



Identifikasi Iklim Mikro pada Single-Span Greenhouse Daerah Tropis menggunakan Artificial Neural Network

Chusnul Arif¹, Herry Suhardiyanto²

1) Mahasiswa Pascasarjana IPB program studi Ilmu Keteknikan Pertanian, email : chusnul_ar@yahoo.com

2) Departemen Teknik Pertanian FATETA-IPB, email : herrysuhardiyanto@ipb.ac.id

Abstract – Identifikasi iklim mikro didalam greenhouse sangat penting dalam meningkatkan efisiensi manajemen dan kontrol lingkungan. Pada paper ini, dikembangkan model Artificial Neural Network (ANN) untuk memprediksi suhu udara didalam single-span greenhouse pada berbagai kemiringan atap. Model ANN terdiri dari 3 layer dengan 5 input dan 1 output. Parameter yang menjadi input model adalah suhu udara didalam greenhouse ($^{\circ}\text{C}$), kelembaban relatif (%), radiasi matahari (W/m^2) dan kemiringan atap ($^{\circ}$), sedangkan suhu udara didalam greenhouse 15 menit kemudian menjadi output model. 4 Model dikembangkan dengan jumlah hidden layer yang berbeda. Hasil validasi model menunjukkan bahwa model dengan 7 hidden layer menghasilkan kinerja terbaik diantara 4 model yang dikembangkan dengan nilai koefisien determinasi (R^2) sebesar 0.8969 dan Root Mean Square Error (RMSE) sebesar 1.24. Hasil prediksi model menunjukkan tren yang sama dengan hasil pengukuran.

Kata kunci : iklim mikro, suhu udara, greenhouse, artificial neural network.

1. PENDAHULUAN

1.1 Latar Belakang

Pada beberapa tahun terakhir, perkembangan metode komputasi dan sensor telah banyak diterapkan pada sistem greenhouse dan industri tanaman. Pendekatan *Artificial Intelligence* telah digunakan antara lain untuk identifikasi dan kontrol sistem produksi tanaman [1] dan kontrol lingkungan greenhouse dengan sistem *hybrid* [2].

Pada daerah tropis, penggunaan greenhouse bermanfaat untuk melindungi tanaman dari serangan hama dan curah hujan yang berlebihan, tetapi adanya *greenhouse effect* menyebabkan suhu udara di dalamnya menjadi terlalu lebih tinggi bagi pertumbuhan tanaman. Salah satu cara mengatasinya adalah menentukan kemiringan sudut atap. Kemiringan sudut atap greenhouse tipe single-span yang optimal untuk daerah tropis adalah 25° [3]. Selain itu beberapa kontrol otomatis telah dikembangkan untuk mengontrol suhu di dalam greenhouse, antara lain kontrol PID (*Proporsional Integral Derivative*) sistem tertutup [4] dan kontrol fuzzy [5,6]. Untuk meningkatkan efisiensi

managemen lingkungan dan kontrol, model iklim greenhouse dan tanaman sangat diperlukan [4].

Model iklim ini dikembangkan dengan mengintegrasikan parameter lingkungan. Hubungan antar parameter ini merupakan hubungan non-linear yang sangat kompleks. Persamaan model pindah panas telah dikembangkan pada tipe tunnel greenhouse [7] dan tipe single-span greenhouse [8] untuk menduga suhu udara didalam greenhouse. Pada model tersebut digunakan beberapa asumsi dan konstanta pindah panas yang mengurangi keakuratan hasil.

Metode lain yang bisa dikembangkan adalah model *black-box non-linear* menggunakan *Artificial Neural Network* (ANN). Pada sistem greenhouse, ANN telah dikembangkan antara lain untuk memprediksi radiasi matahari [9], untuk optimisasi pemberian air dan unsur hara pada pertumbuhan tanaman dalam rumah kaca [10] dan model pertumbuhan tanaman [11].

1.2 Tujuan

Pada paper ini dikembangkan model Artificial Neural Network (ANN) untuk memprediksi suhu udara didalam greenhouse untuk mempermudah dalam menentukan aksi kontrol yang akan dilakukan.

2. BAHAN DAN METODE

2.1 Bahan

Data yang digunakan untuk pengembangan model ini diperoleh dari data sekunder dari penelitian sebelumnya oleh Retnosari [3] pada bulan Agustus – September 2003. *Greenhouse* yang digunakan adalah *singlespan greenhouse* berukuran $6 \times 4 \times 3.9 \text{ m}^3$. Konstruksi *greenhouse* menggunakan kayu, dengan kemiringan atap *greenhouse* yang dapat diubah – ubah menjadi empat kemiringan sudut atap yaitu 15° , 20° , 25° , 35° .

Parameter lingkungan yang diukur meliputi parameter lingkungan makro diluar greenhouse (kelembaban relatif (%), suhu udara di luar ($^{\circ}\text{C}$) dan radiasi matahari (W/m^2)) dan parameter lingkungan mikro didalam greenhouse yaitu suhu udara di dalam greenhouse ($^{\circ}\text{C}$). Pengambilan data menggunakan interval 15 menit.



2.2 Metode


Model Artificial Neural Network (ANN) digunakan sebagai model *black-box non-linear*. Pembelajaran yang digunakan adalah *backpropagation* dengan *multiplayer networks*. Pembelajaran ini merupakan pembelajaran yang paling populer [12]. Model ini terdiri dari tiga layer yaitu *input layer*, *hidden layer* dan *output layer*. Model dikembangkan dengan bahasa pemrograman Visual Basic 6.0

Model ANN yang menggambarkan hubungan *input-output* sistem merupakan *a time delay neural-network model* sebagaimana telah dikembangkan Morimoto, T dan Y. Hashimoto [1] untuk memprediksi pertumbuhan tanaman pada masa pembenihan. Persamaannya diberikan berikut ini:

$$Y(t+1) = T_{in}(t+1) \quad (1)$$

$$Y(t+1) = f\{T_{in}(t), RH(t), Tout(t), Rad(t), sudut\} \quad (2)$$

Dimana $T_{in}(t+1)$ merupakan suhu udara didalam greenhouse ($^{\circ}C$) pada waktu $t+15$ menit kemudian sebagai output kontrol dari model. $T_{in}(t)$ adalah suhu udara didalam greenhouse ($^{\circ}C$) pada waktu t , $RH(t)$ merupakan kelembaban relatif (%) pada waktu t , $Rad(t)$ merupakan radiasi matahari (W/m^2) pada waktu t dan sudut merupakan kemiringan atap ($^{\circ}$) sebagai input kontrol model. Fungsi $f\{\}$ merupakan fungsi *non-linear* yang diberikan oleh model ANN. Model ANN yang dikembangkan dapat dilihat pada Gambar 1.



Gambar 1. Model ANN yang dikembangkan.

Adapun algoritma *backpropagation* yang digunakan adalah sebagai berikut :

1. Inisialisasi Pembobot (*Weight*)

Ambil pembobot awal dengan nilai random yang cukup kecil.

2. Feedforward :

a) Tiap – tiap unit *input* menerima sinyal X_i dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya (*hidden layer*):

b) Tiap – tiap *hidden layer* (H_i) menjumlahkan sinyal – sinyal *input* terbobot sesuai dengan persamaan:

$$h_in_j = \sum X_i V_{ij} \quad (3)$$

dan nilai H_i dihitung dengan menggunakan fungsi sigmoid sebagai fungsi aktivasi. Fungsi ini merupakan fungsi aktivasi yang paling populer digunakan dalam neural network [12] diberikan sebagai berikut:

$$H_i = f(h_in_j) = \frac{1}{1 + e^{-h_in_j}} \quad (4)$$

c) Unit *output* (Y) menjumlahkan sinyal – sinyal *input* terbobot :

$$y_in = \sum H_j w_j \quad (5)$$

dan nilai Y juga dihitung dengan menggunakan fungsi sigmoid sebagai berikut:

$$Y = f(y_in) = \frac{1}{1 + e^{-y_in}} \quad (6)$$

3. Backpropagation :

a) *Backpropagation* dimulai dengan mengitung *error* antara *output* hasil prediksi (Y) dengan target (O_t) sebagai berikut:

$$Error = \frac{1}{2} (O_t - Y)^2 \quad (7)$$

dimana N adalah jumlah data

b) Perbaikan pembobot (w_{jk}) antara *hidden layer* dengan *output layer* dihitung dengan persamaan:

$$\Delta w_j = \eta \delta_k H_i$$

dimana η adalah konstanta pembelajaran dan δ_k dihitung dengan persamaan:

$$\delta_k = (O_t - Y) Y (1 - Y) \quad (8)$$

c) Perbaikan pembobot (V_{ij}) antara *hidden layer* dengan *input layer* dihitung dengan persamaan:

$$\Delta V_{ij} = \eta \delta_j X_i$$



dimana δ_j dihitung dengan persamaan:

$$\delta_j = H_j(1 - H_j) \sum w_j \delta_k \quad (9)$$

d) Pembobot baru dihitung dengan persamaan:

$$w_j(\text{baru}) = w_j(\text{lama}) + \Delta w_j \quad (10)$$

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (11)$$

4. Pengulangan (iterasi)

Proses diatas dilakukan secara berulang sampai pada jumlah pengulangan yang diinginkan sehingga akan sampai pada tes kondisi berhenti.

Kinerja model dinilai berdasarkan nilai koefisien determinasi (R^2) dan nilai *Root Mean Square Error* (RMSE) berdasarkan persamaan berikut ini:

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y(i) - Ot(i))^2}{\sum_{i=1}^N (Y(i) - \overline{Ot})^2} \quad (11)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y(i) - Ot(i))^2} \quad (12)$$

dimana $Y(i)$ adalah hasil prediksi model data ke- i , $Ot(i)$ adalah nilai target data ke- i , \overline{Ot} adalah nilai rata-rata nilai target dan N adalah jumlah data. Kinerja model ANN dengan dua metode tersebut sebagaimana digunakan untuk prediksi evapotranspirasi [13].

Data yang digunakan dibagi menjadi dua kelompok yaitu 128 set data untuk proses pembelajaran model dan 60 set data untuk proses validasi model. Hasil dari model ini adalah nilai pembobot yang akan digunakan untuk memprediksi suhu udara didalam greenhouse 15 menit kemudian.

3. HASIL DAN PEMBAHASAN

3.1 Proses pembelajaran model

Menurut Kusumadewi [14] JST merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Pada model ini proses pembelajaran dilakukan terhadap 128 set data sebanyak 15 000 pengulangan (iterasi). Pada proses pembelajaran ini digunakan 4 nilai *hidden layer* yang berbeda, yaitu 2, 5, 7 dan 9.

Tabel 1. Hasil proses pembelajaran model

No	Jumlah <i>hidden layer</i>	R^2	RMSE
1	2	0.8805	1.35
2	5	0.8958	1.25
3	7	0.9017	1.22
4	9	0.9031	1.21

Tabel 1 diatas menunjukkan hasil proses pembelajaran dengan menggunakan jumlah *hidden layer* yang berbeda-beda. Masing-masing proses pembelajaran tersebut menggunakan konstanta pembelajaran (η) dan jumlah pengulangan (iterasi) yang sama. Pada kasus ini digunakan nilai η sebesar 0.6 dengan 15 000 pengulangan dengan order sistem dipilih sebesar 1 untuk menghemat waktu pembelajaran. Pemilihan konstanta pembelajaran menentukan kecepatan pembelajaran sampai sistem mencapai keadaan optimal, apabila nilainya terlalu besar akan membuat jaringan melompati nilai minimum lokalnya dan akan berosilasi sehingga tidak mencapai konvergensi. Sebaliknya apabila nilainya terlalu kecil menyebabkan jaringan terjebak dalam minimum lokal dan memerlukan waktu lama selama proses pembelajaran.

Pada Tabel 1 diatas dapat dilihat bahwa semakin besar jumlah *hidden layer* yang digunakan menghasilkan proses pembelajaran yang semakin baik. Sehingga ada kemungkinan dengan menambah jumlah *hidden layer* lebih dari 9 akan menghasilkan proses pembelajaran yang lebih baik. Akan tetapi dengan semakin banyak jumlah *hidden layer* akan mengakibatkan proses pembelajaran semakin lama.

Pada model yang dikembangkan jumlah *hidden layer* 7 dan 9 menghasilkan nilai R^2 dan RMSE yang tidak terlalu beda jauh. Nilai R^2 diatas 0.9 yang menunjukkan lebih dari 90% hasil prediksi mendekati hasil pengukuran, sedangkan nilai RMSE sebesar 1.22 dan 1.21 secara berurutan. Nilai RMSE sebesar 1.21 mengindikasikan bahwa hasil prediksi suhu udara didalam greenhouse 15 menit kemudian hanya berselisih 1.21°C dengan hasil pengukuran secara rata-rata. Perbedaan yang cukup kecil ini menunjukkan juga bahwa secara umum model telah mengalami proses pembelajaran dengan baik.

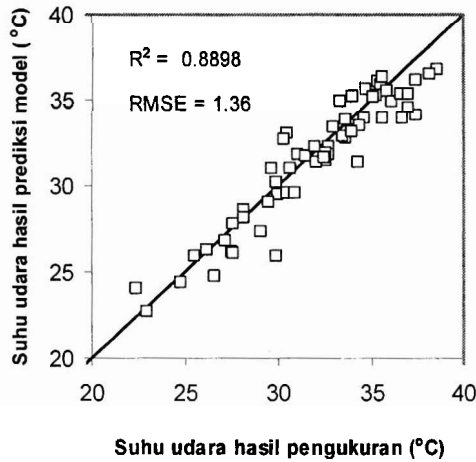
3.2 Hasil validasi model

Data validasi yang digunakan berbeda dengan data pembelajaran. Model validasi ini biasa disebut "*cross validation*" [1]. Hasil validasi masing – masing jumlah *hidden layer* dapat dilihat pada Tabel 2 dan Gambar 2-5 berikut ini:




Tabel 2. Hasil proses validasi model


No	Jumlah <i>hidden layer</i>	R ²	RMSE
1	2	0.8898	1.36
2	5	0.8897	1.30
3	7	0.8969	1.24
4	9	0.8952	1.25



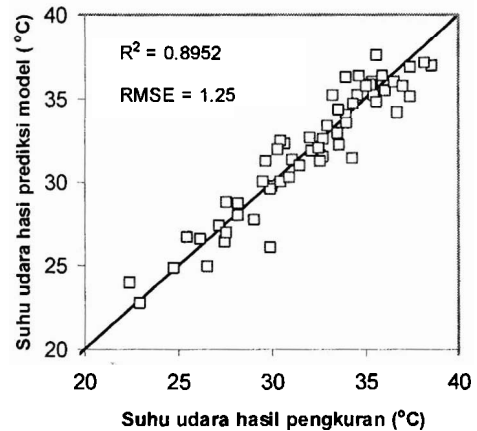
Gambar 2. Grafik perbandingan antara suhu udara didalam greenhouse hasil pengukuran dan pendugaan model dengan 2 *hidden layer*.



Gambar 3. Grafik perbandingan antara suhu udara didalam greenhouse hasil pengukuran dan pendugaan model dengan 5 *hidden layer*.



Gambar 4. Grafik perbandingan antara suhu udara didalam greenhouse hasil pengukuran dan pendugaan model dengan 7 *hidden layer*.




Gambar 5. Grafik perbandingan antara suhu udara didalam greenhouse hasil pengukuran dan pendugaan model dengan 9 *hidden layer*.

Pada Tabel 2 dan grafik diatas dapat dilihat bahwa hasil validasi terbaik dengan “*cross validation*” terjadi pada model dengan 7 *hidden layer*. Hal ini menunjukkan sedikit perbedaan dengan proses pembelajaran, dimana semakin besar jumlah *hidden layer* akan menghasilkan proses pembelajaran yang semakin baik. Sehingga dengan “*cross validation*” menunjukkan bahwa semakin baik proses pembelajaran belum tentu menghasilkan proses validasi yang semakin baik pula.

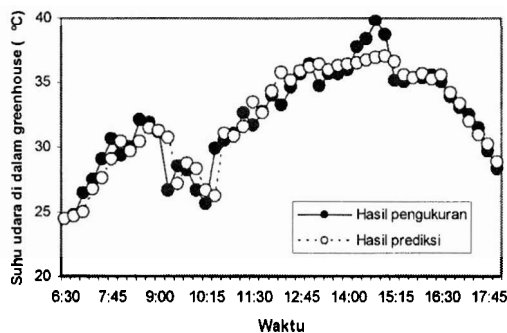
Perbedaan hasil validasi antara model dengan 7 *hidden layer* dan 9 *hidden layer* tidak terlalu besar, baik untuk nilai R² maupun RMSE. Pada model dengan 7 *hidden layer* menghasilkan R² sebesar 0.8969 dan RMSE sebesar 1.24, sedangkan model dengan 9 *hidden layer* menghasilkan R² sebesar 0.8952 dan RMSE sebesar 1.25. Dengan hasil ini maka pembobot yang dihasilkan dari proses pembelajaran dengan 7 *hidden layer* dipilih untuk



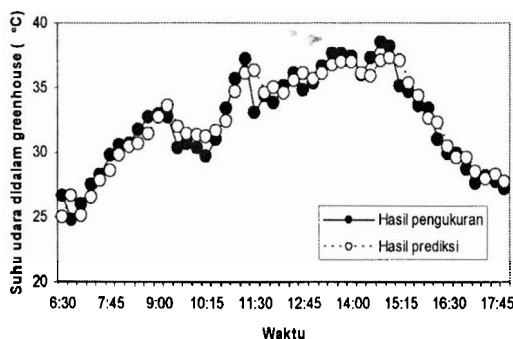
memprediksi suhu udara didalam greenhouse. Hasil prediksi ditunjukkan pada Gambar 6-9 berikut ini:




Gambar 6. Perbandingan suhu udara hasil pengukuran dan prediksi pada greenhouse dengan kemiringan 15°



Gambar 7. Perbandingan suhu udara hasil pengukuran dan prediksi pada greenhouse dengan kemiringan 20°



Gambar 8. Perbandingan suhu udara hasil pengukuran dan prediksi pada greenhouse dengan kemiringan 25°



Gambar 9. Perbandingan suhu udara hasil pengukuran dan prediksi pada greenhouse dengan kemiringan 35°

Pada Gambar 6-9 diatas menunjukkan bahwa hasil prediksi model menunjukkan nilai dengan tren yang hampir sama dengan hasil pengukuran, sehingga model bisa digunakan untuk menentukan suhu udara didalam greenhouse. Dari Gambar tersebut juga terlihat suhu udara didalam greenhouse semakin siang semakin tinggi dan akan menurun kembali setelah mendekati waktu sore hari. Suhu udara didalam greenhouse sangat dipengaruhi oleh radiasi matahari. Besarnya radiasi matahari yang diterima di suatu tempat tergantung dari posisinya pada garis lintang, ketinggian dan tanggal dalam setahun [15].

Nilai pembobot yang dihasilkan dengan 7 *hidden layer* ini merupakan konstanta yang menjadi representasi dari persamaan matematika yang menjelaskan hubungan antara lima parameter *input* iklim dengan suhu udara didalam greenhouse. Untuk dapat meningkatkan kemampuan belajar dari jaringan, maka data pembobot tersebut dapat dipergunakan sebagai acuan untuk memperbaiki pengalaman ANN dengan melakukan validasi terhadap data – data baru.

4. KESIMPULAN

1. Empat model Artificial Neural Network (ANN) yang dikembangkan untuk memprediksi suhu udara didalam greenhouse 15 menit kemudian telah dapat melakukan proses pembelajaran dengan baik.
2. Semakin besar jumlah *hidden layer* semakin baik pula proses pembelajarannya dengan konstanta pembelajaran dan jumlah iterasi yang sama.
3. Hasil validasi terbaik dari keempat model adalah model dengan 7 *hidden layer* yang menghasilkan koefisien determinasi (R^2) sebesar 0.8969 dan RMSE sebesar 1.24.
4. Hasil validasi juga menunjukkan semakin baik proses pembelajaran tidak selalu menghasilkan hasil validasi yang semakin baik pula.



DAFTAR REFERENSI

- [1] Morimoto, T and Y. Hashimoto. 2000. AI approaches to identification and control of total plant production system. *Control Engineering Practice* 8: 555-567.
- [2] Arias, A. Ramirez., J.Goddard*, I.Lopez Cruz. 2002. A Hybrid System for Optimal Greenhouse Climate Control using Artificial Intelligence Techniques. Seventh International Conference on Computers in Agriculture. Orlando, FL, USA. October 26-30th 1998.
- [3] Retnosari, Putik. 2003. Pengembangan Model *Artificial Neural Network* untuk Pendugaan Suhu Udara dalam Greenhouse dengan Berbagai Kemiringan Atap dalam *Single-span Greenhouse* Skripsi. Departemen Teknik Pertanian. Fakultas Teknologi Pertanian. IPB, Bogor.
- [4] Cunha, J. Boaventura. 2003. Greenhouse climate models: an overview. European Federation for Information Technology in Agriculture, Food and Environment (EFITA) conference. Debrecen-Budapest, Hungary. July 5-9th 2003:559-564
- [5] Salgado, Paulo, J. Boaventura Cunha, Carlos Couto. 1998. A Fuzzy Identification and Controller for the Agriculture Greenhouse. Seventh International Conference on Computers in Agriculture. Orlando, FL, USA. October 26-30th 1998.
- [6] Sigrimis, N, N.Rerras, A. Anastasiou, V. Vogli .1998. An Adaptive System for Optimizing the Management of Greenhouses. Seventh International Conference on Computers in Agriculture. Orlando, FL, USA. October 26-30th 1998.
- [7] Romdhonah, Yayu. 2002. Analisis Sudut Datang Radiasi Matahari dan Pengembangan Model Pindah Panas pada *Greenhouse*. Skripsi. Jurusan Teknik Pertanian. Fakultas Teknologi Pertanian. IPB, Bogor.
- [8] Nuryawati, Titin. 2006. Analisis Sudut Datang Radiasi Matahari dan Pengembangan Model Pindah Panas pada Greenhouse Menggunakan Artificial Neural Network. Skripsi. Departemen Teknik Pertanian. Fakultas Teknologi Pertanian. IPB, Bogor.
- [9] Coelho, J.P., J.Boaventura Cunha and P.B. de Moura Oliveira. 2002. Solar Radiation Prediction Methods Applied to Improve Greenhouse Climate Control. World Congress on Computers in Agriculture and Natural Resources. Iguacu Falls, Brazil. March 13-15th 2002.
- [10] Arif Chusnul, Herry Suhardiyanto dan Suroso. 2006. Penerapan Jaringan Syaraf Tiruan dan Algoritma Genetika Untuk Optimisasi Pemberian Air dan Unsur Hara Pada Pertumbuhan Tanaman dalam Rumah Kaca. The 7th Seminar on Intelligent Technology and Its Applications, May 2nd, 2006, Surabaya, Indonesia : II-I-15 – 20.
- [11] Tamrin, K. B. Seminar, H. Suhardiyanto, S. Hardjoamidjodjo. 2005. Model Jaringan Syaraf Tiruan untuk Pertumbuhan Tanaman Ketimun Mini (*Cucumis sativus L. Var. Marla*) pada Fase Vegetatif. *Jurnal Keteknikan Pertanian*. 19 (1): 1-10.
- [12] Nugroho, A. Satrio. 2003. Information Analysis using Soft computing – The Applications to Character Recognition, Meteorological Prediction, and Bioinformatics Problems. A Dissertation. Nagoya Institute of Technology, Nagoya, Japan, pp12.
- [13] Suprayogi, Slamet, Budi Indra Setiawan, Suroso. 2004. Estimasi Evapotranspirasi Potensial menggunakan Jaringan Syaraf Tiruan. *Majalah Geografi Indonesia*. Vol 18(1) : 31-42.
- [14] Kusumadewi, Sri. 2003. Artificial Intellegence (Teknik dan Aplikasinya). Graha Ilmu. Yogyakarta.
- [15] Walls, Ian G. 1993. The Complete Book of the Greenhouse 5th ed. Ward Lock Ltd., London.