

Kinerja Artificial Neural Network pada Model Berat Segar Daun Pakcoy

Artificial Neural Network Performance on Pakcoy Leaf Fresh Weight Model

Riza Yuli Rusdiana^{1*}, Laily Ilman Widuri¹⁾, Didik Pudji Restanto²⁾

^{1)Program Studi Agronomi, Fakultas Pertanian, Universitas Jember}

^{2)Program Studi Magister Agronomi, Fakultas Pertanian, Universitas Jember}

*E-mail: rizayr@unej.ac.id

ABSTRACT

The growth of leaf biomass can be predicted from an increase in the surface area and thickness of the leaves. Measurements of leaf biomass are approached with the fresh weight of the leaves. The relationship between biomass and leaf surface area commonly performed by regression analysis. The analysis requires assuming linear relationship between dependent variables and independent variables. Artificial Neural Network (ANN) is alternative that can be used to analyze the relationship of leaves and leaf biomass without requiring linear relationships. The research aimed to evaluate ANN performance in determining the fresh weight of pakcoy leaves based on leaf area parameters. Datasets in the study included leaf area datasets and length-width datasets. ANN architecture used Multi Layer Perceptron (MLP) with backpropagation. Ramsey's test results showed that leaf area datasets is linier model and length-width datasets is nonlinier model. ANN performs well in predicting leaf fresh weight data on both nonlinear and linear models. The best ANN architecture for modeling the leaf fresh weight with leaf area is MLP (1-3-1) while the leaf fresh weight model with length and width is MLP (2-3-1).

Keywords: leaf fresh weight, multi layer perceptron, pakcoy.

PENDAHULUAN

Daun merupakan organ penting tumbuhan, tempat menyerap sinar matahari dan mengolah energi cahaya menjadi energi kimia (fotosintesis). Semakin besar luas permukaan daun akan menyebabkan semakin besar potensi fotosintesis, evaporasi dan transpirasi. Pada bidang Agronomi, luas daun menjadi parameter yang diperlukan dalam mengembangkan model pertumbuhan dan produktivitas.

Pertumbuhan biomassa daun dapat diprediksi dari peningkatan luas permukaan dan ketebalan daun. Hal ini disebabkan jumlah cahaya yang diserap oleh daun pada proses fotosintesis. Penelitian Jaya (2004) memberikan kesimpulan hubungan positif antara luas daun dan biomassa tanaman akibat potensi penyerapan sinar matahari yang besar. Pengukuran biomassa daun didekati dengan berat segar daun dan berat kering daun. Penelitian Huang *et al.* (2019a) berdasarkan *goodness of fit*, menyimpulkan bahwa lebih baik menggunakan berat segar daun dibandingkan berat kering daun untuk menjelaskan biomassa daun.

Hubungan antara biomassa dan luas permukaan daun telah dipelajari oleh Pan *et al.* (2013), Das (2014) dan Huang *et al.* (2019a). Banyak peneliti menggunakan analisis regresi sebagai alat untuk menganalisis hubungan dan

memprediksi antara biomassa dan luas permukaan daun. Analisis regresi memiliki beberapa asumsi klasik yang harus terpenuhi, diantaranya hubungan linier antara variabel dependen dan variabel independen. Namun, beberapa penelitian terkadang ditemukan bahwa hubungan antar variabel bersifat nonlinier seperti pada penelitian Kusdarjito & Suryantini (2013) dan Hermawan *et al.* (2018).

Analisis alternatif yang tidak mensyaratkan linieritas yaitu *Artificial Neural Network* (ANN). Menurut Bagus *et al.* (2013) ANN sebagai metode nonlinier mampu menginterpretasi parameter yang tidak dapat dijelaskan pada model parametrik dan memiliki bentuk fungsional yang fleksibel. ANN merupakan generalisasi model matematis dari jaringan saraf otak manusia. Analisis ini mampu menyelesaikan permasalahan data yang bersifat kompleks (Setiawan, 2011) dan memprediksi pada tingkat akurasi tinggi dengan nilai *error* yang cukup rendah (Izati & Notobroto, 2019). Pada ANN, arsitektur *Multi Layer Perceptron* (MLP) dapat diterapkan pada berbagai aplikasi. Pada penelitian sebelumnya MLP diterapkan untuk meramalkan produksi minyak mentah (Bagus *et al.*, 2013), kunjungan ibu hamil (Izati & Notobroto, 2019), pengenalan pola penerimaan dan pendapatan petani tebu (Kusdarjito & Suryantini, 2013) dan penentuan

upah minimum kota berdasarkan tingkat inflasi (Yohannes *et al.*, 2015).

Berdasarkan dari penjelasan tersebut, penelitian ini bertujuan untuk mengevaluasi kinerja ANN arsitektur MLP pada data berat segar daun pakcoy berdasarkan parameter luas daun. Manfaat yang diharapkan dalam penelitian ini memperoleh model MLP ($i-j-k$) yang sesuai dan memprediksi berat segar daun dari model terbaik.

METODE

Data

Daun tanaman pakcoy berusia 3 minggu dikumpulkan dari *green house* ATP Universitas Jember (8°09'43.4"S 113°43'03.8"E) pada bulan Juli-Agustus 2020. Data yang digunakan dalam penelitian merupakan data pengukuran panjang daun (L), lebar daun (W), luas daun (LA) dan berat segar daun (LFW) tanaman pakcoy. Informasi terperinci tentang prosedur pengukuran panjang, lebar dan luas daun disajikan oleh (Rusdiana *et al.*, 2021). Berat segar daun ditimbang langsung setelah panen dengan menggunakan timbangan analitik (OHAUS Model No. AP310-0). Variabel penelitian yang digunakan terdiri dari tiga variabel independen (L, W dan LA) dan satu variabel dependen (LFW). Sampel yang digunakan sebanyak 70 daun diambil secara acak dari 17 tanaman. Keseluruhan sampel merupakan data numerik berskala rasio. Dataset pada penelitian meliputi dataset luas daun (LFW~LA) dan dataset panjang-lebar (LFW~L+W).

Uji Linieritas

Bentuk pemodelan statistik tidak hanya linier tetapi juga nonlinier. Ketidaklinieran dalam data disebabkan oleh beberapa hal diantaranya hubungan nonlinier antar variabel dan keberadaan *outlier*. Uji untuk mendeteksi linieritas yaitu uji Ramsey's RESET, dengan hipotesis uji sebagai berikut (Prabowo *et al.*, 2020):

H_0 : model linier

H_1 : model nonlinier

Uji Ramsey's RESET pada penelitian ini menggunakan library *lmtest* di *software* R Studio. Nilai p -value $< \alpha$ menjelaskan model memiliki pola nonlinier.

Artificial Neural Network

Artificial Neural Network (ANN) digunakan untuk mengestimasi model dan memprediksi berat segar daun pakcoy. Teknik ANN mencakup tahap pelatihan, tahap verifikasi dan tahap pengujian menggunakan data *subset*. Data *subset* yang digunakan dipilih secara acak dari *dataset*. *Dataset* dibagi menjadi dua *subset* yaitu data untuk tahap pelatihan dan tahap pengujian. Arsitektur ANN yang digunakan dalam penelitian adalah *Multi Layer Perceptron* (MLP) algoritma *backpropagation*.

MLP merupakan suatu *perceptron* dengan minimal satu *hidden layer* sebagai tambahan. *Hidden*

layer berada diantara *input* dan *output* sebagai perantara (Fausett, 1994). Bagian *input* berisi *neuron-neuron* data panjang, lebar dan luas daun dan *output* berisi data berat segar daun. Hubungan antara *output* (y) dan *input* (x_1, x_2 dan x_3) dengan satu *hidden layer* dapat ditulis secara matematis sebagai berikut:

$$y_k = \varphi_k \left(b_k + \sum_{j \rightarrow k} w_{kj} \varphi_j \left(b_j + \sum_{i \rightarrow j} v_{ji} x_i \right) \right)$$

dimana

y_k = nilai dugaan variabel *output* pada indeks ke- k ;

x_i = variabel *input* indeks ke- i ;

φ_k = fungsi aktivasi di *neuron* ke- k pada *output*

φ_j = fungsi aktivasi di *neuron* ke- j pada *hidden layer*

b_k = bias pada *neuron* ke- k pada *output*

b_j = fungsi aktivasi di *neuron* ke- j pada *hidden layer*

v_{ji} = bobot dari *input* ke- i yang menuju ke *neuron* j pada *hidden layer*

w_{kj} = bobot dari *neuron* ke- j yang menuju ke *output layer*

Algoritma *backpropagation* diterapkan sebagai metode pelatihan pada penelitian ini. Tahapan algoritma *backpropagation* (Fausett, 1994): (1) masukkan data pelatihan sehingga diperoleh nilai *output* (*feedforward*); (2) propagasi balik dari nilai *error* yang diperoleh (*backpropagation*); dan (3) penyesuaian bobot koneksi untuk meminimalkan nilai *error*. Tahapan-tahapan tersebut diulang sampai mendapatkan nilai *error* minimum dan memperoleh bobot terbaik. Fungsi aktivasi *logistic* pada *hidden layer* digunakan dalam *output layer*. Analisis MLP dilakukan dengan menggunakan *package* *neuralnet* *software* R Studio.

Penentuan jumlah *hidden layer* dan jumlah *neuron* pada *hidden layer* berpengaruh penting pada analisis ANN. Fausett (1994) menjelaskan bahwa penggunaan satu *hidden layer* pada algoritma *backpropagation* sudah cukup optimal untuk memetakan input ke output secara kontinu. Menurut Heaton (2005) dalam Yohannes *et al.* (2015), aturan penentuan jumlah *neuron* yaitu: (1) berada dalam interval jumlah *neuron input* dan *neuron output*; (2) 2/3 dari jumlah *neuron input* dan *neuron output*; dan (3) kurang dari atau sama dengan dua kali ukuran *neuron input*.

Goodness of Fit

Pemilihan model terbaik ditentukan dengan menggunakan dua statistik *goodness of fit*, yaitu (Pham, 2019):

Root Mean Squared Error

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (LFW_i - \widehat{LFW}_i)^2}{n}}$$

Adjusted Coefficient of Determination

$$R_{adj}^2 = 1 - \frac{\sum_{i=1}^n (LFW_i - \widehat{LFW}_i)^2 (n-1)}{\sum_{i=1}^n (LFW_i - \widehat{LFW})^2 (n-p)}$$


di mana n merupakan jumlah data; p merupakan jumlah parameter dalam model; LFW_i merupakan nilai berat segar daun ke- i ; \overline{LFW}_i merupakan nilai prediksi berat segar daun ke- i dan \overline{LFW} merupakan rata-rata berat segar daun.

Berikut langkah-langkah analisis yang dilakukan pada penelitian:

1. Mengidentifikasi hubungan variabel LFW dan parameter luas daun;
2. Melakukan uji Ramsey's RESET antara variabel LFW daun dengan variabel L dan W serta LA;
3. Membagi data menjadi dua yaitu data pelatihan sebesar 75% data dan data pengujian sebesar 25% data;
4. Melakukan analisis MLP pada data pelatihan:
 - Menganalisis MLP pada data pelatihan
 - Menentukan jumlah *hidden layer*
 - Menentukan jumlah *neuron* pada *hidden layer*
 - Memprediksi data pengujian menggunakan model MLP dari data pelatihan
 - Memilih MLP terbaik melalui RMSE minimum dan R_{adj}^2 maksimum.

HASIL DAN PEMBAHASAN

Matriks *scatterplot* pada Gambar 1 menjelaskan pola hubungan berat segar dengan panjang, lebar dan luas daun. Arah plot bergerak dari kiri bawah ke kanan atas menunjukkan arah positif atau kenaikan *input* selaras dengan kenaikan *ouput*. Luas daun memiliki korelasi tertinggi ($r=0.9154$) dengan berat segar daun. Begitu juga dengan panjang daun ($r=0.8653$) dan lebar daun ($r=0.8686$) memiliki korelasi positif dengan berat segar daun. Hubungan positif antara massa daun dengan luas, panjang dan lebar daun sesuai dengan hasil penelitian Pan *et al.* (2013) dan Huang *et al.* (2019b). Pada semua tanaman, hubungan antara berat segar daun dan luas area bergantung pada kandungan air dan alokasi karbon (pertumbuhan daun) (Huang *et al.*, 2019b).



Gambar 1. Hubungan variabel berat segar dan parameter luas permukaan daun

Secara grafis, *scatterplot* variabel lebar dan luas daun berbentuk lurus. Berbeda dengan bentuk penyebaran titik-titik pada variabel berat segar dan panjang daun serta lebar daun terlihat melengkung positif. Bentuk *scatterplot* mengindikasi model nonlinier sehingga dilakukan uji linieritas antara berat segar dengan panjang dan lebar serta luas daun.

Tabel 1. Hasil Uji Ramsey's RESET

No	Model	p-value	RESET statistik
1	LFW~LA	0.9993*	0.0007
2	LFW~L+W	0.0056	5.6231

Keterangan: *signifikan α (0.05)

Tabel 1 menunjukkan hasil pengujian model dengan variabel prediktor luas daun dan panjang serta lebar daun terhadap variabel berat segar daun. P-value model pertama lebih besar dari 0.05 sehingga dapat disimpulkan luas daun terhadap berat segar daun merupakan model linier. Uji linieritas panjang dan lebar daun terhadap berat segar daun memiliki p-value kurang dari 0.05 yang menunjukkan model kedua merupakan model nonlinier.


Pemodelan berat segar daun dengan menerapkan ANN arsitektur MLP menggunakan satu *hidden layer* dengan jumlah *neuron* pada *hidden layer* antara satu hingga empat. Pemilihan jumlah *neuron* berdasarkan *trial* dan *error* dengan menggunakan RMSE dan R_{adj}^2 disajikan pada Tabel 2. Izati & Notobroto (2019) menerapkan *trial* dan *error* berdasarkan MSE terkecil untuk menentukan jumlah *hidden neuron* di mana 4 *neuron* pada *hidden layer* menghasilkan error terkecil dibanding lainnya. Lubis & Buono (2012) menggunakan nilai RMSE terkecil dan nilai R^2 terbesar sebagai dasar penentuan jumlah *hidden neuron*.

Tabel 2. Hasil RMSE dan R_{adj}^2 pada pengujian ANN

Model	Jumlah neuron	RMSE	R_{adj}^2
LFW~LA	1	0.2962	0.9199
	2	0.2847	0.9260
	3	0.2790	0.9290
	4	0.3200	0.91167
LFW~L+W	1	0.4686	0.8293
	2	0.3429	0.9086
	3	0.3424	0.9088
	4	0.4348	0.8530

Tabel 2 di atas dengan ketentuan RMSE minimum dan R_{adj}^2 maksimum diperoleh jumlah

neuron optimum. Pada penelitian ini diperoleh kedua model optimum dengan jumlah neuron sebanyak tiga. Arsitektur MLP (1-3-1) untuk dataset luas daun disajikan pada Gambar 2 dan MLP (2-3-1) untuk dataset panjang-lebar disajikan pada Gambar 3.



Gambar 2. Arsitektur MLP (1-3-1)

Pemodelan berat segar daun dengan luas daun sebagai variabel input menggunakan ANN arsitektur MLP (1-3-1) dapat disajikan secara matematis sebagai berikut:


$$LFW = 3.1356 + 1.0039\varphi_1 - 3.4167\varphi_2 + 2.7271\varphi_3$$

dengan:

$$\varphi_1 = 1 + \exp(-(-47.5079 + 0.4630LA))$$

$$\varphi_2 = 1 + \exp(-(3.2997 - 0.0615LA))$$

$$\varphi_3 = 1 + \exp(-(-1.3923 + 0.0036LA))$$



Gambar 3. Arsitektur MLP (2-3-1)

Pemodelan berat segar daun dengan dipengaruhi panjang dan lebar menggunakan ANN arsitektur MLP (2-3-1) dapat disajikan secara matematis sebagai berikut:


$$LFW = 1.6099 + 3.5751\varphi_1 - 5.9039\varphi_2 + 4.0537\varphi_3$$

dengan:

$$\varphi_1 = 1 + \exp(-(-4.3308 - 0.4561L + 1.1953W))$$


$$\varphi_2 = 1 + \exp(-(-3.9190 - 0.5522L + 0.4966W))$$

$$\varphi_3 = 1 + \exp(-(-24.5117 + 1.5058L + 3.1127W))$$



Gambar 4. Grafik nilai prediksi dan nilai observasi menggunakan model MLP (1-3-1)

Gambar 4 merupakan grafik dari nilai prediksi dan nilai observasi untuk model hubungan berat segar daun dengan luas daun menggunakan arsitektur MLP (1-3-1). Sedangkan Gambar 5 merupakan grafik dari nilai prediksi dan nilai observasi untuk model hubungan berat segar daun dengan panjang dan lebar daun menggunakan arsitektur MLP (2-3-1). Kurva hitam menggambarkan nilai observasi atau data aktual dari berat segar daun dan kurva putus-putus merah menggambarkan nilai prediksi dari model yang digunakan. Kurva merah di masing-masing gambar untuk setiap titik sampel mengalami kenaikan dan penurunan yang selaras dengan kurva hitam.



Gambar 5. Grafik nilai prediksi dan nilai observasi menggunakan model MLP (2-3-1)

Kurva pada Gambar 4 dan 5 menjelaskan tidak terdapat perbedaan yang signifikan hasil prediksi model MLP (1-3-1) dan MLP (2-3-1) dengan nilai observasi (aktual). Hal tersebut menunjukkan bahwa ANN memiliki kinerja sangat baik dalam memodelkan data berat segar daun dan mampu mendeskripsikan hubungan linier maupun hubungan nonlinier antar variabel. Selaras dengan hasil penelitian Somers & Casal (2009) bahwa ANN arsitektur MLP dengan satu *hidden layer* berkinerja lebih baik dibandingkan regresi untuk memodelkan

hubungan nonlinier antara kepuasan kerja dengan performa pekerjaan. Selain itu, ANN mampu memprediksi berat segar daun berdasarkan parameter luas daun. Metode ANN juga bersifat lebih fleksibel dibandingkan metode pemodelan statistik lain yang membutuhkan asumsi-asumsi.

KESIMPULAN

ANN memiliki kinerja yang baik dalam memprediksi data berat segar daun baik pada model nonlinier maupun model linier. Jumlah *neuron* optimum pada satu hidden layer untuk data berat segar daun sebanyak tiga. Arsitektur ANN terbaik untuk memodelkan berat segar daun dengan luas daun adalah MLP (1-3-1) sedangkan model berat segar daun dengan panjang dan lebar daun adalah MLP (2-3-1).

DAFTAR PUSTAKA

- Bagus I, Ari O, Dwiatmono AW & U BSS. 2013. Penerapan Bootstrap Pada Neural Network Untuk Peramalan Produksi Minyak Mentah Di Indonesia. *Jurnal Sains dan Seni POMITS*. **2**(2): 201-206.
- Das N. 2014. Modeling Develops To Estimate Leaf Area and Leaf Biomass of Lagerstroemia Speciosa in West Vanugach Reserve Forest of Bangladesh. *ISRN Forestry*. **2014**: 1-9.
- Fausett L. 1994. Fundamentals of Neural Networks: Architectures, Algorithms and Applications. In *IEEE Transactions on Computers*.
- Hermawan DD, Widada B & Vlandari RT. 2018. Perbandingan Hasil Panen Padi Dipengaruhi Rata-rata Curah Hujan Atau Irigasi Dengan Model Regresi Nonlinier Kubik di Kabupaten Sukoharjo. *Jurnal Teknologi Informasi dan Komunikasi (TIKomSiN)*. **6**(1): 6-10.
- Huang W, Ratkowsky DA, Hui C, Wang P, Su J & Shi P. 2019. Leaf Fresh Weight Versus Dry Weight: Which is Better For Describing The Scaling Relationship Between Leaf Biomass and Leaf Area For Broad-Leaved Plants?. *Forests*. **10**(3): 1-19.
- Huang W, Su X, Ratkowsky DA, Niklas KJ, Gielis J & Shi P. 2019b. The Scaling Relationships of Leaf Biomass Vs. Leaf Surface Area of 12 Bamboo Species. *Global Ecology and Conservation*. **20**: 1-10.
- Izati ARM & Notobroto HB. 2019. Penerapan Metode Artificial Neural Network dalam Peramalan Jumlah Kunjungan Ibu Hamil (K4). *Jurnal Biometrika dan Kependudukan*. **8**(1): 11-20.
- Jaya IKD. 2004. Pertumbuhan Dan Hasil Jagung Semi Yang Ditanam Dengan Kerapatan dan Orientasi Berbeda. *Agroteksos*. **13**(4): 196-200.
- Kusdarjito C & Suryantini A. 2013. Penggunaan Artificial Neural Network Untuk Pengenalan Pola: Penerimaan dan Pendapatan Petani Tebu. *Sosiohumaniora*. **15**(3): 294-302.
- Lubis LS & Buono A. 2012. Pemodelan Jaringan Syaraf Tiruan Untuk Memprediksi Awal Musim Hujan Berdasarkan Suhu Permukaan Laut. *Jurnal Ilmu Komputer Agri-informatika*. **1**(2): 52-61.
- Pan S, Liu C, Zhang W, Xu S, Wang N, Li Y, Gao J, Wang Y & Wang G. 2013. The Scaling Relationships Between Leaf Mass and Leaf Area of Vascular Plant Species Change With Altitude. *PLOS ONE*. **8**(10): 1-4.
- Pham H. 2019. A New Criterion For Model Selection. *Mathematics*. **7**(12): 1-12.
- Prabowo H, Suhartono S & Prastyo DD. 2020. The Performance Of Ramsey Test, White Test and Terasvirta Test in Detecting Nonlinearity. *Inferensi*. **3**(1): 1-12.
- Rusdiana RY, Widuri LI & Restanto DP. 2021. Pendugaan Model Luas Daun Tanaman Pakcoy (*Brassica rapa* L.) Dengan Regresi Kuantil. *Agrin*. **25**(1): 48.
- Setiawan SIA. 2011. Penerapan Jaringan Saraf Tiruan Metode Backpropagation Menggunakan VB 6. *ULTIMATICS*. **3**(2): 23-28.
- Somers MJ & Casal JC. 2009. Using Artificial Neural Networks to Model Nonlinearity. *Organizational Research Methods*. **12**(3): 403-417.
- Yohannes E, Mahmudy WF & Rahmi A. 2015. Penentuan Upah Minimum Kota Berdasarkan Tingkat Inflasi Menggunakan Backpropagation Neural Network (BPNN). *Jurnal Teknologi Informasi dan Ilmu Komputer*. **2**(1): 34-40.

