

**PEMODELAN KOMPOSISI PAKAN KAMBING PERANAKAN ETAWA (PE)
UNTUK OPTIMASI KANDUNGAN GIZI SUSU MENGGUNAKAN ARTIFICIAL
NEURAL NETWORK (ANN) DAN PARTICLE SWARM OPTIMIZATION (PSO)
(Studi Kasus pada UPT Pembibitan Ternak dan Hijauan Makanan Ternak Singosari-Malang)
Canny Amerilyse Caesar¹⁾, Imam Cholissodin, S.Si. M.Kom²⁾, M. Ali Fauzi, S.Kom. M.Kom³⁾**

Program Studi Teknik Informatika

Fakultas Ilmu Komputer

Universitas Brawijaya, Malang 65145, Indonesia

email : [camerilyse\[at\]outlook.com](mailto:camerilyse[at]outlook.com)¹⁾, [imamcs\[at\]ub.ac.id](mailto:imamcs[at]ub.ac.id)²⁾, [moch.ali.fauzi\[at\]ub.ac.id](mailto:moch.ali.fauzi[at]ub.ac.id)³⁾

Abstrak

Susu merupakan salah satu sumber protein hewani yang mengandung semua zat yang dibutuhkan tubuh. Ternak penghasil susu utama di Indonesia yaitu sapi perah, namun produksi susunya belum dapat mencukupi kebutuhan masyarakat. Alternatifnya adalah kambing peranakan etawa (PE). Tingginya kualitas kandungan gizi susu sangat dipengaruhi oleh beberapa faktor salah satunya, yaitu faktor pakan. Bagian peternakan kambing PE di UPT Pembibitan Ternak dan Hijauan Makanan Ternak Singosari-Malang masih menghadapi permasalahan, yaitu rendahnya kemampuan dalam memberikan komposisi pakan terhadap kambing PE. Kekurangan tersebut berpengaruh terhadap kualitas susu yang dihasilkan. Diperlukan pengetahuan rekayasa kandungan gizi susu untuk menentukan komposisi pakan dalam menghasilkan susu premium dengan kandungan gizi optimal. Penulis menggunakan metode *Artificial neural network* (ANN) dan *Particle Swarm Optimization* (PSO) untuk membuat pemodelan pakan kambing dalam mengoptimasi kandungan gizi susu kambing. Dalam analisa pengujian yang dilakukan dengan kasus untuk berat badan kambing 32 kg, serta jenis pakan yang digunakan yaitu rumput Odot 70% dan rumput Raja 30% dapat menaikkan protein hingga 3.42% dan menurunkan lemak hingga 5.19% .

Kata Kunci: Susu Kambing, Optimasi, Artificial Neural Network (ANN), *Particle Swarm Optimization* (PSO), Kandungan nutrisi pakan.

Abstract

Milk is one of the animal protein sources which it contains all of the substances needed by human body. The main milk producer cattle in Indonesia is dairy cow, however its milk production has not fulfilled the society needs. The alternative is the goat, the Etawa crossbreed (PE). The high quality of milk nutrients content is greatly influenced by some factors one of them, is the food factor. The PE goat livestock division of the UPT Cattle Breeding and the Cattle Food Greenery in Singosari-Malang still faces the problem, it is the low ability in giving the food composition for PE goat. This flaw affects the quality of the produced milk. It needs the artificial science of the milk nutrients contain in order to determine the food composition to produce premium milk with the optimum nutrients contain. The writer uses the method of the Artificial Neural Network (ANN) and the Particle Swarm Optimization (PSO) to make the modeling of goat food in optimizing the content of goat milk nutrients. In the analysis of the examination that is done with the case of 32 kg goat weight, also the food type used is the 70 % Odot grass and 30% Raja grass can increase the nutrients contain of the protein milk for 3.42% and decrease the fat nutrients contain for 5.19%.

Key Words : Goat Milk, Optimization, Artificial Neural Network (ANN), *Particle Swarm Optimization* (PSO), the food nutrients contain.

1. PENDAHULUAN

1.1 Latar belakang

Susu merupakan bahan makanan yang dapat dikatakan sebagai makanan yang sempurna karena pada susu terdapat kandungan gizi yang sangat diperlukan oleh tubuh, seperti protein, karbohidrat, lemak dan vitamin ^[1]. Tingginya produksi susu dan kualitas kandungan gizi susu sangat dipengaruhi oleh beberapa faktor salah satunya, yaitu faktor pakan ^[7]. Bagian peternakan kambing peranakan etawa (PE) di UPT Pembibitan Ternak dan Hijauan Makanan Ternak Singosari-Malang masih

menghadapi permasalahan, yaitu rendahnya kemampuan dalam memberikan *treatment* komposisi pakan terhadap kambing peranakan etawa. Kekurangan tersebut selain mengakibatkan lambatnya pertumbuhan produksi susu juga berpengaruh terhadap kualitas susu yang dihasilkan ^[3].

Permasalahan rekayasa kandungan gizi susu kambing agar dapat optimal tersebut dapat diselesaikan dengan beberapa metode pemodelan. Perkembangan terakhir pemodelan prediksi dengan menggunakan *Artificial Neural Network* (ANN)

merupakan salah satu pemodelan yang banyak digunakan dalam prediksi ekonomi, keuangan, bisnis dan industri ^[10]. Kemampuan ANN untuk pelatihan data *training* dilakukan dengan menggunakan *backpropagation*, namun lambatnya laju konvergensi dan terjebak dalam minimum local merupakan beberapa kelemahan dari metode *backpropagation* ^[10]. Untuk mengatasi kelemahan tersebut, dapat digunakan beberapa pendekatan optimasi seperti *genetic algoritma* (GA), *particle swarm optimization* (PSO) dan *ant colony optimization* (ACO) ^[11].

Penelitian terdahulu memberikan kesimpulan bahwa dibanding ACO dan GA, secara individu dengan PSO memiliki kinerja terbaik karena dapat lebih cepat mendapatkan hasil yang optimal. ^[10]. Kemudian dikembangkan model dengan menggunakan dua metode yaitu gabungan PSO-ANN untuk menguji beberapa data klasifikasi yang menghasilkan rata-rata yang cukup efektif dalam mencapai konvergensi dan ruang global minimum. Dalam penelitian yang membahas optimasi parameter dalam pembuatan genteng pada sebuah pabrik yang menggunakan metode ANN dan PSO oleh Thitipong Navalertporn dan Nitin V. Afzulpurkar (2011) membuktikan bahwa dengan menggunakan kombinasi ANN dan PSO menghasilkan parameter-parameter yang optimal sehingga meningkatkan hasil produksi dari 60% menjadi 97% serta mendapatkan hasil yang lebih akurat daripada hanya menggunakan metode *backpropagation* saja.

Berdasarkan latar belakang yang telah diuraikan di atas, penulis berinisiatif untuk merancang sistem berbasis komputer untuk memberikan solusi optimasi kandungan gizi susu kambing dalam penelitian tugas akhir yang berjudul “Pemodelan Komposisi Pakan Kambing Peranakan Etawa (PE) untuk Optimasi Kandungan Gizi Susu Menggunakan *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO)”. Penulis berharap hasil penelitian ini dapat membantu peternak kambing peranakan etawa dalam mengoptimalkan kandungan gizi susu yang dihasilkan.

1.2 Rumusan masalah

Berdasarkan latar belakang masalah di atas, dapat dibuat rumusan masalah sebagai berikut:

1. Bagaimana mengimplementasikan metode *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO) untuk menyelesaikan permasalahan Pemodelan Komposisi Pakan Kambing Peranakan Etawa (PE) untuk Mengoptimalkan Kandungan Gizi Susu Kambing?
2. Berapa nilai parameter optimal untuk optimasi dari kandungan gizi susu kambing yang menggunakan metode *Artificial Neural*

Network (ANN) dan *Particle Swarm Optimization* (PSO)?

3. Berapa hasil kualitas solusi untuk optimasi dari kandungan gizi susu kambing yang menggunakan metode *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO)?

1.3 Tujuan

1. Menerapkan *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO) untuk menyelesaikan permasalahan Pemodelan Komposisi Pakan Kambing Peranakan Etawa (PE) untuk Mengoptimalkan Kandungan Gizi Susu Kambing.
2. Mengetahui nilai parameter yang optimal untuk optimasi dari kandungan gizi susu kambing yang menggunakan metode *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO).
3. Mengetahui hasil kualitas solusi untuk optimasi dari kandungan gizi susu kambing yang menggunakan metode *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO).

1.4 Batasan masalah

Batasan masalah yang dijadikan pedoman dalam pelaksanaan penelitian dan penyusunan skripsi ini adalah sebagai berikut:

1. Jenis kambing yang diteliti adalah kambing perah, yaitu kambing peranakan etawa (PE) betina pada masa laktasi dengan bobot badan 32 kg, 34 kg, 36 kg, 38 kg dan 40 kg.
2. Jenis pakan yang digunakan adalah 10 jenis bahan pakan hijauan yaitu rumput taiwan, rumput odot, rumput setaria, rumput raja, rumput B.Decumbens, kaliandra, gamal, lamtoro, turi dan tarum.
3. Jenis pakan yang dapat dimodelkan hanya dua jenis.
4. Terdapat 4 output kandungan gizi susu yang diteliti, yaitu protein, lemak (*fat*), laktosa dan *density* (berat jenis).
5. Kandungan gizi susu yang dapat dioptimalkan adalah protein, laktosa dan *density* (berat jenis).
6. Kandungan gizi susu yang dapat diminimalkan adalah lemak (*fat*).
7. Kandungan nutrisi dari pakan hijauan berupa Abu, PK, LK dan SK.

2. DASAR TEORI

2.1 Jenis Kambing

Jenis kambing dapat dibedakan menjadi kambing potong dan kambing perah ^[12].

a. Kambing Potong

Kambing potong adalah kambing yang ditenak untuk produksi daging.

b. Kambing Perah

Kambing perah adalah kambing yang ditenak untuk produksi susu.

2.2 Kandungan Nutrisi Pakan Kambing Peranakan Etawa (PE)

Pakan ternak harus terjaga kualitas dan kuantitas agar proses perkembangan, produksi dihasilkan menjadi baik. Berikut adalah daftar tabel kandungan dari berbagai bahan pakan hijuan dalam 1 kg yang ditunjukkan pada Tabel 2.1.

Tabel 2.1 Tabel Kandungan Nutrisi Pakan Kambing

No.	Bahan Pakan	Abu (%)	PK (%)	LK (%)	SK (%)
1	Rumput Taiwan	18,78	18,78	26,45	1,20
2	Rumput Odot	16,97	17,03	24,84	1,76
3	Rumput Setaria	11,5	8,5	32,5	1,76
4	Rumput Raja	18,6	13,5	24,84	3,5
5	Rumput Brachiaria decumbens	10,6	8,3	38,3	1,2
6	Kaliandra	7,27	21,55	13,96	2,99
7	Gamal	9,60	19,96	17,59	3,85
8	Lamtoro	-	24,2	21,5	3,7
9	Turi	-	29,2	17,2	3,4
10	Tarum	6,42	24,17	-	-
11	Pollar	-	16,5	10	4
12	Bungkil Sawit	-	18,5	12	2,5
13	Empok Jagung	-	8,40	9,72	6,91
14	Bungkil Kedelai	-	43,7	6	0,9
15	Mineral	-	-	-	-

Sumber: disnak.jatimprov

Keterangan:

1. Abu

Abu merupakan zat pakan anorganik yang mengandung unsur-unsur yang dibutuhkan oleh hewan ternak seperti Ca, K, Na, Mg, Fe, P dan CL.

2. Protein kasar (PK)

Protein adalah bahan organik kompleks yang mempunyai berat molekul tinggi dengan peranan yang banyak dan berbeda-beda dalam tubuh. Yang diperlihatkan dalam tabel kandungan nutrisi bahan ransum pakan kambing PE adalah protein kasar.

3. Lemak kasar (LK)

Kandungan lemak dalam pangan adalah lemak kasar yang merupakan kandungan total lipida dalam jumlah yang sebenarnya.

4. Serat kasar (SK)

Komponen utama penyusun serat kasar berupa karbohidrat. Jumlah serat kasar pada pakan didasarkan pada *feed intake* (jumlah pakan yang dikonsumsi) oleh hewan ternak.

2.3 Kandungan Gizi Susu Kambing

Analisis karakteristik kualitas susu segar yang dilakukan meliputi berat jenis, kadar protein, kadar

lemak, kadar bahan kering dan bahan kering tanpa lemak. Kandungan gizi susu kambing ditunjukkan dalam Tabel 2.2.

Tabel 2.2 Kandungan Gizi Susu Kambing

No	Kandungan	Susu Kambing
1	Protein (g)	3,6
2	Lemak (g)	4,2
3	Karbohidrat (g)	4,5
4	Kalori (g)	69
5	Fosfor I (g)	111
6	Kalsium (g)	134
7	Magnesium (g)	14
8	Besi (g)	0,05
9	Natrium (g)	50
10	Kalium (g)	204
11	Vitamin A (IU)	185
12	Thiamin (mg)	0,05
13	Riboflavin (g)	0,14
14	Niacin (mg)	0,28
15	Vitamin B6 (mg)	0,05

Sumber: Balai Penelitian Veteriner, Bogor (2008)

Berikut ini merupakan tabel kualitas susu kambing ditunjukkan pada Tabel 2.3.

Tabel 2.3 Kualitas Susu

Karakteristik	Kriteria Berkualitas		
	Premium	Baik	Standar
Protein (%)	>3,70	>3,40-3,70	3,10-3,40
Lemak (%)	>4,00	>3,50-4,00	3,25-3,50
Bahan Kering (%)	>13,00	>12,00-13,00	11,70-12,00

Sumber: Thai Agricultural Standard (2008)

2.4 Artificial Neural Network

Terdapat dua tahapan yang dilakukan dalam algoritma *artificial neural network*, antara lain:

1. Feedforward

Bentuk arsitektur *neural networks* (NN) yang secara umum paling banyak digunakan dalam aplikasi di bidang teknik atau rekayasa adalah *Multi Layer Perceptrons* (MLP) yang juga dikenal dengan *Feed Forward Neural Networks* (FFNN). Langkah-langkah pada *feed forward neural network* adalah sebagai berikut [14]:

1. Setiap unit *input* ($x_i, i=1, \dots, n$) akan menerima sinyal *input* x_i dan menyebarkan sinyal yang telah diterima ke semua unit pada *hidden layer*.
2. Setiap unit *hidden* ($z_j, j=1, \dots, p$) harus menjumlahkan bobot dari sinyal *input* dengan menggunakan persamaan berikut.

$$z_{inj} = v_{0j} + \sum_i^n x_i v_{ij} \quad 2.1$$

Setelah menjumlahkan bobot dari sinyal *input* menggunakan persamaan 2.1, tahap selanjutnya adalah menerapkan fungsi aktivasi untuk menghitung sinyal *output* $z_j = f(z_{inj})$ kemudian mengirimkan sinyal tersebut ke semua unit pada *output layer*.

3. Setiap unit *output* ($y_k, k=1, \dots, m$) harus menjumlahkan bobot dari sinyal *input* dengan menggunakan persamaan berikut.

$$y_{ink} = w_{0k} + \sum_j^p z_j w_{jk} \quad 2.2$$

Setelah menjumlahkan bobot dari sinyal *input* menggunakan persamaan 2.1, tahap selanjutnya adalah menerapkan fungsi aktivasi untuk menghitung sinyal *output* dengan persamaan

$$y_k = y_{ink} \quad 2.3$$

2. Backpropagation

Model ANN umumnya menggunakan Algoritma *backpropagation* (BP) yang merupakan pengembangan dari algoritma *least mean square* untuk melatih jaringan dengan beberapa layer. Langkah-langkah metode *backpropagation* adalah sebagai berikut:

- 1) Setiap unit *output* ($y_k, k=1, 2, 3, \dots, m$) menerima pola target yang sesuai dengan *input* pelatihan, kemudian hitung error dengan menggunakan persamaan 2.4 berikut.

$$\delta_k = (t_k - y_k) y_k (1 - y_k) \quad 2.1$$

Kemudian hitung suku perubahan bobot menggunakan *learning rate* dan *momentum* seperti pada persamaan 2.5.

$$\Delta w_{jk} = (\alpha \delta_k z_j) + (\alpha \eta \delta_k z_j) \quad 2.2$$

Keterangan:

t_k = target *output*

δ_k = error unit *output* y_k ke unit *hidden*

Δw_{jk} = perubahan bobot dari *hidden layer* ke *output layer*

α = *learning rate*

η = *momentum*

- 2) Setiap unit tersembunyi ($z_j, j=1, 2, 3, \dots, n$) menjumlahkan delta *input*-nya seperti pada persamaan 2.6.

$$\delta_{inj} = \sum_{k=1}^m \delta_k w_{jk} \quad 2.3$$

Kemudian hitung error menggunakan persamaan 2.7.

$$\delta_j = \delta_{inj} f(z_{inj}) \quad 2.4$$

Hitung perubahan bobot menggunakan persamaan 2.8.

$$\Delta v_{ij} = (\alpha \delta_j x_i) + (\alpha \eta \delta_j x_i) \quad 2.5$$

Keterangan:

δ_j = error dari *output layer* ke *hidden layer* z_j

δ_{inj} = error pada *hidden layer*

Δv_{ij} = perubahan bobot *input layer* ke *hidden layer*

Tahapan Perubahan Bobot

1. Setiap unit *output* ($y_k, k=1, 2, 3, \dots, m$) dilakukan perubahan bobot dengan persamaan 2.9.

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad 2.6$$

Setiap unit tersembunyi ($z_j, j=1, 2, 3, \dots, n$) dilakukan perubahan bobot dengan persamaan 2.10.

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad 2.7$$

Proses Normalisasi

Metode normalisasi data yang digunakan dalam penelitian ini adalah metode *Min-Max*. Normalisasi *Min-Max* merupakan metode yang *re-scale* data dari suatu *range* ke *range* yang baru. Persamaan matematika dari metode ini adalah sebagai berikut [15]. Proses normalisasi dilakukan dengan mencari nilai minimal dan maksimal seperti pada persamaan 2.11

$$x'_i = 0.8 * \left(\frac{x_i - \min(x)}{\max(x) - \min(x)} \right) + 0.1 \quad 2.8$$

Keterangan:

x'_i = Nilai normalisasi data ke- i

x_i = nilai data ke- i

$\min x$ = nilai minimal data

$\max x$ = nilai maksimal data

Proses Denormalisasi

Proses denormalisasi dilakukan untuk mengubah nilai normalisasi ke dalam luaran nilai data asli. Persamaan matematika dari denormalisasi ditunjukkan pada persamaan 2.12 [16] :

$$y_i'' = \frac{((\max(x) - \min(x)) * (x_i' - 0.1))}{0.8} + \min(x) \quad 2.9$$

Keterangan:

y_i'' = nilai denormalisasi

Jumlah Hidden Layer

Berdasarkan penelitian Shibata dan Ikeda (2009) berjudul “*Effect of Number of Hidden Neurons on Learning in Large-scale Layered Neural Networks*” meneliti efek dari stabilitas dari hidden layer di proses pembelajaran jaringan syaraf tiruan. Rumus untuk menentukan jumlah *hidden layer* ditunjukkan pada persamaan 2.13 [17]:

$$h = \sqrt{p + o} \quad 2.10$$

Keterangan:

h = jumlah *hidden layer*

p = jumlah *input layer*

o = jumlah *output layer*

Mean Square Error (MSE)

Mean Square Error (MSE) merupakan salah satu metode yang dapat digunakan untuk melakukan evaluasi kesalahan. Pada ANN, MSE dapat digunakan untuk meningkatkan optimasi dari proses yang dilakukan. Persamaan matematika dari MSE ditunjukkan pada persamaan 2.14 [18]:

$$MSE = \frac{1}{k} \sum_{k=1}^n (y_k - t_k)^2 \quad 2.11$$

Keterangan :

N : jumlah data

y_k : nilai *output* data

t_k : nilai target data

2.5 Parameter PSO

Parameter yang dibutuhkan pada algoritma particle swarm optimization antara lain^[17]:

1. Swarm size

Swarm size atau jumlah partikel. Sebenarnya dalam sebagian besar masalah 5-10 partikel sudah cukup, namun untuk masalah yang sangat sulit atau khusus, bagus untuk mencoba 100 atau 200 particle.

2. Problem dimension

Problem dimension atau dimensi solusi dari partikel. Ini ditentukan dari masalah yang akan dioptimasi.

3. Range

Batas pencarian partikel ini juga ditentukan dari masalah yang akan dioptimasi. Dapat menspesifikasikan range yang berbeda untuk dimensi yang berbeda dari partikel.

4. Inertia weight atau bobot inersia (w)

Bobot inersia dikenalkan oleh Shi dan Eberhart (1998) yang dalam algoritma particle swarm optimization digunakan sebagai keseimbangan antara kemampuan eksplorasi global dan lokal secara utama dan merupakan parameter penurunan kecepatan untuk menghindari stagnasi partikel di lokal optimum^[11]. Bobot inersia (w) pada dasarnya akan mengontrol seberapa besar pengaruh pengetahuan dari arah terbang sebelumnya yang akan mempengaruhi kecepatan baru.

Inersia akan mengecil sesuai dengan bertambahnya iterasi sehingga kemampuan PSO dalam pencarian lokal akan lebih efisien dan konvergensi ke solusi optimum global, dimana nilai minimum dan maksimum w yang digunakan berada dalam range 0 sampai 1^[15]. Adapun persamaan yang digunakan untuk menghitung nilai w adalah

$$w = w_{min} + (w_{max} - w_{min}) * \frac{(t_{max} - t)}{t_{max}} \quad 2.15$$

2.6 Penerapan PSO

1. Inisialisasi Partikel

Proses pertama adalah inisialisasi partikel.

$$x_i(0) = x_{min,d} + r_d(x_{max,d} - x_{min,d}), \forall d = 1, \dots, n_x, \forall i = 1, \dots, n_s \quad 2.16$$

x_{id} adalah posisi partikel ke-i pada dimensi ke-d, dimana $r_d \sim U(0,1)$ merupakan nilai acak (random) dengan range [0,1]. Kecepatan awal dapat diinisialisasi menjadi nol.

$$V_{id}(0) = 0 \quad 2.17$$

Posisi terbaik individu ke-i ($pBest_i$) awal untuk setiap partikel diinisialisasikan dengan posisi partikel pada waktu $t = 0$

$$pBest_i(0) = x_i(0) \quad 2.18$$

2. Menghitung fungsi obyektif ($f(x)$)

Algoritma genetika dapat menyelesaikan masalah kompleks, yaitu permasalahan optimasi. Untuk mendapatkan nilai fitness, suatu individu harus dievaluasi berdasarkan suatu nilai fungsi obyektif tertentu. Jika permasalahannya adalah

optimasi untuk memaksimalkan fungsi h , maka digunakan fungsi obyektif $f(x) = h$ untuk mencari nilai fitnessnya. Akan tetapi, jika permasalahannya adalah optimasi untuk meminimalkan fungsi h , maka digunakan fungsi obyektif $f(x) = 1/h$ untuk mencari nilai fitnessnya. Rumus fitness diperlihatkan pada persamaan 2.19.^[14]

$$f(x) = \frac{1}{(h+a)} \quad 2.19$$

3. Mencari Local Best ($pBest$) dan Global Best ($gBest$)

Komponen kognitif ($pBest$) merupakan posisi terbaik individu atau partikel yang telah dikunjungi sejak waktu pertama. Untuk masalah minimalisasi $pBest$ dihitung sebagai berikut^[14]:

$$pBest_i(t+1) = \begin{cases} pBest_i(t) & \text{jika } f(x_{id}(t+1)) \geq f(pBest_i(t)) \\ x_{id}(t+1) & \text{jika } f(x_{id}(t+1)) < f(pBest_i(t)) \end{cases} \quad 2.20$$

Sedangkan nilai terbaik global ($gBest$) berasal dari hasil social learning dari swarm yang ditemukan sebagai posisi individu terbaik dari keseluruhan partikel yang pernah ditemukan. Mencari $gBest$ untuk kasus minimalisasi dihitung sebagai berikut^[14]:

$$f(gBest_i(t)) = \min\{f(x_{id}(t)), \dots, f(x_{nd}(t+m))\} \quad 2.21$$

4. Memperbarui atau Update Kecepatan dan Posisi

Berdasarkan $pBest$ dan $gBest$ yang diperoleh, maka kecepatan (v_{id}) dan posisi dari particle (x_{id}) diubah. Persamaan untuk perubahan kecepatan (V_{id})^{[11][2]}:

$$v_{id}^{t+1} = w * v_{id}^t + c_1 * r_1 * (pBest_i^t - x_{id}^t) + c_2 * r_2 * (gBest^t - x_{id}^t) \quad 2.22$$

Kecepatan akan ditambahkan pada posisi partikel sekarang untuk mendapatkan posisi baru partikel, dengan kata lain individu bergerak menuju posisi baru sesuai dengan kecepatan. Persamaan untuk perubahan posisi (x_{id}) adalah sebagai berikut^{[11][2]}:

$$x_{id}^{t+1} = x_{id}^t + V_{id}^{t+1} \quad 2.23$$

Untuk mengontrol eksplorasi global partikel, perlu adanya pembatasan kecepatan maksimum. Teknik ini disebut velocity clamping untuk mencegah partikel bergerak terlalu jauh melampaui ruang pencariannya. Dalam penelitian ini, batasan kecepatan atau threshold yang digunakan adalah sebagai berikut^[15]:

$$\begin{aligned} &\text{jika } v_{id}^{t+1} > v_d^{max} \quad \text{maka } v_{id}^{t+1} = v_d^{max} \\ &\text{jika } v_{id}^{t+1} < -v_d^{max} \quad \text{maka } v_{id}^{t+1} = -v_d^{max} \end{aligned} \quad 2.24$$

Strategi velocity clamping telah terbukti lebih efektif dalam meredam osilasi dengan menyediakan keseimbangan yang baik antara eksplorasi global dan eksploitasi lokal^[14]. Namun dalam menentukan nilai v_d^{max} bergantung pada bentuk permasalahan yang diselesaikan.

$$v_d^{max} = k * (x_d^{max} - x_d^{min}), k \in (0,1) \quad (2.15)$$

5. Random Injection

Pada ruang pencarian yang tidak terlalu besar, sering dijumpai pencapaian konvergensi dini. Hal ini disebabkan karena partikel lebih cepat menemukan posisi terbaik global dalam ruang pencarian yang kecil dan disebabkan oleh kurangnya diversitas populasi setelah melewati sekian generasi^[16]. Untuk mengatasi hal tersebut dan membuat partikel lebih teliti atau bertahap dalam melakukan eksploitasi lokal dan eksplorasi global, maka diterapkan sistem *random injection*^[16]. Random injection dilakukan dengan menginisialisasi kembali posisi n partikel setiap g interval iterasi. Penentuan n dan g yang sesuai dilakukan berdasarkan beberapa percobaan sebelumnya pada sistem PSO.

Pada kasus ini ditentukan jumlah partikel yang diinjeksi adalah semua partikel dengan ukuran *swarmsize* serta interval *injection* adalah setiap kelipatan 3 iterasi. Random injection dilakukan dengan mengevaluasi nilai fitness partikel saat memasuki interval injec. Jika nilai local best samdengan nilai fitness maka kondisi akan diinjeksi secara random.


6. Kondisi berhenti

Merupakan kriteria yang digunakan untuk mengakhiri iterasi atau perulangan dan mendapatkan solusi optimum. Kondisi berhenti tidak boleh menyebabkan PSO konvergen dini karena solusi suboptimal akan diperoleh.

Dalam kasus optimasi ini, kondisi berhenti adalah ketentuan saat mencapai nilai iterasi maksimum.

3. METODOLOGI PENELITIAN

Dalam metodologi penelitian dan perancangan akan dijelaskan secara umum tahapan dalam implementasi algoritma *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO) untuk pemodelan komposisi pakan dalam optimasi kandungan gizi susu kambing. Tahapan penelitian dimuali dari studi literatur, analisis kebutuhan, pengumpulan data, perancangan sistem, implementasi sistem, pengujian dan analisis sistem serta tahap akhir yaitu proses kesimpulan dan saran. Tahapan penelitian ini ditunjukkan pada Gambar 3.1



Gambar 3.1 Diagram Alir Metodologi Penelitian

3.1 Data Penelitian

Teknik pengumpulan data dengan melakukan wawancara terhadap pihak UPT, narasumber pak Rokhim, S.Pt bidang pakan ternak, drh. Jayawulandari dan pak Kayat untuk data uji laboratorium kandungan gizi susu. Selain itu juga dari jurnal-jurnal yang terkait. Pengambilan data dilakukan sejak bulan Januari 2016 – Juni 2016.


Data yang dibutuhkan dalam penelitian ini adalah:

1. Data komposisi pakan hijauan untuk kambing
2. Data hasil laboratorium untuk kandungan gizi susu
3. Data range kandungan gizi susu

4. PERANCANGAN SISTEM


Pada bagian alir perancangan sistem akan dijelaskan rancangan alur kerja sistem dalam bentuk diagram alir untuk menyelesaikan masalah menggunakan *Artificial Neural Network* (ANN) dan *Particle Swarm Optimization* (PSO) secara bertahap. Berikut in merupakan rancangan alir kerja system yang ditunjukkan pada Gambar 4.1.

Diagram alir perancangan system merupakan sebuah perancangan system dari awal sampai akhir secara keseluruhan namun digambarkan secara garis besar. Untuk diagram alir setiap metode akan digambarkan pada Gambar 4.2 yaitu diagram alir metode *Artificial Neural Network* (ANN) sedangkan Gambar 4.3 merupakan diagram alir dari metode optimasi *Particle Swarm Optimization* (PSO).




Gambar 4.1 Diagram alir perancangan sistem

Sedangkan untuk proses algoritma, secara umum rancangan implementasi metode ANN terdapat pada Gambar 4.2.



Gambar 4.2 Diagram alir metode ANN


Sedangkan untuk alir perancangan sistem algoritma PSO terdapat pada Gambar 4.3.



Gambar 4.3 Diagram alir metode PSO


5. IMPLEMENTASI

Antarmuka sistem terdiri dari halaman data sistem, dimana user dapat memberikan input pilihan pakan, parameter ANN dan parameter PSO yang akan diberikan. Tampilan antarmuka program ditunjukkan dalam Gambar 4.4 berikut:



Gambar 4.4 Implementasi halaman data sistem

Pada halaman berikutnya merupakan halaman hasil setiap tahapan. Tampilan halaman hasil kesimpulan ditunjukkan dalam Gambar 4.5 berikut:




Gambar 4.5 Implementasi halaman kesimpulan Sistem

6. PENGUJIAN DAN ANALISIS

6.1 Hasil Pengujian terhadap maksimal iterasi pada data latih ANN

Pengujian iterasi maksimal pada data latih ANN menggunakan jumlah data latih yang digunakan sama dengan data uji yaitu 30 data data Premium. *Learning rate* yang digunakan adalah 0.64 dan *hidden layer* sejumlah 4. Pengujian ini juga menghasilkan nilai MSE. Terdapat dua kualitas susu yaitu kualitas Premium dan Baik

Jumlah maksimum iterasi data latih ANN mempengaruhi iterasi yang dipakai dalam optimasi, sehingga semakin kecil nilai MSE yang dihasilkan, maka akan semakin optimal hasil optimasi yang dilakukan. Grafik hasil pengujian perbandingan jumlah data uji dan data latih digambarkan pada Gambar 6.1. Dari grafik tersebut dapat disimpulkan bahwa semakin besar iterasi, akan menghasilkan nilai MSE yang semakin kecil. Dari Gambar 6.1 didapatkan nilai MSE terkecil untuk Premium adalah 0.0088 pada iterasi 10000 sedangkan Baik adalah 0.008 pada iterasi 10000




Gambar 6.1 Grafik pengujian iterasi maskimum data latih ANN

6.2 Hasil Pengujian Kombinasi Nilai Bobot Inersia

Pengujian kombinasi nilai bobot inersia yaitu w_{max} dan w_{min} yang mempengaruhi kecepatan yang ditempuh oleh setiap partikel dalam memperoleh fitness optimal. Pengujian jumlah partikel dilakukan dengan menggunakan data yang sudah diuji sebelumnya, yaitu dengan iterasi ANN 10000 iterasi. Hasil pengujian kombinasi inersia ditunjukkan pada

Pada Gambar 6.2 menunjukkan bahwa kombinasi nilai inersia dengan menghasilkan nilai rata-rata fitness tertinggi terdapat pada kombinasi $w_{min} = 0.3$ dan $w_{max} = 0.6$. Kombinasi nilai inersia tersebut akan digunakan dalam pengujian selanjutnya.




Gambar 6.2 Grafik pengujian Kombinasi Nilai inersia

6.3 Hasil Pengujian terhadap nilai konstanta akselerasi

Pengujian nilai konstanta akselerasi atau c_1 dan c_2 yang mempengaruhi kecepatan yang ditempuh oleh setiap partikel dalam memperoleh fitness optimal. Pengujian jumlah partikel dilakukan dengan menggunakan data yang sudah diuji sebelumnya, yaitu dengan iterasi ANN 10000 iterasi, nilai w_{Max} 0.6 w_{Min} 0.3.

Komponen kognitif (c_1) dan komponen sosial (c_2) disebut juga sebagai koefisien akselerasi yang mempengaruhi jarak maksimum yang dapat diambil oleh sebuah partikel dalam sebuah iterasi. c_1 mengatur jarak yang dipengaruhi oleh memori posisi *personal best* dari partikel tersebut. Sedangkan c_2 mengatur jarak maksimum yang dipengaruhi oleh partikel *global best*. Hasil


pengujian konstanta kecepatan yang mendapatkan nilai rata-rata fitness tertinggi adalah $c_1 = 1$ dan $c_2 = 1.5$ dengan rata-rata fitness 4.1424. Grafik pengujian ditunjukkan oleh Gambar 6.3.



Gambar 6.3 Grafik pengujian nilai Konstanta Kecepatan

6.4 Hasil Pengujian terhadap nilai konstanta pembatasan kecepatan

Pengujian nilai konstanta pembatasan kecepatan yang mempengaruhi kecepatan yang ditempuh agar kecepatan partikel tidak melebihi kecepatan maksimal yang sudah ditentukan dalam memperoleh fitness optimal. Pengujian jumlah partikel dilakukan dengan menggunakan data yang sudah diuji sebelumnya, yaitu dengan iterasi ANN 10000 iterasi, nilai w_{Max} 0.6 w_{Min} 0.3, nilai c_1 adalah 1 sedangkan nilai c_2 adalah 1.5. Data nilai tersebut merupakan data hasil pengujian sebelumnya yang akan digunakan juga pada setiap pengujian selanjutnya, sebab hasil pengujian tersebut setelah dianalisis dapat menghasilkan hasil fitness yang terbesar. Hasil pengujian nilai konstanta pembatasan kecepatan juga akan digunakan pada proses pengujian parameter selanjutnya.




Gambar 6.4 Grafik Konstanta Pembatasan Kecepatan

Pada Gambar 6.4 menunjukkan bahwa nilai konstanta pembatasan kecepatan (k) yang dapat menghasilkan nilai rata-rata fitness tertinggi adalah 0.6. Nilai konstanta tersebut akan digunakan dalam pengujian selanjutnya.


6.5 Hasil Pengujian terhadap jumlah partikel PSO

Pengujian terhadap jumlah partikel mempengaruhi nilai fitness yang didapatkan serta waktu yang digunakan dalam pencarian fitness. Pengujian jumlah partikel dilakukan dengan menggunakan data yang sudah diuji sebelumnya, yaitu dengan iterasi ANN 10000 iterasi, nilai w_{Max}

0.6 w_{Min} 0.3, nilai $c1$ adalah 1 sedangkan nilai $c2$ adalah 1.5 serta nilai k adalah 0.6. Data nilai tersebut merupakan data hasil pengujian sebelumnya yang akan digunakan juga pada setiap pengujian selanjutnya, sebab hasil pengujian tersebut setelah dianalisis dapat menghasilkan hasil fitness yang terbesar.



Gambar 6.5 Grafik jumlah partikel PSO




Gambar 6.6 Grafik Waktu Komputasi Jumlah Partikel

Berdasarkan grafik pengujian Gambar 6.5 rata-rata nilai fitness terbesar didapatkan dengan jumlah partikel sebanyak 30 partikel. Semakin banyak jumlah partikel yang diberikan maka akan semakin tinggi rata-rata fitness yang dihasilkan. Semakin banyak jumlah partikel maka akan menyebabkan waktu komputasi setiap iterasi menjadi semakin lama (Engelbrecht A. P., 2007). Hal ini ditunjukkan pada Gambar 6.6 yang menunjukkan pengaruh jumlah partikel terhadap waktu komputasi. Berdasarkan Gambar 6.5 dan Gambar 6.6, direkomendasikan menggunakan jumlah partikel sebanyak 30 karena saat dilakukan, hasil rata-rata fitness menghasilkan fitness yang cukup besar dengan waktu komputasi yang kecil.

6.6 Hasil Pengujian terhadap maksimal iterasi PSO

Pengujian maksimal iterasi dilakukan dengan menggunakan data yang sudah diuji sebelumnya, yaitu dengan iterasi ANN 10000 iterasi, nilai w_{Max} 0.6 w_{Min} 0.3, nilai $c1$ adalah 1 sedangkan nilai $c2$ adalah 1.5 serta nilai k adalah 0.6, dan jumlah partikel adalah 30 partikel.




Gambar 6.7 Grafik Pengujian Maksimal Iterasi PSO

Hasil pengujian maksimal iterasi divisualisasikan pada Gambar 6.7 dengan rata-rata nilai fitness terbesar didapatkan dengan jumlah iterasi maksimal 100 iterasi. Semakin besar nilai iterasi maksimal akan didapatkan nilai fitness yang semakin tinggi juga. Penentuan jumlah maksimum iterasi bergantung pada permasalahan yang dihadapi, sehingga pada penelitian ini, iterasi 100 dianggap cukup memberikan hasil fitness yang terbaik.

6.7 Pengujian terhadap kombinasi variasi output yang dioptimalkan

Pengujian kombinasi variasi output dilakukan dengan menggunakan data yang sudah diuji sebelumnya, yaitu dengan iterasi ANN 10000 iterasi, nilai w_{Max} 0.6 w_{Min} 0.3, nilai $c1$ adalah 1 sedangkan nilai $c2$ adalah 1.5 serta nilai k adalah 0.6, dan jumlah partikel adalah 30 partikel serta 100 iterasi. Kandungan gizi susu yang dioptimalkan adalah Protein, sedangkan yang diminimalkan adalah Lemak.



Gambar 6.8 Hasil Kenaikan Protein dan Penurunan Lemak

Dari Gambar 6.8 dapat dilihat bahwa dalam 10 percobaan dapat menghasilkan kenaikan protein dan penurunan lemak yang ditunjukkan pada percobaan ke-6 protein naik sebesar 3.4239% sedangkan lemak turun 5.19%.

7. PENUTUP

7.1 Kesimpulan

- Langkah pertama dalam implementasi algoritma Artificial Neural Network dan Particle Swarm Optimization adalah melakukan pelatihan data latih dan pengujian data uji. Data yang digunakan dalam pelatihan dan pengujian adalah kandungan nutrisi dari pakan kambing yang berupa Abu, Pk, Lk dan Sk sebagai data

input. Sedangkan output kandungan gizi susu kambing yang diamati adalah Protein, lemak, Laktosa dan *Density*. Parameter backpropagation digunakan untuk melatih data dalam mencari bobot terbaik untuk menghasilkan nilai MSE terkecil. Bobot yang dihasilkan oleh pelatihan backpropagation akan digunakan dalam proses pengujian dan optimasi PSO. Semakin kecil nilai MSE yang dihasilkan dalam pelatihan, maka akan meningkatkan nilai fitness yang optimal dalam PSO.

2. Hasil pengujian yang dilakukan dalam penelitian ini meliputi pengujian parameter pelatihan ANN serta parameter yang ada di dalam PSO. Pengujian pelatihan ANN dengan parameter *learning rate* adalah 0.64, jumlah *hidden layer* adalah 4. Jumlah data latih sama dengan jumlah data uji, yaitu 30 data untuk kualitas susu Premium dan 15 data untuk kualitas susu Baik, menghasilkan nilai MSE terkecil yaitu 0.0088 pada iterasi ke-10000 dengan 30 data kualitas susu Premium, serta MSE 0.008 dengan 15 data kualitas susu Baik. Pada pengujian parameter PSO, parameter optimal yang didapatkan adalah nilai kombinasi inersia dengan $w_{max} = 0.6$ dan $w_{min} = 0.3$. Nilai konstanta kecepatan yaitu $c_1 = 1$ dan $c_2 = 1.5$. Nilai konstanta pembatasan kecepatan yaitu $k = 0.6$ serta banyaknya jumlah partikel yaitu 30. Iterasi maksimal PSO yaitu 100 iterasi. Dari hasil pengujian dengan parameter optimal PSO tersebut dihasilkan nilai rata-rata fitness sebesar 4.807.
3. Perbandingan hasil *output* dalam kasus pengujian yaitu mengoptimalkan protein dan meminimalkan lemak. Sebelum optimasi, kandungan protein dengan kualitas susu Premium untuk berat badan 32 adalah 3.944%. Setelah dioptimasi rata-rata kandungan protein naik 3.4239% sehingga menjadi 7.3679%. Kandungan lemak sebelum optimasi adalah 8.942%, sesudah optimasi rata-rata kandungan lemak turun 5.19% menjadi 3.637%.

7.2 SARAN

1. Hasil penelitian dari implementasi Algoritma ANN dan PSO untuk memodelkan pakan serta mengoptimalkan kandungan gizi susu kambing ini dapat dikembangkan dan dijadikan bahan penelitian lebih lanjut tidak hanya dari segi mengoptimalkan kandungan gizi susu namun juga dapat meminimalkan harga pakan yang dikeluarkan serta harga jual yang diperoleh dengan kandungan gizi susu yang sudah dioptimalkan.
2. Pada penelitian ini terdapat masalah dalam pencarian jumlah iterasi ANN untuk mencapai konvergen, sehingga terdapat saran untuk mencoba algoritma *nguyen-widrow* untuk dijadikan sebagai perbandingan dalam

pencarian konvergensi serta bobot yang didapatkan.

DAFTAR PUSTAKA

- [1] S. Mulyanto, "Identifikasi Laktoferin Pada Kolostrum Dan Susu Kambing Dengan Metode Single Radial Immunodifusi Dan SDS-PAGE," *Fakultas Peternakan Institut Pertanian Bogor*, 2006.
- [2] G. E. P. A. & H. D. W. Prihatminingsih, "Hubungan antara Konsumsi Protein dengan Produksi, Protein dan Laktosa Susu Kambing Peranakan Ettawa," *Jurnal Ilmu-ilmu Peternakan* 25, pp. Vol.2, 20-27, 2015.
- [3] B. A. Nugroho, "Pasar Susu Dunia dan Posisi Indonesia," 2010.
- [4] J. S. Raharjo, "Model Artificial Neural Network," *Jurnal Sistem Komputer*, pp. Vol.3, No.1, ISSN: 2087-4685, e-ISSN: 2252-3456, 2013.
- [5] R. J. S.-C. Chu, "Ant colony system with communication strategies," *Information Sciences*, pp. vol.167. pp.63-76, 2004.
- [6] H. Gunawan, "Prospek Usaha Penggemukan Kambing Potong," *Pustaka Baru Press*, 2013.
- [7] J. W. Fernanda, "Boosting Neural Network dan Boosting Cart pada Klasifikasi Diabetes Militus Tiper II," *Jurnal Matematika*, vol. 2, no. 2, pp. 33-49, 2012.
- [8] N. W. & S. U. Chamidah, "Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi," *Jurnal ITSMART*, vol. 1, no. 1, pp. 28-33., 2012.
- [9] R. L. Gema, "Jaringan Syaraf Tiruan Propagasi Balik dalam Prediksi Persediaan Ternak Sapi Potong (Studi Kasus di Wilayah Sumatera Barat)," *Jurnal KomTekInfo, Fakultas Ilmu Komputer*, vol. 1, no. 2, pp. 21-27, 2014.
- [10] K. & I. Y. Shibata, "Effect of Number of Hidden Neurons on Learning in Large-Scale Layered Neural Networks," in *Proceedings of the ICRPS-SICE International Joint Conference 2009 (ICCAS-SICE '09)*, pp. 5008-5013, (2009)..
- [11] R. Z. Edo, "Implementasi Backpropagation Neural Network dalam Pembangkitan Otomatis Fungsi Keanggotaan Fuzzy pada Penderita Penyakit Hepatitis," *Skripsi Program Teknologi Informasi dan Ilmu Komputer. Universitas Brawijaya.*, 2014.
- [12] E. R. Zerda, "Analisis dan Penerapan Algoritma Particle Swarm Optimization

(PSO) pada Optimasi Penjadwalan Sumber Daya Proyek,” Bandung, 2009.

- [13] H.-L. e. Chen, “A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest,” *Knowledge-Based Systems*, vol. 24, p. 1348–1359, 2011.
- [14] A. P. Engelbrecht, *Computational Intelligence: An Introduction* 2nd ed, West Sussex: John Wiley & Sons Ltd., 2007.
- [15] F. Marini dan B. Walczak, “Particle swarm optimization (PSO). A tutorial,” *IEEE Chemometrics and Intelligent Laboratory Systems*, p. 13, 2015.
- [16] A. N. Fadilah, “Implementasi Analytical Hierarchy Process (AHP) dan Algoritma Genetika untuk Rekomendasi dan Optimasi Pemupukan Berimbang Tanaman Hortikultura,” *Repository Jurnal Mahasiswa PTIK Universitas Brawijaya*, Vol. %1 dari %25, no.14, 2015.
- [17] W. Mahmudy, “Improved particle swarm optimization untuk menyelesaikan permasalahan part type selection dan machine loading pada flexible manufacturing system (FMS),” *Konferensi Nasional Sistem Informasi*, 2015.

