

## PEMODELAN PENDUGAAN RENDEMEN TEBU BERBASIS SIFAT BIOLISTRIK DAN *ARTIFICIAL NEURAL NETWORK*

Sucipto Sucipto<sup>1,2)\*</sup>, Rhamdani Widyo Utomo<sup>1)</sup>, Dimas Firmanda Al-Riza<sup>3)</sup>,  
Simping Yuliatun<sup>4)</sup>, Supriyanto Supriyanto<sup>5)</sup>, Agus Supriatna Somantri<sup>6)</sup>

<sup>1)</sup>Departemen Teknologi Industri Pertanian - Fakultas Teknologi Pertanian, Universitas Brawijaya

<sup>2)</sup>Halal-Qualified Industry Development (Hal-Q ID), Universitas Brawijaya

<sup>3)</sup>Departemen Keteknikan Pertanian - Fakultas Teknologi Pertanian, Universitas Brawijaya

<sup>4)</sup>Pusat Penelitian Perkebunan Gula Indonesia

<sup>5)</sup>Departemen Teknik Mesin dan Biosistem IPB

<sup>6)</sup>Balai Besar Penelitian dan Pengembangan Pascapanen Pertanian

Jl. Veteran No. 1 Malang 65145

\*email korespondensi: [ciptotip@ub.ac.id](mailto:ciptotip@ub.ac.id)

(Naskah masuk: 27 Januari 2018, diterima untuk diterbitkan: 10 Agustus 2018)

### Abstrak

Rendemen tebu digunakan sebagai parameter kualitas tebu dan acuan dalam pembagian hasil panen oleh petani dan pabrik gula. Saat ini, pengukuran rendemen tebu menggunakan parameter indeks bias dari sampel nira tebu, sehingga perlu persiapan sampel yang cukup lama. Karena itu, perlu dikembangkan metode pengukuran rendemen tebu yang singkat dan akurat, yaitu dengan teknik pengukuran berbasis sifat biolistrik dan model *artificial neural network* (ANN). Tujuan penelitian ini yaitu untuk mengetahui hubungan sifat biolistrik pada berbagai ruas tebu dan waktu tunda giling serta pengembangan model ANN untuk pendugaan rendemen tebu berbasis sifat biolistrik. Pada penelitian ini digunakan rancangan acak kelompok dengan dua faktor dalam pengukuran sifat biolistrik. Faktor pertama adalah ruas tebu (atas, tengah, dan bawah) dan waktu tunda giling sebagai faktor kedua (hari ke-0, 1, dan 2). Input ANN yang digunakan adalah sifat biolistrik meliputi frekuensi, kapasitansi (C), konstanta dielektrik (k), dan impedansi (Z). Hasil model topologi ANN terpilih adalah 4-40-30-1, dengan 4 *node* (frekuensi, kapasitansi, konstanta dielektrik, dan impedansi) sebagai *input layer* serta rendemen tebu sebagai satu-satunya *node* pada *output layer*. Topologi ANN terpilih dapat memprediksi rendemen tebu dengan akurasi 99,13% saat *training* dan 97,29% saat *testing* lebih tinggi dari penelitian sebelumnya dengan analisis regresi yang hanya menghasilkan akurasi 50%.

**Kata kunci:** *Artificial neural network, Biolistrik, Rendemen Tebu, Tebu*

## **MODELLING SUGAR RECOVERY PREDICTION USING BIOELECTRICAL PROPERTIES AND ARTIFICIAL NEURAL NETWORK**

### Abstract

*Sugar recovery has become sugarcane quality parameters and reference in profit share between farmers and sugar mills. Nowadays, measurement of sugar recovery is using refractive index parameters from sugar juice sample, consequently need a long-time sample preparation. Therefore, it is necessary to develop a concise and accurate method for sugar recovery measurement, which can be archived using combination of bioelectrical properties measurement and artificial neural network (ANN) models. The purpose of this study is to determine the effect of sugarcane segments and delay times of milled canes to the bioelectrical properties and then develop an ANN model to predict the sugar recovery based on the bioelectrical properties. A randomized block design was carried out using two factors in the measurement of bioelectrical properties. The first factor is the sugarcane segments (top, center, and bottom) and delay time of milled cane as the second factors (0, 1, and 2 days). ANN inputs were bioelectrical properties included frequency, capacitance (C), dielectric constant (k) and impedance (Z). The selected ANN topology model which is composed 4-40-30-1, with 4 nodes (frequency, capacitance, dielectric constant and impedancy) of input layer and sugar recovery as the only node in output layer. The selected topology could predict sugar recovery with the accuracy is for training 99.13% and for testing 97.29%, while in the previous research using regression analysis the highest accuracy only reached 50%.*

**Keywords:** *Artificial Neural Network, Bioelectrical Properties, Sugar recovery, Sugarcane*

## 1. PENDAHULUAN

Rendemen tebu menyatakan banyak kg gula yang diperoleh per kuintal tebu (Susila & Sinaga, 2005). Gula merupakan kristal dari sukrosa. Dengan demikian penentuan rendemen gula dilakukan dengan mengukur sukrosa dan turunannya pada tebu. Pengukuran sukrosa dan turunannya secara konvensional dengan pendekatan derajat pol dan brix pada nira tebu. Akan tetapi, pengukuran tersebut perlu persiapan sampel cukup lama dan tenaga terampil. Karena itu, perlu dikembangkan teknik analisis cepat, menggunakan metode lebih praktis dibanding metode sebelumnya. Teknik tersebut mempermudah hal-hal teknis lain termasuk dalam pengambilan kebijakan seperti penentuan hasil bagi antara petani dan pabrik gula.

Sistem pengukuran rendemen yang praktis diduga dapat memanfaatkan sifat listrik. Sifat listrik bahan meliputi sifat dielektrik, konduktivitas, impedansi atau lainnya. Beberapa peneliti telah menggunakan sifat listrik untuk pengembangan sistem instrumentasi nira tebu (Naderi-Boldaji dkk., 2015). Perbedaan komposisi bahan berpengaruh pada perbedaan sifat listrik seperti konduktansi, impedansi, kapasitansi, dan konstanta dielektrik (Juansah, 2013). Komposisi sukrosa dan komponen lain pada tebu memengaruhi sifat listrik tebu yang dijadikan dasar deteksi cepat rendemen tebu.

Faktor lain yang memengaruhi sifat listrik adalah penundaan masa giling tebu. Faktor tersebut perlu diperhatikan karena selalu ada tebu yang menunggu penggilingan. Masa tunggu giling dapat 12 jam, 24 jam, hingga 48 jam. Penundaan tebu digiling memengaruhi penyusutan bobot dan kadar gula tebu.

Posisi ruas tebu diduga memengaruhi sifat listrik tebu. Hal ini karena perbedaan komposisi setiap ruas tebu. Menurut Mulyadi (2006), posisi ruas pada batang sangat memengaruhi tingkat kemanisan dan kadar brix, semakin ke atas tingkat kemanisannya berkurang. Karakteristik sifat listrik bahan tersebut, nanti dapat digunakan sebagai acuan dalam pemodelan pendugaan rendemen tebu.

Pemodelan berbasis sifat listrik telah banyak dilakukan seperti penggunaan regresi linear dalam pendugaan kadar air tebu (Taghinezhad dkk., 2012) dan *multiple linear regression* untuk pendugaan derajat pol dan brix pada tebu (Naderi-Boldaji dkk., 2015), bahkan dikembangkan model berbasis *machine learning* seperti *Bayesian network*, *Support vector machine*, dan ANN sehingga didapat model yang lebih kuat dan akurat (Soltani & Omid, 2015). Penelitian sebelumnya menggunakan analisis regresi didapat hubungan sifat listrik dan rendemen tebu yang masih rendah (Sucipto dkk., 2016), sehingga dalam penelitian ini dikembangkan model ANN yang terbukti dari beberapa penelitian dapat memodelkan permasalahan kompleks dengan baik.

Beberapa penelitian menunjukkan *machine learning* menggunakan ANN dapat diandalkan dalam pemodelan kompleks seperti pendugaan kesegaran telur (Soltani & Omid, 2015), tingkat kadaluarsa wafer (Saleh dkk., 2013), dan pengembangan *machine vision* untuk berbagai produk seperti pengeringan kunyit (Zakaria dkk., 2017), dan kontrol pengeringan *Sunagoke moss* (Hendrawan & Murase, 2011). ANN adalah sistem pemroses informasi yang memiliki karakteristik mirip jaringan syaraf biologi. Menurut Benković dkk. (2015), ANN memiliki karakteristik unik dibanding model lain, yaitu memiliki kapabilitas 'belajar' dari data yang diberikan. Karakteristik tersebut memungkinkan ANN digunakan menangani masalah kompleks.

Pada penelitian ini dilakukan pemodelan ANN berbasis biolistrik untuk memprediksi rendemen tebu. Input data yang digunakan berupa frekuensi, kapasitansi, konstanta dielektrik, dan impedansi, sedang targetnya adalah rendemen tebu. Model ANN tersebut diharapkan mampu menduga rendemen tebu secara praktis dan tepat tanpa merusak tebu sehingga dapat mendukung pengembangan pengukuran cepat rendemen tebu.

## 2. METODE PENELITIAN

Penelitian dilakukan di Laboratorium Pusat Penelitian Perkebunan Gula Indonesia (P3GI) Pasuruan dan Laboratorium Instrumentasi Jurusan Fisika, Fakultas MIPA, Universitas Brawijaya. Alat yang digunakan adalah pemotong tebu, penggaris, jangka, LCR meter, timbangan, paralel plate kapasitor, dan pengatur suhu. Bahan yang digunakan adalah tebu dari P3GI Pasuruan varietas PSJK berumur 11-12 bulan. Panjang tebu pada penelitian ini adalah  $\pm 3$  cm. Pengujian sifat biolistrik yang digunakan adalah kapasitansi (C), impedansi (Z), dan konstanta dielektrik. Diagram alir penelitian pada Gambar 1. Teknis pengukuran sifat biolistrik pada tebu telah dikembangkan dan diteliti oleh penulis (Sucipto, dkk, 2016).

Percobaan menggunakan Rancangan Acak Kelompok (RAK) yang tersusun 2 faktor yaitu penundaan waktu giling dan ruas tebu. Faktor I (waktu tunda giling) terdiri dari 3 level yakni hari ke-0, 1 dan 2 dan faktor II (ruas tebu) terdiri dari 3 level yakni ruas atas, tengah, dan bawah, sehingga diperoleh 9 kombinasi perlakuan yang diulang 3 kali. Kombinasi perlakuan pada Tabel 1.

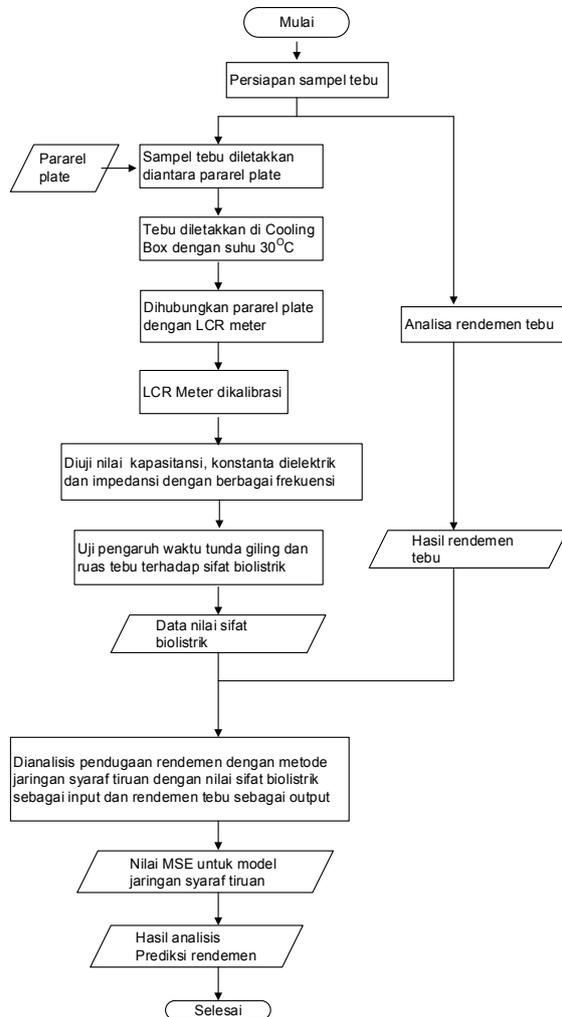
Tabel 1. Kombinasi Perlakuan dari Beberapa Faktor

waktu tunda giling	W1	W2	W3
Ruas tebu			
R1	W1R1	W2R1	W3R1
R2	W1R2	W2R2	W3R2
R3	W1R3	W2R3	W3R3

Analisis rendemen dilakukan pada satu area tebu yang diuji sifat biolistriknnya. Penjelasan teknis analisis rendemen sebagai berikut.

1. Batang tebu dihilangkan pucuk tebu kira-kira 40 cm dari ujung daun tebu yang masih menggulung.
2. Batang tebu dikelompokkan menjadi 3 bagian, yaitu bagian atas, tengah, dan bawah.
3. Batang tebu ditimbang dan dicatat berat tebu.
4. Batang tebu digiling.
5. Selanjutnya dianalisis brix dan pol.

Menurut Santoso (2011) %brix adalah zat padat kering terlarut dalam larutan (gr/100gr larutan) yang dihitung sebagai sukrosa. Persen pol adalah jumlah gula (gr) yang terlarut dalam 100 gram larutan yang mempunyai kesamaan putaran optik dengan sukrosa murni.



Gambar 1. Diagram alir penelitian

Analisis rendemen tebu menggunakan rumus berikut.

$$\text{Rendemen} = \text{FR} \times \text{NN NPP}$$

$$\text{FR} = \text{KNT} \times \text{HPB total} \times \text{PSHK} \times \text{WR} \quad (3.1)$$

Keterangan:

FR : Faktor rendemen yang besarnya dipengaruhi oleh kadar nira dalam tebu dan efisiensi teknis pabrik.

NN NPP: Nilai nira dari nira perahan pertama, yaitu ukuran kualitas nira yang diambil dari gilingan pertama dihitung berdasar rumus:

NN NPP = pol - 0,4 (brix-pol), dimana pol adalah kadar gula dalam nira perahan pertama dan Brix adalah kadar bahan padat terlarut dalam nira perahan pertama.

KNT : Kadar nira dalam tebu.

HPB total: Efisiensi pemerahan gula oleh pabrik.

PSHK : Tingkat kehilangan/kerusakan gula pada gilingan.

WR : Tingkat efisiensi stasiun pengolahan dalam menghasilkan gula dari nira yang ada.

Pengolahan data menggunakan *neural network backpropagation*. Data sifat biolistrik dan rendemen dibagi menjadi dua yakni data *training* 70% dan data *testing* 30%. Data dinormalisasi dengan skala -1 hingga 1. Data dimodelkan dengan jumlah *node hidden layer*. Pemodelan data dihasilkan berbagai nilai MSE, kemudian model dengan nilai MSE terkecil digunakan untuk pengujian pada data *testing*.

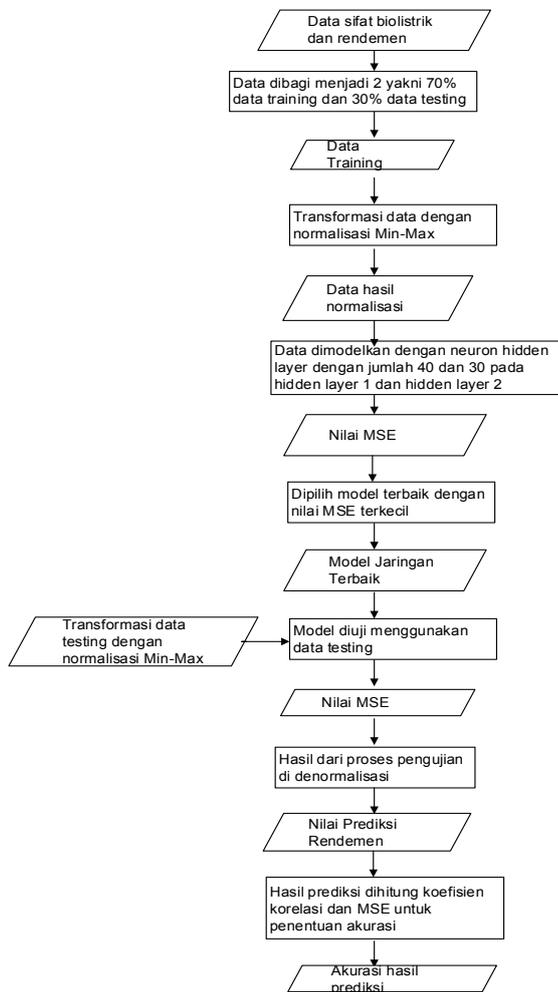
Pada tahap *testing* model terpilih diuji menggunakan data *testing* yang sudah dinormalisasi dengan skala -1 hingga 1. Setelah didapat nilai MSE, hasil proses pengujian di denormalisasi dan dihasilkan nilai prediksi rendemen. Kemudian diuji korelasi untuk mengetahui korelasi dengan data rendemen dari hasil uji laboratorium. Diagram pengolahan data dapat dilihat pada Gambar 2.

Data penelitian ini diperlukan untuk membuat model ANN. Data *input* digunakan untuk prediksi rendemen tebu. Data *input* terdiri dari frekuensi, kapasitansi, impedansi, dan konstanta dielektrik.

Data awal dari hasil pengukuran sifat biolistrik dilakukan *preprocessing* untuk menghilangkan data yang anomali menggunakan teknik data *cleaning*. Menurut Singhal & Jena (2013), untuk membersihkan data yang tidak berkualitas perlu *preprocessing*. Dalam pengolahan data, kualitas data dapat diukur dalam hal akurasi, kelengkapan, konsistensi, ketepatan waktu, *believability* dan *interpretability*.

Selanjutnya, hasil data *cleaning* tersebut dilakukan transformasi menggunakan metode normalisasi Min-Max yang nanti digunakan sebagai input ANN. Panchal dkk. (2011) menyatakan ANN menggunakan data normalisasi pada *range* (-1,1) pada nilai *input* dan *output*. Normalisasi dibuat membagi setiap variabel *input* aktual oleh nilai maksimum. Model ANN yang digunakan adalah *backpropagation* yang terdiri dari *input layer*, *output layer*, dan satu atau lebih *hidden layer*. Dari 3 layer tersebut, *input layer* memiliki 4 *node* dan *output layer* memiliki satu *node*.

Sebelum *training* dilakukan, fungsi pelatihan dimodifikasi agar optimal dalam pelatihan, sehingga hasil *training* baik. Dalam pengembangan ANN ada dua langkah dasar yaitu *training* dan *validation*.



Gambar 2. Diagram pengolahan data

Saat *training* data, parameter pemodelan disesuaikan agar mendapat prediksi output terbaik. Parameter jumlah *node* pada *hidden layer* ditentukan saat *training*. Parameter tersebut berpengaruh pada nilai error pada prediksi. Jumlah *node* pada *hidden layer* dapat ditentukan sebagai berikut (Gallo dkk., 2005):

$$n_{hl} = (n_{in} + n_{out}) : 2 + \sqrt{n_l} \dots \dots \dots (1)$$

Menurut Basheer & Hajmeer (2000), banyak *node* pada *hidden layer* merupakan parameter pembelajaran penting, karena memungkinkan terjadi kondisi *overfitting* atau *underfitting*. *Underfitting* terjadi ketika banyak *node* pada *hidden layer* terlalu sedikit. Jaringan tidak dapat menghasilkan *output* mendekati nilai target dan terlalu banyak menyamaratakan *output*. Sebaliknya, *overfitting* terjadi ketika *node* pada *hidden layer* terlalu banyak. Jaringan akan lebih menjadi *memorizing* daripada

*generalizing*. Dengan kata lain kemampuan mengeneralisasi jaringan menjadi menurun.

Parameter lain dalam *training* adalah jumlah iterasi maksimal ditetapkan 5000, *learning rate* 0,1, dan momentum 0,9. Parameter tersebut dimodelkan dengan beberapa perlakuan untuk mencari akurasi terbaik untuk prediksi.

Langkah awal *training* digunakan 1 dan 2 *hidden layer* serta jumlah *node* seperti rumus ke-1. Menurut Karsoliya (2012), peningkatan jumlah *hidden layer*, akurasi akan bertambah, tetapi waktu pelatihan semakin meningkat. Jika akurasi adalah kriteria utama maka *hidden layer* dapat ditingkatkan.

Hasil akhir dari tahap *training* didapat model ANN dengan bobot terbaik. Setelah diketahui model ANN terbaik, model tersebut diuji menggunakan data *testing* sehingga didapat nilai akurasi terbaik. Proses *testing* dilakukan dengan simulasi data *testing* menggunakan model terbaik sehingga menghasilkan *output*. *Output* dibandingkan target data *testing* untuk didapatkan koefisien korelasi dan akurasinya.

### 3. HASIL DAN PEMBAHASAN

Tebu PSJK-922 merupakan tebu varietas baru yang dirilis pemerintah awal tahun 2012. Singkatan PSJK adalah Pasuruan Jengkol, tempat kelahiran varietas baru tanaman asli Papua Nugini itu. Varietas unggul ini hasil kerja sama antara Pusat Penelitian Perkebunan Gula Indonesia (P3GI) di Pasuruan dan PT. Perkebunan Nusantara PTPN X di Jengkol, Kabupaten Kediri.

Menurut Budiarto (2012) PSJK-922 memiliki rendemen tinggi, yakni 9%. Varietas sebelumnya seperti BL hanya menghasilkan 8 kg gula per kuintal tebu segar atau rendemen 8%. Kelebihan varietas PSJK-922 adalah memiliki pelepah yang mudah lepas.

#### 3.1. Keterkaitan Hasil Uji Tebu dengan Waktu Penundaan pada Ruas Tebu

Hasil uji parameter tersebut dapat dilihat pada Tabel 2.

Tabel 2. Berberapa Parameter Nilai Rendemen Uji Tebu

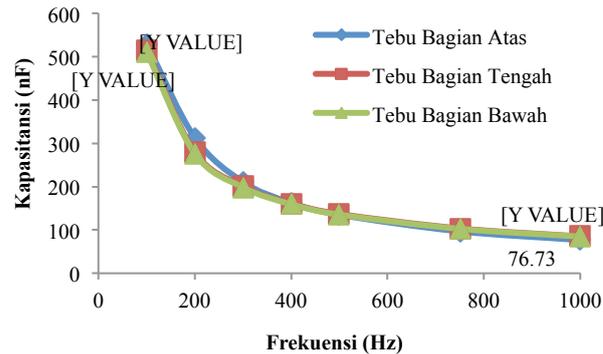
Perlakuan Waktu Tunda Giling (Hari)	Rendemen Tebu Pada Ruas (%)		
	Atas	Tengah	Bawah
0	8,76	11,29	12,28
1	8,67	11,83	12,95
2	7,96	11,13	12,57

Tabel 2 menunjukkan ruas bagian bawah memiliki rendemen lebih besar dari ruas tebu lain. Rendemen cenderung menurun pada waktu tunda giling dipengaruhi oleh penurunan sukrosa tebu. Penurunan sukrosa saat penundaan setelah penebangan mungkin karena kontaminasi bakteri. Mikroba pada tebu dapat memanfaatkan gula sebagai sumber energi. Hal ini sesuai pendapat

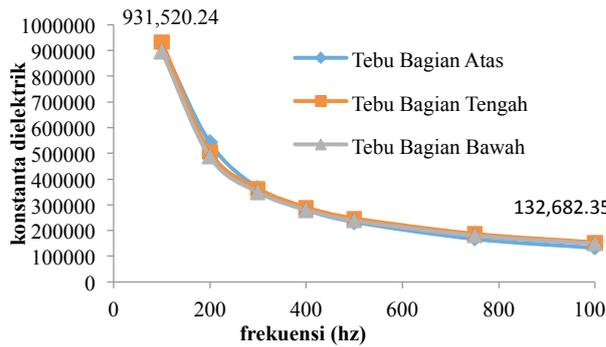
Mulyadi (2006) bahwa keterlambatan waktu giling sangat berpengaruh pada kehilangan gula. Sesaat setelah dipotong batang tebu terinfeksi mikroba dan bakteri. Meski dalam jumlah kecil, mikroba memanfaatkan gula pada batang tebu sebagai sumber energi.

### 3.2. Keterkaitan Kapasitansi dan Konstanta Dielektrik dengan Ruas Tebu

Hasil pengukuran kapasitansi dan konstanta dielektrik ruas tebu pada Gambar 3.



(a)



(b)

Gambar 3. Pengaruh Nilai Frekuensi Terhadap Nilai Kapasitansi (a) dan Nilai Konstanta Dielektrik (b) Pada Ruas Bagian Tebu

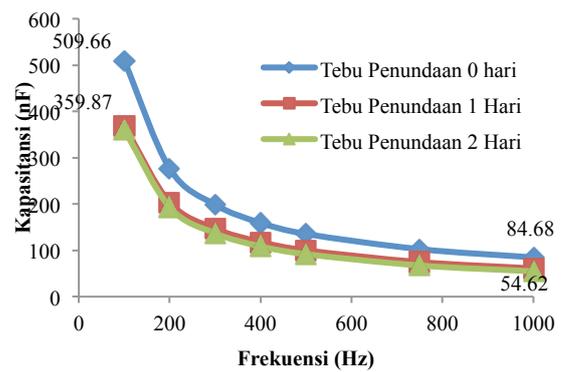
Pada Gambar 3, rata-rata nilai kapasitansi dan konstanta dielektrik menurun seiring naiknya frekuensi. Penurunan nilai kapasitansi karena penyearahan momen dipol pada molekul-molekul penyusun tebu. Nilai kapasitansi berbanding lurus dengan nilai konstanta dielektrik. Menurut Schmitt (2002), bertambahnya konstanta dielektrik seiring dengan kapasitansi. Jika ingin membuat kapasitor dengan bentuk kecil tetapi memiliki kapasitansi besar, maka material berada diantara plat memiliki nilai konstanta dielektrik yang besar. Kapasitansi dan konstanta dielektrik tebu sangat dipengaruhi bahan penyusunnya, termasuk sukrosa.

Sukrosa merupakan senyawa polar karena memiliki banyak ikatan oksigen-hidrogen, dimana menurut Akode dkk. (2004) oksigen memiliki elektronegatif tinggi, oksigen membawa muatan negatif dan hidrogen memiliki muatan positif.

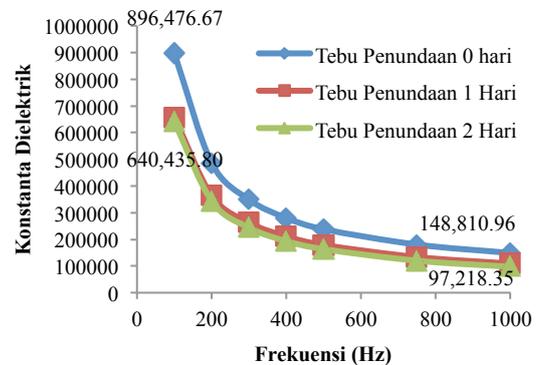
Menurut Nelson & Trabelsi (2012), senyawa polar dapat menyebabkan meningkatnya nilai kapasitansi dan senyawa nonpolar dapat menyebabkan menurunnya nilai kapasitansi. Nilai kapasitansi berbanding lurus dengan nilai konstanta dielektrik, sehingga senyawa polar juga dapat menyebabkan meningkatkan nilai konstanta dielektrik.

### 3.3. Keterkaitan Kapasitansi dan Konstanta Dielektrik dengan Waktu Tunda Tebu

Nilai kapasitansi dan konstanta dielektrik berdasar waktu penundaan pada Gambar 4.



(a)



(b)

Gambar 4. Pengaruh Frekuensi Terhadap Kapasitansi (a) dan Nilai Konstanta Dielektrik (b) Pada Waktu Tunda Giling

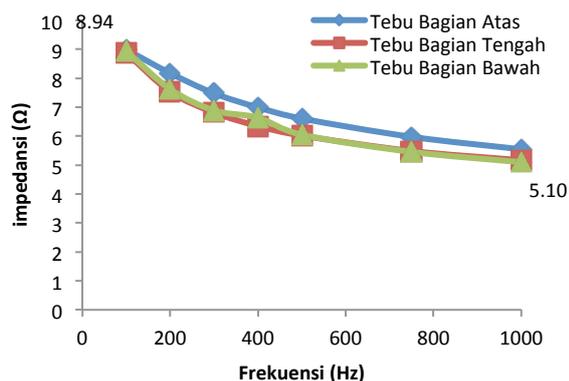
Gambar 4 menunjukkan bahwa nilai kapasitansi dan konstanta dielektrik tebu menurun jika tebu mengalami penundaan. Hal itu disebabkan kandungan sukrosa cenderung menurun dan kadar air tebu juga menurun saat disimpan, sehingga kadar gula berkurang. Menurut Naderi-Boldaji dkk. (2015), kehilangan gula dari saat tebang sampai akhir pengolahan dapat mencapai 35%. Kehilangan terjadi saat tebang sampai akhir pengolahan mencapai 5-25%. Kehilangan ini terutama disebabkan tebu mengalami penundaan giling.

Daerah-daerah kutub akan mengaitkan satu molekul sukrosa ke molekul lainnya untuk membuat gula padat. Menurut Nelson (2015), senyawa polar

adalah senyawa dengan momen dipol lebih besar dari nol karena molekul yang menyusun tidak sejenis dan memiliki perbedaan keelektronegatifan serta mempunyai struktur bangun asimetris. Selain itu, tetapan dielektriknya tinggi.

### 3.4 Keterkaitan Impedansi dengan Ruas Tebu

Nilai impedansi ruas tebu akibat perbedaan frekuensi seperti Gambar 5.



Gambar 5. Impedansi Pada Berbagai Ruas Bagian Tebu

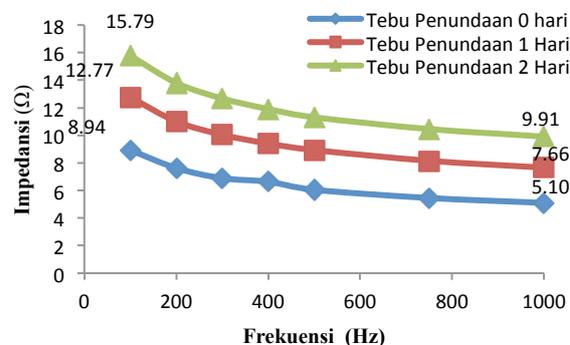
Nilai impedansi pada Gambar 5 sebagian dipengaruhi frekuensi. Semakin besar frekuensi maka impedansi semakin menurun. Impedansi listrik bertindak sebagai gesekan gerakan muatan listrik pada bahan. Besaran impedansi listrik dalam rangkaian dipengaruhi oleh frekuensi, resistansi, dan reaktansi. Pada frekuensi sangat rendah reaktansi menjadi besar, sehingga impedansi besar juga. Ketika frekuensi meningkat, reaktansi menurun. Hal ini berkorelasi dengan penurunan impedansi (Juansah dkk., 2014). Menurut Nelson (2015) pada frekuensi yang lebih tinggi suatu jaringan biologis akan lebih menjadi konduktor, yaitu muatan-muatan pada jaringan akan lebih bebas bergerak dan lebih bersifat konduktif sehingga impedansi semakin kecil.

### 3.5 Keterkaitan Impedansi dengan Waktu Tunda

Nilai impedansi akibat waktu penundaan tebu seperti Gambar 6. Pada Gambar 6, nilai impedansi tebu pada hari ketiga cenderung lebih besar dari hari kedua, dan hari kedua lebih besar dari hari pertama. Pada hari ketiga, kadar air tebu cenderung berkurang karena menguap.

Kadar air dan sukrosa menurun seiring bertambahnya waktu tunda giling. Hal tersebut menyebabkan menurunnya nilai kapasitansi dan konstanta dielektrik serta menaikkan resistensi tebu. Menurut Simanjuntak (2002), air merupakan bahan polar yang memiliki nilai sifat dielektrik lebih tinggi dibanding zat-zat lain yang terkandung dalam bahan, sehingga semakin banyak air dalam bahan maka

nilai sifat dielektriknya semakin tinggi. Jika kadar air berkurang maka hambatan bertambah sehingga impedansi akan naik.



Gambar 6. Pengaruh Frekuensi dan waktu tunda giling Terhadap Impedansi

### 3.6 Pendugaan Rendemen Tebu Menggunakan Sifat Biolistrik dan ANN

Data sifat listrik yang didapat dianalisis dan digunakan sebagai *input* pemodelan ANN untuk pendugaan rendemen tebu, sebagian data input ANN ditampilkan pada Tabel 3. Sebelum diproses data *dipreprocessing* dengan normalisasi Min-Max.

Tabel 3. Data *Input* ANN

Freq*	Cp*	k*	Z*	Rendemen*
100	71,075	$1,22 \times 10^5$	64,32	8,76
300	43,561	$7,62 \times 10^4$	22,26	11,29
500	32,894	$5,75 \times 10^4$	19,53	7,96
750	29,317	$5,18 \times 10^4$	16,9	11,13
1000	23,401	$4,13 \times 10^4$	15,9	12,28

\* Freq = Frekuensi (Hz), Cp = Kapasitansi (F), k = konstanta dielektrik, Z = impedansi (Ω), Rendemen = rendemen sementara tebu (%)

Pemodelan ANN digunakan fungsi pelatihan dalam *trainlm*. Menurut Sharma & Venugopalan (2014) algoritma *trainlm* adalah algoritma terbaik dengan kecepatan tercepat. Algoritma *trainlm* dapat meningkatkan kinerja sistem. Algoritma *trainlm* lebih baik digunakan untuk jaringan kecil dan tidak dapat digunakan untuk jaringan besar. *Trainlm* adalah fungsi pelatihan standar tetapi perlu banyak memori untuk dijalankan.

### 3.7 Analisis Data Biolistrik untuk Prediksi Rendemen Tebu dengan ANN Tahap *Training*

Hasil *training* menunjukkan nilai *error* naik turun. Pada *hidden layer* tersebut didapat MSE terkecil pada jumlah *node* 40 pada *hidden layer* pertama dan *node* 30 pada *hidden layer* kedua. Nilai *error* kecil maka hasilnya semakin baik. Menurut Panchal dkk. (2011), jumlah *node* dan *hidden layer* meningkat, neural network akan mendapat kinerja lebih baik. Pemodelan dengan satu dan dua *hidden*

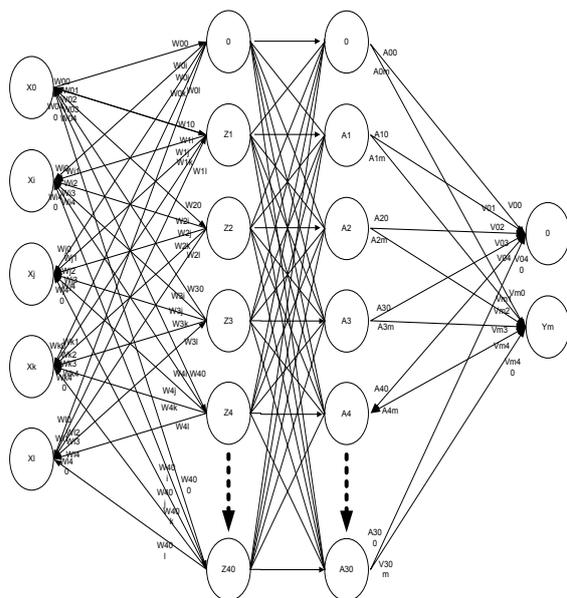
layer dengan berbagai jumlah *node hidden layer* dilakukan seperti pada Tabel 4.

Pada Tabel 4 di atas diartikan nilai akurasi terbesar diperoleh pada 2 *hidden layer* dengan jumlah *node* 40 pada *hidden layer* 1 dan 30 pada *hidden layer* 2, yakni sebesar 0,99139 dan nilai MSE 0,01. MSE merupakan nilai *error* yang didapat dari jaringan yang dilatih. Pada dasarnya semakin bertambah jumlah *node hidden layer* maka semakin lama waktu training. Jika akurasi merupakan kriteria utama penelitian maka jumlah *node* besar dengan nilai MSE kecil dan waktu cukup lama dapat dipilih.

Tabel 4. Sensitivitas *Node* dan *Hidden Layer*

Jumlah <i>Node Hidden layer</i>	Waktu (detik)	MSE	Akurasi (training)
30	309	0,222	0,78285
40	241	0,235	0,76892
30-30	162	0,01	0,99127
<b>40-30</b>	<b>348</b>	<b>0,01</b>	<b>0,99139</b>
40-40	637	0,01	0,99138

Semakin bertambah jumlah *node hidden layer*, nilai MSE cenderung semakin kecil. Menurut Karsoliya (2012), biasanya beberapa lapisan tersembunyi digunakan dalam aplikasi dimana akurasi adalah kriteria dan tidak ada batas waktu pelatihan. Topologi terpilih dari model pelatihan ini adalah *input* 4 *node*, *hidden layer* dengan 40 *node* pada *hidden layer* 1 dan 30 pada *hidden layer* 2 serta *output* 1 *node*. Bentuk dari model ANN pada Gambar 7.

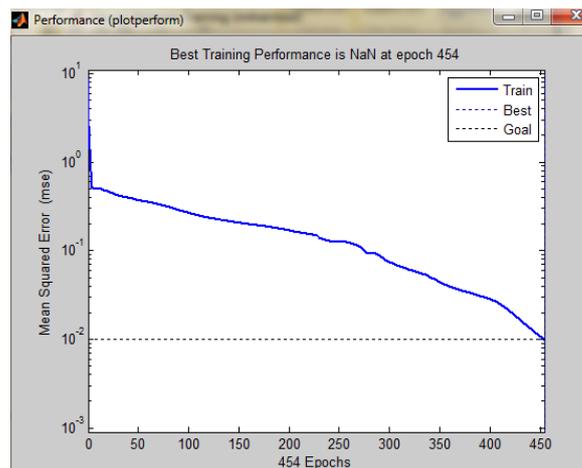


Gambar 7. Struktur model ANN terpilih

Pada tahap *training* didapat model ANN terbaik 4-40-30-1 (4 *node input* yakni frekuensi, kapasitansi, konstanta dielektrik, dan impedansi, 40 *node* pada *hidden layer* 1 dan 30 *node* pada *hidden layer* 2, dan 1 *node output* yakni rendemen).

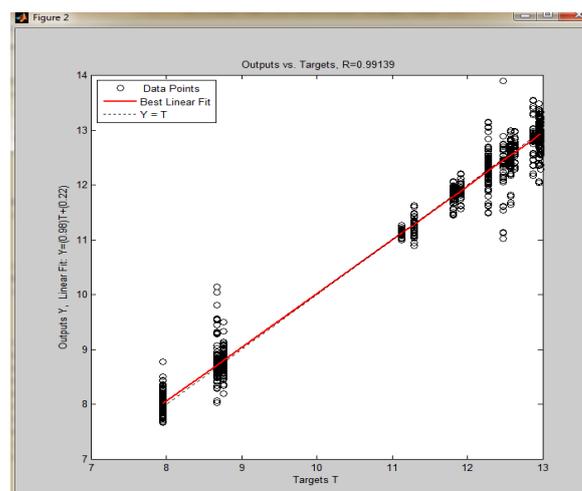
*Training* dengan iterasi 5000 dapat dilihat pada Gambar 8. MSE menurun dengan naiknya iterasi menunjukkan model sudah baik. MSE akhir mencapai *goal* dengan nilai 0,01 pada iterasi ke 454.

Hasil *training* dengan MSE terkecil serta akurasi terbesar, kemudian disimulasi pada *input* data *training*. Dari hasil simulasi didapat *output* dan dihitung koefisien korelasinya. Nilai koefisien korelasi 0,99139. Hasil plot regresi pada simulasi data *training* pada Gambar 9.



Gambar 8. Performansi ANN

Dari koefisien korelasi di atas, maka *output* mencapai akurasi 99,13%. Gambar 9 menunjukkan bahwa *output* merupakan nilai prediksi rendemen dari simulasi data *training* dan Target T merupakan target dari data *training* yang merupakan nilai rendemen. Nilai akurasi cukup tinggi pada *training* menunjukkan model jaringan tersebut layak digunakan saat *testing*.

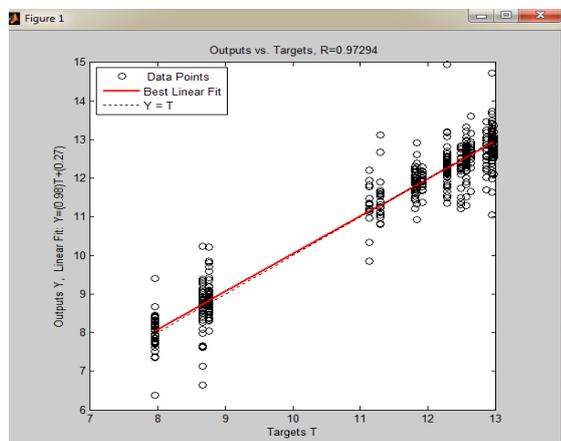


Gambar 9. Regresi hasil simulasi data *training*

### 3.8 Analisis Hasil Pengujian Model ANN pada Tahap *Testing*

Data *testing* untuk menguji model ANN hasil *training*. Hasil prediksi dari data *testing* mendekati

nilai target. Hasil simulasi didapat dari *input* data *testing* disimulasikan dengan jaringan terpilih dari tahap *training*. Nilai koefisien korelasi didapat melalui plot regresi didapat setelah simulasi hasil *testing* selesai. Hasil plot regresi dari hasil prediksi dan data aktual dapat dilihat pada Gambar 10.



Gambar 10. Regresi hasil simulasi data *testing*

Gambar 10 menunjukkan nilai plot regresi *output* hasil data *testing* dan target data *testing*. Target T merupakan nilai target data *testing* yakni nilai *testing* dan nilai rendemen *output*/prediksi dari data *testing*. Adanya data yang menyimpang dari garis linear menyebabkan menurunnya koefisien korelasi. Nilai rendemen aktual dan prediksi memiliki koefisien korelasi (R) cukup besar, yakni 0,97294. Tingkat akurasi tersebut jauh lebih tinggi dibanding model regresi seperti pada Tabel 5.

Tabel 5. Akurasi Model pada Pendugaan Rendemen Tebu

Model	Persamaan/ Topologi	Akurasi
ANN	4-40-30-1	0,9729
Exponential	$y = 10,22e^{0,0025x}$	0,505*
Linear	$y = 0,0297x + 10,153$	0,501*
Logarithmic	$y = 1,377\ln(x) + 6,3998$	0,470*
Polynomial	$y = -0,0002x^2 + 0,057x + 9,5059$	0,516*
Power	$y = 7,4237x^{0,1175}$	0,472*

\* data penelitian sebelumnya (Sucipto dkk., 2016)

Nilai koefisien korelasi ini cukup besar jika diuji dengan data *testing* membuktikan bahwa model jaringan dari proses *training* sudah baik. Menurunnya nilai akurasi dalam data *training* ke data *testing* karena jumlah data *training* lebih banyak. Banyak data dapat mempengaruhi nilai akurasi hasil. Menurut Jouyban (2009) sebagian besar model disediakan untuk prediksi, memiliki nilai *error* relatif tinggi. Kesalahan prediksi yang tinggi karena kesalahan terkait sifat model dan prosedur perhitungan, kualitas data berkontribusi pada salah satu sumber kesalahan pemodelan. Singkatnya, hasil pemodelan rendemen tebu dengan sifat biolistrik dan ANN mampu meningkatkan akurasi prediksi rendemen tebu.

#### 4. KESIMPULAN

Rendemen tebu ruas bawah lebih besar dibanding ruas tengah dan ruas atas. Nilai rendemen menurun seiring lama penundaan. Nilai kapasitansi dan konstanta dielektrik menurun seiring lama waktu penundaan. Nilai impedansi ruas tebu bagian atas cenderung lebih besar dari ruas tebu bagian lain. Nilai impedansi cenderung lebih besar saat tebu mengalami masa penundaan giling.

Hasil pengembangan model ANN berdasar data sifat biolistrik terpilih topologi 4-40-30-1. Empat *node* sebagai *input layer* yakni frekuensi, kapasitansi, konstanta dielektrik, dan impedansi. *Hidden layer* 1 ada 40 *node* dan *hidden layer* 2 ada 30 *node*, serta *output layer* 1 *node* yakni rendemen. Model ANN di atas mampu memprediksi rendemen tebu dengan akurasi tahap *training* sebesar 99,13% dan tahap *testing* 97,29% lebih tinggi dibanding penelitian sebelumnya menggunakan regresi dengan akurasi 50%. Model ANN tersebut berpeluang untuk dikembangkan sebagai alat ukur cepat rendemen tebu.

#### DAFTAR PUSTAKA

- AKODE, C., KANSE, K., LOKHANDE, M., KUMBHARKHANE, A. dan MEHROTRA, S. 2004. Dielectric relaxation studies of aqueous sucrose in ethanol mixtures using time domain reflectometry. *Pramana* 62(4) 973-981.
- BASHEER, I.A. dan HAJMEER, M. 2000. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 43(1) 3-31.
- BENKOVIĆ, M., TUŠEK, A.J., BELŠČAK-CVITANOVIĆ, A., LENART, A., DOMIAN, E., KOMES, D. dan BAUMAN, I. 2015. Artificial neural network modelling of changes in physical and chemical properties of cocoa powder mixtures during agglomeration. *LWT - Food Science and Technology* 64(1) 140-148.
- BUDIARTO 2012. Tak Tumbuh Di Bibir, Tebu Varietas Baru: Tinggi Produksi, Tinggi Rendemen, dan Bebas Penyakit. *Trubus*. 118-119.
- GALLO, C., LETIZIA, C. dan STASIO, G. 2005. Artificial neural networks in financial modelling. XXXVI EWGFM International Meeting "European Working Group on Financial Mathematics", Brescia.
- HENDRAWAN, Y. dan MURASE, H. 2011. Neural-Intelligent Water Drops algorithm to select relevant textural features for developing precision irrigation system using machine vision. *Computer Electronic in Agriculture* 77(2) 214-228.
- JOUYBAN, A. 2009. *Handbook of solubility data for pharmaceuticals*: CRC Press.

- JUANSAH, J. 2013. Kajian spektroskopi impedansi listrik untuk evaluasi kualitas buah jeruk keprok garut secara nondestruktif. *Ilmu Keteknikan Pertanian*. Bogor, Institut Pertanian Bogor.
- JUANSAH, J., BUDIASTRA, I.W., DAHLAN, K. dan SEMINAR, K.B. 2014. Electrical Properties of Garut Citrus Fruits at Low Alternating Current Signal and its Correlation with Physicochemical Properties During Maturation. *International Journal of Food Properties* 17(7) 1498-1517.
- KARSOLIYA, S. 2012. Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture. *International Journal of Engineering Trends and Technology* 3(6) 714-717.
- MULYADI 2006. Study on Technique Rendemen Determination Using Individual based Method at Mojopanggung Sugar Factory, Tulung Agung, East Java. *Teknologi Industri Pertanian*. Bogor, Institut Pertanian Bogor.
- NADERI-BOLDAJI, M., FAZELIYAN-DEHKORDI, M., MIREEI, S.A. dan GHASEMI-VARNAMKHAZI, M. 2015. Dielectric power spectroscopy as a potential technique for the non-destructive measurement of sugar concentration in sugarcane. *Biosystem Engineering* 140 1-10.
- NELSON, S.O. 2015. *Dielectric properties of agricultural materials and their applications*. London, UK: Elsevier Inc.
- NELSON, S.O. dan TRABELSI, S. 2012. Factors Influencing the Dielectric Properties of Agricultural and Food Products. *Journal of Microwave Power and Electromagnetic Energy* 46(2) 93-107.
- PANCHAL, G., GANATRA, A., KOSTA, Y. dan PANCHAL, D. 2011. Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering* 3(2) 332.
- SALEH, E.R.M., NOOR, E., DJATNA, T. dan IRZAMAN, I. 2013. Prediksi Masa Kedaluwarsa Wafer dengan *Artificial Neural Network* (ANN) Berdasarkan Parameter Nilai Kapasitansi. *Agritech* 33(4) 450-457.
- SANTOSO, B. 2011. Analisis kualitas nira dan bahan alur untuk pengawasan pabrikasi di pabrik gula. Pasuruan: Pusat Penelitian Perkebunan Gula Indonesia (P3GI).
- SCHMITT, R. 2002. *Electromagnetics explained: a handbook for wireless/RF, EMC, and high-speed electronics*: Newnes.
- SHARMA, B. dan VENUGOPALAN, K. 2014. Comparison of neural network training functions for hematoma classification in brain CT images. *IOSR-JCE* 16(1) 31-35.
- SIMANJUNTAK, T. 2002. Pengukuran nilai sifat dielektrik lada (*Piper nigrum*, L.) dan andaliman (*Zanthoxylum acanthopodium*, DC.). *Skripsi, Jurusan Teknik Pertanian, Fateta, IPB*.
- SINGHAL, S. dan JENA, M. 2013. A study on WEKA tool for data preprocessing, classification and clustering. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)* 2(6) 250-253.
- SOLTANI, M. dan OMID, M. 2015. Detection of poultry egg freshness by dielectric spectroscopy and machine learning techniques. *LWT--Food Sci. Technol.* 62(2) 1034-1042.
- SUCIPTO, S., AL RIZA, D.F., HASAN, M.L.A., YULIATUN, S., SUPRIYANTO, S. dan SOMANTRI, A.S. 2016. Pengaruh Ukuran Sampel, Frekuensi, dan Suhu terhadap Sifat Biolistrik Tebu (*Saccharum officinarum* L.) untuk Prediksi Cepat Rendemen Tebu. *Industria: Jurnal Teknologi dan Manajemen Agroindustri* 5(3) 140-148.
- SUSILA, W.R. dan SINAGA, B.M. 2005. Pengembangan industri gula Indonesia yang kompetitif pada situasi persaingan yang adil. *Jurnal Litbang Pertanian* 24(1) 1.
- TAGHINEZHAD, J., ALIMARDANI, R. dan JAFARI, A. 2012. Development of a capacitive sensing device for prediction of water content in sugarcane stalks. *Int J Adv Sci Technol* 44 61-68.
- ZAKARIA, M., HENDRAWAN, Y. dan DJOJOWASITO, G. 2017. Modeling in Drying Process of Turmeric (*Curcuma Domestica* Val.) Based on Machine Vision Use Artificial Neural Network. *Jurnal Teknologi Pertanian* 18(1) 11-20.

*Halaman ini sengaja dikosongkan*