



JURNAL STATISTIKA DAN SAINS DATA

Volume 3 Nomor 1, Oktober, 2025, 21-36

<https://journal.student.uny.ac.id/index.php/jssd>

<https://dx.doi.org/10.21831/jssd.v3i1.20233>

Penerapan metode Extreme Learning Machine (ELM) pada peramalan sertifikasi benih di Provinsi Jawa Timur

Gaida Amatullah*, Prodi Statistika FMIPA UNY
Dhoriva Urwatul Wustqa, Prodi Statistika FMIPA UNY
*e-mail: gaidaamatullah.2019@student.uny.ac.id

Abstrak. Penelitian ini bertujuan untuk mendapatkan model peramalan, hasil peramalan dan hasil akurasi peramalan sertifikasi benih UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri menggunakan metode *Extreme Learning Machine* (ELM) pada tahun 2023. Data yang digunakan merupakan data sekunder berupa data mentah bulanan dari tahun 2017 sampai tahun 2022 yang diperoleh langsung dari UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri. Tahapan metode ELM dimulai dari penentuan model peramalan untuk menentukan input, normalisasi data, proses *training*, proses *testing*, denormalisasi data, dan kemudian perhitungan akurasi. Hasil penelitian model peramalan dengan performa terbaik yaitu 6 input neuron untuk komoditas padi, 5 input neuron untuk komoditas jagung, dan 13 input neuron untuk komoditas kedelai. Ketiga komoditas tersebut menggunakan 20 hidden neuron. Hasil peramalan menunjukkan pola yang sama dengan periode sebelumnya yaitu mencapai angka sertifikasi benih yang tinggi pada akhir tahun bulan September untuk komoditas padi dan jagung, dan akhir tahun bulan Oktober untuk komoditas kedelai. Hasil akurasi peramalan baik untuk komoditas padi, jagung, dan kedelai dapat dikategorikan baik/layak dengan masing-masing tingkat kesalahan MAPE yaitu 2,08% untuk komoditas padi, 2,85% untuk komoditas jagung, dan 1,25% untuk komoditas kedelai.

Kata kunci: Peramalan, Sertifikasi Benih, *Extreme Learning Machine*

Abstract. This research aims to obtain a forecasting model, forecasting results and forecasting accuracy results for UPT PSBTH seed certification for the East Java Agriculture and Food Security Service Region III Kediri using the *Extreme Learning Machine* (ELM) method in 2023. The data is secondary data in the form of data monthly raw material from 2017 to 2022 obtained directly from UPT PSBTH East Java Agriculture and Food Security Service Region III Kediri. The stages of the ELM method start from determining the forecasting model to determine the input, normalizing the data, the training process, testing process, denormalizing the data, and then calculating forecasting accuracy. The research results of the forecasting model with the best performance are 6 input neurons for rice commodities, 5 input neurons for corn commodities, and 13 input neurons for soybean commodities. These three commodities use 20 hidden neurons. The forecasting results show the same pattern as the previous period, namely achieving high seed certification rates at the end of the year in September for rice and

corn commodities, and at the end of the year in October for soybean commodities. The forecast accuracy results for rice, corn and soybean commodities can be categorized as good/decent with each MAPE error rate being 2.08% for rice commodities, 2.85% for corn commodities and 1.25% for soybean commodities.

Keywords: Forecasting, Seed Certification, Extreme Learning Machine.

PENDAHULUAN

Padi, jagung dan kedelai adalah tiga komoditas tanaman pangan strategis. Ketiga komoditas tersebut tampaknya masih memiliki hasil produksi yang rendah. Diperoleh dari *cyber extension*, bahwa program perbenihan nasional telah berjalan sekitar 30 tahun, tetapi ketersediaan benih bersertifikat belum mencukupi kebutuhan potensialnya (Fitri, 2019). Ketersediaan benih bersertifikat secara nasional untuk padi baru sekitar 35%. Menurut Dirjen Tanaman Pangan (2016) penggunaan benih jagung hibrida saat ini masih tergolong rendah yaitu baru sekitar 56% dari total pertanaman. Penggunaan benih kedelai bersertifikat meningkatkan produksi kedelai sebesar 21% (Nurasa, 2007), walau demikian fakta lapangan menunjukkan jika penggunaan benih bersertifikat pada tanaman kedelai kurang dari 10% (Ditjentan, 2004). Produktivitas padi, jagung dan kedelai di Jawa Timur masih rendah, terutama karena sebagian masih menggunakan varietas produksi rendah, selain masalah mutu benih dan lingkungan produksi.

Berdasarkan informasi tersebut, dapat disimpulkan bahwa Indonesia masih harus melakukan peningkatan pemeliharaan tanaman pangan, khususnya padi jagung dan kedelai. Balai Pengawasan dan Sertifikasi Benih Tanaman Pangan dan Hortikultura (BPSPTPH) selaku lembaga yang berwenang harus berupaya yang terbaik untuk mempertahankan ketersediaan benih bersertifikat dengan selalu meningkatkan kinerja pengawasan dan peredaran benih. Membuat strategi instansi yang tepat dengan memberikan pelayanan prima bagi para produsen dan penyalur benih serta petani konsumen benih yang di tersebar di wilayahnya. Selain itu, untuk mendukung program pemerintah dalam upaya meningkatkan produksi dan produktivitas tanaman pangan, instansi harus berusaha meningkatkan mutu Sumber Daya Manusia Perbenihan. Terciptanya penyediaan benih dari varietas unggul yang berwawasan agribisnis dan berorientasi pada mutu memiliki 6 sasaran tepat yaitu tepat jumlah, tepat varietas, tepat mutu, tepat harga, tepat lokasi, dan tepat waktu. Dengan sasaran tersebut, instansi perlu melakukan pembinaan dan pengawasan terhadap produsen dan penyalur benih agar dapat memproduksi serta mengedarkan benih bermutu dari varietas unggul sesuai dengan ketentuan. Bentuk evaluasi bagi instansi dapat dilakukan dengan peramalan pada data sertifikasi benih untuk memperkirakan jumlah sertifikasi benih di masa yang akan datang pada periode tertentu.

Peramalan adalah dasar dari segala jenis perencanaan dimana hal ini sangat diperlukan untuk lingkungan yang tidak stabil yaitu menjembatani antara sistem dengan lingkungan (Makridakis et al., 1999). Hasil dari suatu peramalan lebih merupakan pernyataan atau penilaian yang dikuantifisir terhadap kondisi masa depan sebagai proyeksi teknis dari permintaan untuk jangka waktu tertentu. Pada umumnya, hasil dari suatu peramalan dikonversikan menjadi rencana yang strategis, keterikatan dengan sumber daya, dan ketetapan manajemen dalam usaha mencapai sasaran yang tepat. Dengan adanya peramalan sertifikasi benih, maka instansi mampu melangkah kedepan dengan lebih pasti. Instansi dapat memperoleh gambaran tentang keadaan masa depan, dalam hal ini apakah sertifikasi benih meningkat atau menurun pada waktu tertentu. Gambaran tersebut sangat penting bagi instansi, karena kebijakan instansi mungkin dipengaruhi oleh besarnya jumlah sertifikasi benih tersebut. Penelitian tentang peramalan sertifikasi benih sudah dilakukan pada komoditas kentang (Suryadi, 2015), akurasi hasil peramalan cukup tinggi yaitu sekitar 96%-98%.

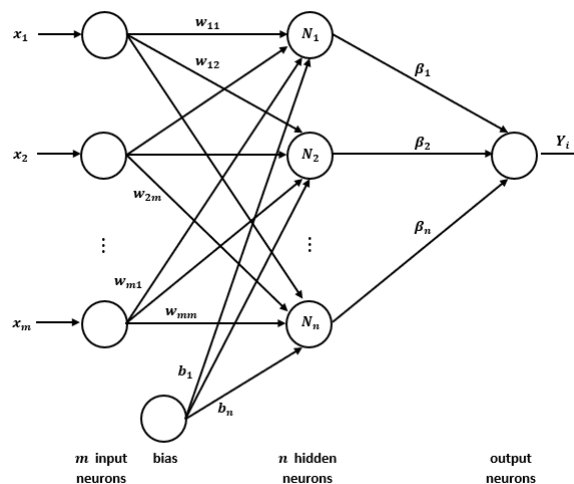
Terdapat beberapa metode peramalan, diantaranya peramalan kualitatif yakni berdasarkan pendapat para ahli dan analisis deskriptif, serta peramalan kuantitatif menggunakan hitungan matematis dengan metode statistika. Selain metode statistika yang umum digunakan dalam peramalan, terdapat metode jaringan syaraf tiruan (*artificial neural*

network) yaitu kecerdasan buatan komputer yang mampu menganalisis pola data kemudian memprediksikan peramalan selanjutnya menggunakan algoritma tertentu yang berupaya meminimalkan tingkat kesalahan peramalan. Salah satu metode jaringan syaraf tiruan yang memiliki *learning speed* yang relatif singkat, dengan tahapan analisis yang sederhana, dan memiliki tingkat akurasi yang baik adalah metode *Extreme Learning Machine* (ELM). Metode ini merupakan jaringan syaraf tiruan *feedforward* dengan satu *hidden layer* atau lebih dikenal dengan istilah *single hidden layer feedforward neural network*. Selain karena metodenya yang tergolong baru, implementasi ELM pada peramalan data *time series* masih jarang dilakukan. Dengan kelebihan tersebut terutama dalam konsumsi waktu, maka metode ini akan digunakan.

Extreme Learning Machine (ELM) diperkenalkan oleh Huang Guang Bin, Zhu, dan Siew pada tahun 2006 dalam penelitiannya yang berjudul *Extreme learning machine: Theory and applications*. Secara teori, proses pembelajaran jaringan menggunakan ELM membutuhkan waktu relatif singkat (Huang et al., 2006). Tiwari et al. (2016) dalam penelitiannya menemukan bahwa ELM mampu menganalisis pola siklik dan *trend* dalam data deret waktu yang mudah digunakan dalam peramalan, kesalahan prediksi jauh lebih kecil dan waktu eksekusi model lebih pendek dibandingkan dengan model *machine learning* lainnya yang dipertimbangkan dalam pekerjaan ini.

METODE

Dalam penelitian yang didapat dari dokumen adalah data sekunder yang diambil secara langsung dari kantor UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri Januari 2017 - Desember 2022. Hasil rekapan yang diberi judul Laporan Bulanan TA Pangan 2017-2022. Data tersebut membahas hasil sertifikasi benih setiap bulan untuk berbagai komoditas beberapa di antaranya yaitu padi, jagung, kedelai.



Gambar 1. Struktur Umum *Extreme Learning Machine*

Gambar 7 merupakan sebuah model *Extreme Learning Machine* (ELM) dengan m *input neuron*, n *hidden neuron* dan fungsi aktivasi $f(x)$. Misalkan diberikan data $\{(x_i, y_i)\}_{i=1,2,\dots,N}$, dimana $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in R^m$ yang menunjukkan vektor *input* dan y_i yang menunjukkan *output* dan N merupakan jumlah data *input*. Selanjutnya diasumsikan bahwa vektor bobot $w_k \in R^m$ dan *bias* $b_k \in R$ dibangkitkan secara acak. Maka, model matematika

ELM standar *Single Hidden Layer Feedforward Neural Networks* (SLFNs) dengan *hidden neuron* sebanyak n dan bahwa *error* dapat diaproksimasi dengan 0 jika dan hanya jika $\beta_k \in R$ secara matematis dapat dimodelkan sebagai berikut (Huang et al., 2006):

$$y_i = \sum_{k=1}^n \beta_k g(w_k \cdot x_i + b_k), \quad (1)$$

Keterangan:

i : indeks pengamatan ($i = 1, 2, \dots, N$).

k : indeks *hidden neuron* ($k = 1, 2, \dots, n$).

w_k : merupakan vektor bobot dari vektor *input neuron* ke *hidden neuron* ke- k $[w_{1k}, w_{2k}, \dots, w_{mk}]^T$.

β : merupakan vektor bobot yang menghubungkan *hidden neuron* dan *output neuron* $[\beta_1, \beta_2, \dots, \beta_n]^T$.

b_k : bias dari *input neuron* pada *hidden neuron* ke- k .

Selanjutnya Persamaan 2 dapat dituliskan dalam bentuk sebagai berikut:

$$H\beta = Y \quad (2)$$

Keterangan:

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_n \end{bmatrix}_{n \times 1} \quad (3)$$

$$Y = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix}_{N \times 1} \quad (4)$$

H : merupakan matriks keluaran *hidden layer* dari jaringan saraf tiruan.
dimana,

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_n \cdot x_1 + b_n) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_n \cdot x_N + b_n) \end{bmatrix}_{N \times n} \quad (5)$$

Dengan asumsi bahwa fungsi aktivasi $g(x)$ terdiferensiasi tak hingga, vektor bobot w_k dan bias b_k tetap, maka solusi β dari persamaan sekian adalah sebagai berikut:

$$\beta = H^+ Y \quad (6)$$

Keterangan:

H^+ : matriks Invers dari matriks H (*Moore-Penrose Generalized Inverse*).

dimana,

$$H^+ = (H^T H)^{-1} H^T \quad (7)$$

Analisis *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Analisis ini bertujuan untuk mengidentifikasi stationeritas dan untuk menentukan parameter msodel. Hasil ACF dan PACF dapat disajikan dengan melihat correlogram atau plot antara lag dengan interval kepercayaan. Pada plot, terdapat garis yang menandakan batas interval, jika melewati batas interval tersebut dapat diartikan terdapat autokorelasi dan autokorelasi parsial. Panjang atau pendeknya batang pada ACF dan PACF bergantung pada nilai autokorelasi dan autokorelasi parsial di setiap lag-nya.

Proses normalisasi data diperlukan karena rentang nilai-nilai *input* tidak sama. *Input*

diproses ke nilai *output* yang kecil sehingga data yang digunakan harus disesuaikan agar dapat diproses untuk mendapatkan nilai normalisasi yang kecil. Data time series dinormalisasikan menjadi data yang lebih kecil dalam interval $[0,1]$ agar dapat digunakan sebagai input pada jaringan dengan mengubah data menjadi nilai desimal. Berikut adalah proses normalisasi data menggunakan metode *Min-Max Normalization* (Jain & Bhandare, 2013):

$$d' = \frac{d - \min}{\max - \min} \quad (8)$$

Keterangan:

d' : nilai hasil normalisasi data
 d : nilai asli data
 \min : nilai minimum pada data set
 \max : nilai maksimal pada data set

Proses pembagian data *training* dan data *testing*. Picard dan Berk merekomendasikan 25%-50% data digunakan sebagai data testing (Picard & Berk, 2017), kemudian Zoghi dan Abolghasemi merekomendasikan 75% data untuk training dan 25% data untuk testing (Zoghi & Abolghasemi, 2009). Berdasarkan referensi tersebut, pada penelitian ini digunakan rasio 75:25, hal ini juga disesuaikan dengan besar data yang digunakan. Data dibagi menjadi dua bagian yaitu sekitar 75% data *training*, dan 25% data *testing*.

Proses training harus dilalui sebelum melakukan proses prediksi sebagai pembelajaran awal. Tujuannya adalah untuk mendapatkan nilai *output weight* (β). Sedangkan *input weight* adalah memasukkan bobot pada sistem. Langkah-langkah proses *training* yaitu sebagai berikut (Huang et al., 2006):

1. Inisialisasi nilai input weight dan bias, pada proses ini nilai akan ditentukan secara acak dari -1 hingga 1.
2. Perhitungan keluaran di *hidden layer* yang dikenakan fungsi aktivasi menggunakan persamaan 5.
3. Perhitungan *output weight* menggunakan persamaan 6. Perhitungan dilakukan dengan terlebih dahulu menghitung matriks *Moore-Penrose Generalized Inverse* menggunakan persamaan 7 dari hasil keluaran *hidden layer* yang telah dikenakan fungsi aktivasi.

Proses *testing* untuk menguji hasil proses *training* yang kemudian diproses kembali pada tahapan proses *testing*. Proses *testing* dilakukan menggunakan *input weight*, *bias* dan *output weight* yang didapatkan dari proses *training*, sehingga tidak perlu kembali melakukan inisialisasi *input weight* dan *bias*. Nilai *output weight* yang telah didapatkan pada proses *training* digunakan untuk menghitung keluaran *output layer* yang merupakan hasil prediksi. Perhitungan nilai *output layer* menggunakan persamaan 1 dan 2.


Proses denormalisasi data untuk membangkitkan nilai yang telah dinormalisasi menjadi nilai asli/aktual. Berikut adalah persamaan untuk proses denormalisasi data:

$$d = d'(\max - \min) + \min \quad (9)$$


Evaluasi dengan perhitungan akurasi peramalan. Dalam tahap ini ditentukan akurasi peramalan untuk mengetahui apakah penerapan metode yang telah dilakukan dapat beroperasi dengan baik dan sesuai dengan tujuan yang diinginkan. Perhitungan akurasi peramalan menggunakan metode MSE (*Mean Squared Error*) dan MAPE (*Mean Absolute Percentage Error*).

PEMBAHASAN


Analisis deskriptif dalam penelitian dilakukan untuk menjelaskan gambaran umum mengenai data sertifikasi benih UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri, agar data yang ada dapat lebih mudah dipahami dan informatif. Gambar 9, 10, 11 merupakan gambaran tentang sertifikasi benih UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri dimulai dari tahun 2017 sampai dengan tahun 2022.



Gambar 2. Grafik Sertifikasi Benih Komoditas Padi Tahun 2017-2022




Gambar 3. Grafik Sertifikasi Benih Komoditas Jagung Tahun 2017-2022



Gambar 4. Grafik Sertifikasi Benih Komoditas Kedelai Tahun 2017-2022

Gambar 2, Gambar 3, dan Gambar 4 menunjukkan bahwa sertifikasi benih secara umum memiliki *trend* yang sedikit cenderung naik, fluktuasi terjadi setiap bulannya secara tidak konstan. Data sertifikasi benih komoditas padi, jagung dan kedelai memiliki pola yang sama selama satu periode yaitu sertifikasi benih rendah terjadi pada awal dan pertengahan tahun dan sertifikasi benih tinggi pada akhir tahun. Berdasarkan data dari UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri, salah satu faktor pemicu pola ini adalah masuknya sampel panen benih yang menyesuaikan gangguan musim, sehingga penyelesaian proses sertifikasi benih dilakukan akhir tahun hingga target.


Plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) diperlukan untuk mengetahui variabel *input* yang digunakan sebelum dilakukan proses peramalan. Plot ACF dan PACF menunjukkan lag-lag yang signifikan. Hasilnya digunakan sebagai acuan penentuan *input*. Gambar 5, 6, dan 7 merupakan plot ACF dan PACF sertifikasi benih dari masing-masing komoditas.



Gambar 5. Plot ACF dan PACF Sertifikasi Benih Komoditas Padi


Berdasarkan Gambar 5 hasil ACF dan PACF komoditas padi terdapat 6 lag yang signifikan yaitu lag 1, lag 6, lag 7, lag 12, lag 18, dan lag 24. Lag yang signifikan tersebut menunjukkan banyaknya *input neuron* komoditas padi sebanyak 6 *neuron* yang terdiri dari data 1 bulan sebelumnya, data 6 bulan sebelumnya, data 7 bulan sebelumnya, data 1 tahun

sebelumnya, data 18 bulan sebelumnya, sampai dengan data 2 tahun sebelumnya.



Gambar 6. Plot ACF dan PACF Sertifikasi Benih Komoditas Jagung

Berdasarkan hasil ACF dan PACF komoditas jagung terdapat 5 lag yang signifikan yaitu lag 1, lag 6, lag 9, lag 10, dan lag 12. Lag yang signifikan tersebut menunjukkan banyaknya *input neuron* komoditas jagung sebanyak 5 *neuron* yang terdiri dari data 1 bulan sebelumnya, data 6 bulan sebelumnya, data 9 bulan sebelumnya, data 10 tahun sebelumnya, sampai dengan data 1 tahun sebelumnya.



Gambar 7. Plot ACF dan PACF Sertifikasi Benih Komoditas Kedelai

Berdasarkan hasil ACF dan PACF komoditas kedelai terdapat 13 lag yang signifikan yaitu lag 1, lag 3, lag 4, lag 5, lag 7, lag 8, lag 9, lag 10, lag 11, lag 12, lag 15, lag 16, dan lag 24. Lag yang signifikan tersebut menunjukkan banyaknya *input neuron* komoditas kedelai sebanyak 13 *neuron* yang terdiri dari data 1 bulan sebelumnya, data 3 bulan sebelumnya, data 4 bulan sebelumnya data 5 bulan sebelumnya, data 7 bulan sebelumnya, data 8 bulan sebelumnya, data 9 bulan sebelumnya, data 10 bulan sebelumnya, data 11 bulan sebelumnya,

data 1 tahun sebelumnya, data 15 bulan sebelumnya, data 16 bulan sebelumnya, sampai dengan data 2 tahun sebelumnya.

Pada penelitian ini dicobakan *hidden neuron* sekitar 5-25 *neuron* yang berbeda untuk setiap komoditas, percobaan banyak *hidden neuron* dilakukan sampai 25 dikarenakan percobaan selanjutnya terus mengalami peningkatan nilai MSE dan tidak memenuhi target yang ditentukan, maka percobaan berhenti pada banyak *hidden neuron* 25. Tabel 1 menyajikan nilai MSE pada setiap *hidden neuron* yang dicobakan berdasarkan perhitungan program. Pengujian untuk *neuron* pada *hidden layer* menunjukkan bahwa semakin banyak *neuron* yang digunakan akan mendapatkan nilai MSE yang lebih sedikit. Nilai MSE terkecil diperoleh pada percobaan *hidden layer* 20 *neuron* untuk setiap komoditas

Tabel 1. Hasil Percobaan Hidden Neuron Berdasarkan Nilai MSE

Proses	Komoditas	Banyak Hidden Neuron				
		5	10	15	20	25
Training	Padi	0,011794	0,007838	0,006293	0,006244	0,010873
	Jagung	0,012708	0,007710	0,007552	0,006368	0,012333
	Kedelai	0,009504	0,007245	0,005973	0,005135	0,010080
Testing	Padi	0,009897	0,006919	0,006146	0,005622	0,009936
	Jagung	0,010354	0,006855	0,006776	0,005684	0,010666
	Kedelai	0,008752	0,006622	0,005986	0,005067	0,009540

Arsitektur jaringan merupakan sebuah lapisan pada jaringan syaraf tiruan yang terdiri dari tiga lapisan yaitu *input layer*, *hidden layer*, dan *ouput layer*. Tabel 2 merupakan rincian rancangan arsitektur jaringan metode *Extreme Learning Machine* (ELM) untuk proses peramalan sertifikasi benih pada tiap komoditas.

Tabel 2. Rincian Arsitektur Jaringan

Komoditas	Input Layer	Hidden Layer	Output Layer
Padi	6 <i>neuron</i>	20 <i>neuron</i>	1 <i>neuron</i>
Jagung	5 <i>neuron</i>		
Komoditas	Input Layer		

Sebelum melakukan analisis, data sertifikasi benih perlu dilakukan normalisasi terlebih dahulu sebelumnya. Data yang digunakan merupakan data yang dibentuk berdasarkan penentuan arsitektur jaringan. Data ini merupakan kolom lapisan *input* yang dilambangkan *x* dan disertai nilai target. Tabel 3 dan 4 merupakan data salah satu komoditas yaitu padi yang digunakan untuk proses *training* dan *testing*.

Tabel 3. Data Training Sertifikasi Benih Komoditas Padi


X1	X2	X3	X4	X5	X6	Target
0,197817	0,617031	0,624017	0,302620	0,470306	0,285153	0,355022
0,355022	0,386463	0,617031	0,320087	0,735808	0,428384	0,424891
0,424891	0,746288	0,386463	0,110480	0,711354	0,100000	0,215284
0,215284	0,550655	0,746288	0,386463	0,707860	0,389956	0,519214
0,519214	0,428384	0,550655	0,382969	0,501747	0,407424	0,288646

X1	X2	X3	X4	X5	X6	Target
0,288646	0,197817	0,428384	0,624017	0,302620	0,519214	0,494760
0,494760	0,355022	0,197817	0,617031	0,302620	0,470306	0,505240
0,505240	0,424891	0,355022	0,386463	0,320087	0,735808	0,386463
0,386463	0,215284	0,424891	0,746288	0,110480	0,711354	0,851092
0,851092	0,519214	0,215284	0,550655	0,386463	0,707860	0,351528
0,351528	0,288646	0,519214	0,428384	0,382969	0,501747	0,309607
0,309607	0,494760	0,288646	0,197817	0,624017	0,302620	0,225764


Tabel 4. Data *Testing* Sertifikasi Benih Komoditas Padi

X1	X2	X3	X4	X5	X6	Target
0,225764	0,505240	0,494760	0,355022	0,617031	0,302620	0,452838
0,452838	0,386463	0,505240	0,424891	0,386463	0,320087	0,631004
0,631004	0,851092	0,386463	0,215284	0,746288	0,110480	0,337555
0,337555	0,351528	0,851092	0,519214	0,550655	0,386463	0,459825
0,459825	0,309607	0,351528	0,288646	0,428384	0,382969	0,337555
0,337555	0,225764	0,309607	0,494760	0,197817	0,624017	0,760262
0,760262	0,452838	0,225764	0,505240	0,355022	0,617031	0,484279
0,484279	0,631004	0,452838	0,386463	0,424891	0,386463	0,508734
0,508734	0,337555	0,631004	0,851092	0,215284	0,746288	0,900000
0,900000	0,459825	0,337555	0,351528	0,519214	0,550655	0,631004
0,631004	0,337555	0,459825	0,309607	0,288646	0,428384	0,679913
0,679913	0,760262	0,337555	0,225764	0,494760	0,197817	0,410917


Gambar 8, 9, dan 10 memperlihatkan grafik dengan warna biru yang menampilkan data aktual sertifikasi benih, serta grafik dengan warna hijau yang menampilkan data hasil peramalan sertifikasi benih menggunakan *Extreme Learning Machine* (ELM). Melalui grafik yang ditampilkan, maka dapat terlihat seberapa besar perbedaan antara data aktual dengan data hasil peramalan sertifikasi benih. Hasil perbandingan antara data aktual dan data hasil peramalan sertifikasi benih pada tiap komoditas tidak jauh berbeda.



Gambar 8. Grafik Perbandingan Data Aktual dan Peramalan Sertifikasi Benih Komoditas Padi Tahun 2019-2022




Gambar 9. Grafik Perbandingan Data Aktual dan Peramalan Sertifikasi Benih Komoditas Jagung Tahun 2018-2022




Gambar 10. Grafik Perbandingan Data Aktual dan Peramalan Sertifikasi Benih Komoditas Kedelai Tahun 2019-2022


Gambar 11, 12, dan 13 memperlihatkan grafik dengan warna hitam yang menampilkan data aktual sertifikasi benih pada tahun 2017 sampai dengan tahun 2022, serta grafik dengan warna abu-abu yang menampilkan data hasil peramalan sertifikasi benih pada tahun 2023 menggunakan *Extreme Learning Machine* (ELM).



Gambar 11. Grafik Hasil Peramalan Sertifikasi Benih Komoditas Padi Tahun 2023



Gambar 12. Grafik Hasil Peramalan Sertifikasi Benih Komoditas Jagung Tahun 2023



Gambar 13. Grafik Hasil Peramalan Sertifikasi Benih Komoditas Kedelai Tahun 2023

Tabel 5 merupakan hasil peramalan sertifikasi benih komoditas padi pada tahun 2023 yang menjelaskan Gambar 11 berupa data angka. Hasil peramalan sertifikasi benih komoditas padi pada tahun 2023 berkisar antara 100 hingga 260, dimana angka tersebut sesuai dengan data sebelumnya. Hasil peramalan tertinggi terjadi pada bulan September 2023 dengan perkiraan hasil sertifikasi benih sebesar 260,3163491, sedangkan hasil peramalan terendah terjadi pada bulan Maret 2023 dengan perkiraan hasil sertifikasi benih sebesar 103,1985904.

Tabel 5. Hasil Peramalan Sertifikasi Benih Komoditas Padi Tahun 2023

Bulan	Hasil Peramalan	
	Normalisasi	Denormalisasi
Januari	0,6238469	174,8609401
Februari	0,6666299	184,1978089
Maret	0,3487287	103,1985904
April	0,6432905	186,5169056
Mei	0,4703564	138,0145195
Juni	0,8231143	238,9914684
Juli	0,5285301	153,6667411
Agustus	0,5904964	172,4045945
September	0,8976117	260,3163491
Oktober	0,5584438	163,2295378
November	0,7204230	209,5960838
Desember	0,4402101	129,3851411

Tabel 6 merupakan hasil peramalan sertifikasi benih komoditas jagung pada tahun 2023 yang menjelaskan Gambar 12 berupa data angka. Hasil peramalan sertifikasi benih komoditas jagung pada tahun 2023 berkisar antara 50 hingga 200, dimana angka tersebut sesuai dengan data sebelumnya. Hasil peramalan tertinggi terjadi pada bulan September 2023 dengan perkiraan hasil sertifikasi benih sebesar 207,5969425, sedangkan hasil peramalan terendah terjadi pada bulan Maret 2023 dengan perkiraan hasil sertifikasi benih sebesar 50,35073750.

Tabel 6. Hasil Peramalan Sertifikasi Benih Komoditas Jagung Tahun 2023

Bulan	Hasil Peramalan	
	Normalisasi	Denormalisasi
Januari	0,3552751	50,85663650
Februari	0,3226941	64,28168688
Maret	0,2983620	58,35073750
April	0,4492423	95,12781063
Mei	0,3211171	63,89729313
Juni	0,4025787	83,75355813
Juli	0,5371193	116,5478294
Agustus	0,6133668	135,1331575
September	0,7875772	207,5969425
Oktober	0,4685141	99,82531188
November	0,5009858	107,7402888
Desember	0,3792006	70,05514625

Tabel 7 merupakan hasil peramalan sertifikasi benih komoditas kedelai pada tahun 2023 yang menjelaskan Gambar 13 berupa data angka. Hasil peramalan sertifikasi benih komoditas kedelai pada tahun 2023 berkisar antara 9 hingga 40, dimana angka tersebut hampir sesuai dengan data sebelumnya. Hasil peramalan tertinggi terjadi pada bulan Oktober 2023 dengan perkiraan hasil sertifikasi benih sebesar 42,69986286, sedangkan hasil peramalan terendah terjadi pada bulan Januari 2023 dengan perkiraan hasil sertifikasi benih sebesar 9,639508810.

Tabel 7. Hasil Peramalan Sertifikasi Benih Komoditas Kedelai Tahun 2023

Bulan	Hasil Peramalan	
	Normalisasi	Denormalisasi
Januari	0,12539213	9,639508810
Februari	0,34468400	16,31663500
Maret	0,57306368	26,87919520
April	0,52866918	24,82594958
Mei	0,20229907	9,731331988
Juni	0,29298610	13,92560713
Juli	0,38695431	18,27163684
Agustus	0,54547854	25,60338248
September	0,55247221	25,92683971
Oktober	0,91513217	42,69986286
November	0,63384997	29,69056111
Desember	0,31544396	14,96428315

Tahap akhir adalah analisis untuk menghitung nilai keakuratan hasil peramalan dengan menggunakan metode *Mean Square Error* (MSE) dan *Mean Absobute Percentage Error* (MAPE). Tujuan dilakukan analisis tersebut adalah untuk mengetahui kelayakan dari penggunaan metode *Extreme Learning Machine* (ELM). Tabel 8 merupakan perbandingan hasil akurasi peramalan menggunakan *Extreme Learning Machine* (ELM). Secara umum, menunjukkan bahwa hasil peramalan sertifikasi benih padi, jagung, kedelai dapat dikategorikan baik karena memiliki tingkat kesalahan kurang dari atau lebih sedikit sama dengan 10%. Hasil akurasi ini menunjukkan bahwa metode *Extreme Learning Machine* (ELM) layak digunakan sebagai model untuk peramalan sertifikasi benih. Tingkat kesalahan peramalan untuk sertifikasi benih komoditas padi yaitu sebesar 2,08%, komoditas jagung yaitu sebesar 2,85%, dan komoditas kedelai yaitu sebesar 1,25%. Model peramalan ini paling cocok digunakan pada data sertifikasi benih komoditas kedelai atau dapat menunjukkan bahwa data lebih stabil dibandingkan dengan data lainnya sehingga baik untuk diramalkan.

Tabel 8. Hasil Akurasi Peramalan Sertifikasi Benih Komoditas Padi, Jagung, dan Kedelai Tahun 2023

Komoditas	Metode Akurasi	
	MSE	MAPE (%)
Padi	1,037618241	2,075236483
Jagung	1,423159055	2,846318109
Kedelai	0,627123729	1,254247458

SIMPULAN

Berdasarkan hasil penelitian dan pembahasan, dapat ditarik beberapa kesimpulan sebagai berikut: (1) Model jaringan syaraf tiruan menggunakan metode Extreme Learning Machine (ELM) dapat dibangun dengan cara terlebih dahulu menentukan banyaknya input neuron dan hidden neuron. Pada penelitian ini model dengan performa terbaik untuk komoditas padi adalah dengan menggunakan 6 input neuron, untuk komoditas jagung adalah dengan menggunakan 5 input neuron, dan untuk komoditas kedelai adalah dengan menggunakan 13 input neuron. Ketiga komoditas tersebut menggunakan 20 hidden neuron; (2) Hasil prediksi sertifikasi benih di UPT PSBTH Dinas Pertanian dan Ketahanan Pangan Jawa Timur Wilayah III Kediri tahun 2023 menunjukkan pola yang sama dengan periode sebelumnya yaitu mencapai angka sertifikasi benih yang tinggi pada akhir tahun bulan September untuk komoditas padi dan jagung, dan angka sertifikasi benih yang tinggi pada akhir tahun bulan Oktober untuk komoditas kedelai; (3) Hasil akurasi peramalan baik untuk komoditas padi, jagung, dan kedelai dapat dikategorikan baik sehingga dapat diartikan metode *Extreme Learning Machine* (ELM) layak digunakan untuk memodelkan peramalan dengan masing-masing tingkat kesalahan MAPE yaitu 2,08% untuk komoditas padi, 2.85% untuk komoditas jagung, dan 1.25% untuk komoditas kedelai.

UCAPAN TERIMA KASIH

Terimakasih kepada Koordinator Program Studi Statistika dan seluruh Dosen Statistika yang telah membagikan ilmu hingga artikel ini dapat disusun dengan baik.

DAFTAR PUSTAKA

- Direktorat Jenderal Tanaman Pangan. (2016). Keputusan Direktur Jenderal Tanaman Pangan Nomor 19 Tahun 2016, tentang Petunjuk Teknis Gerakan Pengembangan Jagung Hibrida.
- Fitri. (2019). *Proses Sertifikasi Benih Padi*. Kementrian Pertanian, 96(1), 10.
- Huang, G.B., Zhu, Q.Y., & Siew, C.K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1–3), 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Jain, Y. K., & Bhandare, S. K. (2013). Min max normalization based data perturbation method for privacy protection. *International Journal of Computer and Communication Technology*, 233–238. <https://doi.org/10.47893/IJCCT.2013.1201>
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1998). *Metode dan aplikasi peramalan jilid 1 (Ir. Untung Sus Ardiyanto, M.Sc. & Ir. Abdul Basith, M.Sc. terjemahan)* (2nd ed.). Jakarta: Erlangga.
- Picard, R. R., & Berk, K. N. (1990). Data Splitting. *The American Statistician*, 44(2), 140-147. <https://doi.org/10.2307/2684155>
- Tiwari, M., Adamowski, J., & Adamowski, K. (2016). Water demand forecasting using extreme learning machines. *Journal of Water and Land Development*, 28(1), 37–52. <https://doi.org/10.1515/jwld-2016-0004>