

BAB I

PENDAHULUAN

1.1 Latar Belakang

Inflasi diartikan sebagai meningkatnya harga-harga secara umum dan terus menerus. Kestabilan inflasi merupakan prasyarat bagi pertumbuhan ekonomi yang berkesinambungan yang pada akhirnya memberikan manfaat bagi peningkatan kesejahteraan masyarakat. Pentingnya pengendalian inflasi didasarkan pada pertimbangan bahwa inflasi yang tinggi dan tidak stabil memberikan dampak negatif kepada kondisi sosial ekonomi masyarakat. Sedangkan laju inflasi merupakan kenaikan atau penurunan inflasi dari periode ke periode yang terus berjalan sesuai dengan urutan waktu. Indikator yang sering digunakan untuk mengukur laju inflasi adalah Indeks Harga Konsumen (IHK). Laju inflasi yang diukur dengan IHK di Indonesia dibagi menjadi 7 kelompok barang.

Peramalan adalah aktivitas menghitung atau memprediksi beberapa kejadian atau kondisi yang akan datang. Dalam penerapannya, model *time series* seringkali dapat digunakan dengan mudah untuk meramal karena pendugaan nilai masa depan dilakukan berdasarkan nilai masa lalu dari suatu peubah (Makridakis, Wheelwright, McGee.1999). Peramalan merupakan alat penting dalam menentukan segala sesuatu agar efektif dan efisien. Selama ini banyak peramalan dilakukan secara intuitif dengan menggunakan metode statistika. Pemilihan metode statistika itu tergantung pada berbagai aspek waktu, pola data, tipe model sistem yang diamati, tingkat keakuratan ramalan yang diinginkan dan sebagainya. Oleh sebab itu, akan muncul suatu masalah apabila pengamatan atau pengujian dilakukan pada suatu sistem dinamis yang memiliki sistem pola data dengan formulasi yang selalu berubah-ubah seperti halnya sistem peramalan laju inflasi.

Salah satu metode statistika yang digunakan untuk peramalan adalah analisis regresi. Dalam regresi dikenal dengan dua jenis peubah, yaitu peubah respon (dependen) dan peubah penjelas (independen). Dengan menggunakan regresi, dapat dibuat peramalan nilai suatu peubah respon jika nilai peubah yang lain berhubungan dengannya (peubah penjelas) sudah ditentukan. Selain itu, dengan

analisis regresi juga dapat mempelajari keeratan hubungan antara peubah respon dengan peubah penjelas, dan juga memberikan model terbaik dari data tersebut. Regresi yang melibatkan lebih dari satu peubah penjelas (minimal dua) disebut dengan regresi linier berganda.

Menurut penelitian Wahyuningsih, dkk (2010) mengenai peramalan laju inflasi dengan analisis regresi berganda yang melibatkan peubah penjelas yaitu uang yang beredar, kurs mata uang, tingkat suku bunga, dan indeks harga saham gabungan, menunjukkan bahwa hanya peubah kurs mata uang yang mempunyai hubungan linier yang artinya berpengaruh nyata terhadap laju inflasi. Walaupun hasil tersebut dikatakan cukup baik berdasarkan tuntutan model, yang dapat dilihat dari nilai analisis variannya, baik dari *p-value* maupun dari *durbin-watson*. Namun peubah tersebut belum menunjukkan kemampuan untuk dilakukan peramalan laju inflasi akibat dari kecilnya koefisien korelasi yang disebabkan oleh beberapa peubah lain yang tidak dimasukkan dalam model, tetapi juga bisa disebabkan pilihan model yang kurang tepat. Sehingga disarankan untuk melakukan uji dengan model yang lain sehingga mencapai model regresi terbaik.

Pengujian asumsi klasik adalah hal yang sangat mendasar dan harus dipenuhi dalam melakukan analisis regresi linier berganda sehingga diperoleh hasil peramalan yang lebih akurat dan diperoleh persamaan regresi yang memiliki sifat *Best Linier Unbiased Estimator* (BLUE). Adapun uji asumsi klasik tersebut diantaranya uji normalitas, multikolinieritas, autokorelasi, dan heterokedastisitas. Jika salah satu asumsi tersebut tidak terpenuhi, maka hasil peramalan akan kurang akurat dan persamaan regresi yang diperoleh tidak memiliki sifat BLUE.

Metode Jaringan Syaraf Tiruan (JST) adalah salah satu metode yang mampu menjawab kendala yang ditemui pada analisis regresi. Perkembangan metode ini menjadi sangat pesat dan menarik untuk diteliti karena metode ini mengadopsi langkah kerja dari saraf biologis manusia ke dalam suatu sistem kecerdasan buatan. Pengklasifikasian, pengelompokan, pendekatan suatu nilai fungsi, peramalan, dan lainnya merupakan aplikasi dari metode JST.

Penelitian oleh Kumar, dkk (2008) memperlihatkan salah satu algoritma yang paling penting dalam JST adalah algoritma

Backpropagation, yang menggunakan *error* untuk mengubah nilai bobot - bobot jaringan dalam arah mundur. Pada penelitian tersebut algoritma *Backpropagation* digunakan dalam bidang peramalan.

Penentuan parameter dalam JST akan sangat berpengaruh terhadap hasil ramalan. Pada penelitian Schlitter (2008) yang menggunakan algoritma *Backpropagation* dengan momentum dalam meramalkan data *Dow Jones Average Industrial Index* dan *German Stock Index* menyatakan bahwa penentuan ukuran dari data yang dilatih akan sangat berpengaruh terhadap hasil ramalan. Pengujian asumsi kenormalan pada data dan pemilihan algoritma pelatihan berpengaruh tidak langsung kepada kekonvergenan proses pelatihan sehingga juga berpengaruh terhadap hasil ramalan.

Kelemahan JST adalah tidak adanya ketentuan dalam menentukan *input* dan banyaknya unit *input* dalam lapisan *input*. Hal ini mengakibatkan kesalahan dalam menentukan *input* yang berakibat model jaringan tidak selalu baik. Oleh karena itu, pada penelitian ini *input* yang digunakan pada JST adalah banyaknya peubah penjelas yang diperoleh dari model regresi terbaik. Model ini diharapkan mampu memodelkan laju inflasi dengan baik dan dapat dijadikan dasar sebagai penentuan *input* jaringan yang baik dalam JST.

Permasalahan yang akan diangkat dalam penelitian ini adalah peramalan laju inflasi umum *Month To Month* (M-T-M) yang merupakan peramalan laju inflasi umum bulanan yang melibatkan data laju inflasi dari 7 kelompok barang yang mempengaruhi nilai dari laju inflasi umum tersebut.

Penelitian ini akan membandingkan hasil peramalan laju inflasi umum (M-T-M) model JST berdasarkan *input* model regresi terbaik dengan analisis regresi linier berganda berdasarkan model regresi terbaik dan JST berdasarkan laju inflasi kelompok barang. Keakuratan dan keefektifan ketiga model tersebut akan diuji dengan nilai *Mean Absolute Deviation* (MAD) dan *Mean Squared Error* (MSE) yang dihasilkan.

1.2 Permasalahan

Permasalahan yang akan dikaji dalam penelitian ini adalah sebagai berikut :

- 1) Bagaimana keakuratan analisis regresi linier berganda berdasarkan model regresi terbaik, JST berdasarkan laju inflasi kelompok barang, dan model JST dengan *input* berdasarkan model regresi terbaik dalam melakukan peramalan laju inflasi umum (M-T-M) dilihat dari nilai MAD dan MSE ?
- 2) Bagaimana model laju inflasi umum (M-T-M) dari model JST dengan *input* berdasarkan model regresi terbaik ?

1.3 Batasan Masalah

Batasan masalah pada penelitian ini difokuskan pada permasalahan seperti :

- 1) Algoritma *training* JST *Backpropagation* yang digunakan pada penelitian ini adalah *Gradient Descent*.
- 2) Metode statistika yang digunakan adalah analisis regresi linier berganda dan pemilihan model regresi terbaik.
- 3) Penelitian ini tidak dilakukan uji pencilan (*outlier*).
- 4) Penelitian ini mencari hasil peramalan laju inflasi umum (M-T-M) dengan menggunakan model yang terbaik.
- 5) Data yang digunakan merupakan data laju inflasi bulanan (M-T-M) berdasarkan kelompok barang di Provinsi Bali dari bulan Januari 2007 sampai dengan Desember 2011.
- 6) Data yang digunakan untuk pemodelan ramalan adalah data dari tahun 2007 sampai tahun 2010, sedangkan data tahun 2011 digunakan untuk menguji hasil dari model ramalan.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut :


- 1) Untuk mengetahui keakuratan analisis regresi linier berganda berdasarkan model regresi terbaik, JST berdasarkan laju inflasi kelompok barang, dan model JST dengan *input* berdasarkan model regresi terbaik dalam melakukan peramalan laju inflasi umum (M-T-M) dilihat dari nilai MAD dan MSE.

- 2) Untuk mengetahui model laju inflasi umum (M-T-M) dari model JST dengan *input* berdasarkan model regresi terbaik.

1.5 Manfaat Penelitian

Adapun manfaat yang diharapkan dari penelitian ini adalah sebagai berikut :

- 1) Dapat memberikan pengetahuan dalam memilih metode peramalan yang cocok untuk kasus peramalan laju inflasi umum (M-T-M) berdasarkan laju inflasi kelompok barang.
- 2) Memberikan suatu alternatif cara menentukan *input* JST yaitu dengan berdasarkan model regresi terbaik.
- 3) Sebagai salah satu metode alternatif peramalan data *time series* selain menggunakan metode statistika yang telah banyak digunakan saat ini.
- 4) Dapat bermanfaat bagi pembaca untuk lebih mengetahui dan memahami tentang JST dan regresi linier berganda yang diterapkan untuk peramalan laju inflasi umum (M-T-M) berdasarkan laju inflasi kelompok barang.



UNIVERSITAS BRAWIJAYA



BAB II TINJAUAN PUSTAKA

2.1 Peramalan Laju Inflasi

Peramalan merupakan suatu proses untuk memprediksi kejadian ataupun perubahan di masa yang akan datang. Dalam penerapannya, data *time series* seringkali dapat digunakan dengan mudah untuk meramal karena data *time series* merupakan serangkaian data pengamatan yang disusun menurut waktu, dimana data pengamatan tersebut bersifat acak dan saling berhubungan (Cryer, 1986). Menurut Rokhmawati (2008), dalam suatu proses kegiatan proses peramalan ini merupakan awal dari suatu rangkaian kegiatan dan sebagai titik tolak kegiatan berikutnya. Pemodelan data *time series* seringkali dikaitkan dengan proses peramalan suatu nilai karakteristik tertentu pada periode kedepan, melakukan pengendalian suatu proses ataupun untuk mengenali pola perilaku sistem. Dengan mendeteksi pola dan kecenderungan data *time series*, kemudian memformulasikannya dalam suatu model, maka dapat digunakan untuk memprediksi data yang akan datang. Peramalan bukanlah suatu dugaan, karena dugaan hanya mengestimasi masa mendatang berdasarkan perkiraan saja sedangkan peramalan menggunakan model matematika sebagai bahan pertimbangan (Gross, 1982).

Menurut Gaspersz (2002), pada dasarnya konsep peramalan merupakan kesimpulan dari beberapa kenyataan pada saat melakukan peramalan, antara lain :

- Peramalan hampir tidak akan memberikan hasil yang tepat, hal ini dikarenakan terdapat faktor-faktor yang tidak dapat diprediksi atau dikendalikan yang berakibat pada hasil peramalan.
- Peramalan pada suatu kelompok data secara keseluruhan cenderung lebih akurat dibandingkan dengan peramalan data secara individu.

Inflasi adalah kenaikan harga-harga secara umum dan terus menerus. Data inflasi merupakan data keuangan deret waktu (*financial time series*). Kenaikan pada suatu atau beberapa barang saja dan tidak berdampak pada sebagian besar barang, tidak dapat disebut sebagai inflasi.

Demikian juga halnya jika kenaikan harga-harga barang yang sifatnya sesaat karena perayaan hari keagamaan, seperti pada perayaan hari lebaran, natal, tahun baru, bukanlah merupakan inflasi. Sebaliknya, yaitu penurunan harga-harga secara umum dan terus menerus disebut deflasi. Sedangkan laju inflasi merupakan kenaikan atau penurunan inflasi dari periode ke periode yang terus berjalan sesuai dengan urutan waktu (Setyowati, 2004).

Kestabilan inflasi merupakan prasyarat bagi pertumbuhan ekonomi yang berkesinambungan yang pada akhirnya memberikan manfaat bagi peningkatan kesejahteraan masyarakat. Pentingnya pengendalian inflasi didasarkan pada pertimbangan bahwa inflasi yang tinggi dan tidak stabil memberikan dampak negatif kepada kondisi sosial ekonomi masyarakat. Indikator yang sering digunakan untuk mengukur laju inflasi adalah Indeks Harga Konsumen (IHK). Laju inflasi yang diukur dengan IHK di Indonesia dibagi menjadi 7 kelompok barang (berdasarkan *The Classification of Individual Consumption by Purpose* - COICOP), yaitu:

- 1) Kelompok Bahan Makanan
- 2) Kelompok Makanan Jadi, Minuman, dan Tembakau
- 3) Kelompok Perumahan
- 4) Kelompok Sandang
- 5) Kelompok Kesehatan
- 6) Kelompok Pendidikan dan Olah Raga
- 7) Kelompok Transportasi dan Komunikasi.

Menurut Santoso (2003), rumus yang digunakan untuk menghitung IHK di Indonesia adalah Indeks Laspeyres yang telah dimodifikasi. Adapun rumus Indeks Laspeyres yang telah dimodifikasi adalah sebagai berikut :

$$IHK_{(n)} = \frac{\sum_{i=1}^k \frac{P_{ni}}{P_{(n-1)}} \cdot P_{(n-1)i} \cdot Q_{0i}}{\sum_{i=1}^k P_{0i} \cdot Q_{0i}} \cdot 100 \quad (2.1)$$

Keterangan :

$IHK_{(n)}$: Indeks Harga Konsumen bulan / tahun ke- n

P_{ni} : Harga jenis barang i bulan / tahun ke- n

$P_{(n-1)i}$: Harga jenis barang i bulan / tahun ke- $(n-1)$

- $P_{(n-1)i} \cdot Q_{0i}$: Nilai konsumsi jenis barang i pada bulan tahun ke- $(n-1)$
 $P_{0i} \cdot Q_{0i}$: Nilai konsumsi jenis barang i pada tahun dasar
 k : Banyaknya jenis barang paket komoditas dalam sub kelompok

Untuk memperoleh persentase (%) perubahan indeks atau laju inflasi setiap bulan, secara umum digunakan rumus sebagai berikut :

$$\text{Laju Inflasi}_{(n)} = \frac{IHK_{(n)} - IHK_{(n-1)}}{IHK_{(n-1)}} \cdot 100\% \quad (2.2)$$

2.2 Regresi

Istilah “ regresi “ pertama kali dikemukakan oleh Sir Francis Galton (1822-1911), seorang antropolog dan ahli meteorologi terkenal dari Inggris. Dalam makalahnya yang berjudul “ *Regression Towards Mediocrity in Hereditary Stature* “, yang dimuat dalam *Journal of The Anthropological Institute*, volume 15, hal. 246-263, tahun 1885. Galton menjelaskan bahwa biji keturunan tidak cenderung menyerupai biji induknya dalam hal besarnya, namun lebih mediuoker (lebih mendekati rata-rata) lebih kecil daripada induknya jika induknya besar dan lebih besar daripada induknya jika induknya sangat kecil (Draper dan Smith, 1992).

Dalam analisis regresi, dikenal dua jenis peubah yaitu peubah respon dan peubah penjelas. Peubah respon disebut juga peubah dependen yaitu peubah yang keberadaannya dipengaruhi oleh peubah lainnya dan dinotasikan dengan Y . Peubah penjelas disebut juga peubah independen yaitu peubah yang bebas (tidak dipengaruhi oleh peubah lainnya) dan dinotasikan dengan X (Pujiati, 1997).

Analisis regresi merupakan analisis statistika yang digunakan untuk mengetahui adanya keterkaitan antara satu peubah respon dengan satu atau lebih peubah penjelas dan mempelajari bagaimana membangun sebuah model fungsional dari data untuk dapat menjelaskan atau meramalkan satu fenomena alami atas fenomena yang lain. Jika dalam analisis melibatkan lebih dari satu (minimal dua) peubah penjelas, analisis yang digunakan adalah analisis regresi linier berganda (Draper dan Smith, 1992).

2.3 Regresi Linier Berganda

2.3.1 Pemodelan Regresi Linier Berganda

Hubungan fungsional atau kausal antara dua atau lebih peubah yang dinyatakan dalam suatu bentuk fungsi linier pada umumnya dapat dinyatakan dalam bentuk persamaan matematika. Untuk hubungan fungsional yang linier dapat dirumuskan dalam bentuk persamaan regresi linier berganda sebagai berikut :

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (2.3)$$

Keterangan :

Y : peubah respon

X : peubah penjelas

β_0 : intersep atau titik potong antara sumbu tegak Y dan garis fungsi linier

$\beta_1, \beta_2, \beta_k$: koefisien regresi atau koefisien kemiringan

ε : sisaan

i : pengamatan ke- i

2.3.2 Estimasi Parameter Model Regresi Linier Berganda

Estimasi parameter ini bertujuan untuk mendapatkan model regresi linier berganda yang akan digunakan dalam analisis. Metode kuadrat terkecil (*Ordinary Least Square* = OLS) merupakan suatu metode untuk mendapatkan garis regresi yang baik yaitu sedekat mungkin dengan datanya sehingga nanti menghasilkan hasil peramalan yang baik (Widarjono, 2007).

Dasar dari pendugaan parameter koefisien regresi dalam regresi linier berganda adalah metode OLS yaitu meminimumkan jumlah kuadrat sisaan sedemikian sehingga didapat koefisien-koefisien regresi yang tak bias.

Pendugaan koefisien-koefisien regresi dengan menggunakan metode OLS yaitu dengan meminimumkan jumlah kuadrat sisaan

$\sum_{i=1}^n \varepsilon_i^2$. Misalkan model yang akan diestimasi adalah parameter dari persamaan dengan n pengamatan, maka diperoleh (persamaan 2.4) :

Persamaan hasil pendugaan dari persamaan (2.4) dapat ditulis sebagai berikut :

$$Y = X\hat{\beta} + \varepsilon$$

atau

$$\varepsilon = Y - X\hat{\beta} \quad (2.5)$$

Karena tujuan dari OLS adalah meminimumkan jumlah kuadrat dari sisaan yaitu $\sum_{i=1}^n \varepsilon_i^2$, maka :

$$\begin{aligned} \sum_{i=1}^n \varepsilon_i^2 &= \varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_n^2 \\ &= [\varepsilon_1^2 \quad \varepsilon_2^2 \quad \dots \quad \varepsilon_n^2] \begin{bmatrix} \varepsilon_1^2 \\ \varepsilon_2^2 \\ \dots \\ \varepsilon_n^2 \end{bmatrix} = \varepsilon^T \varepsilon \quad (2.6) \end{aligned}$$

Sehingga dari persamaan (2.6) dapat dijabarkan sebagai berikut,

$$\begin{aligned} \sum_{i=1}^n \varepsilon_i^2 &= \varepsilon^T \varepsilon \\ &= (Y - X\hat{\beta})^T (Y - X\hat{\beta}) \\ &= Y^T Y - \hat{\beta}^T X^T Y - Y^T X \hat{\beta} + \hat{\beta}^T X^T X \hat{\beta} \end{aligned}$$

Oleh karena $\hat{\beta}^T X^T Y$ adalah sebuah matriks (1 x 1) atau sebuah skalar, maka transposenya adalah $(\hat{\beta}^T X^T Y)^T = Y^T X \hat{\beta}$. Dan $\sum_{i=1}^n \varepsilon_i^2$ dapat dinyatakan sebagai,

$$\varepsilon^T \varepsilon = Y^T Y - 2\hat{\beta}^T X^T Y + \hat{\beta}^T X^T X \hat{\beta} \quad (2.7)$$

Untuk menduga parameter $\hat{\beta}$ maka $\varepsilon^T \varepsilon$ harus diminimumkan terhadap $\hat{\beta}^T$, maka :

$$\sum_{i=1}^n \varepsilon_i^2 = Y^T Y - 2\hat{\beta}^T X^T Y + \hat{\beta}^T X^T X \hat{\beta}$$

$$\frac{\partial \sum_{i=1}^n \varepsilon_i^2}{\partial \hat{\beta}^T} = -2\mathbf{X}^T \mathbf{Y} + 2\mathbf{X}^T \mathbf{X} \hat{\beta} = 0$$

Disederhanakan menjadi,

$$\mathbf{X}^T \mathbf{X} \hat{\beta} = \mathbf{X}^T \mathbf{Y} \quad (2.8)$$

Persamaan (2.8) merupakan persamaan normal dari metode OLS.

Untuk menyelesaikan persamaan normal ini, kedua sisi persamaan (2.8) akan dikalikan dengan invers dari $\mathbf{X}^T \mathbf{X}$. Maka penduga OLS dari $\hat{\beta}$ adalah

$$\hat{\beta} = [\mathbf{X}^T \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{Y} \quad (2.9)$$

dengan

$$\mathbf{X}^T = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ X_{11} & X_{12} & X_{13} & \dots & X_{1n} \\ X_{21} & X_{22} & X_{23} & \dots & X_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ X_{k1} & X_{k2} & X_{k3} & \dots & X_{kn} \end{bmatrix}, \mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ \cdot \\ Y_n \end{bmatrix}, \hat{\beta} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \cdot \\ \cdot \\ \hat{\beta}_k \end{bmatrix}$$

Jika $\mathbf{X}^T \mathbf{X}$ tak singular, maka $\mathbf{X}^T \mathbf{X}$ mempunyai invers, sehingga diperoleh persamaan $\hat{\beta} = [\mathbf{X}^T \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{Y}$, jika $\mathbf{X}^T \mathbf{X}$ singular, maka $\mathbf{X}^T \mathbf{X}$ tidak punya invers (Draper dan Smith, 1992).

2.4 Pengujian Asumsi Klasik Regresi Linier Berganda

Menurut Setyadharma (2010), model regresi linier berganda dapat disebut sebagai model yang baik jika model tersebut memenuhi kriteria *Best Linier Unbiased Estimator* (BLUE). BLUE dapat dicapai bila memenuhi asumsi klasik. Nachrowi, dkk (2006) menjelaskan bahwa Gauss Markov telah membuktikan bahwa penduga dalam regresi mempunyai sifat BLUE atau mempunyai sifat yang linier, tidak bias, dan ragam minimum. Jika $\hat{\beta}$ adalah penduga yang baik dari β , maka $\hat{\beta}$ dikatakan penduga yang tak bias. $\hat{\beta}$ dan $\bar{\beta}$ keduanya merupakan penduga tak bias untuk β maka $\hat{\beta}$ dikatakan lebih efisien atau memiliki ragam yang minimum dari $\bar{\beta}$. Jika $\hat{\beta}$ merupakan penduga tak bias untuk β , maka $\hat{\beta}$ dikatakan sebagai penduga yang terbaik dan tak bias jika untuk setiap penduga tak bias untuk β (ragam $\hat{\beta} \leq$ ragam β). Sifat linier jika $\hat{\beta}$ mempunyai hubungan yang linier terhadap nilai dari sampel.

Uji asumsi klasik yang dilakukan terhadap model regresi berganda, diantaranya adalah normalitas, non multikolinieritas, homoskedastisitas, dan non autokorelasi.

2.4.1 Uji Normalitas

Uji normalitas pada model regresi bertujuan untuk menguji apakah data sisaan dari regresi terdistribusi normal atau tidak (Ghozali, 2009). Model regresi yang baik adalah model yang memiliki data sisaan yang terdistribusi normal. Ada dua cara untuk mendeteksi apakah data sisaan berdistribusi normal atau tidak yaitu dengan analisis grafik dan uji statistik.

a. Analisis grafik

Menurut Ghozali (2009), salah satu cara termudah untuk melihat normalitas data sisaan adalah dengan melihat grafik histogram yang membandingkan antara data sisaan dengan distribusi normal. Distribusi normal akan membentuk satu garis lurus diagonal, dan *plotting* data sisaan akan dibandingkan dengan garis diagonal.

Dasar pengambilan keputusan dengan analisis grafik normal *probability plot* adalah:

- 1) Jika titik (data sisaan) menyebar di sekitar garis diagonal dan mengikuti arah garis diagonal, maka model regresi memenuhi asumsi normalitas.
- 2) Jika titik (data sisaan) menyebar jauh dari garis diagonal dan atau tidak mengikuti arah garis diagonal, maka model regresi tidak memenuhi asumsi normalitas.

b. Uji statistik

Uji statistik yang dapat digunakan untuk menguji normalitas data sisaan adalah uji statistik *Kolmogorov-smirnov* (K-S). Prinsip dari uji statistik K-S adalah menghitung selisih absolut antara fungsi distribusi frekuensi kumulatif sampel sisaan $S(\varepsilon_i)$ dan fungsi distribusi frekuensi kumulatif teoritis dari sampel sisaan $F_0(\varepsilon_i)$. Prosedur uji statistik K-S adalah sebagai berikut :

- 1) Menetapkan hipotesis.

H_0 : Data sisaan menyebar normal

H_1 : Data sisaan tidak menyebar normal

- 2) Menentukan tingkat signifikansi (α).

Tingkat signifikansi (α) yang sering digunakan dalam penelitian adalah 5%.

- 3) Menghitung statistik uji.

Statistik uji yang digunakan adalah :

$$K-S = | S(\varepsilon_i) - F_0(\varepsilon_i) | \text{ terbesar} \quad (2.10)$$

- 4) Menentukan daerah kritis (penolakan H_0).

Daerah kritis yang digunakan adalah :

H_0 ditolak jika $K-S > K-S_{(1-\alpha)}$, $K-S_{(1-\alpha)}$ didapatkan dari tabel *Kolmogorov-Smirnov* sesuai dengan banyaknya data residual. Selain dari daerah kritis diatas, menurut Ghazali (2009), dasar pengambilan keputusan uji statistik dengan *Kolmogorov-Smirnov* yaitu jika *p-value* kurang dari tingkat signifikansi (α), maka H_0 ditolak.

- 5) Menarik kesimpulan.

2.4.2 Uji Non Multikolinieritas

Multikolinieritas adalah terjadinya hubungan linier antar peubah penjelas dalam suatu model regresi linier berganda (Gujarati, 2003). Hubungan linier antar peubah penjelas dapat terjadi dalam bentuk hubungan linier yang sempurna (*perfect*) dan hubungan linier yang kurang sempurna (*imperfect*).

Adapun dampak adanya multikolinieritas dalam model regresi linier berganda adalah (Simamora, 2004) :

- 1) Ragam menjadi besar (dari pendugaan OLS).
- 2) Akibat OLS mempunyai ragam yang besar, mengakibatkan standar *error* besar sehingga menyebabkan interval estimasi akan cenderung lebih lebar dan nilai hitung statistik uji *t* akan kecil, sehingga membuat peubah penjelas secara statistik tidak signifikan mempengaruhi peubah respon.
- 3) Walaupun secara individu peubah penjelas tidak berpengaruh terhadap peubah respon melalui uji *t*, tetapi nilai koefisien determinasi (R^2) masih bisa relatif tinggi.

Menurut Ghozali (2009), untuk mendeteksi adanya multikolinieritas dalam model regresi linier berganda dapat dilihat dari nilai *Tolerance* (TOL) dan *Variance Inflation Factor* (VIF).

$$TOL_j = (1 - R_j^2) \quad (2.11)$$

dan

$$VIF_j = \frac{1}{TOL_j} \quad (2.12)$$

Dengan ketentuan jika nilai TOL kurang dari 0.10 dan nilai VIF melebihi 10, maka terjadi multikolinieritas dalam model regresi.

2.4.3 Uji Homoskedastisitas

Homoskedastisitas adalah ragam antara sisaan yang satu dengan sisaan yang lain pada model regresi sama (Gujarati, 2003). Sedangkan kebalikannya disebut heteroskedastisitas.

Dampak adanya heteroskedastisitas dalam model regresi adalah walaupun pendugaan OLS masih linier dan tidak bias, tetapi

tidak lagi mempunyai ragam yang minimum. Selain itu pengujian t maupun F tidak bisa lagi dipercaya karena membesar-besarkan signifikansi statistik dari parameter yang diduga secara konvensional (Gujarati, 2003).

Selanjutnya dilakukan deteksi masalah heteroskedastisitas dalam model regresi. Salah satu cara yang dapat digunakan untuk mendeteksi adanya heteroskedastisitas dalam model regresi adalah dengan Metode Glejser (Gujarati, 2003). Glejser merupakan seorang ahli ekonometrika dan mengatakan bahwa nilai ragam dari sisaan model regresi tergantung dari peubah penjelas, sehingga untuk mengetahui pola peubah sisaan mengandung heteroskedastisitas, Glejser menyarankan untuk melakukan regresi nilai absolut sisaan dengan peubah penjelas.

$$|\varepsilon_i| = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + v_i \quad (2.13)$$

Dimana $i = 1, 2, \dots, n$ dan v_i adalah unsur kesalahan. Jika nilai dari signifikansi antara absolut sisaan dengan peubah penjelas lebih dari 0.05, maka tidak terjadi masalah heteroskedastisitas sehingga asumsi homoskedastisitas terpenuhi.

2.4.4 Uji Non Autokorelasi

Autokorelasi adalah terjadinya korelasi antara satu peubah sisaan dengan peubah sisaan yang lain (Gujarati, 2003).

Adapun dampak dari adanya autokorelasi dalam model regresi adalah sama dengan dampak heteroskedastisitas yang telah diuraikan di atas, yaitu walaupun estimator OLS masih linier dan tidak bias, tetapi tidak lagi mempunyai ragam yang minimum. Selain itu, pada pengujian t dan F yang biasa tidak lagi sah dan jika diterapkan akan memberikan kesimpulan yang salah mengenai arti statistik dari koefisien regresi yang diduga (Gujarati, 2003).

Selanjutnya untuk mendeteksi adanya autokorelasi dalam model regresi linier berganda dapat digunakan metode Durbin-Watson. Durbin-Watson telah berhasil mengembangkan suatu metode yang digunakan untuk mendeteksi adanya masalah autokorelasi dalam model regresi linier berganda menggunakan pengujian hipotesis sebagai berikut :

H_0 : Tidak ada korelasi antar sisaan

H_1 : Ada korelasi antar sisaan

Adapun statistik uji yang digunakan adalah sebagai berikut.

$$d = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2} \quad (2.14)$$

Kemudian Durbin-Watson berhasil menurunkan nilai kritis batas bawah (d_L) dan batas atas (d_U) sehingga jika nilai d hitung dari persamaan (2.14) terletak diluar nilai kritis ini, maka ada atau tidaknya autokorelasi baik positif atau negatif dapat diketahui. Deteksi autokorelasi pada model regresi linier berganda dengan metode Durbin-Watson adalah seperti pada Tabel 2.1 berikut.

Tabel 2.1 Kriteria keputusan uji statistik Durbin-Watson (DW)

| Nilai Statistik DW | Hasil |
|---------------------------|---|
| $0 < d < d_L$ | Menolak H_0 ; ada autokorelasi positif |
| $d_L \leq d \leq d_U$ | Daerah keragu-raguan ; tidak ada keputusan |
| $d_U \leq d \leq 4-d_U$ | Menerima H_0 ; tidak ada autokorelasi positif / negatif |
| $4-d_U \leq d \leq 4-d_L$ | Daerah keragu-raguan ; tidak ada keputusan |
| $4-d_L \leq d \leq 4$ | Menolak H_0 ; ada autokorelasi positif |

Sumber : Widarjono (2007)

Salah satu keuntungan dari uji Durbin-Watson yang didasarkan pada sisaan adalah bahwa setiap program komputer untuk regresi selalu memberi informasi statistik d . Adapun prosedur uji Durbin-Watson adalah (Widarjono, 2007) :

1. Melakukan regresi metode OLS dan kemudian mendapatkan nilai sisaan.
2. Menghitung nilai d dari persamaan (2.14). (kebanyakan program komputer secara otomatis menghitung nilai d).
3. Dengan jumlah observasi (n), kita cari nilai kritis d_L dan d_U pada tabel Durbin-Watson dengan $\alpha = 0.05$.
4. Keputusan ada atau tidaknya autokorelasi dalam model regresi di dasarkan pada Tabel 2.1.

Selain kriteria pengambilan keputusan seperti Tabel 2.1, dapat juga digunakan kriteria lain untuk mendeteksi adanya autokorelasi dalam model regresi linier berganda adalah sebagai berikut (Santoso, 2000) :

1. Jika nilai $d < -2$, maka ada autokorelasi positif
2. Jika $-2 \leq d \leq 2$, maka tidak ada autokorelasi
3. Jika nilai $d > 2$, maka ada autokorelasi negatif.

2.5 Pengujian Hipotesis Model Regresi Linier Berganda

Pengujian hipotesis dilakukan dengan menggunakan model analisis regresi setelah memenuhi asumsi klasik agar hasil pengujian dapat diinterpretasikan dengan tepat. Metode regresi linear berganda yaitu metode yang digunakan untuk menguji pengaruh dua atau lebih peubah penjelas terhadap peubah respon dalam suatu persamaan linier (Indriantoro dan Supomo (2002) dalam Sulastini, 2007).

Menurut Ghozali (2009), ketepatan fungsi regresi tersebut dalam menaksir nilai aktual dapat diukur dari *goodness of fit*-nya, yang secara statistik dapat diukur dari koefisien determinasi, nilai statistik F , dan nilai statistik t .

2.5.1 Koefisien Determinasi

Koefisien determinasi atau R^2 merupakan ikhtisar yang menyatakan seberapa baik garis regresi mencocokkan data (Ghozali, 2009), yang dihitung dengan menggunakan rumus sebagai berikut.

$$R^2 = \frac{JKR}{JKT} \quad (2.15)$$

JKR adalah jumlah kuadrat regresi dan JKT adalah jumlah kuadrat total. Nilai R^2 berkisar antara 0 sampai dengan 1. Nilai yang kecil berarti kemampuan peubah penjelas dalam menjelaskan keragaman peubah respon amat terbatas. Sebaliknya, nilai yang mendekati 1 berarti peubah penjelas memberikan hampir semua informasi yang dibutuhkan untuk memprediksi keragaman peubah respon.

Menurut Anwar (2010), salah satu masalah jika menggunakan ukuran R^2 untuk menilai baik buruknya suatu model adalah mendapatkan nilai R^2 yang terus naik seiring dengan penambahan peubah penjelas ke dalam model sehingga R^2 -adjusted

secara umum memberikan hukuman terhadap penambahan peubah penjelas yang tidak mampu menambah daya prediksi suatu model. Rumus yang digunakan untuk menghitung R^2 -adjusted adalah,

$$R^2\text{-adjusted} = R^2 - \frac{k-1}{n-k} (1-R^2) \quad (2.16)$$

Dengan k adalah banyaknya peubah penjelas dan n adalah banyaknya data yang digunakan. Nilai R^2 -adjusted tidak akan pernah melebihi nilai R^2 bahkan bisa turun jika ditambahkan peubah penjelas yang tidak perlu.

Sehingga, pada penelitian ini peneliti memutuskan untuk menggunakan R^2 -adjusted untuk mengetahui seberapa besar kelompok-kelompok barang yang memberikan semua informasi yang dibutuhkan untuk meramalkan laju inflasi umum.

2.5.2 Uji Signifikansi Pengaruh Simultan (Uji Statistik F)

Uji statistik F menunjukkan apakah peubah penjelas yang dimasukkan dalam model mempunyai pengaruh terhadap peubah respon. Prosedur pengujian secara simultan adalah sebagai berikut :

a) Membuat hipotesis.

$$H_0 : \beta_1, \beta_2, \dots, \beta_k = 0$$

$$H_1 : \beta_1, \beta_2, \dots, \beta_k \neq 0$$

Atau :

H_0 : Peubah X_1, X_2, \dots, X_k secara simultan tidak berpengaruh terhadap peubah respon.

H_1 : Peubah X_1, X_2, \dots, X_k secara simultan berpengaruh terhadap peubah respon.

b) Menentukan tingkat signifikansi (α).

Tingkat signifikansi (α) yang sering digunakan dalam penelitian adalah 5%.

c) Menentukan statistik uji.

Statistik uji yang digunakan adalah :

$$F = \frac{KT_{Regresi}}{KT_{Residual}} \quad (2.17)$$

dengan :

$KT_{Regresi}$ adalah rata-rata kuadrat regresi.

KT_{Sisa} adalah rata-rata kuadrat sisaan.

- d) Membuat tabel analisis ragam regresi

Tabel 2.2 Bagan tabel analisis ragam regresi

| Sumber Keragaman (SK) | Derajat Bebas (db) | Jumlah Kuadrat (JK) | Kuadrat Tengah (KT) | F_{hitung} |
|-----------------------|--------------------|------------------------------------|---------------------------|----------------------------------|
| Regresi | k | $\hat{\beta}^T X^T Y - n\bar{Y}^2$ | $\frac{SS_{Regresi}}{k}$ | $\frac{MS_{Regresi}}{MS_{Sisa}}$ |
| Sisa | $n-k-1$ | $Y^T Y - \beta^T X^T Y$ | $\frac{SS_{Sisa}}{n-k-1}$ | |
| Total | $n-1$ | $Y^T Y - n\bar{Y}^2$ | | |

Keterangan pada Tabel 2.2 :

k : banyaknya peubah penjelas (X)

n : banyaknya data.

- e) Menentukan daerah kritis (penolakan H_0).

Daerah kritis yang digunakan adalah H_0 ditolak jika $F > F_{(\alpha; p-1, n-p)}$. Dengan $F_{(\alpha; p-1, n-p)}$ disebut F tabel. Selain dari daerah kritis di atas, dapat juga digunakan daerah kritis yang lain yaitu jika nilai peluang ($Sig.$) $<$ tingkat signifikansi (α), maka H_0 ditolak.

- f) Menarik Kesimpulan.

2.5.3 Uji Signifikansi Parameter Secara Parsial (Uji Statistik t)

Uji statistik t menunjukkan seberapa jauh pengaruh masing-masing peubah penjelas secara individu terhadap peubah respon. Prosedur pengujian secara simultan adalah sebagai berikut :

- a) Membuat hipotesis.

$$H_0 : \beta_k = 0$$

$$H_1 : \beta_k \neq 0$$

Atau

H_0 : Peubah penjelas ke- k tidak berpengaruh terhadap peubah respon

H_1 : Peubah penjelas ke- k berpengaruh terhadap peubah respon

b) Menentukan tingkat signifikansi (α).

Tingkat signifikansi (α) yang sering digunakan dalam penelitian adalah 5%.

c) Menentukan statistik uji.

Statistik uji yang digunakan adalah :

$$t = \frac{b_k}{s(b_k)} \quad (2.18)$$

dengan :

b_k adalah nilai penduga dari parameter β_k .

$s(b_k)$ adalah standar deviasi nilai penduga dari parameter β_k .

$$s(b_k) = \sqrt{\frac{KT_{Regrasi}}{\sum x_{ik} - \frac{(\sum x_{ik})^2}{n}}} \quad (2.19)$$

d) Menentukan daerah kritis (penolakan H_0).

Daerah kritis yang digunakan adalah :

H_0 ditolak jika $t > t_{\left(\frac{\alpha}{2}; n-p\right)}$ atau dengan $t_{\left(\frac{\alpha}{2}; n-p\right)}$ disebut t tabel.

Selain dari daerah kritis di atas, dapat juga digunakan daerah kritis yang lain yaitu jika nilai peluang ($Sig.$) $<$ tingkat signifikansi (α), maka H_0 ditolak.

e) Menarik kesimpulan.

2.6 Pemilihan Model Regresi Terbaik

Model regresi terbaik adalah model yang dapat menjelaskan perilaku peubah respon dengan sebaik-baiknya dengan memilih peubah-peubah penjelas dari sekian banyak peubah penjelas yang tersedia dalam data. Untuk menentukan peubah penjelas mana yang akan dimasukkan ke dalam model regresi, menurut Draper dan Smith (1992), ada dua kriteria yang saling bertentangan yaitu :

1) Agar persamaannya bermanfaat untuk peramalan, biasanya ingin dimasukkan sebanyak mungkin peubah sehingga diperoleh nilai ramalan yang andal.

- 2) Karena untuk memperoleh informasi dari banyak peubah serta pemantauannya seringkali diperlukan biaya yang tinggi, maka diinginkan persamaan regresi yang mencakup sedikit mungkin peubah. Kompromi diantara kedua kriteria itulah yang disebut pemilihan model regresi terbaik.

Ada beberapa metode untuk pemilihan model regresi terbaik yang selama ini kita kenal, diantaranya *All Possible Regression Evaluation*, *Best Subset Regression*, *Forward Selection*, *Backward Elimination*, dan *Stepwise Regression*.

Pada penelitian ini, peneliti menggunakan metode *Stepwise Regression* merupakan metode yang melibatkan dua jenis proses yaitu *Forward Selection* dan *Backward Elimination*. Menurut Mendenhall dan Reinmuth (1982), metode *Stepwise Regression* relatif memiliki kelebihan karena dengan prosedur seleksi dan eliminasi yang dilakukan pada setiap langkahnya memungkinkan analisis secara detail atas peubah-peubah yang akhirnya dimasukkan ke dalam model prediksi, baik secara individu maupun gabungan dari peubah-peubah tersebut. Wibisono (2002) juga menjelaskan bahwa kelebihan metode *Stepwise Regression* adalah sifat penilaiannya *reversible* terhadap peubah penjelas yang akan masuk persamaan regresi. Jadi pemeriksaan yang dilakukan pada *Stepwise Regression* relatif lebih ketat.

Adapun langkah-langkah yang dilakukan dalam metode *Stepwise Regression* adalah sebagai berikut :

- 1) Hitung nilai korelasi dari masing - masing peubah penjelas terhadap peubah responnya. Rumus korelasi adalah sebagai berikut (persamaan 2.20).

$$r_{X_i,Y} = \frac{\sum X_i Y - \frac{\sum X_i \sum Y}{n}}{\sqrt{\left\{ \sum X_i^2 - \frac{(\sum X_i)^2}{n} \right\} \left\{ \sum Y^2 - \frac{(\sum Y)^2}{n} \right\}}} \quad (2.20)$$

Sebagai peubah pertama yang akan masuk persamaan regresi adalah yang memiliki nilai korelasi terbesar. Kita sebut saja peubah ini sebagai X_A .

- 2) Regresikan Y pada X_A . Simpan X_A dalam model jika seluruh uji F menunjukkan bahwa persamaan regresi secara statistik signifikan.

- 3) Hitung nilai korelasi parsial dari seluruh peubah penjelas yang berada di luar persamaan. Korelasi parsial merupakan uji korelasi antara masing-masing peubah penjelas terhadap peubah responnya, akan tetapi dengan mengeluarkan peubah penjelas lainnya yang mungkin dianggap berpengaruh terhadap peubah respon, dengan kata lain disebut sebagai peubah kontrol. Rumus korelasi parsial dengan 1 peubah kontrol adalah sebagai berikut.

$$r_{X_i Y | X_j} = \frac{r_{X_i Y} - (r_{X_i Y})(r_{X_i X_j})}{\sqrt{(1 - r_{X_i Y}^2)(1 - r_{X_i X_j}^2)}} \quad (2.21)$$

Pilih peubah penjelas yang memiliki korelasi parsial terbesar sebagai peubah penjelas kedua yang masuk persamaan, kita sebut saja X_B .

- 4) Dengan dua peubah penjelas di dalam model, hitung kembali persamaan regresi. Simpan X_B pada persamaan bila nilai F signifikan dibandingkan dengan nilai kritis di bawah distribusi F dengan derajat bebas 1 dan $n-2-1$. Simpan X_A pada persamaan bersama-sama X_B bila nilai F signifikan bila dibandingkan dengan peubah yang telah ditentukan.
- 5) Sekarang pilih peubah penjelas lainnya yang akan masuk persamaan, dengan syarat memiliki nilai koefisien korelasi parsial terbesar diantara peubah penjelas lainnya yang berada di luar persamaan. Kita sebut saja X_C . Rumus korelasi parsial dengan 2 atau lebih peubah kontrol adalah sebagai berikut (persamaan 2.22).

$$r_{X_i Y | X_j, \dots, X_{k-1}} = \frac{r_{X_i Y} - (r_{X_i Y})(r_{X_i X_k | X_j, \dots, X_{k-1}})}{\sqrt{(1 - r_{X_i Y}^2)(1 - r_{X_i X_k | X_j, \dots, X_{k-1}}^2)}} \quad (2.22)$$

- 6) Masukkan X_C ke dalam persamaan yang telah mengandung X_A dan X_B . Putuskan apakah :
- X_C sebaiknya masuk ke dalam persamaan yang mengandung X_A dan X_B
 - X_A masih layak berada dalam persamaan, dimana telah ada X_B dan X_C
 - X_B masih layak berada dalam persamaan dimana X_A dan X_C . Telah berada dalam persamaan tersebut.

- 7) Seluruhnya berdasarkan nilai F . Sebagai contoh jika nilai F jatuh pada peubah X_A dan jika nilai tersebut kurang dari nilai kritis di bawah distribusi F dengan derajat bebas 1 dan $n-3-1$, maka keluarkan X_i dari persamaan. Lalu hitung kembali persamaan regresi dan uji nilai F parsial dari kedua peubah lainnya (X_B dan X_C). Prosedur *Stepwise Regression* berlanjut hingga tidak ada lagi peubah penjelas yang akan masuk atau keluar persamaan regresi. (Wibisono, 2002).

2.7 Jaringan Syaraf Tiruan (JST)

2.7.1 Sejarah Jaringan Syaraf Tiruan (JST)

JST sederhana pertama kali diperkenalkan oleh McCulloch dan Pitts di tahun 1943. McCulloch dan Pitts menyimpulkan bahwa kombinasi beberapa unit sederhana menjadi sebuah sistem syaraf akan meningkatkan kemampuan komputasinya. Bobot dalam jaringan yang diusulkan oleh McCulloch dan Pitts diatur untuk melakukan fungsi logika sederhana. Fungsi aktivasi yang dipakai adalah fungsi *threshold*. Metode *training* diperkenalkan untuk mengoptimalkan hasil iterasinya.

Widrow dan Hoff (1960) mengembangkan *perceptron* dengan memperkenalkan aturan pelatihan jaringan, yang dikenal sebagai aturan delta (sering disebut kuadrat rata-rata terkecil). Aturan ini akan mengubah bobot *perceptron* apabila keluaran yang dihasilkan tidak sesuai dengan target yang diinginkan. Apa yang dilakukan oleh Widrow dan Hoff hanya menggunakan jaringan dengan lapisan tunggal. Sehingga, Rumelhart (1986) mengembangkan *perceptron* menjadi *Backpropagation*, yang memungkinkan jaringan diproses melalui beberapa lapisan.

JST ditentukan oleh tiga hal :

- a. Pola hubungan antar neuron (disebut arsitektur jaringan).
- b. Metode untuk menentukan bobot penghubung (disebut metode pembelajaran/*training*).
- c. Fungsi aktivasi.

(Darmawan, 2009).

2.7.2 Definisi Jaringan Syaraf Tiruan (JST)

JST adalah suatu struktur yang memproses informasi yang terdistribusi dan bekerja secara paralel, terdiri atas elemen yang melakukan proses (memiliki memori lokal dan beroperasi dengan informasi lokal) yang diinterkoneksi bersama dengan alur sinyal searah yang disebut koneksi. Setiap elemen yang melakukan proses tersebut memiliki *output* tunggal yang bercabang ke sejumlah kolateral yang diinginkan. Seluruh proses yang berlangsung pada setiap elemen tempat proses itu terjadi harus benar-benar dilakukan secara lokal, yaitu *output* hanya bergantung pada nilai *input* (Hecht, 1988).

Wardani (2006), mendefinisikan JST sebagai suatu model matematika yang berupa sistem pengolahan informasi yang mengadopsi kinerja jaringan saraf biologis. JST dapat dipertimbangkan sebagai teknik pengolahan data yang mampu memetakan informasi arus *input* berupa *time series* dan *output* berupa hasil peramalan.

JST terdiri dari atas sel-sel yang disebut unit. Jaringan tersebut terdiri sebuah lapisan *input*, sebuah lapisan *ouput*, dan kemungkinan satu atau lebih lapisan tersembunyi. Setiap lapisan terdiri dari beberapa unit dan terhubung dengan unit lain pada lapisan terdekat.


Meskipun banyak model JST sama atau identik dengan model statistika, terminologi dalam literatur JST berbeda dengan literatur yang ada dalam statistika. Berikut ini disajikan istilah – istilah statistika yang ada dalam JST.

- Peubah penjelas disebut nilai *input*
- Nilai prediksi disebut nilai *output*
- Peubah respon disebut target
- Sisaan disebut *error*
- Perkiraan disebut pelatihan (*training*)

2.7.3 Struktur Jaringan Saraf Biologis

Menurut Kusumadewi (2003), otak manusia terdiri dari berjuta - juta sel saraf yang bertugas memproses informasi. Tiap-tiap sel bekerja seperti suatu proses sederhana.

Masing-masing sel saling berinteraksi sehingga mendukung kemampuan otak manusia, seperti terlihat pada Gambar 2.1.



Gambar 2.1 Susunan saraf manusia (Kusumadewi, 2003)


Menurut Yani (2005), otak terdiri dari sekitar sepuluh milyar sel saraf yang saling berhubungan. Sel saraf mempunyai cabang struktur sebagai *input* (*dendrites*), sebuah inti sel dan percabangan struktur sebagai *output* (*axon*). *Axon* dari sebuah sel terhubung dengan *dendrites* yang lain melalui sebuah *synapse*. Signal ini melewati *synapses* menuju ke sel saraf yang lain. Sebuah sel saraf lain akan mendapatkan signal jika memenuhi batasan tertentu yang disebut dengan nilai ambang.

2.7.4 Pemodelan Jaringan Syaraf Tiruan (JST)

Secara umum proses pemodelan JST terbagi menjadi dua bagian yaitu proses *training* dan *testing*. Proses *training* merupakan proses pembelajaran dari sistem jaringan saraf yang mengatur nilai *input* serta bagaimana pemetaanya pada *output* sampai diperoleh model yang sesuai. Proses *training* terjadi pada saat pengaturan bobot dan bias. Sedangkan proses pengujian adalah proses menguji ketelitian dari model yang sudah diperoleh dari proses *training*. Yao

dan Tan (2001) menyarankan pembagian data menjadi data *training* dan *testing* masing-masing adalah 80%, dan 20% atau pembagian tersebut didasarkan pada pengalaman peneliti.

Saraf tiruan dalam struktur JST adalah sebagai bagian pemrosesan seperti pada Gambar 2.2 yang dapat berfungsi seperti halnya saraf. Sejumlah signal *input* a dikalikan dengan masing-masing bobot yang bersesuaian w . Kemudian dilakukan penjumlahan dari seluruh hasil perkalian tersebut dan *output* yang dihasilkan diteruskan kedalam fungsi aktivasi untuk mendapatkan tingkat derajat signal keluaran $F(a,w)$. Walaupun masih jauh dari sempurna, namun kinerja dari saraf tiruan ini identik dengan kinerja dari sel biologis yang kita kenal saat ini.



Gambar 2.2 Model tiruan sebuah JST (Kusumadewi, 2003)

Keterangan :

- a_j : Nilai aktivasi dari unit j
- a_i : Nilai aktivasi dari unit i
- $w_{j,i}$: Bobot dari unit j ke i
- in_i : Penjumlahan bobot dan nilai masukan ke unit i
- g : Fungsi aktivasi

Menurut Suhartono (2007), secara umum model ini bekerja dengan menerima suatu vektor dari nilai *input* x dan kemudian menghitung suatu respon atau *output* $\hat{y}(x)$ dengan memproses nilai x melalui elemen-elemen proses yang saling terkait. Elemen - elemen proses tersusun dalam beberapa lapisan dan data *input* x , mengalir dari satu lapisan ke lapisan berikutnya secara berurutan.

Dalam tiap lapisan, nilai *input* ditransformasi ke dalam lapisan secara nonlinear oleh elemen - elemen proses dan kemudian

diproses maju ke lapisan berikutnya. Akhirnya, nilai - nilai *output* \hat{y} , yang dapat berupa nilai-nilai skalar atau vektor, dihitung pada lapisan *output* dengan persamaan sebagai berikut :

$$\hat{y}_{(k)} = f^o \left[\sum_{j=1}^q v_j^o f_j^h \left(\sum_{i=1}^p w_{j,i}^h x_{i(k)} + b_j^h \right) + b^o \right] \quad (2.23)$$

Keterangan :

$x_{i(k)}$: Peubah *input* ke- i , ($i=1,2,\dots, p$) dimana p merupakan jumlah *input*

$\hat{y}_{(k)}$: Nilai dugaan dari peubah *output*

k : Indeks pasangan data *input*-target ($x_{i(k)}$, $\hat{y}_{(k)}$) , $k=1,2,\dots, n$, dimana n merupakan jumlah pola

$w_{j,i}^h$: Bobot dari *input* ke- i yang menuju neuron ke- j pada lapisan tersembunyi, ($j=1,2,\dots,q$)

b_j^h : Bias pada neuron ke- j pada lapisan tersembunyi, ($j=1,2,\dots,q$) dimana q merupakan jumlah node pada lapisan tersembunyi.

f_j^h : Fungsi aktivasi di neuron ke- j pada lapisan tersembunyi

v_j^o : Bobot dari neuron ke- j di lapisan tersembunyi yang menuju neuron pada lapisan *output*

b^o : Bias pada neuron di lapisan *output*

f^o : Fungsi aktivasi pada neuron di lapisan *output*.


2.7.5 Arsitektur Jaringan Syaraf Tiruan (JST)

JST biasanya mempunyai 3 lapisan yaitu : lapisan *input* yang terhubung dengan lapisan tersembunyi yang selanjutnya terhubung dengan lapisan *output*.

1. Aktivitas unit-unit lapisan *input* menunjukkan informasi dasar yang kemudian digunakan dalam JST.
2. Aktivitas setiap unit-unit lapisan tersembunyi ditentukan oleh aktivitas dari *input* dan bobot dari koneksi antara unit-unit *input* dan unit-unit lapisan tersembunyi.

3. Karakteristik dari unit-unit *output* tergantung dari aktivitas unit-unit lapisan tersembunyi dan bobot antara unit-unit lapisan tersembunyi dan unit-unit *output*.

Jaringan dengan banyak lapisan memiliki satu atau lebih lapisan yang terletak diantara lapisan *input* dan lapisan *output*, seperti terlihat pada Gambar 2.3. Umumnya, ada lapisan bobot-bobot yang terletak antara dua lapisan yang bersebelahan. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit dibandingkan dengan lapisan tunggal, tentu saja dengan pembelajaran yang lebih rumit. Namun demikian, pada banyak kasus, pembelajaran pada jaringan dengan banyak lapisan ini lebih sukses dalam menyelesaikan masalah (Suryono,1999).



Gambar 2.3 Jaringan syaraf dengan banyak lapisan (Suryono, 1999)

Yao dan Tan (2001) menyatakan bahwa pada pemilihan arsitektur jaringan, semakin kompleks tipe jaringan yang digunakan dan semakin banyak lapisan tersembunyi dan unit tersembunyi yang digunakan tidak menjamin peramalan yang dihasilkan selalu lebih baik. Oleh karena itu, tipe jaringan yang digunakan adalah tipe yang sesederhana mungkin namun dengan hasil yang seefisien mungkin.

2.7.6 Proses Pembelajaran Jaringan Syaraf Tiruan (JST)

Proses pembelajaran JST harus mengetahui secara pasti hubungan antara *input* dan *output* dan jika hubungan tersebut telah diketahui maka dapat dibuat suatu model. Hal lain yang penting adalah proses belajar hubungan antara nilai *input* dan *output* yang dilakukan dengan paradigma belajarnya yang dikenal sebagai algoritma belajar dalam JST. Berdasarkan strategi *training*, paradigma belajar JST dapat diklasifikasikan menjadi dua paradigma yaitu:

1) Pembelajaran Terawasi (*Supervised Learning*)

Pada metode pembelajaran terawasi, metode ini digunakan jika *output* yang diharapkan telah diketahui sebelumnya. Biasanya pembelajaran dilakukan dengan menggunakan data yang telah ada.

2) Pembelajaran Tak Terawasi (*Unsupervised Learning*)

Pada metode pembelajaran tak terawasi ini tidak memerlukan target *output*. Pada metode ini, tidak dapat ditentukan hasil seperti apakah yang diharapkan selama proses pembelajaran. Selama proses pembelajaran, nilai bobot disusun dalam suatu jarak tertentu tergantung pada nilai masukan yang diberikan. Tujuan pembelajaran ini adalah mengelompokkan unit-unit yang hampir sama dalam suatu area tertentu (*clustering*). Pembelajaran seperti ini biasanya sangat cocok untuk klasifikasi (penentuan pola).

2.7.7 Fungsi Aktivasi Jaringan Syaraf Tiruan (JST)

Karakter dari JST tergantung atas bobot dan fungsi dari nilai *input* dan *output* yang mempunyai ciri tertentu untuk setiap unit. Fungsi ini terdiri dari 3 kategori yaitu :

- 1) Untuk *linear units*, aktivitas *output* adalah sebanding dengan jumlah bobot *output*
- 2) Untuk *threshold units*, nilai *output* diatur satu dari dua tingkatan tergantung dari apakah jumlah *input* lebih besar atau lebih kecil dari nilai ambang.
- 3) Untuk *sigmoid units*, nilai *output* terus menerus berubah-ubah tetapi tidak berbentuk linier.

Unit ini mengandung kesamaan yang lebih besar dari sel saraf sebenarnya dibandingkan dengan linier dan threshold unit, namun ketiganya harus dipertimbangkan dengan perkiraan kasar.

Galang (2010) menjelaskan sebelum dilakukan *training*, data *input* dan target *output* dari data perlu dilakukan normalisasi terlebih dahulu. Hal ini dilakukan agar nilai *input* dan target *output* sesuai dengan jarak dari fungsi aktivasi yang digunakan dalam JST, sehingga nilai *input* dan target *output* dapat masuk ke dalam selang fungsi aktivasi. Data *input* dan target *output* dinormalisasi dengan cara membawa data tersebut ke dalam bentuk normal yang memiliki rata-rata = 0 dan simpangan baku = 1. Normalisasi dilakukan untuk mentransformasi data aktual menjadi data normalisasi dengan batasan 0,1 sampai 0,9 sehingga dapat digunakan untuk pemodelan JST. Rumusan yang digunakan adalah :

$$x' = \frac{(x - x_{\min})(b - a)}{x_{\max} - x_{\min}} + a \quad (2.24)$$

Keterangan :

x' : nilai data normalisasi

x : data aktual

x_{\min} : nilai minimum data aktual keseluruhan

x_{\max} : nilai maksimum data aktual keseluruhan

a : batas bawah normalisasi (0,1)

b : batas atas normalisasi (0,9)

2.8 Jaringan Syaraf Tiruan (JST) *Backpropagation*

2.8.1 JST *Backpropagation*


Kelemahan JST yang terdiri dari lapisan tunggal membuat perkembangan JST menjadi terhenti pada sekitar tahun 1970 an. Penemuan JST *Backpropagation* yang terdiri dari beberapa lapisan membuka kembali cakrawala. Terlebih setelah berhasil ditemukannya berbagai aplikasi yang dapat diselesaikan dengan JST *Backpropagation*, membuat JST semakin diminati orang. JST lapisan tunggal memiliki kelemahan dalam pengenalan pola. Kelemahan ini bisa ditanggulangi dengan menambahkan satu atau beberapa lapisan tersembunyi diantara

lapisan *input* dan *output*. Meskipun penggunaan lebih dari satu lapisan tersembunyi memiliki kelebihan manfaat untuk beberapa kasus, tetapi pada proses *training* memerlukan waktu yang lama.

Seperti halnya model JST lain, *JST Backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola *input* yang serupa (tetapi tidak sama) dengan pola yang dipakai selama *training*.

2.8.2 Arsitektur Jaringan *Backpropagation*

Arsitektur jaringan *Backpropagation* memiliki beberapa unit yang ada dalam satu atau lebih lapisan. Gambar 2.4 adalah arsitektur jaringan *Backpropagation* dengan 3 unit *input* (ditambah sebuah bias), 2 unit pada lapisan tersembunyi (ditambah sebuah bias) dan 1 unit pada lapisan *output*.



Gambar 2.4 Arsitektur jaringan *backpropagation* (Kusumadewi, 2003)

v_{ji} ($v_{11}, v_{12}, \dots, v_{32}$) merupakan bobot garis dari unit *input* x_i (x_1, x_2 , dan x_3) ke unit lapisan tersembunyi z_j (z_1 dan z_2). w_1 dan w_2 merupakan bobot dari unit lapisan tersembunyi z_j ke unit *output* y . b_{11} dan b_{12} merupakan bobot bias yang menuju ke unit pertama dan kedua pada lapisan tersembunyi, sedangkan b_2 merupakan bobot bias yang menghubungkan lapisan tersembunyi dengan lapisan *output*.


2.8.3 Fungsi Aktivasi JST *Backpropagation*

Dalam JST *Backpropagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu : kontinu, terdifferensial dengan mudah dan merupakan fungsi yang tidak turun. Salah satu fungsi yang memenuhi ketiga syarat tersebut sehingga sering dipakai adalah fungsi sigmoid bipolar yang memiliki range (-1,1).

$$f(x) = \frac{2}{1 + e^{-x}} - 1 \tag{2.25}$$

dengan turunan $f'(x) = \frac{(1 + f(x))(1 - f(x))}{2}$ (2.26)

Grafik fungsinya seperti pada Gambar 2.5.




Gambar 2.5 Grafik fungsi sigmod range (-1,1) (Galang, 2010)

2.8.4 Algoritma *Training JST Backpropagation*

Algoritma *training JST Backpropagation* meliputi 3 fase. Fase pertama adalah fase maju. Pola *input* dihitung maju mulai dari lapisan *input* hingga lapisan *output* menggunakan fungsi aktivasi yang ditentukan. Fase kedua adalah fase mundur. Selisih antara nilai *output* jaringan dengan target yang diinginkan merupakan *error* yang terjadi. *Error* tersebut dipropagasikan mundur, dimulai dari garis

yang berhubungan langsung dengan unit - unit di lapisan *output*. Fase ketiga adalah modifikasi bobot untuk menurunkan *error* yang terjadi.

Ketiga fase tersebut diulang - ulang terus hingga kondisi penghentian dipenuhi. Umumnya kondisi penghentian yang dipakai adalah jumlah iterasi atau toleransi kesalahan. Iterasi akan dihentikan jika jumlah iterasi yang dilakukan sudah melebihi jumlah maksimum yang ditetapkan, atau jika kesalahan yang terjadi sudah lebih kecil dari batas toleransi yang diijinkan.



Gambar 2.6 Alur kerja *Backpropagation* (Hendra, 2010)

a. Fase I : Propagasi Maju

Selama propagasi maju, nilai *input* (x_i) dipropagasikan ke lapisan tersembunyi menggunakan fungsi aktivasi yang ditentukan. Nilai *output* dari setiap unit lapisan tersembunyi (z_j)

tersebut selanjutnya dipropagasikan maju lagi ke lapisan tersembunyi di atasnya menggunakan fungsi aktivasi yang ditentukan. Demikian seterusnya hingga menghasilkan nilai *output* pada jaringan (y_k). Berikutnya, nilai *output* dari jaringan (y_k) dibandingkan dengan target yang harus dicapai (t_k). Selisih $t_k - y_k$ adalah *error* yang terjadi. Jika kesalahan ini lebih kecil dari batas toleransi yang ditentukan, maka iterasi dihentikan. Akan tetapi apabila kesalahan masih lebih besar dari batas toleransinya, maka bobot setiap garis dalam jaringan akan dimodifikasi untuk mengurangi kesalahan yang terjadi.

b. Fase II : Propagasi Mundur

Berdasarkan kesalahan $t_k - y_k$, dihitung faktor δ_k ($k = 1, 2, \dots, m$) yang dipakai untuk mendistribusikan kesalahan di unit y_k ke semua unit tersembunyi yang terhubung langsung dengan y_k . δ_k juga dipakai untuk mengubah bobot garis yang berhubungan langsung dengan unit *output*.

Dengan cara yang sama, dihitung faktor δ_j di setiap unit di lapisan tersembunyi sebagai dasar perubahan bobot semua garis yang berasal dari unit tersembunyi di lapisan di bawahnya. Demikian seterusnya hingga semua faktor δ di unit tersembunyi yang berhubungan langsung dengan unit *input* dihitung.

c. Fase III : Perubahan Bobot

Setelah semua faktor δ dihitung, bobot semua garis dimodifikasi bersamaan. Perubahan bobot suatu garis didasarkan atas faktor δ neuron di lapisan atasnya. Sebagai contoh, perubahan bobot garis yang menuju ke lapisan *output* didasarkan atas δ_k yang ada di unit *output*.

2.8.5 Algoritma *Training Gradient Descent*

Masalah utama yang dihadapi dalam *JST Backpropagation* adalah lamanya iterasi yang harus dilakukan. *JST Backpropagation* tidak dapat memberikan kepastian tentang berapa *epoch* yang harus dilalui untuk mencapai kondisi yang diinginkan. Oleh karena itu, orang berusaha meneliti bagaimana parameter - parameter jaringan dibuat sehingga menghasilkan jumlah iterasi yang minimum.

Algoritma *training* yang paling sering digunakan untuk jaringan *feedforward* adalah menggunakan gradien dari fungsi kinerja untuk menentukan bagaimana mengatur bobot-bobot dalam rangka meminimumkan iterasi. Prinsip dasar dari algoritma *Gradient Descent* adalah memperbaiki bobot-bobot jaringan dengan arah yang membuat fungsi iterasi menjadi turun dengan cepat atau membuat *error* jaringan minimal. *Error* jaringan dapat dirumuskan sebagai teknik optimasi sebagai berikut.

$$\frac{1}{2} \sum_{s=1}^m (y_{ds} - y_s)^2 \quad (2.27)$$

di mana

$$y_s = f_s^o \left(\sum_{j=1}^l w_{sj}^o f_j^h \left(\sum_{i=1}^n w_{ji}^h x_i \right) \right) \quad (2.28)$$

y_s : *output* jaringan

y_{ds} : target yang ditentukan

w_{ji}^h : bobot pada *input* ke lapisan tersembunyi

f_j^h : fungsi aktivasi dari lapisan *input* ke lapisan tersembunyi

w_{sj}^o : bobot dari lapisan tersembunyi ke lapisan *output*

f_s^o : fungsi aktivasi dari lapisan tersembunyi ke lapisan *output*

Penyelesaian masalah optimasi *error* jaringan dalam *Backpropagation* dilakukan dengan menghitung turunan parsial dari *error* jaringan terhadap bobot (w). Perhitungan ini terjadi apabila jaringan telah menghasilkan *output* yang mengandung *error* atau pada saat jaringan melakukan fase propagasi mundur. (Persamaan 2.29)

$$\begin{aligned} E(w) &= \frac{1}{2} \sum_{s=1}^m (y_{ds} - y_s)^2 \\ &= \frac{1}{2} \sum_{s=1}^m \left(y_{ds} - f_s^o \left(\sum_{j=1}^l w_{sj}^o f_j^h \left(\sum_{i=1}^n w_{ji}^h x_i \right) \right) \right)^2 \end{aligned}$$

Langkah pertama yang dilakukan untuk mendapatkan *error* yang optimal adalah menurunkan fungsi *error* jaringan terhadap bobot dari lapisan *output* ke lapisan tersembunyi (w_{sj}^0), yang dinotasikan

$$E(w) = \frac{1}{2} \sum_{p=1}^m \left(y_{dp} - f_p^o \left(\sum_{q=1}^l w_{pq}^o z_q \right) \right)^2 \quad (2.30)$$

Di mana untuk setiap $q = 1, \dots, l$,

$$z_q = f_q^h \left(\sum_{i=1}^n w_{qi}^h x_{di} \right) \quad (2.31)$$

Dengan menggunakan aturan rantai, didapatkan

$$\frac{\partial E}{\partial w_{sj}^o}(w) = -(y_{ds} - y_s) f_s^o \left(\sum_{q=1}^l w_{sq}^o z_q \right) z_j \quad (2.32)$$

Untuk meringkasnya dapat dinotasikan

$$\delta_s = (y_{ds} - y_s) f_s^o \left(\sum_{q=1}^l w_{sq}^o z_q \right) \quad (2.33)$$

Sehingga

$$\frac{\partial E}{\partial w_{sj}^o}(w) = -\delta_s z_j \quad (2.34)$$

Kedua, menurunkan fungsi *error* jaringan terhadap bobot dari lapisan tersembunyi ke lapisan *input* (w_{ji}^h), yang dinotasikan,

$$E(w) = \frac{1}{2} \sum_{p=1}^m \left(y_{dp} - f_p^o \left(\sum_{q=1}^l w_{pq}^o f_q^h \left(\sum_{i=1}^n w_{qi}^h x_{di} \right) \right) \right)^2 \quad (2.35)$$

Dengan menggunakan aturan rantai, didapatkan

$$\begin{aligned} \frac{\partial E}{\partial w_{ji}^h}(w) &= - \sum_{p=1}^m (y_{dp} - y_p) f_p^o \left(\sum_{q=1}^l w_{pq}^o z_q \right) w_{pq}^o f_j^h \left(\sum_{r=1}^n w_{jr}^h x_{dr} \right) x_{di} \\ \frac{\partial E}{\partial w_{ji}^h}(w) &= - \left(\sum_{p=1}^m \delta_p w_{pj}^o \right) f_j^{h'}(v_i) x_{di} \end{aligned} \quad (2.36)$$

Dari hasil turunan *error* jaringan terhadap bobot didapatkan algoritma *Gradient Descent* untuk memperbaiki bobot dari JST.

$$w_{sj}^{o(k+1)} = w_{sj}^{o(k)} + \eta \delta_s^{(k)} z_j^{(k)} \quad (2.37)$$

$$w_{ji}^{h(k+1)} = w_{ji}^{h(k)} + \eta \left(\sum_{p=1}^m \delta_p^{(k)} w_{pj}^{o(k)} \right) f_j^h \left(v_j^{(k)} \right) x_{di} \quad (2.38)$$

Di mana η adalah *learning rate* dan,

$$v_j^{(k)} = \sum_{i=1}^n w_{ji}^{h(k)} x_{di} \quad (2.39)$$

$$z_j^{(k)} = f_j^h \left(v_j^{(k)} \right) \quad (2.40)$$

$$y_s^{(k)} = f_s^o \left(\sum_{q=1}^l w_{sq}^{o(k)} z_q^{(k)} \right) \quad (2.41)$$

$$\delta_s^{(k)} = \left(y_{ds} - y_s^{(k)} \right) f_s^{o'} \left(\sum_{q=1}^l w_{sq}^{o(k)} z_q^{(k)} \right) \quad (2.42)$$

Notasi yang digunakan dalam algoritma *training Gradient*

Descent yaitu :

\mathbf{x} : Vektor *input training*

\mathbf{x} : $(x_1, \dots, x_i, \dots, x_n)$

\mathbf{t} : Vektor target

\mathbf{t} : $(t_1, \dots, t_k, \dots, t_m)$

δ_k : Besarnya korelasi *error* dalam penyelesaian bobot untuk w_{jk} karena *error* pada unit y_k ; juga merupakan informasi pada y_k yang di propagasi mundur ke lapisan tersembunyi unit z_j

δ_j : Besarnya korelasi dalam penyelesaian bobot untuk v_{ji} karena propagasi mundur informasi *error* dari lapisan *output* ke tersembunyi unit z_j

η : *Learning rate*

x_i : Unit *input* ke- i

v_{0j} : Bias pada lapisan tersembunyi unit ke- j

z_j : Lapisan tersembunyi unit ke- j

Total *input* untuk z_j ditulis sebagai z_in_j di mana

$$z_in_j = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (2.43)$$

Dan signal *output* (aktivasi) untuk z_j , di mana

$$z_j = f(z_in_j) \quad (2.44)$$

w_{ok} = Bias pada unit *output* ke- k

y_k = Unit *output* ke- k

Total *input* untuk y_k ditulis sebagai y_in_k , di mana

$$y_in_k = w_{ok} + \sum_{j=1}^n z_j w_{jk} \quad (2.45)$$

Dan signal *output* (aktivasi) untuk y_k

$$y_k = f(y_in_k) \quad (2.46)$$

dengan menggunakan satu lapisan tersembunyi (dengan fungsi aktivasi sigmoid bipolar), algoritma *training Backpropagation* adalah sebagai berikut :

Langkah 0 :

Inisialisasi bobot (dengan random yang cukup kecil), *set learning rate* $0 < \alpha < 1$

Langkah 1 :

Jika kondisi berhenti belum terpenuhi, lakukan langkah 2 – 9

Langkah 2 :

Untuk setiap pasang data *training*, lakukan langkah 3 – 8

(Fase I)

Langkah 3 :

Untuk unit *input* x_i , $i = 1, \dots, n$ menerima signal x_i dan menghantarkan sinyal ini ke semua unit lapisan di atasnya (unit tersembunyi),

Langkah 4 :

Untuk setiap unit tersembunyi (z_j , $j = 1, \dots, p$), jumlahkan bobot sinyal *input*,

$$z_{-in_j} = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (2.47)$$

v_{oj} = bias pada unit tersembunyi j aplikasikan aktivasinya untuk menghitung sinyal *output*,

$$z_j = f(z_{-in_j}), \text{ fungsi aktivasinya : } f(x) = \frac{2}{1 + e^{-x}} - 1$$

Dan kirimkan sinyal ini ke seluruh unit pada lapisan di atasnya (unit *output*).

Langkah 5 :

Untuk setiap unit *output* ($y_k, k = 1, \dots, m$), jumlahkan bobot sinyal *input*,

$$y_{-in_k} = w_{ok} + \sum_{j=1}^n z_j w_{jk} \quad (2.48)$$

w_{ok} = bias pada unit *output* k dan aplikasikan fungsi aktivasinya untuk menghitung sinyal *output*,

$$y_k = f(y_{-in_k}) \quad (2.49)$$

(Fase II)

Langkah 6 :

Untuk setiap unit *output* ($y_k, k = 1, \dots, m$) menerima pola target yang berhubungan dengan pola *training* dan dihitung informasi kesalahannya,

$$\delta_k = (t_k - y_k) f'(y_{-in_k}) \quad (2.50)$$

Kemudian dihitung koreksi nilai bobot yang kemudian akan digunakan untuk memperbaharui nilai w_{jk} :

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (2.51)$$

Hitung koreksi nilai bias yang kemudian akan digunakan untuk memperbaharui nilai w_{ok} :

$$\Delta w_{ok} = \alpha \delta_k \quad (2.52)$$

Dan kemudian nilai δ_k dikirim ke unit-unit lapisan dibawahnya.

Langkah 7 :

Untuk setiap lapisan tersembunyi ($z_j, j = 1, \dots, p$) jumlahkan hasil perubahan pada *input* (dari unit-unit lapisan di atasnya),

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (2.53)$$

Kemudian nilai tersebut dikalikan dengan nilai turunan dari fungsi aktivasi untuk menghitung informasi kesalahannya,

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (2.54)$$

Hitung koreksi bobot yang kemudian digunakan untuk memperbaharui v_{ij}

$$\Delta v_{ij} = \alpha \delta_j z_j \quad (2.55)$$

(Fase III)

Langkah 8 :

Tiap unit *output* ($y_k, k = 1, \dots, m$) diperbarui nilai bias dan bobotnya ($j = 0, \dots, p$) :

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.56)$$

Tiap unit lapisan tersembunyi ($z_j, j = 1, \dots, p$) diperbarui nilai bias dan bobotnya ($i = 0, \dots, n$) :

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (2.57)$$

Langkah 9 :

Menguji apakah kondisi berhenti sudah terpenuhi. Kondisi berhenti ini terpenuhi jika kesalahan yang dihasilkan mendekati atau bernilai 0.

2.9 Model Jaringan Syaraf Tiruan *Backpropagation* dengan *Input* Berdasarkan Model Regresi Terbaik

2.9.1 Konsep Dasar Pembentukan Model Jaringan Syaraf Tiruan *Backpropagation* dengan *Input* Berdasarkan Model Regresi Terbaik

Model jaringan syaraf tiruan *Backpropagation* dengan *input* berdasarkan model regresi terbaik digunakan untuk peramalan laju inflasi umum *month to month* berdasarkan laju inflasi kelompok

barang. Secara umum, laju inflasi umum di Indonesia dipengaruhi oleh laju inflasi dari 7 kelompok barang yang merupakan bagian dari IHK. Tetapi pada penelitian ini, data yang digunakan adalah data laju inflasi umum provinsi, dimana peneliti menduga dari 7 kelompok barang tersebut ada yang tidak berpengaruh signifikan terhadap laju inflasi umum di setiap provinsi yang ada di Indonesia, khususnya di Provinsi Bali. Untuk mengetahui hal tersebut, maka peneliti menggunakan analisis regresi linier berganda dengan pemilihan model regresi terbaik.

Analisis regresi linier berganda digunakan untuk mengetahui hubungan fungsional atau kausal antara peubah respon (Y) dengan satu atau lebih peubah penjelas (X) yang dinyatakan dalam suatu bentuk fungsi linier. Model regresi linier berganda seperti pada persamaan 2.3. Pada penelitian ini, laju inflasi umum merupakan peubah respon dan 7 kelompok barang dijadikan peubah penjelasnya, sehingga model regresi linier berganda yang terbentuk adalah sebagai berikut (persamaan 2.58).

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + \hat{\beta}_4 X_{4i} + \hat{\beta}_5 X_{5i} + \hat{\beta}_6 X_{6i} + \hat{\beta}_7 X_{7i} \quad (2.58)$$

dengan :

- \hat{Y}_i : nilai estimasi laju inflasi umum bulan ke- i
- X_1, \dots, X_7 : 7 kelompok barang
- $\hat{\beta}_0$: nilai estimasi dari intersep
- $\hat{\beta}_1, \dots, \hat{\beta}_7$: nilai estimasi koefisien regresi 7 kelompok barang
- i : pengamatan pada bulan ke- i

Backpropagation merupakan algoritma *training* dari metode JST yang terawasi (*supervised learning*) yang diharapkan metode ini memiliki target *output*. Namun kelemahan dari JST adalah tidak adanya ketentuan dalam menentukan *input* dan banyaknya unit *input* pada lapisan *input*. Sehingga peneliti melakukan pemilihan model regresi terbaik yang bertujuan untuk mengetahui dari 7 kelompok barang tersebut yang dapat menjelaskan laju inflasi umum dengan

sebaik-baiknya. Misalkan dari model regresi terbaik diperoleh model,

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i}$$

maka yang dijadikan unit *input* pada lapisan *input* adalah kelompok 1 (X_1) dan kelompok 2 (X_2), dan yang dijadikan target *output* adalah laju inflasi umum dari data aktual, bukan hasil pendugaan.

2.9.2 Tahapan Peramalan Menggunakan Model Jaringan Syaraf Tiruan *Backpropagation* dengan *Input* Berdasarkan Model Regresi Terbaik

Tahapan peramalan menggunakan model jaringan syaraf tiruan dengan *input* berdasarkan model regresi terbaik adalah sebagai berikut :

- 1) Diketahui laju inflasi umum dipengaruhi oleh laju inflasi 7 kelompok barang, masalahnya adalah kelompok barang mana yang signifikan mempengaruhi laju inflasi umum.
- 2) Membentuk unit *input* pada lapisan *input*. Unit input yang digunakan adalah berdasarkan model regresi terbaik. Contohnya model regresi terbaik yang terbentuk,

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i}$$

maka yang dijadikan unit *input* adalah kelompok 1 (X_1) dan kelompok 2 (X_2).

- 3) Target *output* yang digunakan adalah laju inflasi umum.
- 4) Menentukan banyaknya unit pada lapisan tersembunyi. Pada penelitian ini, ditentukan banyaknya unit pada lapisan tersembunyi yang akan diuji adalah 10, 15, 20, 25, dan 30 unit.
- 5) Pembagian data *training* dan data *testing*. Yao dan Tan (2001) menyarankan pembagian data *training* dan *testing* masing-masing adalah 80%, dan 20%.
- 6) Menurut Bodis (2004), model yang paling baik digunakan sebagai model peramalan adalah model yang baik digunakan untuk data *training* dan juga baik digunakan untuk data *testing* dengan melihat nilai MAD dan MSE terkecil.
- 7) Model JST.

2.10 Kriteria Pemilihan Model Terbaik untuk Peramalan Data Laju Inflasi (M-T-M)

2.10.1 Mean Absolute Deviation (MAD)

MAD merupakan ukuran pertama kesalahan peramalan keseluruhan untuk sebuah model. Nilai ini dihitung dengan mengambil jumlah nilai absolut dari tiap kesalahan peramalan dibagi dengan jumlah periode data.

$$MAD = \frac{\sum_{i=1}^n |e_t|}{n} \quad (2.59)$$

Keterangan :

$$e_t = y_t - \hat{y}_t$$

y_t = nilai aktual pada periode ke t

\hat{y}_t = nilai peramalan pada periode ke t

n = banyaknya data

2.10.2 Mean Squared Error (MSE)

Kriteria kebaikan model dapat ditentukan berdasarkan *error* atau residual yang dikuadratkan kemudian dibagi dengan banyaknya data yaitu dengan MSE. Semakin kecil nilai MSE maka model semakin baik.

$$MSE = \frac{\sum_{i=1}^n e_t^2}{n} \quad (2.60)$$

Keterangan :

$$e_t = y_t - \hat{y}_t$$

y_t = nilai aktual pada periode ke t

\hat{y}_t = nilai peramalan pada periode ke t

n = banyaknya data

UNIVERSITAS BRAWIJAYA



BAB III METODE PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data laju inflasi umum *Month To Month* (M-T-M) berdasarkan laju inflasi kelompok barang di Provinsi Bali dari bulan Januari 2007 sampai dengan Desember 2011 yang didapatkan dari Kelompok Kajian Ekonomi (KKE) Kantor Bank Indonesia Denpasar. Data secara keseluruhan diberikan pada lampiran 1.

3.2 Metodologi

Metode analisis yang digunakan dalam penelitian ini adalah regresi linier berganda berdasarkan model regresi terbaik, JST *Backpropagation* dengan *input* berdasarkan laju inflasi kelompok barang, dan JST *Backpropagation* dengan *input* berdasarkan model regresi terbaik. Keakuratan dan keefektifan dari ketiga model tersebut dalam meramalkan laju inflasi umum (M-T-M) dapat dilihat dari nilai MAD dan MSE yang dihasilkan. Adapun tahapan yang dilakukan dalam penelitian ini adalah sebagai berikut :

- Tahap 1 : Analisis regresi linier berganda berdasarkan model regresi terbaik.
 - 1.1 : Menyiapkan data laju inflasi (M-T-M).
 - 1.2 : Pemilihan model regresi terbaik dengan menggunakan metode *Stepwise Regression* (lakukan langkah- langkah seperti pada sub bab 2.6).
 - 1.3 : Pengujian asumsi klasik.
 - 1.4 : Pengujian hipotesis.
 - 1.5 : Peramalan.
 - 1.6 : Hitung nilai MAD dan MSE.

- Tahap 2 : Analisis JST *Backpropagation* dengan *input* berdasarkan laju inflasi kelompok barang.
 - 2.1 : Menyiapkan data laju inflasi (M-T-M).
 - 2.2 : Data dinormalisasi terlebih dahulu sehingga data laju inflasi berada pada selang -1 dan 1.

- Hal ini disebabkan oleh penggunaan fungsi aktivasi sigmoid bipolar yang berada pada selang -1 dan 1.
- 2.3 : Pembagian data *training* dan data *testing* dengan ketentuan 80% data *training* dan 20% data *testing*.
 - 2.4 : Penentuan laju pemahaman (*learning rate*), *maksimum epoch* serta *target error*.
 - 2.5 : Inisialisasi bobot (secara acak)
 - 2.6 : Proses *training*
 - 2.6.1 : Propagasi maju pola *input* hingga respon mencapai lapisan *output* (lakukan langkah 3 sampai langkah 5 seperti pada sub bab 2.8.4).
 - 2.6.2 : Respon yang dihasilkan pada lapisan *output* akan dibandingkan dengan nilai target, dan dihitung MAD dan MSE. Jika sudah terpenuhi sesuai dengan target *error*, maka proses penghitungan dihentikan. Namun sebaliknya jika kriteria penghentian belum terpenuhi maka, dilanjutkan ke langkah 4 seperti pada sub bab 2.8.4.
 - 2.6.3 : Bergerak propagasi mundur dari lapisan *output* kembali ke lapisan *input* dan melakukan penyesuaian bobot serta mengulangi proses seperti pada sub bab 2.8.4 dan ikuti langkah 6 sampai 7).
 - 2.6.4 : Menguji kondisi penghentian proses *training* (*training* dihentikan jika *error* sesuai target).
 - 2.6.5 : Simpan bobot dengan MAD dan MSE terkecil untuk digunakan dalam proses *testing*.
 - 2.7 : Proses *testing*
 - 2.7.1 : *Load* data aktual yang akan diuji. Selanjutnya data dinormalisasi terlebih dahulu sehingga data berada pada selang -1 dan 1.
 - 2.7.2 : *Load* bobot hasil proses *training*.
 - 2.7.3 : Simulasi data dengan *JST Backpropagation (feed forward)* dengan bobot - bobot hasil proses *training*.
 - 2.7.4 : Hitung MAD dan MSE dan pilih model terbaik yang digunakan sebagai peramalan.
 - 2.7.5 : Data hasil peramalan didenormalisasi sehingga diperoleh hasil peramalan laju inflasi umum (M-T-M) berdasarkan laju inflasi kelompok barang.


- Tahap 3 : Analisis JST *Backpropagation* dengan *input* berdasarkan model regresi terbaik.
- 3.1 : Menyiapkan data laju inflasi (M-T-M)
 - 3.2 : Memodelkan data menggunakan metode regresi linier berganda berdasarkan model regresi terbaik (langkah pengerjaan seperti pada sub bab 3.2 Tahap 1)
 - 3.3 : Model terbaik yang diperoleh dari hasil analisis regresi linier berganda berdasarkan model regresi terbaik disimpan.
 - 3.4 : Simpan peubah penjelas (X_i) dari model regresi terbaik.
 - 3.5 : Peubah penjelas (X_i) yang diperoleh dari model regresi terbaik kemudian dijadikan *input* untuk model JST *Backpropagation*. Misalkan diperoleh model regresi terbaik adalah $\hat{Y}_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i}$, maka *input* dari JST *Backpropagation* menggunakan data laju inflasi kelompok barang X_1 , X_2 , dan X_3 dan targetnya laju inflasi umum.
 - 3.6 : Data dinormalisasi terlebih dahulu sehingga data laju inflasi berada pada selang -1 dan 1. Hal ini disebabkan oleh penggunaan fungsi aktivasi sigmoid bipolar yang berada pada selang -1 dan 1.
 - 3.7 : Membagi data yang terbentuk dari model regresi terbaik menjadi data training dan testing dengan ketentuan 80% data *training* dan 20% data *testing*.
 - 3.7 : Penentuan laju pemahaman (*learning rate*), *maksimum epoch* serta *target error*.
 - 3.8 : Inialisasi bobot (secara acak)
 - 3.9 : Proses *training*
 - 3.9.1 : Propagasi maju pola *input* hingga respon mencapai lapisan *output* (lakukan langkah 3 sampai langkah 5 seperti pada sub bab 2.8.4).
 - 3.9.2 : Respon yang dihasilkan pada lapisan *output* akan dibandingkan dengan nilai target, dan dihitung MAD dan MSE. Jika sudah terpenuhi sesuai dengan target *error*, maka proses penghitungan dihentikan. Namun

sebaliknya jika kriteria penghentian belum terpenuhi maka, dilanjutkan ke langkah 4 seperti pada sub bab 2.8.4.


- 3.9.3 : Bergerak propagasi mundur dari lapisan *output* kembali ke lapisan *input* dan melakukan penyesuaian bobot serta mengulangi proses seperti pada sub bab 2.8.4 dan ikuti langkah 6 sampai 7).
- 3.9.4 : Menguji kondisi penghentian proses *training* (*training* dihentikan jika *error* sesuai target).
- 3.9.5 : Simpan bobot dengan MAD dan MSE terkecil untuk digunakan dalam proses *testing*.
- 3.10 : Proses *testing*
- 3.10.1: *Load* data aktual yang akan diuji. Selanjutnya data di normalisasi terlebih dahulu sehingga data berada pada selang -1 dan 1.
- 3.10.2: *Load* bobot hasil proses *training*.
- 3.10.3: Simulasi data dengan JST *Backpropagation* (*feed forward*) dengan bobot-bobot hasil proses *training*.
- 3.10.4: Hitung MAD dan MSE dan pilih model terbaik yang digunakan sebagai peramalan.
- 3.10.5: Data hasil peramalan dinormalisasi sehingga diperoleh hasil peramalan laju inflasi umum (M-T-M) berdasarkan model regresi terbaik.

- Tahap 4 : Membandingkan hasil peramalan laju inflasi umum (M-T-M) dengan menggunakan regresi linier berganda berdasarkan model regresi terbaik, JST *Backpropagation* dengan *input* berdasarkan laju Inflasi kelompok barang, dan JST *Backpropagation* dengan *input* berdasarkan model regresi terbaik.
- 4.1 : Membandingkan nilai MAD dan MSE (persamaan 2.39 dan 2.40) yang terkecil yang dihasilkan oleh ketiga model.
- 4.2 : Model dengan MAD dan MSE terkecil adalah model terbaik untuk kasus peramalan laju inflasi umum (M-T-M) berdasarkan laju inflasi kelompok barang di Provinsi Bali.
- 4.3 : Kesimpulan.


3.3 Alur Penelitian




Gambar 3.1 Diagram alir analisis regresi linier berganda berdasarkan model regresi terbaik




Gambar 3.2 Diagram alir JST *Backpropagation* dengan *input* berdasarkan kelompok barang dan JST *Backpropagation* dengan *input* berdasarkan model regresi terbaik




Gambar 3.3 Diagram alir pembentukan *input* model JST *Backpropagation* dengan *input* berdasarkan model regresi terbaik



Gambar 3.4 Diagram alir proses *training JST Backpropagation*



Gambar 3.5 Diagram alir proses *testing* JST *Backpropagation*




Gambar 3.6 Diagram alir perbandingan MAD dan MSE

BAB IV HASIL DAN PEMBAHASAN

4.1 Data Laju Inflasi (M-T-M) Berdasarkan Kelompok Barang

Data laju inflasi (M-T-M) yang digunakan dalam penelitian ini adalah data laju inflasi bulanan berdasarkan kelompok barang yang didapatkan dari Kelompok Kajian Ekonomi (KKE) Kantor Bank Indonesia Denpasar, Provinsi Bali mulai Januari 2007 sampai dengan Desember 2011. Data laju inflasi (M-T-M) berdasarkan kelompok barang diberikan pada lampiran 1.

Laju inflasi umum yang kita kenal selama ini sebenarnya tersusun atas nilai – nilai laju inflasi pembentuk inflasi umum yang tersusun atas tujuh kelompok barang yaitu kelompok bahan makanan (X_1), kelompok makanan jadi, minuman, dan tembakau (X_2), kelompok perumahan (X_3), kelompok sandang (X_4), kelompok kesehatan (X_5), kelompok pendidikan dan olah raga (X_6), kelompok transportasi dan komunikasi (X_7).



Gambar 4.1 Laju inflasi umum (M-T-M) bulan Januari 2007 sampai dengan Desember 2011 di Provinsi Bali

Dari Gambar 4.1, tampak bahwa laju inflasi umum (M-T-M) bulan Januari 2007 sampai dengan Desember 2011 di Provinsi Bali sangatlah bersifat fluktuatif, artinya kecenderungan nilai naik maupun turun dari laju inflasi umum sangat sulit diramalkan.

4.2 Peramalan Menggunakan Regresi Linier Berganda Berdasarkan Model Regresi Terbaik

4.2.1 Pemilihan Model Regresi Terbaik dengan Menggunakan Metode *Stepwise Regression*

Adapun tahapan yang dilakukan untuk pemilihan model regresi terbaik diantaranya adalah sebagai berikut :

a) Menghitung nilai korelasi dari laju inflasi masing – masing kelompok barang terhadap laju inflasi umum (Y).

Hasil korelasi dari laju inflasi masing-masing kelompok barang terhadap laju inflasi umum menunjukkan bahwa X_1 memiliki nilai korelasi terbesar (0.783), sehingga X_1 yang pertama kali dimasukkan ke dalam persamaan model regresi.

b) Meregresikan laju inflasi umum dengan X_1 .

$$\hat{Y}_i = 0.325 + 0.250X_{1i}$$

Dari hasil analisis ragam regresi X_1 terhadap Y , regresi X_1 memiliki nilai $F_{hitung} = 96.746$ dengan nilai $F_{tabel(0.05)} = 4.052$. Hasil tersebut menunjukkan bahwa persamaan regresi ini nyata secara statistik, sehingga X_1 dipertahankan di dalam persamaan regresi.

c) Hitung nilai korelasi parsial dari laju inflasi masing-masing kelompok barang yang berada di luar persamaan terhadap laju inflasi umum (Y).

Kelompok barang yang berada di luar persamaan adalah $X_2, X_3, X_4, X_5, X_6,$ dan X_7 . Hasil korelasi parsial terbesar dari kelompok barang terhadap laju inflasi umum yang dikontrol oleh X_1 adalah X_7 dengan nilai korelasi parsial sebesar 0.669, sehingga X_7 masuk ke dalam persamaan regresi sebagai peubah yang ke-2.

- d) Meregresikan laju inflasi dengan X_1 dan X_7 .

$$\hat{Y}_i = 0.276 + 0.257X_{1i} + 0.191X_{7i}$$

Dari hasil analisis ragam regresi X_1 , X_7 terhadap Y , regresi $(X_1|X_7)$ dan $(X_7|X_1)$ memiliki nilai F_{hitung} masing-masing 167.132 dan 51.339 dengan nilai $F_{tabel(0.05)} = 4.056$. Hasil tersebut menunjukkan bahwa persamaan regresi ini nyata secara statistik, sehingga X_1 dan X_7 dipertahankan di dalam persamaan regresi.

- e) Pilih kelompok barang yang lain dengan syarat kelompok yang memiliki nilai korelasi parsial terbesar diantara kelompok lainnya yang berada di luar persamaan terhadap (Y) .

Kelompok barang yang berada di luar persamaan adalah X_2 , X_3 , X_4 , X_5 , dan X_7 . Hasil korelasi parsial terbesar dari kelompok barang terhadap laju inflasi umum yang dikontrol oleh X_1 dan X_7 adalah X_3 dengan nilai korelasi parsial sebesar 0.727, sehingga X_3 masuk ke dalam persamaan regresi sebagai peubah yang ke-3.

- f) Meregresikan laju inflasi dengan X_1 , X_7 dan X_3 .

$$\hat{Y}_i = 0.095 + 0.262X_{1i} + 0.196X_{7i} + 0.345X_{3i}$$

Dari hasil analisis ragam regresi X_1 , X_7 , dan X_3 terhadap Y , regresi $(X_1|X_7, X_3)$, $(X_7|X_1, X_3)$, dan $(X_3|X_1, X_7)$ memiliki nilai F_{hitung} masing-masing 146.545, 36.060, dan 28.727 dengan nilai $F_{tabel(0.05)} = 4.062$. Hasil tersebut menunjukkan bahwa persamaan regresi ini nyata secara statistik, sehingga X_1 , X_7 , dan X_3 dipertahankan di dalam persamaan regresi.

- g) Pilih kelompok barang yang lain dengan syarat kelompok yang memiliki nilai korelasi parsial terbesar diantara kelompok lainnya yang berada di luar persamaan terhadap (Y) .

Kelompok barang yang berada di luar persamaan adalah X_2 , X_4 , X_5 , dan X_6 . Hasil korelasi parsial terbesar dari kelompok barang terhadap laju inflasi umum yang dikontrol oleh kelompok X_1 , X_7 , X_3 adalah X_2 dengan nilai korelasi parsial sebesar 0.637,

sehingga X_2 masuk ke dalam persamaan regresi sebagai peubah yang ke-4.

- h) Meregresikan laju inflasi dengan X_1, X_7, X_3 dan X_2 .

$$\hat{Y}_i = 0.022 + 0.232X_{1i} + 0.207X_{7i} + 0.242X_{3i} + 0.206X_{2i}$$

Dari hasil analisis ragam regresi X_1, X_7, X_3 , dan X_2 terhadap Y , regresi $(X_1|X_7, X_3, X_2)$, $(X_7|X_1, X_3, X_2)$, $(X_3|X_1, X_7, X_2)$ dan $(X_2|X_1, X_7, X_3)$ memiliki nilai F_{hitung} masing – masing sebesar 145.400, 41.467, 16.367 dan 5.000 dengan nilai $F_{tabel(0.05)} = 4.067$. Hasil tersebut menunjukkan bahwa persamaan regresi ini nyata secara statistik, sehingga X_1, X_7, X_3 , dan X_2 dipertahankan di dalam persamaan regresi.

- i) Pilih kelompok barang yang lain dengan syarat kelompok yang memiliki nilai korelasi parsial terbesar diantara kelompok lainnya yang berada di luar persamaan terhadap (Y).

Kelompok barang yang berada di luar persamaan adalah X_4, X_5 , dan X_6 . Hasil korelasi parsial terbesar dari kelompok barang terhadap laju inflasi umum yang dikontrol oleh kelompok X_1, X_7, X_3 dan X_2 adalah X_5 dengan nilai korelasi parsial sebesar 0.639, sehingga X_5 masuk ke dalam persamaan regresi sebagai peubah yang ke-5.

- j) Meregresikan laju inflasi dengan X_1, X_7, X_3, X_2 dan X_5 .

$$\hat{Y}_i = -0.008 + 0.226X_{1i} + 0.209X_{7i} + 0.244X_{3i} + 0.228X_{2i} + 0.041X_{5i}$$

Dari hasil analisis ragam regresi X_1, X_7, X_3, X_2 dan X_5 terhadap Y , regresi $(X_1|X_7, X_3, X_2, X_5)$, $(X_7|X_1, X_3, X_2, X_5)$, $(X_3|X_1, X_7, X_2, X_5)$, $(X_2|X_1, X_7, X_3, X_5)$ dan $(X_5|X_1, X_7, X_3, X_2)$ memiliki nilai F_{hitung} masing – masing sebesar 148.214, 40.214, 19.357, 4.786 dan 4.178 dengan nilai $F_{tabel(0.05)} = 4.072$. Hasil tersebut menunjukkan bahwa persamaan regresi ini nyata secara statistik, sehingga X_1, X_7, X_3, X_2 dan X_5 dipertahankan di dalam persamaan regresi.

- k) Pilih kelompok barang yang lain dengan syarat kelompok yang memiliki nilai korelasi parsial terbesar diantara kelompok lainnya yang berada di luar persamaan terhadap (Y).

Kelompok barang yang berada di luar persamaan adalah X_4 dan X_6 . Hasil korelasi parsial terbesar dari kelompok barang terhadap laju inflasi umum yang dikontrol oleh kelompok X_1, X_7, X_3, X_2 dan X_5 adalah X_6 dengan nilai korelasi parsial sebesar -0.054, sehingga X_6 masuk ke dalam persamaan regresi sebagai peubah yang ke-6.

- l) Meregresikan laju inflasi dengan X_1, X_7, X_3, X_2, X_5 dan X_6 .

$$\hat{Y}_i = -0.050 + 0.162X_{1i} + 0.168X_{7i} + 0.362X_{3i} + 0.175X_{2i} + 0.034X_{5i} - 0.150X_{6i}$$

Dari hasil analisis ragam regresi X_1, X_7, X_3, X_2, X_5 , dan X_6 terhadap Y , regresi ($X_1|X_7, X_3, X_2, X_5, X_6$), ($X_7|X_1, X_3, X_2, X_5, X_6$), ($X_3|X_1, X_7, X_2, X_5, X_6$), ($X_2|X_1, X_7, X_3, X_5, X_6$), ($X_5|X_1, X_7, X_3, X_2, X_6$) dan ($X_6|X_1, X_7, X_3, X_2, X_5$) memiliki nilai F_{hitung} masing – masing sebesar 142.103, 38.000, 18.448, 4.552, 3.966 dan 0.103 dengan nilai $F_{tabel(0.05)} = 4.078$. Hasil tersebut menunjukkan bahwa X_6 tidak nyata secara statistik. Dengan memasukkan X_6 , uji F pada X_5 juga menjadi tidak nyata secara statistik, sehingga X_6 dikeluarkan dari persamaan regresi.

- m) Variabel yang belum dilakukan pengujian pada pemodelan regresi terbaik ini adalah X_4 , sehingga langsung dimasukkan ke dalam persamaan regresi yang mengandung X_1, X_7, X_3, X_2 dan X_5 .

$$\hat{Y}_i = -0.045 + 0.162X_{1i} + 0.175X_{7i} + 0.349X_{3i} + 0.172X_{2i} + 0.042X_{5i} - 0.037X_{4i}$$

Dari hasil analisis ragam regresi X_1, X_7, X_3, X_2, X_5 , dan X_4 terhadap Y , regresi ($X_1|X_7, X_3, X_2, X_5, X_4$), ($X_7|X_1, X_3, X_2, X_5, X_4$), ($X_3|X_1, X_7, X_2, X_5, X_4$), ($X_2|X_1, X_7, X_3, X_5, X_4$), ($X_5|X_1, X_7, X_3, X_2, X_4$) dan ($X_4|X_1, X_7, X_3, X_2, X_5$) memiliki nilai F_{hitung} masing – masing sebesar 140.276, 34.931, 17.517, 4.758, 3.482 dan 0.172 dengan

nilai $F_{\text{tabel}(0.05)} = 4.078$. Hasil tersebut menunjukkan bahwa X_4 tidak nyata secara statistik. Dengan memasukkan X_4 , uji $F X_5$ juga menjadi tidak nyata secara statistik, sehingga indikator X_4 juga dikeluarkan dari persamaan regresi.

Semua kelompok barang yang mempengaruhi laju inflasi umum sudah dilakukan pengujian, didapatkan model regresi terbaik dengan melibatkan X_1, X_7, X_3, X_2 dan X_5 . Kelima peubah inilah yang akan dijadikan sebagai unit *input* pada model JST *Backpropagation* berdasarkan hasil dari model regresi terbaik. Hasil perhitungan dari pemilihan model regresi terbaik dengan menggunakan metode *Stepwise Regression* diberikan pada lampiran 2.

Sehingga dari hasil pemilihan model terbaik tersebut, didapatkan model persamaan regresi linier berganda sebagai berikut.

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + \hat{\beta}_5 X_{5i} + \hat{\beta}_7 X_{7i}$$

atau

$$\hat{Y}_i = -0.008 + 0.226X_{1i} + 0.228X_{2i} + 0.244X_{3i} + 0.041X_{5i} + 0.209X_{7i}$$

Keterangan :

\hat{Y} : Nilai peramalan untuk laju inflasi umum (M-T-M)

X_1 : Laju inflasi kelompok bahan makanan

X_2 : Laju inflasi kelompok makanan jadi, minuman, dan tembakau

X_3 : Laju inflasi kelompok perumahan

X_5 : Laju inflasi kelompok kesehatan

X_7 : Laju inflasi kelompok transportasi dan komunikasi.

Dari model regresi terbaik yang terbentuk tersebut, dapat dijelaskan sebagai berikut :

1) $\hat{\beta}_0 = -0.008$

Nilai konstanta ini menunjukkan jika laju inflasi X_1, X_2, X_3, X_5 dan X_7 sama dengan nol, maka nilai peramalan pada laju inflasi umum (M-T-M) sebesar -0,008 persen.

2) $\hat{\beta}_1 = 0.226$

Koefisien regresi X_1 diperoleh laju inflasi X_1 0.226. Hasil ini menunjukkan bahwa setiap kenaikan 1 persen X_1 , maka laju inflasi

umum (M-T-M) akan meningkat sebesar 0.226 persen, dengan asumsi laju inflasi kelompok barang yang lain tetap.

3) $\hat{\beta}_2 = 0.228$

Koefisien regresi X_2 diperoleh laju inflasi X_2 0.228. Hasil ini menunjukkan bahwa setiap kenaikan 1 persen X_2 , maka laju inflasi umum (M-T-M) akan meningkat sebesar 0.228 persen, dengan asumsi laju inflasi kelompok barang yang lain tetap.

4) $\hat{\beta}_3 = 0.244$

Koefisien regresi X_3 diperoleh laju inflasi X_3 0.244. Hasil ini menunjukkan bahwa setiap kenaikan 1 persen X_3 , maka laju inflasi umum (M-T-M) akan meningkat sebesar 0.244 persen, dengan asumsi laju inflasi kelompok barang yang lain tetap.

5) $\hat{\beta}_5 = 0.041$

Koefisien regresi X_5 diperoleh laju inflasi X_5 0.041. Hasil ini menunjukkan bahwa setiap kenaikan 1 persen X_5 , maka laju inflasi umum (M-T-M) akan meningkat sebesar 0.041 persen, dengan asumsi laju inflasi kelompok barang yang lain tetap.

6) $\hat{\beta}_7 = 0.209$

Koefisien regresi X_7 diperoleh laju inflasi X_7 0.209. Hasil ini menunjukkan bahwa setiap kenaikan 1 persen X_7 , maka laju inflasi umum (M-T-M) akan meningkat sebesar 0.209 persen, dengan asumsi laju inflasi kelompok barang yang lain tetap.

4.2.2 Pengujian Asumsi Klasik


Model regresi linier berganda dapat disebut sebagai model yang baik jika model tersebut memenuhi kriteria *Best Linier Unbiased Estimator* (BLUE). BLUE dapat dicapai bila memenuhi asumsi klasik.

Terdapat empat uji asumsi klasik yang harus dilakukan terhadap suatu model regresi berganda (hasil pengujian asumsi klasik secara lengkap diberikan pada lampiran 3), diantaranya adalah sebagai berikut :

a. Uji Normalitas

Ada dua cara untuk mendeteksi apakah sisaan menyebar normal atau tidak yaitu dengan analisis grafik dan uji statistik.

1) Analisis Grafik



Gambar 4.2 Plot grafik uji normalisasi

Dari Gambar 4.2, dapat diketahui bahwa titik-titik data sisaan menyebar sekitar garis dan mengikuti garis diagonal sehingga data sisaan tersebut telah menyebar normal.

2) Uji statistik *Kolmogorov-smirnov* (K-S)

Uji statistik K-S diperoleh nilai absolut terbesar adalah 0.112 lebih kecil dari 0.173 (nilai tabel K-S dengan $\alpha = 0.05$ dan $n = 48$), maka data sisaan tersebut telah menyebar normal. Begitupula dengan *p-value* diperoleh sebesar 0,581 yang lebih besar dari 0.05 ($0.581 > 0.05$).

b. Uji Non Multikolinieritas

Nilai *Tolerance* dan *Variance Inflation Factor* (VIF) dapat digunakan untuk mendeteksi adanya multikolinieritas dalam model regresi linier berganda. Hasil dari uji multikolinieritas dengan menggunakan nilai *Tolerance* dan VIF dapat dilihat pada Tabel 4.1.

Tabel 4.1 Nilai *Tolerance* dan VIF

| Kelompok | Nilai <i>Tolerance</i> | Nilai VIF |
|----------|------------------------|-----------|
| X_1 | 0.812 | 1.231 |
| X_2 | 0.669 | 1.494 |
| X_3 | 0.799 | 1.251 |
| X_5 | 0.971 | 1.030 |
| X_7 | 0.980 | 1.020 |

Dari Tabel 4.1, dapat diketahui bahwa dari lima kelompok yang diuji, semua kelompok memiliki nilai *tolerance* lebih besar dari 0.10, begitupula nilai VIF pada semua kelompok memiliki nilai lebih kecil dari 10, sehingga bisa dikatakan bahwa antar kelompok yang akan dijadikan model untuk menduga nilai laju inflasi umum tidak terjadi permasalahan multikolinearitas, maka asumsi non multikolinieritas terpenuhi.

c. Uji Homoskedastisitas

Metode Glejser dapat digunakan untuk mendeteksi adanya heteroskedastisitas dalam model regresi. Untuk mengetahui ragam dari residual model regresi tidak konstan atau ragam antara sisaan yang satu dengan sisaan yang lain berbeda, maka dengan metode glejser akan diregresikan laju inflasi kelompok - kelompok yang mempengaruhi laju inflasi umum terhadap nilai absolut dari sisaan.

Tabel 4.2 Nilai signifikansi kelompok barang pada metode glejser

| Kelompok | Nilai Signifikansi |
|----------|--------------------|
| X_1 | 0.369 |
| X_2 | 0.256 |
| X_3 | 0.344 |
| X_5 | 0.534 |
| X_7 | 0.892 |

Dari Tabel 4.2, dapat diketahui bahwa nilai signifikansi dari kelima kelompok lebih dari 0.05. Dengan demikian dapat disimpulkan bahwa asumsi homoskedastisitas terpenuhi pada model regresi.

d. Uji Non Autokorelasi

Selanjutnya untuk mendeteksi adanya autokorelasi dalam model regresi linier berganda dapat digunakan metode Durbin-Watson.

Pada data laju inflasi dengan menggunakan lima kelompok barang yang menjadi kelompok terbaik untuk menduga nilai laju inflasi umum, diperoleh nilai Durbin-Watson yang dihasilkan dari model regresi linier berganda sebesar 1.649. Sedangkan dari tabel Durbin-Watson dengan signifikansi 0,05 dan jumlah data (n) = 48, dan $k = 5$ (k adalah jumlah variabel prediktor) diperoleh nilai dL sebesar 1,3167 dan dU sebesar 1,7725. Karena nilai dari Durbin-Watson sebesar 1,649 yang berada pada daerah antara dL dan dU , maka tidak menghasilkan kesimpulan yang pasti (berada di daerah keragu-raguan).

Sehingga untuk mengatasi permasalahan tersebut, maka peneliti akan menggunakan kriteria yang lain untuk mendeteksi adanya autokorelasi seperti yang dijelaskan oleh Santoso (2000). Dengan menggunakan kriteria tersebut, karena nilai Durbin-Watson yang dihasilkan dari model regresi linier berganda pada penelitian ini terletak pada kisaran -2 sampai dengan 2 , maka dapat disimpulkan bahwa asumsi non autokorelasi terpenuhi.

4.2.3 Pengujian Hipotesis

Pengujian hipotesis dilakukan setelah model regresi yang diperoleh sudah memenuhi uji asumsi klasik agar hasil pengujian dapat diinterpretasikan dengan tepat. Ketepatan fungsi dari model regresi tersebut dalam menaksir nilai aktual dapat diukur dari *goodness of fit*-nya, yang secara statistik dapat diukur dari koefisien determinasi, nilai statistik F , dan nilai statistik t . Hasil pengujian hipotesis secara lengkap diberikan pada lampiran 3.

a. Koefisien Determinasi

Pada penelitian ini, untuk meramalkan laju inflasi umum (M-T-M) berdasarkan kelompok barang, diperoleh persamaan regresi linier berganda dengan model regresi terbaik sebagai berikut.

$$\hat{Y}_i = -0.008 + 0.226X_{1i} + 0.228X_{2i} + 0.244X_{3i} + 0.041X_{5i} + 0.209X_{7i}$$

Dari model regresi terbaik tersebut diperoleh nilai R^2 -adjusted sebesar 0.917, sehingga dapat dijelaskan bahwa X_1 , X_2 , X_3 , X_5 dan X_7 mampu memberikan informasi yang dibutuhkan untuk meramalkan laju inflasi umum (M-T-M) sebesar 97.7%.

b. Uji Signifikansi Pengaruh Simultan (Uji Statistik F)

Uji statistik F digunakan untuk mengetahui apakah kelompok - kelompok yang terpilih ke dalam model regresi mempunyai pengaruh secara simultan terhadap laju inflasi umum (M-T-M).

Tabel 4.3 Hasil Uji Simultan

| SK | db | SS | MS | F_{hitung} | F_{tabel} | Sig. |
|----------|----|--------|-------|--------------|-------------|-------|
| Regresi | 5 | 14.699 | 2.940 | 104.556 | 2.438 | 0.000 |
| Residual | 42 | 1.181 | 0.028 | | | |
| Total | 47 | 15.880 | | | | |

Berdasarkan hasil uji simultan pada Tabel 4.3, didapatkan F -hitung sebesar 228.289 dengan signifikansi sebesar 0.000. Karena F_{hitung} lebih besar dari F_{tabel} dan nilai signifikansi lebih kecil dari 0.05, maka dapat disimpulkan bahwa kelompok - kelompok yang terpilih ke dalam model regresi terbaik memiliki pengaruh yang signifikan secara simultan terhadap laju inflasi umum (M-T-M).

c. Uji Signifikansi Parameter Secara Parsial (Uji Statistik t)

Uji statistik t digunakan untuk mengetahui pengaruh masing-masing kelompok yang terpilih ke dalam model regresi terbaik secara individu terhadap laju inflasi umum (M-T-M).

Tabel 4.4 Hasil Uji Parsial

| Kelompok | β | Standar Deviasi | t_{hitung} | t_{tabel} | Sig. |
|----------|---------|-----------------|--------------|-------------|-------|
| X_1 | 0.226 | 0.010 | 21.889 | 2.018 | 0.000 |
| X_2 | 0.228 | 0.030 | 7.613 | 2.018 | 0.000 |
| X_3 | 0.244 | 0.033 | 7.313 | 2.018 | 0.000 |
| X_5 | 0.041 | 0.008 | 5.381 | 2.018 | 0.000 |
| X_7 | 0.209 | 0.013 | 15.515 | 2.018 | 0.000 |

Dari Tabel 4.4, dapat dilihat bahwa semua kelompok memiliki nilai t -hitung lebih besar dari t -tabel, begitu pula dengan nilai signifikansi semua kelompok lebih kecil dari 0.05, sehingga dapat disimpulkan bahwa masing-masing kelompok yang terpilih ke dalam model regresi terbaik secara individu memiliki pengaruh yang signifikan terhadap laju inflasi umum (M-T-M).

4.2.4 Hasil Peramalan dengan Regresi Linier Berganda Berdasarkan Model Regresi Terbaik


Pada peramalan laju inflasi umum (M-T-M) dengan regresi linier berganda ini, digunakan model regresi terbaik yang sudah memenuhi uji asumsi klasik. Model regresi terbaik yang terbentuk adalah sebagai berikut.

$$\hat{Y}_i = -0.008 + 0.226X_{1i} + 0.228X_{2i} + 0.244X_{3i} + 0.041X_{5i} + 0.209X_{7i}$$

Dengan menggunakan model regresi terbaik ini, maka dilakukan peramalan terhadap laju inflasi umum (M-T-M). Pada tahap pertama, dilakukan peramalan dengan menggunakan data yang dijadikan model, kemudian dilakukan juga peramalan dengan menggunakan data pengujian model ramalan. Hasil dari pengujian model ramalan tersebut diberikan pada lampiran 4. Pada Tabel 4.5 berikut ini adalah nilai MAD dan MSE yang dihasilkan dari data yang dijadikan model dan data pengujian model ramalan tersebut.

Tabel 4.5 MAD dan MSE model regresi terbaik

| Data | MAD | MSE |
|-------------------------|--------|------------|
| Model ramalan | 0.0854 | 0.01510047 |
| Pengujian model ramalan | 0.0344 | 0.00170987 |



Gambar 4.3 Hasil perbandingan nilai aktual dengan hasil peramalan model regresi terbaik

Dari Gambar 4.3, terlihat bahwa model regresi terbaik cukup mampu mengikuti pola dari data aktual dalam meramalkan data laju inflasi umum (M-T-M), walaupun tidak semua bisa tepat dengan data ramalan. Seperti yang ditunjukkan oleh Tabel 4.23, model regresi terbaik memiliki nilai MAD sebesar 0.0344 dan nilai MSE sebesar 0.00170987 pada saat pengujian.

4.3 Peramalan Laju Inflasi Umum (M-T-M) Menggunakan JST Backpropagation

4.3.1 Preprocessing Data

Data laju inflasi (M-T-M) berdasarkan kelompok barang pada penelitian ini harus dinormalisasi terlebih dahulu. Data pada Jaringan Syaraf Tiruan (JST) perlu dilakukan normalisasi sehingga data tersebut dapat masuk dalam selang fungsi aktivasi yang digunakan, yaitu Sigmoid Bipolar dengan selang antara -1 dan 1. Data hasil normalisasi diberikan pada lampiran 5.

4.3.2 Arsitektur JST Backpropagation

Arsitektur jaringan yang digunakan dalam pemodelan Jaringan Syaraf Tiruan (JST) penelitian ini adalah jaringan dengan lapisan lebih dari satu (*multy layer perception*). Banyaknya unit pada

lapisan *input* yang digunakan adalah 7 unit. 7 unit *input* yang dimaksud mengacu pada kelompok – kelompok barang pembentuk laju inflasi umum, yaitu:

1. Kelompok Bahan Makanan (X_1)
2. Kelompok Makanan Jadi, Minuman, dan Tembakau (X_2)
3. Kelompok Perumahan (X_3)
4. Kelompok Sandang (X_4)
5. Kelompok Kesehatan (X_5)
6. Kelompok Pendidikan dan Olah Raga (X_6)
7. Kelompok Transportasi dan Komunikasi (X_7).

Struktur *input* yang digunakan pada JST *Backpropagation* ditunjukkan oleh Tabel 4.6 berikut.

Tabel 4.6 Struktur data *input* JST *Backpropagation*

| <i>Input</i> | | | | | | | Target (<i>T</i>) |
|--------------|-------|-------|-------|-------|-------|-------|------------------------|
| X_1 | X_2 | X_3 | X_4 | X_5 | X_6 | X_7 | |
| ... | ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... | ... | ... |

Struktur data *input* JST *Backpropagation* memiliki unit *input* berupa nilai laju inflasi dari masing-masing kelompok barang setiap bulannya. Sedangkan target dari JST *Backpropagation* ini adalah nilai laju inflasi umum (M-T-M).

Dalam arsitektur JST *Backpropagation*, penentuan banyaknya unit pada lapisan tersembunyi yang akan diuji yaitu 10, 15, 20, 25 dan 30. Dasar penentuan banyaknya unit tersembunyi tersebut adalah dalam pengambilan banyaknya unit pada lapisan tersembunyi antara 1-10, nilai MAD dan MSE yang dihasilkan tidaklah signifikan sehingga banyaknya unit pada lapisan tersembunyi yang digunakan 10. Sedangkan antara 11-20 diambil dua nilai yaitu 15 unit dan 20 unit. Hal yang sama dilakukan pada banyaknya unit antara 21 -30, diambil dua nilai yaitu 25 dan 30.

Dari arsitektur jaringan diatas yang telah ditentukan, maka arsitektur jaringan yang diindikasikan menjadi model yang optimal untuk peramalan laju inflasi umum (M-T-M) berdasarkan kelompok barang ditunjukkan oleh Tabel 4.7 adalah sebagai berikut.

Tabel 4.7 Arsitektur JST *Backpropagation* yang diuji

| No. | Arsitektur (A-B-C) |
|-----|--------------------|
| 1 | 7 – 10 – 1 |
| 2 | 7 – 15 – 1 |
| 3 | 7 – 20 – 1 |
| 4 | 7 – 25 – 1 |
| 5 | 7 – 30 – 1 |

Rumusan untuk arsitektur modelnya adalah model JST (A,B,C) di mana :

A = banyaknya unit dalam lapisan *input*,

B = banyaknya unit dalam lapisan tersembunyi, dan

C = banyaknya unit dalam lapisan *output*.

Arsitektur JST *Backpropagation* diatas akan diuji dengan parameter-parameter *input* yang harus diberikan dalam sebuah *training* dan *testing* JST *Backpropagation* untuk peramalan laju inflasi umum (M-T-M) berdasarkan kelompok barang. Parameter-parameter yang dimaksud adalah sebagai berikut :

Tabel 4.8 Inisialisasi parameter JST *Backpropagation*

| No. | Parameter | Keterangan |
|-----|-------------------------------|---------------------|
| 1 | Bobot | (pada lampiran 6) |
| 2 | <i>Maksimum epochs</i> | 10000 |
| 3 | <i>Learning rate</i> | 0.05 |
| 4 | Metode <i>Gradient Decent</i> | <i>Traingd</i> |

Sedangkan fungsi aktivasi yang digunakan dalam penelitian ini adalah *Tansig* (Sigmoid bipolar) pada lapisan tersembunyi, dan *Purelin* pada lapisan *output*.

4.3.3 Penentuan Data *Training* dan Data *Testing*

Data aktual yang digunakan adalah Januari 2007 sampai Desember 2011. Selanjutnya data *training* yang digunakan adalah 80% dari total data aktual, yaitu sebanyak 48 bulan antara januari 2007 sampai desember 2010. Sedangkan sisanya adalah data *testing* sebanyak 20%, yaitu 12 bulan pada data tahun 2011.

4.3.4 Training dan Testing Berdasarkan Kelompok Barang

Peramalan laju inflasi umum (M-T-M) berdasarkan kelompok barang dengan JST *Backpropagation* menggunakan arsitektur jaringan yang sudah ditentukan sebelumnya untuk diuji sesuai dengan Tabel 4.7. Proses *training* JST *Backpropagation* dilakukan dengan tujuan membentuk pola dari JST sehingga mampu mengenali suatu masukan data yang benar-benar berbeda dari data *training*.

Hasil *training* dan *testing* JST *Backpropagation* data laju inflasi (M-T-M) berdasarkan kelompok barang bulan Januari 2007 sampai Desember 2010 ditunjukkan dengan nilai MAD, MSE dan plot data target (data inflasi aktual) dengan *output* (data inflasi hasil *training*) dari masing-masing arsitektur yang dapat dilihat sebagai berikut.

Tabel 4.9 MAD hasil *training* dan *testing* JST *Backpropagation*

| No. | Arsitektur JST | MAD Training | MAD Testing |
|----------|-------------------|---------------|---------------|
| 1 | 7 – 10 – 1 | 0.0243 | 0.0201 |
| 2 | 7 – 15 – 1 | 0.0259 | 0.0247 |
| 3 | 7 – 20 – 1 | 0.0248 | 0.0150 |
| 4 | 7 – 25 – 1 | 0.0255 | 0.0222 |
| 5 | 7 – 30 – 1 | 0.0250 | 0.0313 |


Tabel 4.10 MSE hasil *training* dan *testing* JST *Backpropagation*

| No. | Arsitektur JST | MSE Training | MSE Testing |
|----------|-------------------|-------------------|-------------------|
| 1 | 7 – 10 – 1 | 0.00099993 | 0.00086300 |
| 2 | 7 – 15 – 1 | 0.00099995 | 0.00099961 |
| 3 | 7 – 20 – 1 | 0.00099965 | 0.00039151 |
| 4 | 7 – 25 – 1 | 0.00099989 | 0.00083380 |
| 5 | 7 – 30 – 1 | 0.00099969 | 0.00186470 |


Dari Tabel 4.9, tampak bahwa arsitektur yang memiliki nilai MAD *testing* terkecil adalah arsitektur 7 – 20 – 1 dengan nilai MAD *testing* 0.0150 dan MAD *training* 0.0248. Hasil tersebut diperkuat dengan nilai MSE di Tabel 4.10 dengan nilai MSE *testing* 0.00039151 dan MSE *training* 0.00099965. Pemilihan MAD dan MSE terkecil saat proses *testing* adalah menghindari terjadinya

overfitting, yaitu kondisi dimana MAD dan MSE *testing* membesar, sedangkan proses *training* kecil. Dari hasil proses tersebut, maka arsitektur dengan 20 unit pada layer tersembunyi yang nantinya digunakan sebagai arsitektur untuk melakukan peramalan laju inflasi umum (M-T-M) berdasarkan 7 kelompok barang.

Plot data aktual (*target*) dan ramalan (*output*) dari arsitektur terpilih, yaitu 7 – 20 – 1 pada saat *training* dan *testing* dapat dilihat pada Gambar 4.4 dan Gambar 4.5 sebagai berikut.



Gambar 4.4 Plot data aktual (*target*) dan ramalan (*output*) saat proses *training*



Gambar 4.5 Plot data aktual (*target*) dan ramalan (*output*) saat proses *testing*

Dari proses *training*, terlihat bahwa MAD dan MSE yang dihasilkan oleh masing-masing arsitektur memiliki perbedaan yang tidak terlalu besar. Artinya bahwa dalam tahapan ini, JST *Backpropagation* sudah mampu mengenali pola dengan baik dengan berbagai banyaknya layer tersembunyi. Namun demikian, unit pada lapisan tersembunyi yang terlalu banyak mengakibatkan waktu komputasi yang dibutuhkan juga akan lama dan nilai *error* yang dihasilkan juga akan mengalami kenaikan. Dari proses *training* diatas, dapat disimpulkan bahwa dalam penelitian ini banyaknya unit pada lapisan tersembunyi yang memiliki nilai MSE minimum baik saat proses *training* maupun *testing* adalah 20 unit.

Sedangkan pada proses *testing*, peramalan laju inflasi umum (M-T-M) JST *Backpropagation* berdasarkan kelompok barang menggunakan arsitektur jaringan terpilih, yaitu 7 – 20 – 1 diberikan pada lampiran 6.

4.4 Peramalan Laju Inflasi Umum (M-T-M) Menggunakan JST Berdasarkan *Input* Model Regresi Terbaik

Setelah dilakukan pemilihan model regresi terbaik, diperoleh kesimpulan bahwa model regresi terbaik menggunakan 5 kelompok barang. Sehingga kelompok - kelompok barang yang mempengaruhi laju inflasi umum (M-T-M) adalah sebagai berikut :

1. Kelompok Bahan Makanan (X_1)
2. Kelompok Makanan Jadi, Minuman, dan Tembakau (X_2)
3. Kelompok Perumahan (X_3)
4. Kelompok Kesehatan (X_5)
5. Kelompok Transportasi dan Komunikasi (X_7).

Struktur *input* yang digunakan pada JST *Backpropagation* ditunjukkan oleh Tabel 4.11 berikut.

Tabel 4.11 Struktur data *input* JST *Backpropagation* berdasarkan Model Regresi Terbaik

| <i>Input</i> | | | | | Target (T) |
|--------------|-------|-------|-------|-------|-----------------------|
| X_1 | X_2 | X_3 | X_5 | X_7 | |
| ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |

Parameter - parameter *input* dan metode pendekatan penurunan gradien yang digunakan adalah sama dengan peramalan JST *Backpropagation* dengan menggunakan 7 kelompok barang. Arsitektur jaringan yang akan diuji juga sama yaitu 5 arsitektur meliputi 5 – 10 – 1, 5 – 15 – 1, 5 – 20 – 1, 5 – 25 – 1 dan 5 – 30 – 1. Perbedaan utama antar peramalan laju inflasi umum (M-T-M) berdasarkan model regresi terbaik ini adalah banyaknya kelompok yang digunakan, yaitu 5 dari 7 kelompok barang yang ada, sedangkan data yang digunakan adalah sama tetapi jumlahnya berbeda dan tentunya bobot yang digunakan antar jaringan dari setiap peramalan karena banyaknya unit pada lapisan *input* yang digunakan juga berbeda.

4.4.1 *Training dan Testing Berdasarkan Model Regresi Terbaik*

Proses *training* dan *testing* sama dengan tahap JST *Backpropagation* sebelumnya menggunakan 7 kelompok IHK yaitu menggunakan 80% data aktual untuk proses *training* dan 20% data aktual untuk proses *testing*. Tujuan utama tahap ini adalah mencari nilai MAD dan MSE terkecil pada proses *testing* sehingga diperoleh arsitektur terpilih untuk peramalan.

Hasil MAD dan MSE *training* dan *testing* peramalan laju inflasi umum (M-T-M) berdasarkan model regresi terbaik dengan JST *Backpropagation* adalah masing – masing seperti pada Tabel 4.12 dan Tabel 4.13 sebagai berikut.

Tabel 4.12 MAD hasil *training* dan *testing* model regresi terbaik


| No. | Arsitektur JST | MAD Training | MAD Testing |
|----------|-------------------|---------------|---------------|
| 1 | 5 – 10 – 1 | 0.0244 | 0.0214 |
| 2 | 5 – 15 – 1 | 0.0226 | 0.0130 |
| 3 | 5 – 20 – 1 | 0.0224 | 0.0121 |
| 4 | 5 – 25 – 1 | 0.0287 | 0.0319 |
| 5 | 5 – 30 – 1 | 0.0232 | 0.0168 |

Tabel 4.13 MSE hasil *training* dan *testing* model regresi terbaik


| No. | Arsitektur JST | MSE Training | MSE Testing |
|----------|-------------------|-------------------|-------------------|
| 1 | 5 – 10 – 1 | 0.00099985 | 0.00081464 |
| 2 | 5 – 15 – 1 | 0.00099937 | 0.00028357 |
| 3 | 5 – 20 – 1 | 0.00099916 | 0.00020884 |
| 4 | 5 – 25 – 1 | 0.00099974 | 0.00027258 |
| 5 | 5 – 30 – 1 | 0.00099941 | 0.00046046 |

Dari Tabel 4.12, tampak bahwa nilai MAD minimum pada saat *testing* adalah 0.0121 dan pada saat *training* adalah 0.0224. Nilai-nilai tersebut diperoleh dari arsitektur jaringan 5 – 20 – 1 yaitu menggunakan 20 unit pada lapisan tersembunyi. Hasil tersebut diperkuat dengan hasil MSE di Tabel 4.13 dengan MSE minimum pada saat *testing* adalah 0.00020884, sedangkan pada saat proses *training* nilai MSE minimum adalah 0.00099916. Karena nilai MAD dan MSE minimum ada pada arsitektur ini, maka model arsitektur inilah yang nantinya digunakan sebagai peramalan laju inflasi umum (M-T-M) berdasarkan *input* dari model regresi terbaik dengan 5 kelompok menggunakan JST *Backpropagation*.

Plot data aktual (*target*) dan ramalan (*output*) dari arsitektur terpilih, yaitu 5 – 20 – 1 pada saat *training* dan *testing* dapat dilihat pada Gambar 4.6 dan 4.7 sebagai berikut.



Gambar 4.6 Plot *training* data aktual (*target*) dan ramalan (*output*) model regresi terbaik



Gambar 4.7 Plot *testing* data aktual (*target*) dan ramalan (*output*) model regresi terbaik

Dari plot data aktual dan *output* ramalan baik *training* maupun *testing* menggunakan JST *Backpropagation* terlihat bahwa arsitektur yang terpilih dengan 20 unit pada lapisan tersembunyi memiliki karakteristik yang sama dengan data aktual (*target*). Secara grafik tampak jelas bahwa pada tahap pengujian (*testing*), JST *Backpropagation* dengan arsitektur terpilih mampu mengikuti pola naik dan turun dari data aktual. Perbedaan signifikan yang terjadi adalah pada bulan oktober 2011, dimana hasil ramalan mampu mengikuti pola naik data aktual, namun nilai perbedaan antara target dan *output* berbeda cukup jauh yaitu -0.60838 pada data aktual (*target*) dan -0.5785 pada data hasil ramalan (*output*). Terjadi perbedaan ramalan sebesar -0.02988.

Hasil proses *testing* JST *Backpropagation* menggunakan kelompok barang berdasarkan model regresi terbaik selengkapnya diberikan pada lampiran 8.

4.5 Pemilihan Model Peramalan Terbaik

Makridakis, dkk (1994) menyebutkan bahwa metode peramalan terbaik adalah metode yang menghasilkan *error* terkecil. Dalam penelitian ini nilai kesalahan yang digunakan adalah *Mean Absolute Deviation* (MAD) dan *Mean Square Error* (MSE). Perbandingan dari ketiga model yang diuji pada penelitian ini dapat dilihat pada Tabel 4.14 sebagai berikut.


Tabel 4.14 Perbandingan nilai MAD dan MSE

| Metode Peramalan | MAD | MSE |
|---|--------|------------|
| Regresi linier berganda berdasarkan model regresi terbaik | 0.0344 | 0.00170987 |
| JST <i>Backpropagation</i> berdasarkan laju inflasi kelompok barang | 0.0150 | 0.00039151 |
| JST <i>Backpropagation</i> berdasarkan <i>input</i> model regresi terbaik | 0.0121 | 0.00020884 |

Tabel 4.14 memperlihatkan bahwa dengan menggunakan model JST *Backpropagation* berdasarkan *input* model regresi terbaik lebih baik dalam melakukan peramalan data laju inflasi umum (M-T-M) berdasarkan laju inflasi kelompok barang daripada menggunakan model regresi terbaik dengan peramalan regresi linier berganda dan JST *Backpropagation* berdasarkan kelompok barang, karena nilai MAD dan MSE yang dihasilkan paling minimum. Hal ini bisa terjadi karena peneliti menduga pada data laju inflasi (M-T-M) yang digunakan belum stasioner sehingga dengan menggunakan regresi linier berganda walaupun sudah dilakukan pemilihan model regresi terbaik tidak dapat mendeteksi hal tersebut. Begitupula dengan JST *Backpropagation* yang menggunakan semua kelompok barang ternyata kurang tepat dalam menggunakan semua kelompok yang dijadikan *input* pada JST. Sehingga model dengan JST *Backpropagation* berdasarkan *input* model regresi terbaik dapat mengatasi kelemahan dari masing-masing metode tersebut.

4.6 Peramalan Dengan Model Terbaik

Model terbaik dari hasil perbandingan metode pada tabel 4.32 adalah model dari *JST Backpropagation* berdasarkan *input* model regresi terbaik. Setelah didapatkan model peramalan terbaik untuk meramalkan data laju inflasi umum (M-T-M) berdasarkan kelompok barang, maka jaringan telah mampu untuk melakukan peramalan data untuk waktu ke depan. Kemampuan jaringan dalam meramalkan 1,2,3,..., m periode ke depan juga merupakan suatu indikator dalam menentukan suatu model peramalan dikatakan baik, hal tersebut dibuktikan dengan *JST Backpropagation* yang lebih mampu mengikuti karakteristik dari data aktualnya daripada metode yang lain seperti pada Gambar 4.8 berikut.



Gambar 4.8 Perbandingan hasil peramalan

Model yang didapatkan dari *JST Backpropagation* berdasarkan *input* model regresi terbaik pada data laju inflasi (M-T-M) berdasarkan kelompok barang adalah model (5 – 20 – 1) atau jaringan yang memiliki 5 unit *input*, 20 unit dalam lapisan tersembunyi, dan 1 unit pada lapisan output adalah sebagai berikut.

$$\hat{y}_{(k)} = f^o \left[\left[\left(-0.1027 \cdot f_1^h \left(0.2664x_{1(k)} + 10.2730x_{2(k)} + 6.7314x_{3(k)} - 0.2785x_{4(k)} - 3.3620x_{5(k)} + 4.3312 \right) + \dots - \left(0.4024 \cdot f_{20}^h \left(0.2160x_{1(k)} + 5.2519x_{2(k)} - 11.1933x_{3(k)} - 0.6328x_{4(k)} + 2.597x_{5(k)} + 1.3961 \right) \right) \right] + 0.3449 \right]$$

Dari uji coba yang telah dilakukan menggunakan data *testing* dengan arsitektur terpilih berdasarkan model regresi terbaik yaitu 5 – 20 - 1, maka hasil peramalan laju inflasi umum (M-T-M) pada data *testing* harus dilakukan denormalisasi kembali sehingga data kembali ke bentuk awal. Hasil peramalan laju inflasi umum (M-T-M) berdasarkan kelompok barang yang masuk ke dalam model regresi terbaik pada tahun 2012 adalah sebagai berikut :

Tabel 4.15 Hasil peramalan laju inflasi umum (M-T-M) tahun 2012
JST *Backpropagation* berdasarkan model regresi terbaik

| No. | Bulan | Hasil Peramalan Laju Inflasi Umum (M-T-M) Tahun 2012 |
|-----|-----------|---|
| 1 | Januari | 1,20 |
| 2 | Februari | -0,14 |
| 3 | Maret | 0,29 |
| 4 | April | -0,06 |
| 5 | Mei | -0,03 |
| 6 | Juni | 0,78 |
| 7 | Juli | 0,78 |
| 8 | Agustus | 0,03 |
| 9 | September | -0,01 |
| 10 | Oktober | 0,26 |
| 11 | November | 0,17 |
| 12 | Desember | 0,52 |

BAB V KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dari pembahasan sebelumnya, maka dapat diambil beberapa kesimpulan sebagai berikut :

1. Model JST *Backpropagation* dengan *input* berdasarkan model regresi terbaik dapat memberikan hasil ramalan laju inflasi umum (M-T-M) yang lebih akurat daripada analisis regresi linier berganda berdasarkan model regresi terbaik dan JST *Backpropagation* dengan *input* berdasarkan kelompok barang, karena memiliki nilai MAD dan MSE paling minimum yaitu masing-masing sebesar 0.0121 dan 0.00020884.

2. Model laju inflasi umum (M-T-M) dari model JST dengan *input* berdasarkan model regresi terbaik yaitu,

$$\hat{y}_{(k)} = f^o \left[\left[\left(-0.1027 \cdot f_1^h (0.2664x_{1(k)} + 10.2730x_{2(k)} + 6.7314x_{3(k)} - 0.2785x_{4(k)} - 3.3620x_{5(k)} + 4.3312) \right) + \dots - \left(0.4024 \cdot f_{20}^h (0.2160x_{1(k)} + 5.2519x_{2(k)} - 11.1933x_{3(k)} - 0.6328x_{4(k)} + 2.597x_{5(k)} + 1.3961) \right) \right] + 0.3449 \right]$$

5.2 Saran

Walaupun secara umum model JST *Backpropagation* berdasarkan *input* hasil dari model regresi terbaik ini dapat memodelkan laju inflasi umum (M-T-M) cukup baik, namun apakah hasil ini merupakan yang paling akurat atau tidak masih belum bisa dipastikan. Penentuan parameter - parameter seperti *learning rate*, *momentum*, *epochs* yang terbaik akan lebih membuat model akurat.

Pada penelitian ini data yang digunakan adalah data inflasi bulanan (M-T-M), maka dari itu untuk lebih mengembangkan penelitian mengenai peramalan laju inflasi umum, data inflasi tri wulan atau tahunan juga perlu dilakukan analisis lebih lanjut. Selain itu perlu ditambahkan peubah lain selain laju inflasi kelompok barang dalam penelitian selanjutnya dengan metode yang berbeda pula sehingga diperoleh hasil peramalan yang lebih baik dan akurat.

UNIVERSITAS BRAWIJAYA



DAFTAR PUSTAKA

- Anwar, A.B. 2010. *Analisis Pengaruh Kinerja Keuangan dan Kualitas Pengungkapan Informasi Terhadap Return Saham*. Magister Akutansi FE UI, Jakarta.
- Cryer, J.D. 1986. *Time Series Analysis*. PWS-KENT Publishing Company, Boston.
- Darmawan, R. 2009. *Perbandingan Jaringan Syaraf Tiruan Algoritma Backpropagation Dan Algoritma Genetika Untuk Peramalan Data Time Series*. Skripsi Program Studi Statistika Jurusan Matematika Fakultas MIPA Universitas Brawijaya Malang. (Tidak Dipublikasikan).
- Draper, N.R., dan H.Smith. 1992. *Analisis Regresi Terapan*. PT Gramedia Pustaka Utama, Jakarta.
- Galang, J.S. 2010. *Peramalan Beban Listrik Menggunakan Jaringan Saraf Tiruan Metode Kohonen*. ITS, Surabaya.
- Gaspersz, V. 2002. *Production Planning and Inventory Control*. PT. Gramedia Pustaka Utama, Jakarta.
- Ghozali, I. 2009. *SPSS. Analisis Multivariate Dengan Program SPSS*. Badan Penerbit Undip, Semarang
- Gross. 1982. *Forecasting for Trade*. Englewood Cliffs, Prentice-Hall, New Jersey.
- Gujarati, D.N. 2003. *Basic Econometric*. McGraw Hill.
- Haykin, S. 1994. *Neural Networks. A Comprehensive Foundation*. Macmillan, New York.
- Hecht-Nielsen. 1988. *Applications of Counterpropagation Networks*. Neural Networks.

Hendra, H. 2010. *Detektor Sniffing Aktif (ARP Spoofing) Dengan Metode Jaringan Saraf Tiruan Konstruktif Backpropagation*. UIN, Malang.

Kusumadewi, D. 2003. *Artificial Intelligence, Teknik dan Aplikasi*. Graha Ilmu, Yogyakarta.

Kumar, P.R., M.V.R. Murty, dkk. 2008. *Time Series Modeling Using Artificial Neural Networks*. <http://www.jatit.org/volumes/researchpapers/Vol4No12/12Vol4No12.pdf>. Tanggal akses: 18 Oktober 2011.

Makridakis, S. dan S.C.Wheelwright. 1994. *Metode-Metode Peramalan untuk Manajemen*. Edisi Kelima. Alih Bahasa Drs. Daniel Wirajaya. Binarupa Akasara, Jakarta.

Makridakis, S., S.C.Wheelwright dan V.E.McGee. 1999. *Metode dan Aplikasi Peramalan*. Edisi Kedua Jilid Satu. Alih Bahasa Hari Suminto. Binarupa Akasara, Jakarta.

Mendenhall, W., dan J.E Reinmuth. 1982. *Statistika Untuk Manajemen dan Ekonomi Jilid 2*. (terjemahan Drs. Sumarno). Penerbit Erlangga. Jakarta.

Nachrowi, D., Usman, H. 2006. *Analisis Ekonomi dan Keuangan*. Fakultas Ekonomi Universitas Indonesia. Jakarta.

Pujiati, A. 1997. *Analisis Regresi Linier Berganda untuk Mengetahui Hubungan Antara Beberapa Aktifitas Promosi dengan Penjualan Produk*. Skripsi Jurusan Statistika Institut Teknologi Sepuluh Nopember. Surabaya.

Rokhmawati, K. 2008. *Peramalan Data Time Series Menggunakan Metode ANFIS*. Syarat dalam Mencapai Gelar Sarjana Strata Satu Program Teknik Informatika Universitas Mercu Buana. Jakarta.

- Santoso, S. 2000. *Buku Latihan SPSS Statistik Parametrik*. PT Elex Media Komputindo, Jakarta.
- Santoso, S. 2003. *Statistik Deskriptif Konsep dan Aplikasi dengan Microsoft Excel dan SPSS*. Penerbit Andi, Jogjakarta.
- Schlitter. 2008. *A Case Study of Time series Forecasting with Backpropagation Networks*. http://www.nicoschlitter.de/downloads/Schlitter_ChemInfBericht2008.pdf. Tanggal akses : 18 Oktober 2011
- Setyadharma, A. 2010. *Uji Asumsi Klasik Dengan SPSS 16.0*. Fakultas Ekonomi. Universitas Negeri Semarang.
- Setyowati, E. 2004. *Ekonomi Makro Pengantar Edisi 2*. Bagian Penerbitan STIE YKPN Yogyakarta.
- Simamora, B. 2004. *Analisis Multivariat Pemasaran*. PT. Gramedia Pustaka Utama. Jakarta.
- Suhartono. 2007. *Feedforward Neural Networks Untuk Pemodelan Runtun Waktu*. Disertasi Universitas Gajah Mada. Yogyakarta.
- Sulastini, S. 2007. *Pengaruh Karakteristik Perusahaan Terhadap Social Disclosure Perusahaan Manufaktur Yang Telah Go Public*. Skripsi S1 Fakultas Ekonomi Undip.
- Suryono, H. 2009. *Penerapan Jaringan Syaraf Tiruan Untuk Peramalan (Peralaman Menggunakan Data Mining)*. <http://www.petra.ac.id/~puslit/journals/pdf.php?PublishedID=IND00020205>. Tanggal akses: 18 Oktober 2011.
- Wahyuningsih, D., Idah,Z., dan Zainuri. 2010. *Prediksi Inflasi Indonesia dengan Model Artificial Neural Network*. Skripsi Fakultas Ekonomi Universitas Muhammadiyah Malang.

- Wardani, U.G.S. 2006. *Penggunaan Algoritma Genetika dan Artificial Neural network Untuk Peramalan Harga Saham*. Tesis Program Studi Teknik dan Manajemen Industri Institut Teknologi Bandung.
- Wibisono, D. 2002. *Riset Bisnis (Panduan bagi praktisi dan akedemisi)*. PT Gramedia Pustaka Utama, Jakarta.
- Widarjono, A. 2007. *Ekonometrika Teori dan Aplikasi*. Ekononisia FE UII, Yogyakarta
- Widrow dan Hoff. 1960. *Adaptive switching circuits*. Institute of Radio Engineers.
- Yani, E. 2005. *Pengantar Jaringan Syaraf Tiruan*. http://trirezqiarian.toro.files.wordpress.com/2007/05/jaringan_syaraf_tiruan.pdf. Tanggal akses: 18 Oktober 2011.
- Yao, J.T., dan C.L.Tan. 2001. *Guidelines for Financial Forecasting with Neural Networks*. http://www2.cs.uregina.ca/~jtyao/Papers/guide_iconip01.pdf. Tanggal Akses: 18 Oktober 2011.
- Zurada, J.M. 1992. *Introduction to Artificial Neural Systems*. West Publishing Company.