

**MODEL BACKPROPAGATION NEURAL NETWORK
UNTUK PERAMALAN KASUS DEMAM BERDARAH
DI D.I YOGYAKARTA**

SKRIPSI

Diajukan Kepada Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Negeri Yogyakarta untuk memenuhi
sebagian persyaratan guna memperoleh
Gelar Sarjana Sains



Oleh
Shinta Prajna Paramita Jati
09305141003

PROGRAM STUDI MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI YOGYAKARTA
2013

i

**BAB I
PENDAHULUAN**

A. Latar Belakang

Demam berdarah (DB) adalah penyakit demam akut yang disebabkan oleh virus dengue, yang masuk ke peredaran darah manusia. Virus dengue merupakan virus dari genus *Flavivirus*, famili *Flaviviridae*. Penyakit DB ditemukan di daerah tropis dan subtropis seperti Indonesia terutama di musim hujan dimana suhu udara yang lembab memungkinkan perkembangbiakan nyamuk *Aedes aegypti* meningkat (Dinkes, 2010: 1).

Penyakit DB masih merupakan salah satu masalah kesehatan masyarakat yang utama di Indonesia. Jumlah penderita dan luas daerah penyebarannya semakin bertambah seiring dengan meningkatnya mobilitas dan kepadatan penduduk. *World Health Organization (WHO)* mencatat negara Indonesia sebagai negara dengan kasus DB tertinggi di Asia Tenggara (Dinkes, 2010: 1).

WHO memperkirakan penduduk yang terkena DB meningkat selama 50 tahun terakhir. Kasus DB terjadi baik di daerah tropik maupun subtropik wilayah urban, menyerang lebih dari 100 juta penduduk tiap tahun, termasuk 500.000 kasus DBD dan sekitar 30.000 kematian terutama anak-anak. Penyakit ini endemik di 100 negara termasuk Asia. Pemanasan global dan perubahan lingkungan merupakan variabel utama penyebab meluasnya kasus demam berdarah di berbagai belahan dunia (Umar Fachmi Achmadi, 2010: 15). Menurut Mc Michael (2006),

**MODEL BACKPROPAGATION NEURAL NETWORK
UNTUK PERAMALAN KASUS DEMAM BERDARAH
DI D.I YOGYAKARTA**

Oleh:
Shinta Prajna Paramita Jati
NIM. 09305141003
shintaprajna@gmail.com

ABSTRAK

Demam berdarah (DB) adalah penyakit demam akut yang disebabkan oleh virus dengue, yang masuk ke peredaran darah manusia melalui gigitan nyamuk dari genus *Aedes*. Penyakit DB ditemukan di daerah tropis dan subtropis seperti Indonesia terutama di musim penghujan dimana suhu udara yang lembab memungkinkan perkembangbiakan nyamuk *Aedes aegypti* meningkat. Tujuan dari penelitian ini adalah: (1) menjelaskan proses pembentukan *Backpropagation Neural Network (BPNN)* untuk prediksi kasus demam berdarah, (2) meramalkan kasus demam berdarah di D.I Yogyakarta menggunakan *Backpropagation Neural Network (BPNN)*.

Langkah-langkah pemodelan kasus demam berdarah di D.I Yogyakarta dengan model *Backpropagation Neural Network (BPNN)* adalah: (1) pembagian data kasus demam berdarah menjadi 2 yaitu data *training* 80% yaitu 67 data dan data *testing* 20% yaitu 17 data, (2) identifikasi *input* yang berupa data kasus demam berdarah, suhu udara, curah hujan dan kelembaban udara dengan plot ACF dan PACF, (3) estimasi model untuk menentukan bobot-bobot, (4) Uji *white noise* pada *error* dengan plot ACF dan PACF, (5) peramalan data kasus demam berdarah.

Model *Backpropagation Neural Network (BPNN)* ini diterapkan pada data kasus demam berdarah bulan Januari 2005 hingga Desember 2012. *Input* yang digunakan merupakan faktor-faktor yang mempengaruhi kasus demam berdarah yaitu suhu udara, curah hujan, dan kelembaban udara. Struktur jaringan terbaik yang diperoleh adalah dengan 11 neuron *input* dan 11 neuron pada *hidden layer* dengan menggunakan fungsi aktivasi *sigmoid bipolar*, fungsi linear, dan algoritma pembelajaran *traindx*. Pada data *training* dan data *testing*, peramalan kasus DB dengan model *Backpropagation Neural Network* tersebut menghasilkan nilai MAPE sebesar 0,287 dan 1,131. Hasil peramalan untuk bulan Januari 2013-Juni 2013 adalah 306, 208, 239, 203, 255, dan 252.

Kata kunci: *Backpropagation Neural Network*, peramalan, kasus demam berdarah.

vii

perubahan iklim menyebabkan perubahan curah hujan, suhu, kelembaban, arah udara sehingga berefek terhadap ekosistem daratan dan lautan serta berpengaruh terhadap kesehatan terutama terhadap perkembangbiakan vektor penyakit seperti nyamuk *Aedes*, malaria dan lainnya (Dinkes, 2010: 1). Curah hujan yang tinggi mengakibatkan suhu udara yang rendah sehingga udara di sekitar akan lembab di daerah dengan kondisi seperti inilah yang menyebabkan perkembangbiakan nyamuk meningkat (WA Kristyanto, 2012: 1). Dengan demikian perlu diwaspadai perkembangbiakan nyamuk *Aedes* pada saat memasuki musim penghujan.

Ancaman mematikan dari virus DB tersebut dapat menyerang siapa saja, sehingga perlunya tindakan preventif untuk meminimalisir kasus DB. Oleh karena itu, peramalan mengenai berapa banyak kasus DB yang mungkin akan terjadi pada bulan tertentu menjadi sangat penting bagi pemerintah beserta Dinas Kesehatan untuk dapat melakukan tindakan pencegahan sebelum banyak korban. Penelitian yang berhubungan dengan peramalan kasus DB telah banyak dilakukan sebelumnya. Beberapa peneliti tersebut: WA Kristyanto (2012) yang meramalkan kasus DB di kecamatan Ungaran, Kabupaten Semarang, Provinsi Jawa Tengah menggunakan metode *exponential smoothing*, Metta Octara (2010) yang meramalkan kasus DB dengan membandingkan metode Box Jenkins (arima) dan metode winter, Elli Anna, Sediono, Salamun (2008) yaitu prediksi kejadian luar biasa (KLB) Kasus Demam Berdarah Dengue di Surabaya dengan pendekatan *time series*.

Data kasus DB setiap bulan pertahunnya merupakan data deret berkala karena data disajikan dalam jangka waktu tertentu. Deret berkala yaitu jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu (Alan Pankratz, 1983: 6). Model deret berkala ada 2 jenis, yaitu model stasioner, yakni suatu model yang sedemikian hingga semua sifat statistiknya (rata-rata, variansi, kovarians) tidak berubah dengan pergeseran waktu. Pada model ini, sifat-sifat statistiknya di masa yang akan datang dapat diramalkan berdasarkan data historis yang telah terjadi di masa yang lalu. Beberapa model deret berkala stasioner (khususnya sering disebut model linear) yaitu *Moving Average*, *Autoregressive Moving average (ARMA)*, dan model ARMA dengan variabel eksogen/prediktor (yakni model ARMAX). Kedua, model *non-stasioner*, yaitu model yang tidak memenuhi model stasioner. Beberapa model deret berkala *non-stasioner* yakni model trend, model *Autoregressive Integrated Moving Average (ARIMA)*, *Seasonal ARIMA (SARIMA)*, Model ARIMAX, model heteroskedastik ARCH/GARCH.

Dalam perkembangan selanjutnya berkembang metode peramalan baru menggunakan sistem Jaringan Syaraf Tiruan (JST) atau *Neural Networks (NN)*. NN digunakan untuk memprediksi nilai masa depan didukung oleh kemampuan NN dalam memformulasikan keadaan non-linear. Metode peramalan NN kemudian mengalami perkembangan. Beberapa diantaranya yang tergolong dalam model NN antara lain *Feed Forward Neural Network (FFNN)*, *Backpropagation Neural Network (BPNN)*, *Radial Basis Function (RBF)*, dan *Generalized Regression Neural Network (GRNN)*. Metode yang

digunakan pada penelitian ini adalah *Backpropagation Neural Network (BPNN)*. *Backpropagation Neural Network (BPNN)* merupakan model NN dengan *multilayer* yang sering digunakan pada perkiraan data deret berkala. Metode ini merupakan juga metode yang baik dalam menangani masalah-masalah pengenalan pola-pola kompleks. Beberapa aplikasi yang menggunakan metode ini adalah kompresi data, deteksi virus komputer, pengidentifikasian objek, dan lain-lain. Hal ini memungkinkan karena jaringan dengan algoritma BPNN dilatih menggunakan proses pembelajaran *supervised training* (Fausset, 1994: 289). Penerapan metode BPNN telah banyak dilakukan pada penelitian sebelumnya. Beberapa diantara peneliti tersebut antara lain Wei-dong Gao (2010) dalam penelitiannya yang menggunakan *backpropagation* pada peramalan populous, Dinar Atika Sari (2011) yang menggunakan model *backpropagation* untuk peramalan beban jangka pendek, Nico Schlitter (2008) tentang studi kasus menggunakan *backpropagation* pada indeks industri, dan Intan Widya Kusuma (2011) yang menggunakan *backpropagation* untuk perkiraan produksi tebu.

Pada umumnya BPNN dapat diterapkan di berbagai bidang sebagai metode peramalan, skripsi ini akan menerapkan model BPNN untuk meramalkan kasus DB di D.I Yogyakarta dengan *input* faktor-faktor lingkungan yang mempengaruhi DB yaitu curah hujan, suhu udara, dan kelembaban udara. Oleh karena itu, tugas akhir ini diberi judul "Model *Backpropagation Neural Network (BPNN)* pada Peramalan Kasus Demam Berdarah di D.I Yogyakarta".

□

□

B. Rumusan Masalah

Berdasarkan latar belakang di atas maka masalah yang akan dibahas adalah sebagai berikut:

1. Bagaimana proses membentuk model *Backpropagation Neural Network (BPNN)* untuk peramalan kasus demam berdarah?
2. Bagaimana hasil peramalan kasus demam berdarah di Yogyakarta menggunakan *Backpropagation Neural Network (BPNN)*?

C. Tujuan Penelitian

Tujuan penulisan penelitian ini adalah:

1. Menjelaskan proses pembentukan *Backpropagation Neural Network (BPNN)* untuk peramalan kasus demam berdarah.
2. Meramalkan kasus demam berdarah di D.I Yogyakarta menggunakan *Backpropagation Neural Network (BPNN)*.

D. Manfaat Penelitian

Manfaat dilakukannya penelitian ini adalah:

1. Bagi Penulis
Menambah dan memperkaya pengetahuan model *Backpropagation Neural Network (BPNN)* dan penerapannya pada peramalan data deret berkala.
2. Bagi Mahasiswa Matematika
 - a. Menambah pengetahuan tentang model *Backpropagation Neural Network (BPNN)*
 - b. Memberikan suatu metode alternatif untuk peramalan data deret berkala dengan *Backpropagation Neural Network (BPNN)*

□

□

3. Bagi Dinas Kesehatan

Peramalan kasus demam berdarah di D.I Yogyakarta dapat membantu pemerintah/Dinas Kesehatan dalam melakukan tindakan preventif terhadap penyakit demam berdarah.

BAB II

KAJIAN TEORI

A. Demam Berdarah

1. Pengertian Demam Berdarah

Demam berdarah (DB) adalah penyakit demam akut yang disebabkan oleh virus dengue, yang masuk ke peredaran darah manusia melalui gigitan nyamuk dari genus *Aedes*, misalnya *Aedes aegypti* atau *Aedes albopictus*. Virus dengue merupakan virus dari genus *Flavivirus*, famili *Flaviviridae*. Penyakit DB ditemukan di daerah tropis dan subtropis seperti Indonesia terutama di musim hujan dimana suhu udara yang lembab memungkinkan perkembangbiakan nyamuk *Aedes aegypti* meningkat (Dinkes, 2010: 1).

Penyakit DB masih merupakan salah satu masalah kesehatan masyarakat yang utama di Indonesia. Jumlah penderita dan luas daerah penyebarannya semakin bertambah seiring dengan meningkatnya mobilitas dan kepadatan penduduk. *World Health Organization (WHO)* mencatat negara Indonesia sebagai negara dengan kasus DB tertinggi di Asia Tenggara (Dinkes, 2010: 1).

2. Jenis Demam Berdarah

Demam berdarah dibedakan menjadi 3 jenis dengan gejala yang berbeda. Pertama, demam berdarah klasik dengan gejala demam dan

▣

jam. Kebocoran plasma sering didahului oleh lekopeni progresif disertai penurunan hitung trombosit. Ketiga, fase pemulihan bila fase kritis terlewati maka terjadi pengembalian cairan dari ekstrasvaskuler ke intravaskuler secara perlahan pada 48 ó 72 jam setelahnya. Keadaan umum penderita membaik, nafsu makan pulih kembali, hemodinamik stabil, dan diuresis membaik (Primal Sudjana, 2010: 23).

4. Faktor Lingkungan

Pada skripsi ini menggunakan 3 faktor lingkungan yang mempengaruhi banyaknya kasus demam berdarah, yaitu:

a. Suhu Udara

Suhu merupakan karakteristik yang dimiliki oleh suatu benda yang berhubungan dengan panas dan energi. Jika panas dialirkan pada suatu benda, maka suhu benda tersebut akan meningkat, sebaliknya suhu benda tersebut akan turun jika benda yang bersangkutan kehilangan panas (Lakitan, 1997: 89). Suhu dapat diukur dengan menggunakan termometer yang berisi air raksa atau alkohol.

Satuan pengukuran suhu, antara lain derajat *Celcius* ($^{\circ}C$), derajat *Fahrenheit* ($^{\circ}F$), derajat *Reamur* ($^{\circ}R$), dan derajat *Kelvin* ($^{\circ}K$). Satuan derajat *celcius* adalah satuan yang paling sering digunakan. Parameter dalam pengukuran skala suhu adalah panas atau energi yang dimiliki oleh air pada titik beku (diberi nilai 0) dan titik didih (diberi nilai 100) (Handoko, 1995: 42).

▣

muncul ruam pada bayi, sedangkan pada usia dewasa gejalanya demam tinggi, sakit kepala, nyeri pada sendi tulang, mual dan muntah. Penyakit ini disertai penurunan jumlah sel darah putih (*leukopenia*) dan penurunan keping darah (*trombositopenia*). Kedua, demam berdarah dengue (*hemoragik*) yaitu demam berdarah dengan gejala yang hampir sama dengan demam berdarah klasik hanya saja demam berdarah dengue sering kali disertai pendarahan hebat disertai pembesaran hati dan kegagalan sistem sirkulasi darah sehingga muncul kerusakan pembuluh darah. Ketiga, *syndrome* syok dengue dengan infeksi virus terparah yang mengakibatkan kebocoran cairan di luar pembuluh darah, hal ini terjadi pada penderita yang telah terinfeksi virus dengue untuk kedua kalinya yang dapat menyebabkan kematian.

3. Fase Demam Berdarah

Fase pada penyakit DB yang pertama adalah fase febris biasanya demam mendadak tinggi 2 ó 7 hari, disertai muka kemerahan, eritema kulit, nyeri seluruh tubuh, mialgia, artralgia dan sakit kepala. Pada beberapa kasus ditemukan nyeri tenggorok, injeksi farings dan konjungtiva, anoreksia, mual dan muntah. Pada fase ini dapat pula ditemukan tanda perdarahan seperti petekie, perdarahan mukosa, walaupun jarang dapat pula terjadi perdarahan pervaginam dan perdarahan gastrointestinal. Kedua, fase kritis terjadi pada hari 3 ó 7 sakit dan ditandai dengan penurunan suhu tubuh disertai kenaikan permeabilitas kapiler dan timbulnya kebocoran plasma yang biasanya berlangsung selama 24 ó 48

▣

b. Curah Hujan

Curah hujan merupakan ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap, dan tidak mengalir. Menurut Tjasyono (2004) jumlah hujan dicatat dalam inci atau millimeter. Curah hujan dapat diartikan sebagai ketinggian air yang terkumpul dalam tempat yang datar, dengan asumsi tidak meresap, tidak mengalir dan tidak menguap ke atmosfer.

c. Kelembaban Udara

Kelembaban udara merupakan salah satu faktor yang berpengaruh dalam prediksi suhu udara. Menurut Lakitan (1997: 187), kelembaban udara menggambarkan kandungan uap air di udara yang dapat dinyatakan sebagai kelembaban mutlak, kelembaban nisbi (relatif) maupun defisit tekanan uap air.

Kelembaban mutlak adalah kandungan uap air (dapat dinyatakan dengan massa uap air atau tekanannya) per satuan volume. Kelembaban nisbi adalah perbandingan massa uap air yang ada dalam satu satuan volume udara dengan massa uap air yang diperlukan untuk menjenuhkan satu satuan volume udara tersebut pada suhu yang sama. Sedangkan defisit tekanan uap air adalah selisih antara tekanan uap jenuh dan tekanan uap aktual (Handoko, 1995: 57).

Menurut Joghnan Sitorus (2003) suhu udara, curah hujan, dan kelembaban udara mempunyai hubungan yang signifikan dengan peningkatan kasus demam berdarah. Curah hujan yang tinggi, suhu udara

yang rendah, dan kelembaban udara yang tinggi menyebabkan perkembangbiakan larva nyamuk meningkat (Topan Nirwana dkk, 2003: 6) Dengan demikian pada musim penghujan kasus demam berdarah akan bertambah banyak.

B. Peramalan

Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien (Makridakis, 1999: 3). Peramalan nilai-nilai yang akan datang didasari dengan data historis dan pengalaman. Peramalan sering digunakan pada bidang ekonomi, perencanaan produksi, peramalan penjualan, dan kontrol stok. Meramal juga dapat didasarkan pada keahlian *judgment*, yang ada pada gilirannya didasarkan pada data historis dan pengalaman (Makridakis, 1999: 519)

C. Analisis Deret Berkala


Deret berkala (*time series*) merupakan serangkaian variabel yang diamati pada interval waktu yang sama. Tujuan dari analisis deret berkala adalah untuk menemukan pola data secara historis dan mengekstrapolasikan pola tersebut untuk masa yang akan datang. Gerakan atau variasi data deret berkala terdiri dari empat macam sebagai berikut (Hanke & Wichern, 2005: 58-60):

1. Gerakan Horizontal

Suatu pergerakan ketika data observasi berfluktuasi di sekitar nilai konstan atau *mean* yang membentuk garis horizontal. Data ini disebut dengan data stasioner. Contoh gerakan horizontal dapat dilihat pada plot

11


data penjualan (**Gambar 2.1**). Jumlah penjualan berfluktuasi di sekitar nilai konstan.



Gambar 2.1. Contoh Pola Gerakan Horizontal

2. Gerakan Trend


Suatu gerakan yang menunjukkan arah pergerakan secara umum baik kecenderungan yang naik ataupun turun dan arah gerakan itu bertahan dalam jangka waktu yang lama. **Gambar 2.2** menunjukan gerakan *trend* dari data harga suatu produk yang meningkat dari tahun ke tahun.



Gambar 2.2. Contoh Pola Gerakan Trend Naik

3. Gerakan Siklis

Pola data siklis terjadi bilamana deret berkala dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti siklus bisnis. Pada **Gambar 2.3** indeks harga konsumen umum, padi-padian dan pendidikan menunjukkan gerakan siklis. Pertengahan tahun 1997 terjadi krisis di Indonesia sehingga menyebabkan indeks harga naik. Fluktuasi ini cukup tinggi dan berpengaruh dalam jangka panjang.




Gambar 2.3. Contoh Pola Gerakan Siklis

4. Gerakan Musiman

Gerakan yang dipengaruhi oleh faktor musiman. Pola data ini mempunyai pola musim yang berulang dari periode ke periode berikutnya. Misalnya pola yang berulang setiap hari tertentu, minggu tertentu, bulan tertentu, atau pada tahun tertentu. Contoh pola dari data musiman ada pada **Gambar 2.4** yaitu plot debit air telaga Ngebel yang diukur setiap harinya. Dari plot tersebut terlihat bahwa terjadi pola yang berulang setiap periode

12

sepuluh hari, sehingga bisa disimpulkan bahwa data tersebut merupakan pola data musiman.



Gambar 2.4. Contoh Pola Gerakan Musiman

D. Autokorelasi

Autokorelasi digunakan untuk menjelaskan hubungan antara nilai-nilai suatu deret berkala yang sama pada periode waktu berbeda. Autokorelasi mirip dengan korelasi hanya saja autokorelasi menghubungkan suatu deret berkala yang sama untuk selang waktu (*time lag*) yang berbeda. Pola dari koefisien autokorelasi sering digunakan untuk menetapkan ada tidaknya faktor musiman (*seasonality*) di dalam deret berkala, dan untuk menentukan order model deret berkala yang tepat pada situasi tertentu, serta untuk menentukan kestasioneran data.

Suatu deret $\{ Y_t \}$ yaitu $\{ Y_t \}$ dikatakan stasioner jika mean $\mu = E(Y_t)$ dan varians $\sigma^2 = \text{Var}(Y_t)$ konstan, serta kovarians antara Y_t dengan Y_{t-k} adalah (Wei, 1994: 10):

$$(2.1)$$

dengan

12

μ : rata-rata
 γ_k : autokovarians pada lag k
 ρ_k : autokorelasi pada lag k
 t : waktu pengamatan, $t = 1, 2, 3, \dots$

Autokorelasi pada lag k atau korelasi antara Y_t dan Y_{t+k} didefinisikan sebagai

$$\rho_k = \frac{\text{cov}(Y_t, Y_{t+k})}{\sqrt{\text{var}(Y_t)}\sqrt{\text{var}(Y_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.2)$$

Koefisien autokorelasi dari pengamatan pada waktu ke t sampai waktu $t+k$ yang digunakan untuk penduga ρ_k dan diberi simbol $\hat{\rho}_k$ dirumuskan sebagai (Tsay, 1951: 31)

$$\hat{\rho}_k = r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, k = 0, 1, 2, \dots \quad (2.3)$$

dengan,

r_k : koefisien autokorelasi untuk lag k
 \bar{Y} : nilai rata-rata variabel Y
 Y_t : nilai pengamatan pada waktu t
 Y_{t-k} : nilai pengamatan pada lag k

Hipotesis untuk menguji signifikansi autokorelasi dirumuskan sebagai

$H_0: \rho_k = 0$ (autokorelasi pada lag ke k tidak signifikan)


$H_1: \rho_k \neq 0$ (autokorelasi pada lag ke k signifikan)

Uji signifikansi menggunakan distribusi t, dengan statistik uji

$$t = \frac{r_k}{SE(r_k)} \quad (2.4)$$

18

Berikut (Gambar 2.5) plot autokorelasi pada deret berkala. Garis yang keluar dari batas signifikan menunjukkan autokorelasi signifikan:



Gambar 2.5. Contoh Autokorelasi Pada Data Deret Berkala

E. Kriteria Model Terbaik

Peramalan sebagai proses mengolah informasi mengenai kejadian di masa lampau untuk diramalkan di masa yang akan datang. Kegunaan peramalan terlihat pada saat pengambilan keputusan, keputusan terbaik adalah keputusan yang didasarkan atas pertimbangan apa yang akan terjadi pada waktu keputusan itu dilaksanakan. Langkah-langkah peramalan yang baik :

1. Menganalisa data masa lampau
2. Menentukan metode yang digunakan
3. Memproyeksikan data yang lalu dengan menggunakan metode yang sesuai dan mempertimbangkan adanya beberapa faktor perubahan

Peramalan yang baik adalah peramalan yang mempunyai kesalahan peramalan minimum. Kesalahan peramalan dapat diukur dengan metode *Mean Absolute Percentage Error* (MAPE) sesuai dengan prinsip parsimony, yaitu

18

Standar *error* dari koefisien autokorelasi menggunakan rumus berikut (Hanke & Wichern, 2005: 64):

$$SE(r_k) = \sqrt{\frac{1+2\sum_{k=1}^{k-1} r_k^2}{n}} \quad (2.5)$$

dengan

$SE(r_k)$: standar *error* koefisien korelasi pada lag k
 r_k : koefisien korelasi pada lag
 n : banyak pengamatan

Jika $k = 1$, maka

$$SE(r_k) = \sqrt{\frac{1}{n}} \quad (2.6)$$

Koefisien autokorelasi pada lag k dikatakan signifikan jika $t_{nk,lag} > t_{(n-1)}(\frac{\alpha}{2})$ atau $t_{hitung} < -t_{(n-1)}(\frac{\alpha}{2})$ dan apabila menggunakan nilai *Sig.* maka koefisien autokorelasi pada lag k dikatakan signifikan jika *Sig.* $< \frac{\alpha}{2}$

Signifikansi koefisien autokorelasi juga dapat dilihat dari selang kepercayaan dengan pusat $r_k = 0$ yang apabila dilihat dari tampilan plot fungsi autokorelasi berupa garis putus-putus yang berwarna merah. Selang kepercayaan tersebut decari dengan cara menghitung

$$0 \pm t_{(n-1)}(\alpha/2) \times SE(r_k) \quad (2.7)$$

18

suatu kriteria pemilihan model terbaik dengan memilih nilai yang minimal dan paling sederhana. Prinsip parsimony merupakan hal yang penting karena pada prakteknya umumnya model yang parsimony menghasilkan ramalan yang lebih baik (Alan Pankratz, 1983: 81). MAPE merupakan persentase nilai rata-rata *Absolute Error* dari kesalahan meramal tanpa menghiraukan tanda positif atau negatif yang dirumuskan (Hanke & Wichern, 2005: 80)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (2.8)$$

dengan,

Y_t : nilai pengamatan ke t
 \hat{Y}_t : nilai peramalan pada waktu ke t
 n : banyaknya pengamatan


F. Jaringan Syaraf

1. Jaringan Syaraf Biologi

Jaringan syaraf adalah suatu sel biologi khusus yang mengolah informasi. Suatu syaraf biologi seperti yang ditunjukkan pada Gambar 2.6 terdiri atas *neuron*, sel tubuh atau *soma* dan dua cabang menyerupai pohon yang menjulur ke luar, yaitu: *axon* dan *dendritis*. *Neuron* adalah sel syaraf yang merupakan unit anatomis dan fungsional dari sistem syaraf. *Dendrit* adalah tonjolan yang menghantarkan informasi menuju badan sel atau *axon*. Sebuah inti sel (*nucleus*) yang berisi informasi tentang sifat keturunan dan sebuah plasma yang mengandung molekuler untuk menghasilkan material yang dibutuhkan oleh syaraf. Syaraf menerima sinyal impuls dari syaraf-syaraf lainnya melalui *dendrite*, dijumlahkan pada

18

soma, kemudian dikirim melalui *axon* yang bercabang pada untai dengan sub-untai yang berupa *synapse*. *Synapse* merupakan struktur dasar dari unit fungsional antara dua syaraf, yaitu: untai *axon* pada satu syaraf dan *dendrite* pada syaraf lainnya. Ketika sinyal implus sampai pada *synapse*, suatu zat kimia tertentu yaitu *neurotransmitter* dilepaskan. *Neurotransmitter* merupakan zat kimia sintetis dalam *neuron* yang menyebar melintasi celah-celah *synapse*, yang akan bertambah maupun terhambat tergantung dari tingkat aktivitas syaraf. Setiap aktivitas syaraf akan menyebabkan bobot *synapse* berubah. Bobot ini dinyatakan sebagai memori yang bertanggungjawab terhadap ingatan manusia (Liyu Feriyawati, 2006: 7-8)



Gambar 2.6. Jaringan Syaraf Biologi

2. Neural Network (NN) atau Jaringan Syaraf Tiruan (JST)

Jaringan syaraf tiruan berawal dari memodelkan jaringan syaraf pada otak manusia dengan karakteristik kerja yang sama dengan jaringan syaraf biologi. Selain itu juga dapat merancang struktur dasar suatu jaringan yaitu neuron menjadi rancangan yang pasti seperti pengenalan pola lebih cepat.

18

Kerangka kerja NN dapat dilihat dari jumlah lapisan (*layer*) dan jumlah simpul (*node*) pada setiap lapisan.

Lapisan-lapisan penyusun NN dibagi menjadi tiga yaitu (Hu & Hwang, 2002: 17):

a. Lapisan Input (*input layer*)

Node-node di dalam lapisan *input* disebut neuron-neuron *input*. Neuron-neuron *input* menerima *input* dari dunia luar, *input* yang diberikan merupakan penggambaran suatu permasalahan.

b. Lapisan Tersembunyi (*hidden layer*)

Node-node di dalam *hidden layer* disebut neuron-neuron tersembunyi. *Output* dari lapisan ini tidak dapat diamati secara langsung.

c. Lapisan Output (*output layer*)

Node-node di dalam *output layer* disebut neuron-neuron *output*. Keluaran dari lapisan ini merupakan hasil dari jaringan syaraf tiruan terhadap suatu permasalahan.

4. Arsitektur Jaringan Syaraf Tiruan

Jaringan syaraf tiruan diklasifikasikan sebagai jaringan lapisan tunggal (*single layer net*) atau jaringan banyak lapisan (*multilayer net*). Banyak *input* tidak dapat dihitung sebagai banyak lapisan, sebaliknya banyaknya lapisan tidak berarti sama dengan banyak *input*, melainkan banyaknya lapisan bergantung pada bobot koneksi. Hal ini dikarenakan bobot koneksi mengandung informasi penting pada setiap lapisan (Fausset, 1994: 12).

21

Jaringan ini menyerupai otak manusia dalam dua hal: pengetahuan diperoleh jaringan melalui proses pembelajaran, dan kekuatan koneksi antar neuron dikenal sebagai bobot sinaptik yang digunakan untuk menyimpan pengetahuan (Haykin, 1998: 1-2). Algoritma NN secara umum digunakan dalam klasifikasi pola, pola penyelesaian, fungsi pendekatan, prediksi, optimasi, dan aplikasi sistem kontrol (Stevencz, 2013: 417).

NN merupakan sistem pemrosesan informasi yang memiliki karakteristik kinerja tertentu yang sama dengan jaringan syaraf biologi manusia yang telah dikembangkan sebagai generalisasi model matematika dari *humancognition* atau syaraf biologi. Generalisasi matematika membentuk NN dari jaringan syaraf biologi, dengan asumsi (Fausset, 1994: 3):

- Pemrosesan informasi terjadi pada banyak elemen sederhana (neuron)
- Sinyal dikirim diantara neuron-neuron melalui penghubung
- Penghubung antar neuron mempunyai bobot terikat yang pada jaringan mengalikan sinyal transmisi
- Setiap neuron menerapkan fungsi aktivasi (biasanya nonlinier) pada *inputnya* untuk menentukan sinyal *output*


3. Kerangka Jaringan Syaraf Tiruan

Jaringan syaraf adalah merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk menstimulasi proses pembelajaran pada otak manusia tersebut (Hu & Hwang, 2002: 13).

20

a. Jaringan Lapisan Tunggal (*Single Layer Net*)

Pada Gambar 2.7 merupakan gambar jaringan *single layer*. Jaringan ini hanya mempunyai satu lapisan bobot koneksi (*one layer of weight*) dan hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus melalui *hidden layer* (Fausset, 1994: 12)




Gambar 2.7. Single Layer Net

b. Jaringan Banyak Lapisan (*Multilayer Net*)

Jaringan *multilayer* pada Gambar 2.8 merupakan jaringan yang mempunyai lapisan lebih dari satu yang berada di antara *input* dan *output*. Pada umumnya ada lapisan bobot yang letaknya di antara dua lapisan yang bersebelahan. Jaringan dengan *multilayer* dapat menyelesaikan permasalahan yang lebih sulit serta dengan pembelajaran yang lebih rumit dibandingkan jaringan *single layer*. Jaringan ini akan lebih berhasil dalam penyelesaian masalah walaupun membutuhkan waktu yang lebih lama (Fausset, 1994: 14).

22



Gambar 2.8. Multilayer Net

5. Fungsi Aktivasi


Fungsi aktivasi adalah fungsi yang mengubah *input* ke neuron menjadi *output* melalui neuron tersebut (Fausset, 1994: 3). Fungsi aktivasi (Fausset, 1994: 18-19) tersebut yaitu :

a. Fungsi Undak Biner (Binary Step Function)

Jaringan dengan *single layer* sering menggunakan fungsi undak biner (*step function*) seperti pada Gambar 2.9 untuk mengkonversikan *input* dari suatu variabel yang bernilai kontinu ke suatu *output* biner (0 atau 1).

Fungsi undak biner dirumuskan sebagai

$$(2.9)$$




Gambar 2.9. Fungsi Aktivasi: Undak Biner (Binary Step Function)

b. Fungsi Bipolar (Symetric Hard Limit)

Fungsi bipolar yaitu Gambar 2.10 sebenarnya hampir sama dengan fungsi undak biner, hanya saja *output* yang dihasilkan berupa 1, 0, atau -1.

Fungsi bipolar dirumuskan sebagai

$$(2.10)$$




Gambar 2.10. Fungsi Aktivasi: Bipolar (Symetric Hard Limit)

c. Fungsi Linier (Identitas)

Fungsi linier memiliki nilai *output* yang sama dengan nilai *inputnya* seperti yang ditunjukkan Gambar 2.11.

Fungsi linier dirumuskan sebagai

$$(2.11)$$



Gambar 2.11. Fungsi Aktivasi: Linier (Identitas)


d. Fungsi Sigmoid Biner

Fungsi sigmoid biner (Gambar 2.12) ini digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode *backpropagation*. Fungsi sigmoid biner memiliki nilai pada range 0 sampai 1. Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai *output* yang terletak pada interval 0 sampai 1. Namun, fungsi ini bisa juga digunakan oleh jaringan syaraf yang nilai *outputnya* 0 atau 1.

Fungsi sigmoid biner dirumuskan sebagai

$$(2.12)$$

$$(2.13)$$



Gambar 2.12. Fungsi Aktivasi: Sigmoid Biner

e. Fungsi Sigmoid Bipolar


Fungsi sigmoid bipolar (Gambar 2.13) hampir sama dengan fungsi sigmoid biner, hanya saja *output* dari fungsi ini memiliki range antara -1 sampai 1.

Fungsi sigmoid bipolar dirumuskan sebagai

$$(2.14)$$

$$(2.15)$$

Fungsi ini sangat dekat dengan fungsi *hyperbolic tangent*. Keduanya memiliki range antara -1 sampai 1.



Gambar 2.13. Fungsi Aktivasi: Sigmoid Bipolar

6. Metode Pelatihan

Secara umum ada dua metode pelatihan dalam NN yang melibatkan faktor luar maupun tidak (Fausset, 1994: 15-16), yaitu :

a. *Supervised training* adalah proses pelatihan yang diselesaikan melalui proses yang berulang, menggunakan vektor *input* yang dihubungkan dengan vektor target. Dalam pelatihan ini terdapat pasangan data

(input dan output) yang dipakai untuk melatih jaringan hingga diperoleh bobot yang diinginkan. Pada setiap kali pelatihannya, suatu input diberikan ke jaringan. Jaringan akan memproses sehingga menghasilkan output. Selisih antara output dengan target (output yang diinginkan) merupakan error. Jaringan akan memodifikasi bobot sesuai dengan error tersebut.

- b. *Unsupervised training* adalah apabila proses pelatihan menggunakan vektor input tetapi tidak ditentukan vektor targetnya. Bobot ditentukan dengan memodifikasinya sehingga untuk vektor input yang sama akan diberikan vektor output yang sama.

7. Proses Pembentukan Jaringan Syaraf Tiruan

Metode *Neural Network* yang digunakan sangat mempengaruhi nilai output yang dihasilkan. Oleh karena itu, perancangan struktur jaringan merupakan langkah penting dalam perancangan sistem. Proses pembentukan struktur jaringan untuk peramalan adalah sebagai berikut:

a. Pembagian Data

Dalam pembagian data, data dibagi menjadi data *training*, dan data *testing*. Aspek pembagian data harus ditekankan supaya memperoleh data *training* yang secukupnya yang selanjutnya digunakan untuk proses pembelajaran dan data *testing* digunakan untuk menguji proses pembelajaran yang dilakukan data *training* berdasarkan nilai MAPE data *training* dan *testing*. Komposisi pembagian data untuk data *training* yang kurang sesuai akan menyebabkan jaringan tidak dapat

mempelajari sebaran data dengan baik. Sebaliknya jika data yang digunakan untuk proses pembelajaran cukup banyak akan melambatkan proses pemusatan.

b. Perancangan Jaringan Yang Optimum

Perancangan jaringan yang optimum yaitu menentukan banyaknya neuron input, banyaknya *hidden layer*, banyaknya neuron tersembunyi, dan banyaknya neuron output yang akan digunakan dalam jaringan. Penggunaan jaringan dengan dua atau lebih *hidden layer* dalam masalah peramalan kebanyakan tidak akan memberikan pengaruh yang sangat besar terhadap hasil yang diperoleh jaringan untuk melakukan peramalan. Selain ini akan melambatkan proses pembelajaran yang disebabkan bertambahnya neuron.

c. Pemilihan Parameter Pembelajaran

Pemilihan koefisien pembelajaran dan momentum mempunyai peranan penting untuk pembentukan struktur jaringan. Dalam pembentukan struktur jaringan yang akan digunakan dalam peramalan, model yang kurang baik dapat diperbaiki dengan menggunakan koefisien pemahaman dan momentum secara *trial* dan *error* untuk mendapatkan nilai bobot yang paling optimum supaya MAPE jaringan dapat diperbarui.

d. Memilih Dan Menggunakan Struktur Jaringan Yang Optimum

Jaringan yang dibangun akan dinilai keakuratan ramalannya yaitu dengan menentukan neuron terbaik dan input yang optimal. Salah satu

penilaian yang digunakan dalam memilih struktur jaringan adalah *Mean Absolute Percentage Error (MAPE)*. Berdasarkan nilai MAPE yang terendah dari proses pembelajaran, diperoleh jaringan yang terbaik.

e. Pengujian Struktur Jaringan Yang Terpilih

Pengujian struktur jaringan yang terpilih dengan cara melihat perbedaan nilai MAPE antara hasil pembelajaran pada data *training* dan data *testing*. Selain itu, menguji error pada jaringan yang akan dipilih apakah error telah signifikan atau belum, pengujian menggunakan uji *White Noise*.

G. Uji White Noise

Suatu proses {*et*} disebut proses *white noise* jika terdiri dari variabel random (acak) yang tidak berkorelasi dan berdistribusi tertentu dengan rata-rata konstan $E(e_t)=0$, variansi konstan $var(e_t)=\sigma_e^2$ dan $\gamma k=(e_{t+k})=0$ untuk $k \neq 0$ (Wei, 2006: 15-16). Proses *white noise* {*et*} adalah stasioner dengan fungsi autokovarians:

$$\gamma_k = \begin{cases} \sigma_e^2, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.16)$$

dengan fungsi autokorelasi:

$$\rho_k = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.17)$$

dan fungsi autokorelasi parsial:

$$\phi_k = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.18)$$

Pada proses *white noise*, nilai ACF dan PACF tidak berbeda signifikan dengan nol. Untuk mendeteksi bahwa suatu proses {*et*} *white noise*, pada analisis galat dilakukan uji Ljung-Box-Pierce. Berikut hipotesis yang digunakan dalam uji Ljung-Box-Pierce:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_m = 0 \text{ (koefisien autokorelasi tidak signifikan)}$$

$$H_1 : \exists \rho_k \neq 0, k = 1, 2, 3, \dots, m \text{ (koefisien autokorelasi signifikan)}$$

Taraf signifikansi yang dipakai $\alpha = 0,05$ dengan menggunakan statistik uji sebagai berikut (Hanke & Wichern, 2005: 65)

$$Q = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n-k} \quad (2.19)$$

dengan,

- n* : banyaknya pengamatan
- k* : lag ke
- m* : banyaknya lag yang di uji
- $\hat{\rho}_k$: dugaan autokorelasi galat periode *k*

Kriteria keputusan yang dibuat adalah H_0 ditolak jika $Q_{hitung} > X_{\alpha,df}^2$ (tabel) dengan df merupakan *m* dikurangi banyaknya parameter pada model atau *p-value* < α

DAFTAR PUSTAKA

- Badan Pusat Statistik. (2006). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2007). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2008). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2009). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2010). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2011). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2012). *DIY Dalam Angka*. Yogyakarta: BPS.
 -----.(2013). *DIY Dalam Angka*. Yogyakarta: BPS.
- Demuth, H. & Beale, M. (2002). *Neural Network Toolbox User's Guide (For Use with MATLAB) Version 4*. United States: The MathWorks, Inc.
- Dinar Atika Sari. (2011). Peramalan Kebutuhan Beban Jangka Pendek Menggunakan Jaringan Syaraf Tiruan *Backpropagation*. Skripsi. Universitas Diponegoro.
- Elly Anna, Sediono, dan Salamun. (2007). Prediksi Kejadian Luar Biasa (KLB) Kasus Demam Berdarah Dengue di Surabaya dengan Pendekatan *Time Series*. *Jurnal MIPA Universitas Airlangga*. Hlm. 205.
- Ethiene Arruda Pedrosa et al. (2010). *Impact of Small Variations In Temperature and Humidity On The Reproductive Activity and Survival of Aedes Aegypti (Diptera, Culicidae)*. *Journal Revista Brasileira de Entomologia* Vol. 54 No. 3.
- Fausett, L. (1994). *Fundamentals of Neural Network (Architectures, Algorithms, and Applications)*. Upper Saddle River, New-Jersey: Prentice-Hall.
- Handoko (Ed). (1995). *Klimatologi Dasar*. Jakarta: PT. Dunia Pustaka Jaya.
- Hanke, J.E. & Wichern, D.W. (2005). *Business Forecasting Eight Edition*. Canada: Prentice Hall.
- Haykin, S. (1998). *Neural Network A Comprehensive Foundation*. Canada: Prentice Hall.
- Heri Mauridi & Agus Kurniawan. (2006). *Supervised Neural Network dan Aplikasinya*. Yogyakarta: Graha Ilmu.
- Hu, Yu Hen & Hwang, Jenq-Neng. (2002). *Handbook of Neural Network Signal Processing*. New York: CRC Press.
- Intan Widya Kusuma. (2011). Aplikasi Model *Backpropagation Neural Network* Untuk Perkiraan Produksi Tebu Pada PT. Perkebunan Nusantara IX. *Prosiding*. Yogyakarta: FMIPA UNY.
- Jendela Epidemiologi*. Dinas Kesehatan RI. Agustus 2010.
- Lakitan, B. (1997). *Dasar-Dasar Klimatologi*. Jakarta: PT. Raja Grafindo Persada.
- Lita Feriyawati. (2005). Anatomi Sistem Syaraf dan Perannya Dalam Regulasi Kontraksi Otot Rangka. *USU Repository*. Sumatra Utara: FK USU.
- Lori Stevens, et al. (2013). Assessing Linkages In Stream habitat, Geomorphic Condition, and Biological Integrity Using A Generalized Regression Neural Network. *Journal Of The America Water Resources Association (Vol. 49, No. 2)*. Page 415-425.
- Makridakis, S. Wheelwright, S.C., & Mc Gee, V.E. (1999). *Metode dan Aplikasi Peramalan Jilid I (I. Untung Sus Ardiyanto, M.Sc. dan Ir. Abdul Basith, M.Sc. Terjemahan)*. Edisi Kedua. Jakarta: Penerbit Erlangga.
- Metta Octora. (2010). Perbandingan Metode *Box Jenkins* (Arima) dan Metode *Winter* Dalam Peramalan Kasus Demam Berdarah Dengue. *Abstrak Hasil Penelitian Biostatistik*. Surabaya: Universitas Airlangga.
- Nico Schlitter. (2008). *A Case Study of Time Series Forecasting with Backpropagation Networks*. *Group Knowledge Management and Discovery*. University Magdeburg.
- Pankratz, A. (1983). *Forecasting with Univariate Box-Jenkins Models Concepts and Cases*. Canada: John Wiley & Sons, Inc.
- Primal Sudjana. Demam Berdarah Dengue Dewasa. (2010). *Buletin Jendela Epidemiologi*. Hlm. 21-25.
- Rojas, Raul. (1996). *Neural Networks: A Systematic Introduction*. Berlin: Springer-Verlag
- Siang. (2005). *Jaringan Saraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: Penerbit Andi.
- Sitorus, Jughan. (2003). Hubungan Iklim Dengan Penyakit Demam Berdarah Dengue (DBD) di Kotamadya Jakarta Timur 1998-2002. *Thesis*. Depok: Universitas Indonesia
- Sri Kusumadewi. (2004). *Membangun Jaringan Syaraf Tiruan Menggunakan Matlab dan Excel Link*. Yogyakarta: Graha Ilmu.
- Topan Nirwana, Ardini Raksanagara, dan Irvan Afriandi. (2003). Pengaruh Curah Hujan, Temperatur, dan kelembaban Udara Terhadap Kejadian Penyakit DBD, ISPA, dan Diare: Suatu Kajian Literatur. *Jurnal Universitas Padjadjaran Bandung*.
- Tsay, R.S. (1951). *Analysis Of Financial time series, 3rd edition*. New York: Willey.
- Umar Fachmi Achmadi. (2010). Manajemen Demam Berdarah Berbasis Wilayah. *Buletin Jendela Epidemiologi*. Hlm. 15-20.
- WA Kristyanto. (2012). Prediksi Periode serangan Demam Berdarah Dengue (DBD) Berdasarkan Dasarian Awal Bulan Hujan Menggunakan Metode *Exponential Smoothing*. *Jurnal Universitas Kristen Satya Wacana*. Hlm. 1-9.
- Wei, W.W.S. (2006). *Time Series Analysis Univariate and Multivariate Methods Second Edition*. New York: Pearson Education.
- Wei-dong Gao. (2010). *Backpropagation Neural Network for Prediction of Populus Seedlings Water Consumption*. *Advanced Computer Theory and Engineering (ICACTE)*.