

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Grzesiak [2] melakukan penelitian dengan membandingkan antara algoritma *Neural Network* (NN) dengan *Multiple Linear Regression* (MLR). Data yang diolah sebanyak 1390 data dari 902 sapi dari peternakan sapi North-Western Poland. Data dibagi dalam 2 grup dimana grup pertama sebanyak 853 ekor sapi dan grup kedua sebanyak 49 ekor sapi. Sapi pada grup kedua diambil secara acak yang digunakan untuk melakukan verifikasi atau pengujian prediksi pada kedua model.

Neural network yang diusulkan terdiri dari 7 neuron untuk layer input, 10 neuron pada hidden layer, dan 1 neuron untuk layer output. Dari dataset yang berjumlah 1390, dibagi kedalam training data sebanyak 700, 345 untuk data verifikasi, dan 345 data testing. Dari eksperimen yang dilakukan, neural network memiliki *Mean Error Prediction* (MEP) sebesar 6,9% lebih rendah sebesar 0,5% dibanding MLR yang memiliki MEP 7,4%.

Gandhi et.al. [1] melakukan prediksi produksi susu seumur hidup berdasar data laktasi pertama. Data diambil dari 1493 ekor sapi selama periode ternak 1966-2005 di 3 tempat peternakan berbeda. Data dibagi menjadi 2 yang terdiri dari 1120 *record training* set dan 373 test set. *Neural network* yang dibangun adalah *feed forward back propagation neural network* dengan 3 layer yaitu *input*, *hidden*, *output* masing-masing 5, 3, 1.

Pada input dan hidden layer diterapkan fungsi *hyperbolic tangent sigmoid transformation*, sedangkan fungsi *pureline linear transfer* diterapkan pada layer output. Untuk optimalisasi pengujian network digunakan *Bayesian regulation back propagation training function*. Dari eksperimen yang dilakukan menunjukkan akurasi 25,62% untuk *Multiple Regression Analysis* (MRA), dan 30,04% akurasi untuk *neural network*.

Sharma [4] melakukan penelitian mengenai pemilihan model aturan heuristik yang efektif pada model *connectionist* untuk prediksi produksi susu sapi. Untuk membangun model *connectionist* menggunakan berbagai parameter internal

diantaranya data *pre-processing*, strategi partisi data, sinkronisasi awal, jumlah *hidden layer*, jumlah neuron pada tiap layer, jumlah waktu, dan lain-lain [4] . Salah satu hal yang cukup penting diperhatikan dalam membangun *neural network* adalah jika terlalu banyak neuron dan layer menjadikan model tidak reliabel.

Untuk itu diperlukan suatu model yang dapat membantu menentukan jumlah neuron dan layer. Metode heuristic dan eksperimen digunakan untuk menentukan jumlah hidden layer dan neuron untuk tiap hidden layer hingga didapatkan model yang paling tepat. Namun ada aturan umum untuk mendapatkan performa terbaik adalah dengan cara menentukan jumlah *hidden layer* lebih sedikit daripada hidden neuron.

Data yang digunakan oleh Sharma diambil dari Karan Fries Cow National Dairy Research Institute (NDRI) India yaitu sebanyak 672 ekor sapi dari tahun 1980-2001. Variabel yang dipakai diantaranya grup genetik, masa kelahiran, berat lahir, umur kedewasaan, berat saat dewasa, masa melahirkan, umur saat melahirkan, berat saat melahirkan, produksi susu tertinggi, hari saat mencapai produksi maksimal pada laktasi pertama. Untuk keperluan prediksi tersebut diimplementasikan model *Multiple Linear Regression* (MLR) dan dibandingkan kinerjanya dengan model *connectionist*. Dimana hasilnya adalah dengan jumlah *hidden neuron* yang sama dengan jumlah *input neuron*, *connectionist model* menunjukkan akurasi 88,15%, sedangkan MLR menunjukkan akurasi prediksi 86,31%. Dengan begitu model *connectionist* dengan jumlah *hidden neuron* dan *input neuron* sama bisa digunakan sebagai model alternatif untuk melakukan prediksi produksi susu.

Ruhil et.al. [3] melakukan prediksi produksi susu sapi menggunakan *back propagation neural network* berdasar data laktasi parsial. Data yang digunakan untuk penelitian diambil dari NDRI sebanyak 587 ekor sapi selama periode 49 tahun (1961-2009). Prediksi dilakukan pada laktasi pertama, dimana diambil pada ciri hari tertentu saja yaitu hari ke-6, 35, 65, 95, 125, 155, 185, 215, 245, dan hari ke 275.

Simulasi prediksi menggunakan 4 algoritma back propagation yaitu *Bayesian Regulation* (BR), *Scaled Conjugated gradient* (SCG), *Levenberg-Marquardt* (LM), dan *BFGS Quasi-Newton* (BFG). *Neural network* yang dibangun terdiri 1 dan 2

hidden layer dengan 2-6 *neuron* untuk tiap *hidden layer*. pada *output layer* diimplementasikan fungsi transformasi linier murni untuk mendapatkan respon network. Tingkat akurasi pada metode *back propagation* dengan menggunakan data parsial adalah sebesar 80%.

Cui dan Zeng [13] melakukan penelitian terhadap kecepatan prediksi menggunakan algoritma *Particle Swarm Optimization* (PSO). Dalam kesimpulannya, mereka mengatakan bahwa *Modified PSO* (MPSO) menunjukkan kecepatan yang lebih baik dibanding metode PSO. Misalnya pengujian menggunakan fungsi Schafer pada algoritma PSO menunjukkan hasil 1918,18 sedangkan menggunakan MPSO menjadi 853,14. Demikian juga ketika menggunakan fungsi lainnya yaitu *Spherical*, *Quadric*, *Griewank*, dan *Rosenbrock* menunjukkan hasil yang lebih baik menggunakan MPSO daripada PSO.

Cui [14] dalam penelitian lainnya juga melakukan perbandingan antara *Enhanced PSO* (EPSO) dengan *Predicted PSO* (PPSO), dimana hasilnya adalah PPSO yang diajukan oleh Cui dengan fungsi Schafer menunjukkan rata-rata kecepatan 474,38 lebih baik dibanding dengan metode EPSO yang hanya menghasilkan 581,5. Pengujian PPSO pada algoritma *Griewank* juga menunjukkan hasil yang lebih baik dibanding dengan EPSO, dengan hasil 1690,74 untuk EPSO dan 257,06 untuk PPSO.

Pada tahap-tahap data mining, sebelum data dianalisis dengan berbagai metode, terlebih dahulu data dilakukan *pre-processing*, diantaranya dengan melakukan transformasi data. Jika data yang diolah berukuran sangat besar maka pada tahap *pre-processing* bisa dilakukan *data reduction*, yaitu proses reduksi data untuk mengurangi volume data namun dengan tanpa menghilangkan informasi penting dari data tersebut. Salah satu cara reduksi data dengan metode *discrete wavelet transform* (DWT). Langkah reduksi data sebelum dilakukannya analisis dimaksudkan untuk mempercepat algoritma pada saat eksekusi analisis data, karena dengan mengurangi ukuran asli data *time series* membutuhkan waktu yang sedikit untuk akses data [12].

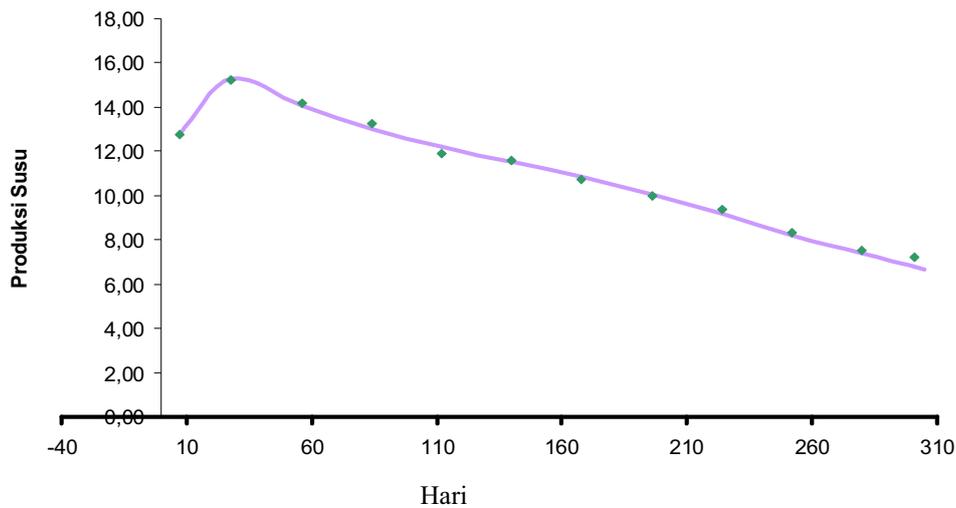
2.2 Landasan Teori

Sapi menjadi salah satu hewan ternak yang penting sebagai sumber daging, susu, kulit binatang hingga bio gas yang merupakan varian baru dari produk yang dihasilkan dari peternakan sapi. Sapi menghasilkan sekitar 50% kebutuhan daging dunia, 95% kebutuhan susu dan 85% kebutuhan kulit [13]. Sapi berasal dari famili bovidae seperti halnya bison, banteng, kerbau.

Secara garis besar, bangsa-bangsa sapi yang terdapat di dunia ada dua yaitu Zabu atau jenis sapi yang berpunuk yang berasal dan tersebar di daerah tropis, dan kelompok kedua adalah primigenius yang tersebar di daerah sub tropis. Jenis sapi perah yang paling banyak dipelihara adalah sapi Shorhorn dari Inggris, Friesian Holstein dari Belanda, Brown Swiss dari Switzerland, Red Danish dari Denmark dan Droughmaster dari Australia. Jenis sapi yang paling cocok dibudidayakan di Indonesia adalah kenis Friesian Holstein dai Belanda.

Hasil peternakan sapi perah diantaranya produksi susu, dimana semakin banyak produksi susunya maka kualitas sapi tersebut semakin bagus. Seperti dikatakan Sudono dalam Andri Sukandar [14] bahwa produksi susu dipengaruhi oleh beberapa faktor diantaranya faktor genetik dan faktor lingkungan. Masa dimana sapi sedang menghasilkan susu disebut masa laktasi. Seekor sapi bisa memiliki masa laktasi hingga 7 kali selama hidupnya. Untuk satu kali masa laktasi biasanya selama kurang lebih 305 hari. Berdasar hasil wawancara yang dilakukan penulis dengan narasumber di BBPTU Sapi Perah Baturraden diketahui bahwa faktor-faktor yang berpengaruh terhadap produksi susu sapi ada 3 yaitu bibit, pakan, dan manajemen pemeliharaan.

Pada masa awal laktasi akan mengalami peningkatan yang tajam dalam hal produksi susu, namun lambat laun akan mengalami penurunan hingga akhir masa laktasi seperti terlihat pada grafik masa laktasi pada gambar 1 berikut ini.



Gambar 1. Kurva produksi susu sapi [14].

2.2.1 Prediksi Time Series

Prediksi merupakan proses membangkitkan informasi yang mungkin terjadi pada masa mendatang melalui proses analisis data pada waktu sebelumnya [15]. Lebih lanjut Kasabov [15] menjelaskan tiga tugas yang berbeda yang membedakan masalah umum prediksi yaitu:

- *Short-term prediction* (yang mana istilah tersebut terbatas dan sebagai pengertian kata “prediksi”).
- *Modeling*, menemukan struktur, model, dan formula yang dapat menjelaskan perilaku proses dalam jangka waktu lama dan dapat digunakan untuk long-term prediction juga untuk mengetahui pola pada data yang telah ada.
- *Characterization*, bertujuan untuk menemukan properties (parameter atau variabel) yang mendasar (paling berpengaruh) pada sebuah proses Weigend and Gershefeld (1993) dalam [15].

Proses prediksi dapat dilakukan dengan berbagai metode yaitu:

- Metode statistik, berdasar pada analisis regresi dan analisis *probability*
- Neural network, prediksi dengan metode pencocokan pola (*pattern matching*).
- *Rule-based system*, termasuk didalamnya *fuzzy rule-based system*, merupakan perwujudan pengetahuan keahlian heuristik; aturan didapatkan dari data sebelumnya menggunakan teknik machine-learning.

- *Hybrid system*, metode yang menggabungkan penggunaan data yang telah ada dan expert rule dalam sebuah sistem.

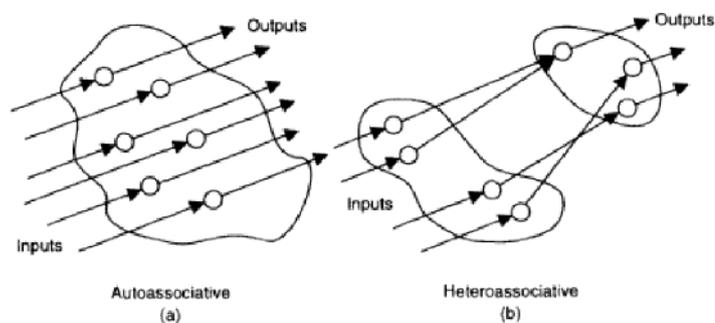
2.2.2 Neural Network

Neural network menurut Jha [16] didefinisikan sebagai struktur pemetaan non linier yang meniru cara kerja otak manusia. Neural network sangat bagus untuk pemodelan terutama jika hubungan antar variabel utama tidak diketahui. Neural network dapat mengidentifikasi dan mempelajari pola antara data set input dengan output yang sesuai. Neural network cocok digunakan untuk pemodelan data-data pertanian dimana banyak data kompleks dan kadang-kadang tidak linier.

Artificial neural network atau secara sederhana sering hanya disebut neural network merupakan model komputasional yang terdiri dari 4 parameter yaitu [15]:

1. Neuron atau sering disebut node.
2. Connectionist architecture – untuk mengatur/ hubungan antar node.
3. Learning algorithm
4. Recall algorithm

Dua arsitektur hubungan (*connectionist architecture*) dapat dibedakan tergantung pada jumlah input dan output neuron dan layer neuron yang digunakan (lihat gambar 3) yaitu [15]: pertama disebut *autoassociative*, dimana input neuron juga berlaku sebagai output neuron, contohnya adalah Hopfield network. Sedangkan arsitektur kedua adalah *heteroassociative*, yaitu neuron dibagi input dan output secara terpisah.

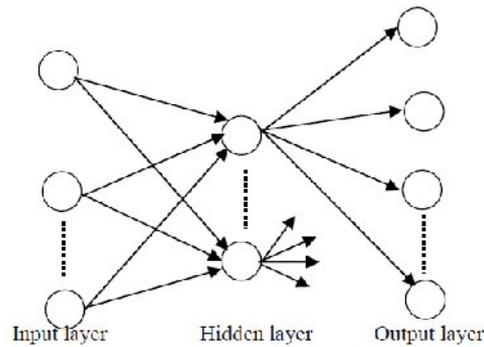


Gambar 2. Tipe neural network assosiative dan heteroassosiative [16].

Untuk arsitektur neural network secara umum terdapat dua model yaitu:

1. Feed forward architecture

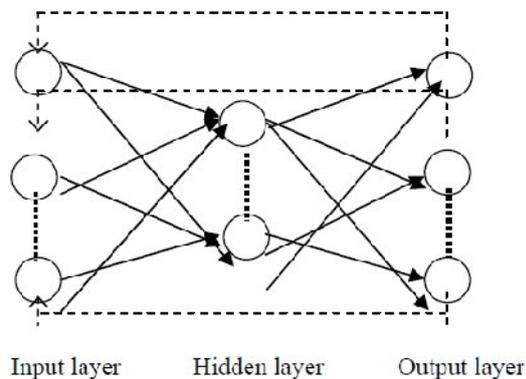
Pada arsitektur ini, arah aliran koneksi satu arah dari layer input menuju hidden layer dan dilanjutkan ke output layer. jadi tidak ada koneksi mundur dari output menuju hidden layer atau input layer.



Gambar 3. Multilayer feed forward neural network architecture [16].

2. Feedback/recurrent architecture

Feedback architecture meminjam istilah Nikola K. Kasabov [15] atau recurrent network menurut Girish Kumar Jha [16] pada dasarnya adalah koneksi feed forward yang memungkinkan koneksi berbalik arah dari output layer menuju hidden layer hingga ke input layer.



Gambar 4. Multi layer feedback/recurrent neural network architecture [16].

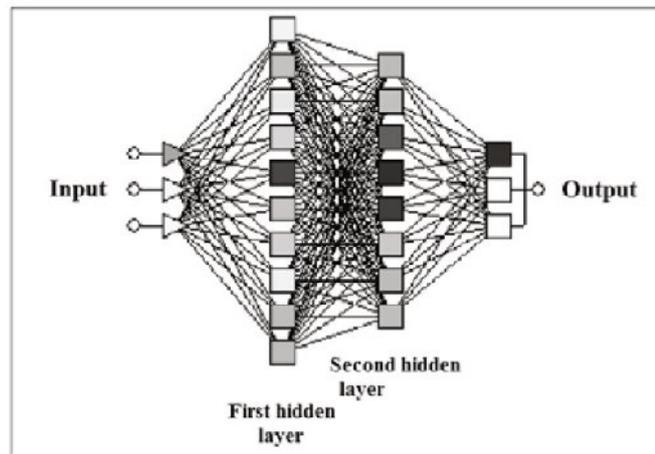
2.2.3 Algoritma supervised learning

Salah satu karakteristik yang menarik dari neural network adalah kemampuan untuk belajar, yang memungkinkan model untuk memodifikasi kelakuan dalam merespon lingkungan network. Algoritma *supervised learning* adalah proses learning yang berbasis pada data training [17]. Data training adalah contoh dari sebagian kecil data yang diambil dari keseluruhan data uji. Proses learning dilakukan dalam dua tahap yaitu tahap training dan tahap prediksi. Tahap *learning* untuk mempelajari *clasifier/ regresor* dari *training data*, sedangkan langkah prediksi adalah menentukan class label ke data test. Beberapa metode *supervised learning* diantaranya *Perceptron*, *Liner Discriminant Analysis (LDA)*, *Support Vector Machines (SVM)*, *linear Regression (LR)*.

2.2.4 Multi Layer Perceptron

Multi layer perceptron adalah *neural network* yang terdiri dari beberapa *layer neuron (computing unit)* yang dihubungkan secara hirarkis secara *feed foorward* [18]. Menurut Girish Kumar Jha [16], *Multi layer perceptron*:

- a. Memiliki beberapa input
- b. Memiliki satu atau beberapa hidden layer dengan beberapa unit
- c. Input layer menggunakan fungsi kombinasi linier
- d. Hidden layer secara umum menggunakan fungsi aktivasi sigmoid
- e. Dapat memiliki satu atau beberapa output dengan beberapa fungsi aktifasi
- f. Koneksi terdiri dari input layer dengan hidden layer pertama, ke hidden layer berikutnya sampai hiden layer terakhir, dan koneksi hidden layer terakhir dengan output layer.



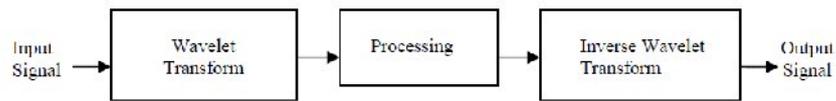
Gambar 5. Multi layer perceptron dengan dua hidden layer [18].

Multilayer perceptron menggunakan beberapa teknik learning, diantaranya yang paling populer adalah algoritma *back-propagation*. Arsitektur *neural network back-propagation* adalah desain hirarkis yang berisi node pada tiap layer yang saling terkoneksi secara penuh [19]. Pada algoritma *back-propagation* memungkinkan jika ada error pada *output* maka akan dikembalikan ke *node* pada *hidden layer* untuk kemudian memberikan bobot yang berbeda pada *node* tersebut untuk selanjutnya dilakukan update pada *node* output layer [20]. Salah satu hal penting dalam mendesain arsitektur *back-propagation* adalah memilih fungsi aktivasi *sigmoidial*, dimana fungsi tersebut telah digunakan oleh banyak para peneliti [19].

2.2.5 Discrete Wavelet Transform

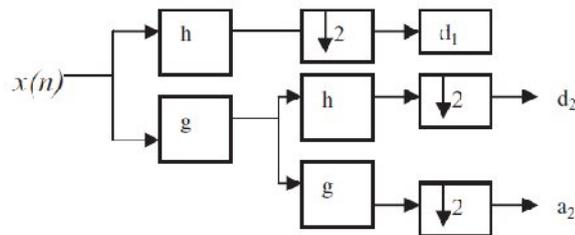
Discrete wavelet transform (DWT) merupakan sebuah fungsi yang digunakan untuk melakukan transformasi data yang bertujuan untuk memperkecil ukuran atau mengurangi *noise* [12]. Berdasar namanya, *wavelet* merupakan gelombang yang berukuran kecil [21]. *Wavelet* adalah fungsi matematika yang digunakan untuk melakukan dekomposisi data ke dalam komponen yang lain [12].

Implementasi DWT untuk analisis data berupa sinyal diilustrasikan seperti gambar 7 di bawah ini.



Gambar 6. Pemrosesan sinyal dengan wavelet transform [22].

Input sinyal dilakukan transformasi *wavelet*, dimana transformasi yang dilakukan adalah *low-pass* dan *high-pass* untuk menghasilkan detail produk dan perkiraan koefisien. Proses tersebut diulang hingga level yang diinginkan. Proses dekomposisi tersebut menggunakan *Mallat's decomposition tree* [12], seperti terlihat pada gambar 8, dimana $x(n)$ adalah sinyal (pada *time-series* adalah data), h dan g adalah *high* dan *low-pass filter*, secara berturut-turut, dan d_1 , d_2 , dan a_2 adalah menunjukkan level transformasi pada *low* dan *high-pass filter* secara berturut-turut. Data asli dapat direkonstruksi menggunakan nilai *low* dan *high-pass filter*.



Gambar 7. Dekomposisi wavelet 2 level

Wavelet paling lama dan paling sederhana adalah *Haar wavelet* yang dideskripsikan sebagai berikut:

$$h(t) = \begin{cases} 1 & 0 \leq t < 1 \\ -1 & 1 \leq t < 2 \\ 0 & \text{elsewhere} \end{cases} \quad (1)$$

2.2.6 Proses DWT Menggunakan Operator Haar Wavelet

Misalnya diketahui data *time-series* S dengan jumlah data $N=12$ yang dinotasikan dengan $S_1 - S_{12}$ dengan nilai masing-masing berturut-turut **19, 25, 22, 18, 28, 30, 27, 25, 22, 19, 18, 17**. Selanjutnya dari data tersebut dilakukan operasi *Haar wavelet* untuk menentukan *wavelet approximation coefficient (high-pass filter)* dengan rumus:

$$(S_{n+1}+S_n)/2 \tag{2}$$

dan *wavelet detail coefficient (low-pass filter)* dengan rumus

$$(S_{n+1}-S_n)/2 \tag{3}$$

sehingga didapatkan nilai sebagai berikut:

Wavelet approximation coefficient (WAC): 22, 20, 29, 26, 20.5, 17.5

Wavelet deatil coefficient (WDC): 3, -2, 1, -1, -1.5, -0.5

Hasil diatas dapat dilakukan operasi *Haar wavelet* kembali untuk menghasilkan transformasi pada level 2 dan seterusnya.

Selanjutnya adalah proses untuk rekonstruksi dari *wavelet approximation coefficient* dan *wavelet detail coefficient*. Untuk S_{n+1} digunakan rumus:

$$WDC_n - WAC_n \tag{4}$$

sedangkan untuk S_n digunakan rumus:

$$WDC_n + WAC_n. \tag{5}$$

Tabel 1. Hasil rekonstruksi dari wavelet level 1 ke data asli.

wac	wdc	reconstruct
22	3	19
		25
20	-2	22
		18
29	1	28
		30
26	-1	27
		25
20,5	-1,5	22
		19
17,5	-0,5	18
		17

Data awal yang terdiri dari 19, 25, 22, 18, 28, 30, 27, 25, 22, 19, 18, 17 selanjutnya dilakukan proses *Haar Wavelet* sehingga menghasilkan nilai WAC dan WDC. Dimana nilai WAC dan WDC tersebut selanjutnya digunakan untuk mengembalikan ke nilai semula. Dari tabel 1 diatas menunjukkan hasil rekonstruksi yang sempurna yaitu 19, 25, 22, 18, 28, 30, 27, 25, 22, 19, 18, 17. Dengan demikian algoritma *Haar Wavelet* dapat diandalkan untuk melakukan *discretization*.

2.3 Pengujian Dengan MAPE, SMAPE, MAE, dan RMSE

Pengujian dilakukan dengan menggunakan rumus *Mean Absolute Percentage Error* (MAPE) dan *Symetric Mean Absolute Percentage Error* (SMAPE), *Mean Absolute Error* (MAE), dan *Roor Mean Square error* (RMSE). Jika semakin rendah tingkat error maka performance model semakin baik, namun sebaliknya jika tingkat error semakin besar maka performance model semakin buruk. Rumus untuk MAPE adalah sebagai berikut:

$$= \frac{\%}{\sum} \quad \text{---} \quad (6)$$

Dimana adalah nilai aktual dan adalah nilai *forecast* (prediksi). Nilai rentang antara dan dibagi dengan nilai lagi yang kemudian nilai tersebut diabsolutkan sehingga semua nilainya menjadi positif. Nilai absolut tersebut dijumlahkan semua dan dibagi kembali dengan n jumlah data yang diproses.

Sebagai uji pembanding dilakukan evaluasi menggunakan SMAPE dengan rumus sebagai berikut:

$$= - \sum \frac{| \quad |}{\quad} \quad (7)$$

Dimana nilai dan sama seperti pada rumus MAPE yaitu sebagai nilai aktual dan nilai prediksi. Perbedaannya dengan MAPE dapat dilihat pada pembagi yang digunakan yaitu jika MAPE langsung menggunakan presentase 100%, namun pada SMAPE pembagian dilakukan pada tiap data n . Jika pada MAPE pengurangan - dibagi dengan nilai , namun pada SMAPE, - dibagi dengan + . Berbeda dengan MAPE, SMAPE memiliki nilai batas atas dan batas bawah.

Pengujian lain dilakukan dengan rumus *Mean Absolute Error* (MAE) dengan rumus sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

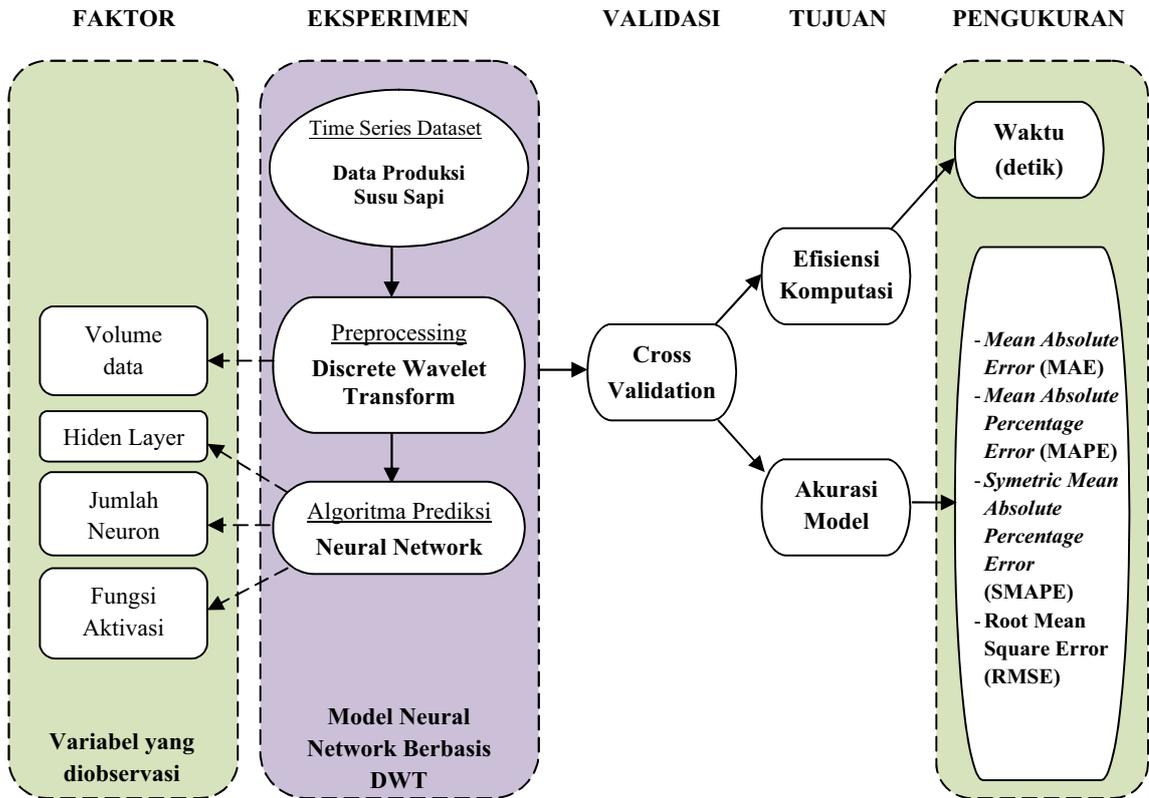
Dimana \hat{y}_i adalah nilai prediksi dan y_i adalah nilai aktual. Nilai n dan i sama dengan n dan i pada rumus MAPE dan SMAPE. *Mean Absolute Error* (MAE) merupakan pengukuran yang umum digunakan untuk prediksi error pada analisis time series, dimana term *mean absolute deviation* (MAD) kadang digunakan juga yang mengacu pada *mean absolute error*.

Root Mean Squared Error atau RMSE sebagai suatu estimator adalah salah satu dari berbagai cara untuk mengukur jumlah dengan estimator berbeda dari nilai benar banyaknya nilai yang di perkirakan. Sebagai *loss function*, RMSE disebut juga *squared error loss*. MSE mengukur rata-rata yang “error” dari empat persegi. Error adalah jumlah yang diperkirakan dari kuantitas yang diperkirakan. Perbedaan yang terjadi karena nilai acak atau karena estimator tidak dapat menghasilkan nilai untuk informasi yang dapat menghasilkan perkiraan lain yang lebih akurat[16]. Mean square error digunakan untuk menghitung tingkat error dari dua buah hasil percobaan model, atau jika diimplementasikan dalam data mining maka untuk mengukur tingkat error dari hasil penghitungan sebuah analisis yang menggunakan metode tertentu antara data *training* dan data *testing*.

Pengukuran RMSE dilakukan dengan rumus seperti berikut ini:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (9)$$

2.4 Kerangka teori



Gambar 8. Kerangka Teori

Pada tahap awal penelitian ini dilakukan observasi terhadap beberapa variabel yang berpengaruh terhadap proses prediksi yaitu faktor dari sisi pre-processing dimana faktor ini merupakan faktor utama yang dibahas pada penelitian ini. Variabel yang diobservasi adalah volume data. Faktor kedua dari sisi algoritma yang digunakan untuk prediksi yaitu *neural network*. Beberapa variabel yang dilakukan observasi pada algoritma neural network terdiri dari jumlah hidden layer, jumlah neuron, dan fungsi aktivasi. Ketiga faktor tersebut akan berpengaruh terhadap tingkat akurasi hasil prediksi.

Eksperimen dilakukan dengan mengambil sample data dari BBPTU Sapi Perah Baturraden yang selanjutnya dilakukan tahap pre-processing seperti pada penelitian-penelitian sebelumnya [1], [2], [3], [4]. Mereka langsung melanjutkan eksperimen dengan algoritma pilihan mereka masing-masing yang selanjutnya dilakukan pengukuran hasil. Namun pada penelitian ini sebelum dilakukan proses prediksi

dengan algoritma Neural Network, masih dilakukan tahap pre-processing selanjutnya yaitu tahap reduksi data. Teknik reduksi data yang dilakukan dengan metode *Discrete Wavelet Transform* dengan algoritma *Haar Wavelet*. Dimana untuk proses Haar Wavelet sendiri memiliki dua langkah yaitu langkah reduksi untuk mengubah jumlah record agar lebih kecil. Langkah kedua dilakukan rekonstruksi yang berfungsi untuk mengembalikan jumlah data ke ukuran sebelumnya. disinilah model baru diusulkan yaitu model pre-processing lanjutan untuk mereduksi data menggunakan metode *Discrete Wavelet Transform* dengan algoritma *Haar Wavelet*.

Untuk menguji tingkat performa prediksi dilakukan pengujian dengan 2 (dua) cara yaitu pengujian terhadap kecepatan proses prediksi atau efisiensi komputasi dan pengujian kedua untuk mengukur tingkat akurasi. Pengujian pertama dengan melihat lamanya proses yang terekan dalam tool yang digunakan atau waktu yang dibutuhkan untuk menyelesaikan proses prediksi. Pengujian kedua dilakukan dengan menghitung tingkat akurasi menggunakan rumus *Mean Absolute Error (MAE)*, *Mean Absolute Percentage Error (MAPE)*, *Symetrical Mean Absolute Percentage Error (SMAPE)*, dan *Root Mean Square Error (RMSE)*.

2.5 Tinjauan Organisasi

2.5.1 Latar belakang

Balai Besar Pembibitan Ternak Unggul Sapi Perah (BBPTU-SP) Baturraden merupakan salah satu Unit Pelaksana Teknis di bawah Direktorat Jenderal Peternakan Kementerian Pertanian dan satu-satunya UPT pembibitan yang memiliki tugas dan tanggungjawab dalam pengembangan sapi perah di Indonesia. BBPTU-SP Baturraden terletak di sebelah utara kota Purwokerto, lereng selatan Gunung Slamet merupakan kawasan berbukit dengan hawa sejuk menjadikan habitat yang cocok untuk pengembangan sapi perah.

Penyebaran informasi tentang BBPTU Sapi Perah Baturraden didukung oleh lokasi Balai yang terletak dikawasan wisata Baturraden yang merupakan salah satu tujuan wisata berskala internasional. Pengembangan kawasan Baturraden yang dilaksanakan oleh Pemerintah kabupaten Banyumas sebagai daerah pariwisata

disikapi dengan pengembangan agrowisata dengan melakukan penataan dan pemenuhan sarana serta menjalin kerjasama dengan stakeholder. Kebutuhan bibit sapi perah yang semakin meningkat seiring dengan peningkatan permintaan kebutuhan susu sebagai bahan baku dan bahan makanan sumber protein menuntut balai ini agar mampu meningkatkan kinerja berupa peningkatan produksi bibit unggul sapi perah.

2.5.2 Visi dan Misi

Balai Besar Pembibitan Ternak Unggul Sapi Perah (BBPTU-SP) Baturraden memiliki visi “Mewujudkan institusi yang profesional dalam menghasilkan bibit sapi perah yang berkualitas, berdaya saing, berkelanjutan untuk meningkatkan kesejahteraan peternak”. Institusi yang *profesional* artinya institusi yang mampu mengerjakan pekerjaan sesuai dengan tugas pokok dan fungsi yang diemban dengan penuh tanggung jawab berdasarkan pada target sasaran yang ditetapkan. *Berkualitas* artinya produk yang dihasilkan oleh balai telah melalui proses produksi yang ditetapkan dan melalui pengawasan selama proses produksi sehingga diperoleh hasil yang memenuhi standar kualitas yang telah ditetapkan. *Daya saing* mempunyai arti yang mampu menghasilkan output yang berkualitas yang memiliki keunggulan yang kompetitif dan komparatif. *Berkelanjutan* artinya mampu eksis dan dinamis dalam menghadapi perubahan lingkungan. Kesejahteraan peternak diartikan peternak mampu dalam memenuhi kebutuhan ekonomi keluarganya melalui usaha sapi perah yang dikelolanya.

BBPTU-SP Baturraden juga memiliki dua misi yaitu:

- a. Mengembangkan pembibitan sapi perah nasional, dengan melaksanakan kebijakan di bidang pemuliaan, pemeliharaan, produksi, dan pemasaran bibit unggul sapi perah dan hasil ikutannya
- b. Mengembangkan sumber daya manusia aparatur, pelaku usaha sapi perah, sarana dan prasarana, pembinaan, evaluasi, Sistem Informasi Manajemen (SIM) dan Pelayanan Prima, serta meningkatkan kesejahteraan peternak.

2.5.3 Tugas dan Fungsi

Tugas pokok BBPTU-SP Baturraden sesuai dengan SK Menteri Pertanian Nomor 630/Kpts/OT.140/12/2003 adalah melaksanakan tugas pemuliaan, pemeliharaan, produksi, dan pemasaran bibit unggul sapi perah.

Dalam melaksanakan sebagaimana dimaksud diatas BBPTU-SP Baturraden menyelenggarakan fungsi-fungsi:

- a. Menyusun dan mengevaluasi program kegiatan pemuliaan, pemeliharaan, produksi, dan pemasaran bibit unggul sapi perah.
- b. Melaksanakan pemuliaan bibit unggul sapi perah.
- c. Melaksanakan uji *performance* (betina) dan uji *progeny* (jantan) sapi perah unggul.
- d. Melaksanakan pencatatan (*recording*) pembibitan sapi perah unggul.
- e. Melaksanakan pemeliharaan bibit unggul sapi perah.
- f. Merawat kesehatan bibit unggul sapi perah dan pengawasan higienis produksi susu segar.
- g. Memberikan saran teknis pemuliaan, pemeliharaan, produksi dan pemasaran bibit unggul sapi perah.
- h. Memberikan pelayanan teknik kegiatan pemuliaan, pemeliharaan, dan produksi bibit unggul sapi perah.
- i. Melaksanakan distribusi, pemasaran, dan informasi terhadap produksi bibit unggul sapi perah, dan hasil ikutannya.
- j. Mengelola tata usaha dan rumah tangga BBPTI-SP Baturraden.