemen tebu, tenaga pekerja dan lama giling. Analisis teknikal merupakan analisis yang menggunakan data historis produksi gula yang dibuat menjadi 4 *sequence* data dengan menggunakan data produksi 4 bulan sebelumnya. Sedangkan untuk analisis gabungan merupakan analisis yang menggabungkan data antara data analisis fundamental dengan teknikal.

Berdasarkan grafik pada Gambar 3, analisis fundamental memiliki nilai MAPE minimal yaitu sebesar 16.83%. Analisis fundamental pada data produksi gula ini didasarkan pada faktor-faktor yang mempengaruhi produksi gula, dimana faktor-faktor produksi gula ini yang menentukan berapa banyak produksi yang dapat dihasilkan. Sedangkan pada

analisis teknikal diasumsikan bahwa data produksi gula yang mencerminkan seluruh faktor yang relevan mempengaruhi hasil produksi gula yang ada, sehingga hasil yang didapatkan tidak lebih baik jika dibanding dengan analisis fundamental.

5.2. Hasil dan Analisa Uji Coba Range Input Weight

Pengujian *range input weight* digunakan untuk mengetahui *range* bobot terbaik dalam ELM untuk menghasilkan nilai kesalahan minimal. Untuk pengujian *range input weight*, *range* yang digunakan adalah [-1;1], [-0,8;1], [-0,6;1], [-0,4;1], [-0,2;1] dan [0;1]. Inisialisasi parameter yang digunakan pada pengujian ini adalah jumlah *neuron* yaitu 3. *Input weight* dilakukan secara *random* setiap kali percobaan (nilai *input weight* setiap kali percobaan disertakan pada Lampiran B). Pengujian menggunakan data analisis fundamental dan masing-masing pengujian dilakukan sebanyak 10 kali percobaan. Hasil pengujian *range input weight* dapat dilihat pada Gambar 4.




Gambar 4 Grafik Pengujian Range Input Weight

Input weight digunakan dalam menyeimbangkan nilai tawar sistem untuk menemukan *gradient* dari pola-pola data yang ada sehinggalah menghasilkan nilai MAPE minimal. Terdapat beberapa faktor untuk mendapat nilai *input weight* yaitu diantaranya lebar interval. Berdasarkan grafik pada Gambar 4, perbedaan *range input weight* berpengaruh terhadap nilai MAPE yang didapatkan. Semakin lebar interval *range* yang digunakan semakin baik hasilnya. Hal ini karena dengan semakin lebar interval yang ada memungkinkan untuk mendapatkan lebih banyak kemungkinan angka *random* untuk nilai *input weight* yang cocok dalam menghasilkan nilai *error* minimal. Berdasarkan hasil pengujian, *range* yang

menghasilkan nilai MAPE terkecil ada pada *range* [-1;1] dengan rata-rata nilai MAPE yaitu 12.64%.

5.3. Hasil dan Analisa Uji Coba Perbandingan Jumlah Data *Training* dan Data *Testing*

Pengujian perbandingan jumlah data *training* dan data *testing* ini bertujuan untuk mengetahui pengaruh dari perbandingan jumlah data *training* dengan data *testing* terhadap nilai MAPE yang dihasilkan serta berapa lama waktu eksekusi yang didapatkan. Perbandingan jumlah data *training* : data *testing* pada pengujian ini adalah 80% : 20%, 70% : 30%, 60% : 40%, 50% : 50%, 40% : 60%, 30% : 70% dan 20% : 80%. Inisialisasi parameter yang digunakan pada pengujian ini adalah jumlah *neuron* yaitu 3. *Input weight* dilakukan secara *random* setiap kali percobaan dengan *range* data yang diambil dari hasil pengujian *range* terbaik pada pengujian sebelumnya, yaitu [-1,1] (nilai *input weight* setiap kali percobaan disertakan pada Lampiran B). Pengujian ini menggunakan data analisis fundamental dengan percobaan sebanyak 10 kali untuk setiap rasio perbandingan. Hasil pengujian perbandingan jumlah data *training* dan data *testing* dapat dilihat pada Gambar 5.



Gambar 5 Grafik Pengujian Perbandingan Jumlah Data *Training* dan Data *Testing*

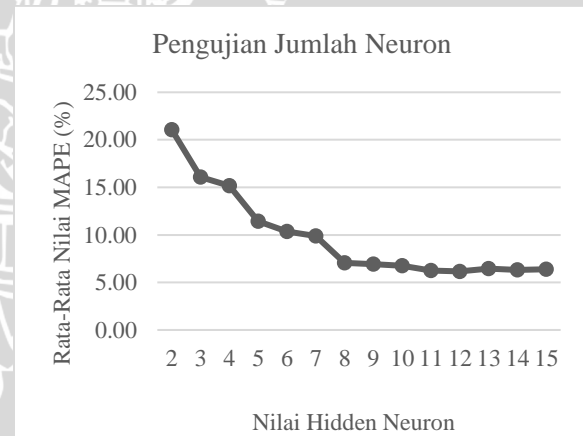
Data *training* merupakan data yang digunakan untuk proses pembelajaran pada peramalan. Data *training* pada proses *training* memberikan nilai *input weight* dan nilai *output weight* yang akan dilanjutkan pada proses *testing*. Data *testing* merupakan data uji yang akan digunakan untuk menghitung hasil ramalan dan kesalahan ramalan berdasarkan nilai MAPE.

Berdasarkan grafik pada Gambar 5, nilai MAPE terkecil didapatkan pada perbandingan jumlah data *training* sebanyak 80% dengan 36 data dan data *testing* sebanyak 20% dengan 9 data yaitu rata-rata

nilai *error* sebesar 11.90%. Banyaknya jumlah data *training* dan data *testing* pada ELM ini berpengaruh terhadap nilai *error* yang dihasilkan. Hal ini disebabkan karena metode ELM merupakan metode pelatihan. Dimana semakin banyak jumlah data *training* yang digunakan, semakin baik nilai *error* yang didapat.

5.4. Hasil dan Analisa Uji Coba Jumlah *Hidden Neuron*

Pengujian jumlah *neuron* digunakan untuk mengetahui jumlah *neuron* terbaik dalam ELM untuk menghasilkan nilai kesalahan yang minimal serta berapa lama waktu eksekusi yang didapatkan. Banyaknya jumlah *neuron* yang diuji coba adalah dimulai dari angka 2 dan berhenti pada titik dimana menunjukkan hasil yang konvergen. Inisialisasi parameter yang digunakan pada pengujian ini adalah *range input weight* dan perbandingan jumlah data *training* dan *testing* terbaik yang diambil dari hasil pengujian sebelumnya, yaitu *range* [-1,1] (nilai *input weight* setiap kali percobaan disertakan pada Lampiran B) dan perbandingan data *training* dan data *testing* sebesar 80%:20%. Pengujian menggunakan data analisis fundamental dan masing-masing pengujian dilakukan sebanyak 10 kali percobaan. Hasil pengujian jumlah *hidden layer* dapat dilihat pada Gambar 6.



Gambar 6 Grafik Pengujian Jumlah *Hidden Layer*

Hidden neuron pada *Extreme Learning Machine* terdiri dari *node-node* merupakan yang merupakan unit yang melakukan proses perhitungan yang mengolah masukan menjadi keluaran. Selain itu, *hidden layer* memiliki parameter yang menghubungkan antar *layer* (Shamsirband dkk, 2009). Parameter-parameter tersebut dibentuk berdasarkan banyaknya *hidden neuron*. Setiap penghubung memiliki tingkat kekuatan yang berbeda (nilai yang berbeda) (Huang dkk, 2005). Hal ini memungkinkan

adanya perbedaan hasil yang dicapai oleh setiap unit *hidden neuron*.

Berdasarkan grafik pada Gambar 6, semakin banyak jumlah *hidden neuron* yang digunakan semakin kecil rata-rata nilai MAPE yang didapatkan. Nilai *hidden neuron* yang semakin besar akan membentuk banyak penghubung (*connector*) dengan *input layer* dan *output layer*. Kondisi ini memungkinkan unit pemroses pada sistem yang melakukan proses pembobotan untuk mengenali data memiliki kemampuan yang baik dengan semakin banyaknya pertimbangan keputusan yang dilakukan oleh *hidden node*.

6. PENUTUP

6.1. Kesimpulan

Berdasarkan hasil pengujian dan pembahasan dari peramalan produksi gula pasir menggunakan *Extreme Learning Machine* (ELM) maka diperoleh kesimpulan sebagai berikut:

1. Metode *Extreme Learning Machine* dapat digunakan dalam peramalan produksi gula pasir yang menghasilkan nilai *error* terkecil dengan melibatkan jumlah *hidden layer* dan *random input weight*. *Hidden layer* pada ELM terdiri dari *node-node* yang berfungsi sebagai unit pemrosesan yang menghubungkan *input layer* dengan *output layer*. Banyaknya *hidden node* pada bagian *hidden layer* mempengaruhi hasil perhitungan dari suatu permasalahan dimana *hidden node* mengolah semua masukan yang nantinya menjadi keluaran. Pada *hidden layer* terdapat parameter *input weight* yang terhubung dengan *input layer* dan *output weight* yang terhubung pada *output layer*.
2. Perbedaan *range input weight* berpengaruh terhadap nilai MAPE yang didapatkan. Semakin lebar interval *range* yang digunakan memungkinkan untuk lebih banyak mendapatkan nilai *input weight* terbaik berdasarkan hasil *random*. Perbandingan jumlah data *training* dan data *testing* serta penambahan jumlah *hidden layer* berpengaruh terhadap *output* peramalan yang dihasilkan. Tingkat kesalahan yang rendah berdasarkan pengujian yang dilakukan dengan nilai MAPE yaitu sebesar 0.74% pada *range input weight* [-1,1] dan perbandingan jumlah data *training* dan data *testing* yaitu 80%:20% serta jumlah *hidden layer* sebanyak 12 menggunakan analisis fundamental. Analisis fundamental memiliki tingkat kesalahan yang lebih baik dibanding dengan analisis teknikal dan gabungan. Hal ini karena pada analisis fundamental melibatkan faktor-faktor yang mempengaruhi proses produksi gula.

6.2. Saran

Berdasarkan penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dikembangkan untuk penelitian selanjutnya yaitu:

1. Untuk penelitian selanjutnya, peneliti dapat menambahkan parameter lain yang merupakan faktor-faktor dalam produksi gula. Hal ini bertujuan agar hasil peramalan lebih obyektif, dimana semakin banyak parameter faktor produksi yang digunakan akan menghasilkan hasil yang lebih baik.
2. Pengembangan metode atau penggabungan metode lain dengan ELM seperti *Optimally Pruned* metode *Extreme Learning Machine* (OPELM) dapat digunakan pada penelitian selanjutnya untuk meningkatkan hasil yang didapat dari penelitian sebelumnya.

DAFTAR PUSTAKA

- Adi Pangestuti, Nita. 2013. *Implementasi Pelatihan Jaringan Syaraf Tiruan Dengan Algoritma Genetika Untuk Peramalan Cuaca*. Jurusan Informatika/Illmu Komputer Universitas Brawijaya. Malang.
- Anam, Khoirul. 2012. *Setting TCSC dan SVC Menggunakan Extreme Learning Machine (ELM) untuk Menjaga Kestabilan Tegangan Akibat Kontingensi*. Jurusan Teknik Elektro Institut Teknologi Sepuluh Nopember (ITS). Surabaya.
- Atmojo, T. B., Pulungan, R., Syahputra, H. 2013. *Pengembangan Model Peramalan Permintaan Kebutuhan Reseller Menggunakan Extreme Learning Machine Dalam Konteks Intelligent Warehouse Management System (IWMS)*. Jurusan Ilmu Komputer Universitas Gadjja Mada. Yogyakarta.
- Dwi Agustina, Irwin. 2009. *Penerapan Metode Extreme Learning Machine Untuk Peramalan Permintaan*. Jurusan Sistem Informasi Institut Teknologi Sepuluh November. Surabaya.
- Fardani, Delia Putri. 2015. *Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus: Poli Gigi RSU Dr. Wahidin Sudiro Husodo Mojokerto)*. Vol.1, No. 1, April 2015. Universitas Airlangga.
- Huang, G. B., Zhu, Q.Y., dan Siew, C. K. 2004. *Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks*. Proceeding of International Joint Conference on Neural Networks. Hungary.

Huang, G. B., Zhu, Q.Y., dan Siew, C. K. 2006. *Extreme Learning Machine : Theory and Application*. Elsevier science : Neurocomputing.

Khotimah, B. K., Sari R, E. M., Yulianarta, H. 2010. *Kinerja Metode Extreme Learning Machine (ELM) Pada Sistem Peramalan*. Jurusan Teknik Informatika Universitas Trunojoyo. Madura.

Makridakis, S., Wheelwright, S. C. & McGee, V. E., 1999. *Forecasting 2nd Edition (Metode dan Aplikasi Peramalan)*. Jakarta : Penerbit Erlangga.

Napitupulu, D.A. 2013. *Faktor-Faktor yang Mempengaruhi Produksi Gula Dalam Negeri dan Proyeksi Produksi dan Konsumsi Gula di Indonesia*. Universitas Atmajaya. Yogyakarta.

Patro, S.G.K., Sahu, K.K., 2015. *Normalization: A Preprocessing Stage*. Department of CSE & IT, VSSUT, Burla, Odisha, India.

Shamshirband, Shahaboddin., Mohammadi, Karsa.,Tog, Chong Wen., Petkovic, Dalibor., Porcu, Emilio., Mostafaepour, Ali., Ch, Sudheer., dan Sedaghat, Ahmat. 2015. *Application of extreme learning machine for estimation of wind speed distribution*. Springer-Verlag Berlin Heidelberg.

Subagyo, Pangestu. 1986. *Forecasting Konsep dan aplikasi* . Yogyakarta: BPPE UGM.

Widarwati, Tutik. 2008. *Analisis Faktor-Faktor yang Mempengaruhi Produksi Gula di PG Pagottan*. Institut Pertanian Bogor. Bogor.

