

## PERANCANGAN SISTEM PAKAR UNTUK IDENTIFIKASI KECEPATAN PUTARAN MOTOR INDUKSI

*Khairul Saleh,*

Staf Pengajar Institut teknologi Medan

*Dicky Apdilah*

Staff Pengajar Amik INTEL Com GLOBAL INDO, dicky@nusa.net.id

### ABSTRACT

*Induction motors are used in many industrial types. To make application system using induction motor, we use speed sensor as one of important apparatus to count rotor speed. Neural Network observer needs input data of current and voltage, designed to estimate rotor speed of induction motor. We expect Neural network observer replace the function of speed sensor. Neural network observer uses constructive backpropagation algorithm to learn input data.*

*Simulation result indicate that estimation of fluksi and speed obtained yield small error, equally neural network observer is able to identify fluksi and rotor speed of induction motor.*

*Keywords : Induction Motor, Neural network observer, and constructive algorithm*

### 1. Pendahuluan

Motor induksi adalah mesin yang kokoh, andal, dan murah dibandingkan dengan motor DC. Dalam aplikasi motor induksi pada industri diperlukan pengoperasian kecepatan variable, untuk mendapatkan kecepatan variable dapat dilakukan dengan sistem loop tertutup oleh karena itu diperlukan sensor kecepatan. Namun sensor kecepatan mempunyai kelemahan-kelemahan, misalnya kurang akuratnya hasil pengukuran yang diakibatkan penempatan system sensor terlalu jauh dari system pengendalian sehingga tidak efektif untuk system pengendalian dengan plant yang besar. Karena kelemahan-kelemahan penggunaan sensor tersebut maka pada penelitian ini akan dirancang suatu observer yang dapat menggantikan sensor kecepatan.

Metode kontrol vektor tanpa sensor kecepatan (speed sensorless vector control methods) untuk motor industri dikembangkan begitu pesat [1 – 6]. Dalam aplikasi sistem penggerak, kontrol loop tertutup mempunyai beberapa variabel yang penting yaitu torsi, kecepatan, dan posisi. Untuk memperoleh respon arus yang cepat, sebuah loop torsi akan digunakan untuk sistem pengaturan kecepatan dan posisi. Sedangkan untuk memperoleh respon torsi yang cepat diperlukan sebuah kontroler fluksi yang terpisah. Pemisahan kontroler fluksi dan torsi dinamakan kontrol vektor (field oriented control) [7]. Dengan metode field

oriented control motor induksi mempunyai karakteristik yang sama dengan motor DC.

Neural network observer dengan pembelajaran backpropagasi merupakan salah satu pengembangan observer yang dapat menunjukkan unjuk kerja yang sangat baik sehingga dalam hasil simulasinya akan diperoleh error fluksi sebenarnya dan fluksi yang diramalkan dapat dijaga dengan interval yang kecil [4].

Namun pembelajaran backpropagasi mempunyai kelemahan yaitu arsitektur jaringan harus ditentukan secara tepat. Arsitektur jaringan yang terlalu kecil tidak akan menghasilkan estimasi dengan baik, tetapi jika ukuran arsitektur jaringan terlalu besar akan menyebabkan over-fitting sehingga generalisasi menjadi buruk. Oleh sebab itu dalam penelitian ini dirancang suatu observer yang dapat mengestimasi fluksi sekaligus kecepatan yang diperlukan pada pengontrolan motor induksi dengan menggunakan algoritma pembelajaran backpropagasi terkonstruksi (constructive backpropagation).

Algoritma backpropagasi terkonstruksi merupakan pengembangan dari algoritma backpropagasi yaitu mempunyai kemampuan untuk melakukan penyesuaian arsitektur jaringan dengan kompleksitas permasalahan yang dihadapi selama proses pembelajaran [7]. Dengan aturan pembelajaran tersebut akan memperkecil error besaran sebenarnya dengan estimasi yang akan diperoleh.

Hasil estimasi fluksi dan kecepatan rotor yang dihasilkan neural network observer dapat dipergunakan dalam system pengendalian kecepatan motor induksi dengan metode field oriented control. Hasil simulasi menunjukkan bahwa estimasi kecepatan dan fluksi yang diperoleh mempunyai error yang kecil dengan kata lain neural network observer mampu melakukan estimasi fluksi dan identifikasi kecepatan motor induksi.

**2. Prinsip Kerja Motor Induksi**


Motor induksi merupakan motor arus bolak balik (ac) yang paling banyak digunakan pada industri-industri. Prinsip kerja motor ini berdasarkan proses induksi yang terjadi pada bagian rotor. Secara singkat prinsip kerja motor induksi tiga fasa sebagai berikut :

- Apabila sumber tegangan tiga fasa disuplai pada kumparan stator maka akan timbul medan putar dengan kecepatan angular (  $\omega_s$  ).
- Medan putar stator akan memotong konduktor pada rotor sehingga akan terbangkit gaya gerak listrik (ggl) induksi.
- Karena rangkaian rotor merupakan rangkaian tertutup, maka akan timbul arus rotor yang diakibatkan oleh ggl tersebut.
- Interaksi antara arus dan medan putar menimbulkan torsi yang menyebabkan rotor berputar.
- Agar tegangan terinduksi, maka diperlukan adanya perbedaan antara kecepatan angular dari medan putar stator (  $\omega_s$  ) dan kecepatan putar rotor (  $\omega_r$  )

**2.2 Sistem Koordinat a-b-c**

Rangkaian ekuivalen motor induksi tiga fasa simetris bila ditinjau dalam rangkaian rotor yang berputar (rotating frame) akan ditunjukkan pada Gambar 2.1.

Rangkaian stator digambarkan sepanjang sumbu-sumbu as, bs, dan cs, sedangkan rangkaian rotor digambarkan sepanjang sumbu-sumbu ar, br, dan cr.



Gambar 2.1. Stator dan rotor motor induksi dalam sistem koordinat a, b, c

Berdasarkan gambar tersebut dapat dijabarkan persamaan tegangan stator dan rotor sebagai berikut :

$$V_{abc_s} = R_s i_{abc_s} + p\lambda_{abc_s}$$

$$V_{abc_r} = R_r i_{abc_r} + p\lambda_{abc_r}$$

$$p = \frac{d}{dt}$$

$$p\lambda_{abc_s} = L_s i_{abc_s} + L_m i_{abc_r}$$

$$p\lambda_{abc_r} = L_r i_{abc_r} + L_m i_{abc_s}$$

Matrik  $L_s$  dan  $L_r$  dinyatakan sebagai


$$L_s = \begin{bmatrix} L_{l_s} + L_{m_s} & \frac{1}{2} L_{m_s} & \frac{1}{2} L_{m_s} \\ -\frac{1}{2} L_{m_s} & L_{l_s} + L_{m_s} & -\frac{1}{2} L_{m_s} \\ -\frac{1}{2} L_{m_s} & -\frac{1}{2} L_{m_s} & L_{l_s} + L_{m_s} \end{bmatrix}$$

dan

$$L_r = \begin{bmatrix} L_{l_r} + L_{m_r} & \frac{1}{2} L_{m_r} & \frac{1}{2} L_{m_r} \\ \frac{1}{2} L_{m_r} & L_{l_r} + L_{m_r} & -\frac{1}{2} L_{m_r} \\ \frac{1}{2} L_{m_r} & -\frac{1}{2} L_{m_r} & L_{l_r} + L_{m_r} \end{bmatrix}$$

**Sistem Koordinat d-q**

Rangkaian ekuivalen motor induksi dalam koordinat d-q dapat dilihat pada Gambar 2.2.




Gambar 2.2. Rangkaian ekuivalen motor induksi dalam koordinat d-q

Untuk mentransformasi persamaan dari sistem koordinat a-b-c ke sistem koordinat d-q, menggunakan persamaan (2.7), dengan variable f sebagai tegangan, arus, atau fluksi.

$$f_{qds} = T(\theta) f_{abc_s}$$

**PWM Inverter**


Vektor rotasi terhadap arus magnetisasi dan arus torsi menghasilkan arus fase referensi yang digunakan untuk sinyal kontrol PWM inverter. Prosedur pensaklaran (switching) diperlihatkan pada Gambar 2.6, dengan  $E_{s\_ph}$  adalah tegangan yang akan digunakan oleh stator.



Gambar 2.3 PWM inverter

**NEURAL NETWORK**

Jaringan syaraf tiruan didasari dari cara kerja jaringan syaraf manusia dalam menerima rangsangan dan merespon rangsangan yang diterima, sehingga arsitektur jaringan syaraf tiruan dibuat menyerupai arsitektur jaringan syaraf manusia [11]. Otak manusia dapat dikatakan sebagai suatu computer yang sangat modern yang terdiri dari sekitar 10 milyar neuron, aktivitas manusia akan diatur oleh neuron tersebut. Masing-masing neuron akan selalu berhubungan dengan neuron yang lain dan membentuk suatu jaringan yang disebut sebagai neural network (jaringan syaraf). Sebuah sel syaraf terdiri dari sebuah badan sel (soma) dengan inti sel (nucleus) di dalamnya. Pada badan sel terdapat serat halus yang disebut dendrit.




Gambar 3.1. Sel Syaraf

Dendrit berfungsi mengantarkan sinyal masuk ke dalam badan sel. Pada badan sel terdapat serat panjang yang disebut akson, bermula dari sebuah titik yang dinamakan akson hillock. Akson berfungsi menyalurkan sinyal dari badan sel. Ujung akson mempunyai cabang-cabang kecil yang bersentuhan dengan dendrit, soma, atau akson dari sel syaraf lain. Sambungan ini disebut sinapsis.

Pemodelan sistem jaringan syaraf manusia kedalam model matematik dalam bentuk neural network didasarkan atas beberapa asumsi, yaitu:

- A. Pemrosesan informasi terjadi pada elemen-elemen prosesor sederhana yang dinamakan neuron.
- B. Sinyal yang dilewatkan di antara neuron-neuron melalui suatu penghubung.
- C. Setiap penghubung memiliki pembobot  $w_{kj}$ , dengan sinyal yang dikirim  $x_j$  akan dikalikan dengan pembobot tersebut.
- D. Setiap neuron memiliki fungsi aktivasi  $\phi(\cdot)$  biasanya non-linier terhadap masukan-masukannya untuk menghasilkan sinyal keluaran.

Neuron adalah unit pemroses informasi yang fundamental untuk operasi jaringan syaraf sehingga neuron sering diistilahkan sebagai elemen pemroses (processing element). Secara sederhana bentuk matematik dari neural network dijelaskan pada Gambar 3.2.



Gambar 3.2. Pemodelan jaringan syaraf ke model matematik

Sebuah neuron k dapat dituliskan dalam dua persamaan di bawah ini.

$$u_k = \sum_{j=1}^p w_{kj} x_j$$

$$y_k = \phi(u_k - \theta_k)$$

dengan

- p = jumlah sinyal masukan
- $x_1, x_2, \dots, x_p$  = sinyal masukan
- $w_{k1}, w_{k2}, \dots, w_{kj}$  = bobot sinapsis neuron k
- $u_k$  = keluaran hasil penjumlahan
- $\theta_k$  = nilai ambang
- $\phi(\cdot)$  = fungsi aktivasi
- $y_k$  = sinyal keluaran neuron.

Dapat disimpulkan karakteristik neural network ditentukan oleh :

- Fungsi aktivasi
- Pola koneksi antar neuron (arsitektur)
- Metode penentuan pembobot (algoritma pelatihan atau pembelajaran)


### 3.1 Fungsi Aktifasi

Operasi dasar dari neural network merupakan penjumlahan dari perkalian masing-masing sinyal input dengan pembobotnya kemudian masuk ke dalam suatu fungsi transfer (fungsi aktivasi) untuk menghasilkan output. Fungsi aktivasi disimbolkan dengan  $\phi(\cdot)$  bentuknya bermacam-macam dan memiliki keunggulan masing-masing. Pertimbangan yang dapat digunakan untuk menentukan fungsi aktivasi yang sesuai adalah kemudahan perhitungan dan pengaruhnya pada konvergensi. Fungsi aktivasi dapat dibedakan menjadi tiga tipe dasar, yaitu :

#### 1. Fungsi ambang

Persamaan fungsi aktivasi ini adalah

$$\phi(v) = \begin{cases} 0, & \text{jika } v < 0 \\ 1, & \text{jika } v > 0 \end{cases}$$




Gambar 3.3. Fungsi ambang

#### Fungsi identitas

Fungsi ini dinyatakan dengan persamaan

$$\phi(v) = v \text{ untuk seluruh } v$$




Gambar 3.4. Fungsi identitas

### 3. Fungsi sigmoid

Fungsi sigmoid adalah fungsi aktivasi yang paling sering digunakan untuk membentuk jaringan syaraf tiruan. Fungsi sigmoid didefinisikan seperti Persamaan (3.7).

$$\phi(v) = \frac{1}{1 + \exp(-av)}$$

dengan a adalah parameter kemiringan dari fungsi sigmoid, yang grafiknya dapat dilihat pada gambar 3.5. Jika harga a mendekati tak terhingga, maka fungsi sigmoid di atas akan menjadi sebuah fungsi ambang.




Gambar 3.5. Fungsi sigmoid dengan beberapa parameter a

Neuron-neuron dalam jaringan syaraf saling berhubungan dengan struktur tertentu. Arsitektur jaringan syaraf dapat dibedakan sebagai berikut :

#### 1. Jaringan umpan maju satu lapisan (single-layer feedforward network)

Ilustrasi dari struktur ini dapat dilihat pada Gambar 3.6. Pada Gambar 3.6 lingkaran mewakili sebuah neuron. Simpul-simpul pada input tidak disebut sebagai lapisan karena fungsinya hanya mendistribusikan masukan dan tidak melakukan perhitungan.




Gambar 3.6. Jaringan umpan maju satu lapisan

#### Jaringan umpan maju banyak lapisan (multi-layer feedforward network)

Pada struktur ini terdapat satu atau beberapa hidden layer. Disebut hidden karena unit-unit pada lapisan ini tidak berhubungan dengan

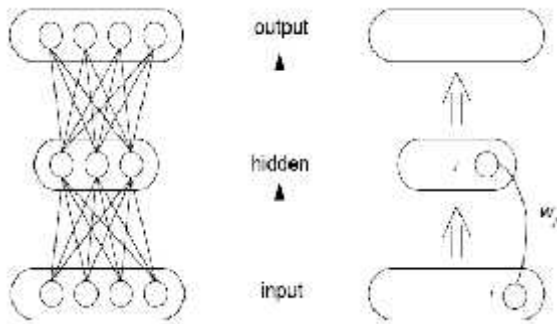
dunia luar. Contoh struktur ini ditunjukkan pada Gambar 3.7.



Gambar 3.7. Jaringan umpan maju dengan satu hidden layer

**Backpropagasi**

Backpropagasi sering digunakan sebagai supervised learning untuk neural network.



Gambar 3.8. Feedforward neural network, hubungan dari unit i ke unit j


Multilayer feedforward network ditunjukkan pada Gambar 3.8 diatas. Didefinisikan i, j, dan k sebagai unit, o sebagai output unit, p sebagai pola pembelajaran (dimana masing-masing pola pembelajaran berisi input dan output target),  $x_j^p$  sebagai input untuk unit j ke pola p,  $Y_j^p$  sebagai output aktivasi dari unit j pada pola p,  $W_{ij}$  sebagai bobot dari unit i ke unit j,  $T_j^p$  sebagai target aktivasi untuk unit j dalam pola p untuk (j o),  $E^p$  sebagai global output error untuk pola pembelajaran p dan E sebagai global error untuk set pembelajaran. Diasumsikan jenis network adalah :

$$x_j^p = \sum w_{ji} y_i^p$$


$$y_j^p = \sigma(x_j^p) = \frac{1}{1 + e^{-x_j^p}}$$

**Backpropagasi Terkonstruksi**

Algoritma arsitektur jaringan yang tepat sangatlah diperlukan. Terlalu kecil jaringan tidak dapat mempelajari masalah dengan baik, tetapi terlalu besar mengakibatkan over-fitting dan kinerja yang lemah.



Gambar 3.10. Inisialisasi state pada backpropagasi terkonstruksi

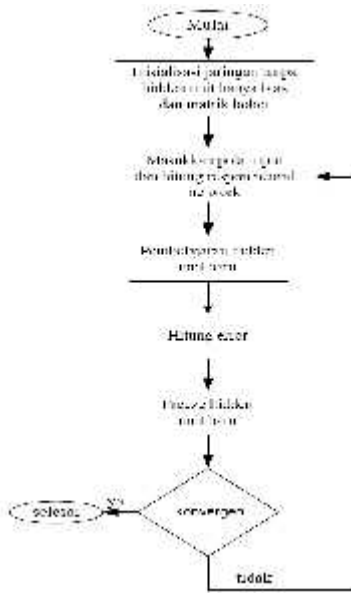


Gambar 3.11. Inisialisasi state setelah penambahan dua hidden unit

Algoritma dasar dari backpropagasi terkonstruksi adalah:

1. Inisialisasi:

Jaringan tidak mempunyai hidden unit. Bias pembobot dan hubungan langsung (hubungan short cut) dari input ke output unit setelah pembelajaran pembobot dari konfigurasi inisialisasi adalah tetap.



Gambar 3.13. Diagram alir backpropagasi terkonstruksi

2. Pembelajaran hidden unit baru :

Menghubungkan input ke unit baru (unit baru adalah unit ke- $i$ ,  $i > 0$ ) dan menghubungkan outputnya ke output unit. Mengatur semua pembobot yang dihubungkan ke unit baru.

3. Pembekuan (freeze) hidden unit baru.

Menetapkan pembobot yang dihubungkan ke unit baru.


4. Pengetesan konvergensi

Jika jumlah hidden unit sekarang menghasilkan solusi yang bisa diterima (konvergen) maka pembelajaran berhenti jika tidak maka kembali ke langkah 2.

Algoritma diatas dapat digambarkan dalam bentuk diagram alir pada Gambar 3.13.

**Perancangan Neural Network Observer**

Mengembangkan dari beberapa penelitian yang telah dilakukan oleh H. Kubota, dkk [1], Jehudi Maes, dkk [2], V. Petridis [4] dan Seong-Hwan Kim[6], maka blok diagram sistem yang dikembangkan pada penelitian ini adalah seperti ditunjukkan pada Gambar 4.1.



Gambar 4.1 Diagram blok sistem

Blok diagram Gambar 4.1

dikembangkan kedalam simulasi permodelan sistem dengan menggunakan fasilitas m-file dari Matlab 6.0. Rating motor tiga fasa yang dipakai untuk simulasi adalah :

115 Volt , 2 pasang kutub, 60 Hz

$R_s = 176$  resistansi stator (ohm)

$R_r = 190$  resistansi rotor (ohm)

$L_s = 3.79$  induktansi diri stator (H)

$L_r = 3.31$  induktansi diri rotor (H)

$M = 3.21$  induktansi gandeng (H)

$J = 1.05e-5$  momen inersia (kg.m<sup>2</sup>)

$K_d = 1.49e-5$  konstanta gesek (kg.m<sup>2</sup>/s)

Neural network observer berfungsi sebagai estimator fluksi sehingga fluksi rotor yang merupakan variabel keadaan dari model motor induksi dapat diketahui dan dimanfaatkan dalam sistem pengendalian. Persamaan (2.20) digunakan neural network observer untuk menirukan dinamika persamaan variabel motor induksi sehingga dengan pembelajaran data-data yang diperoleh, neural network observer dapat mengestimasi fluksi dan kecepatan rotor.

**Pengambilan Data**

Data pembelajaran diambil dari simulasi sistem saat dijalankan tanpa neural network observer. Motor induksi dikemudikan dengan PWM inverter dan time sampling yang diambil sebesar 0,00005 detik. Data ini digunakan untuk pembelajaran neural network dengan metode backpropagasi terkonstruksi.


**Pembelajaran**

Metode pembelajaran untuk estimasi fluksi dan identifikasi kecepatan motor induksi tiga fasa menggunakan pembelajaran backpropagasi terkonstruksi (learning constructive backpropagation). Jaringan ini terdiri dari tiga layer, yaitu input layer, hidden layer, dan output layer.


Proses pembelajaran menggunakan 10 neuron pada masing-masing hidden layer dan pembelajaran dilakukan sebanyak 500 epoch. Apabila hasil pembelajaran belum konvergen atau tidak sesuai target maka akan terjadi penambahan hidden layer baru dengan jumlah neuron dan epoch yang sama yaitu 10 neuron dan 500 epoch, penambahan hidden layer akan berhenti bila hasil pembelajaran konvergen.

Pembelajaran dilakukan dengan menggunakan parameter laju pembelajaran (learning rate) 0,5 dan error yang ingin dicapai adalah 0,001. Harga awal pembobot ditentukan random berkisar antara -0,5 dan 0,5 untuk mencari parameter optimal yang menghasilkan kinerja yang terbaik dari neural network yaitu dengan melakukan penilaian menurut suatu besaran mean square error sesuai dengan persamaan (3.10).

Konfigurasi saat pembelajaran off-line yaitu pembelajaran dari neural network observer untuk estimasi fluksi rotor menggunakan model motor induksi tanpa adanya parameter dari motor induksi pada saat beroperasi, konfigurasi tersebut dapat dilihat pada Gambar 4.2. Pada Gambar 4.3 diperlihatkan konfigurasi pembelajaran off line neural network observer untuk identifikasi kecepatan putaran rotor.




Gambar 4.2. Skema pembelajaran off line neural network observer untuk estimasi fluks




Gambar 4.3 Skema pembelajaran off line neural network observer untuk identifikasi kecepatan

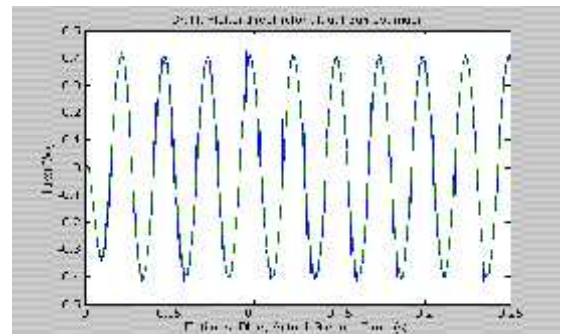
Berikut ini beberapa hasil simulasi yang diperoleh untuk estimasi fluksi rotor, performansi yang ditunjukkan menampilkan hasil simulasi pada kecepatan yang berbeda.




Gambar 4.5 Estimasi fluksi direct (Fdr) pada kecepatan 1000 rpm



Gambar 4.6 Estimasi fluksi quadratur (Fqr) pada kecepatan 1000 rpm

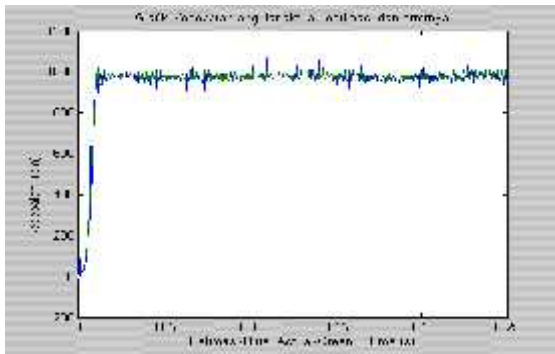


Gambar 4.7 Estimasi fluksi direct (Fdr) pada kecepatan 1200 rpm

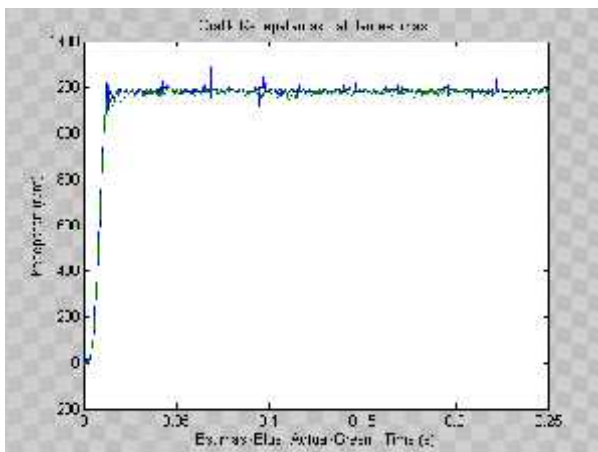


Gambar 4.8 Estimasi fluksi quadratur (Fqr) pada kecepatan 1200 rpm

Sedangkan untuk identifikasi kecepatan diperoleh hasil sebagai berikut :



Gambar 4.9 Identifikasi kecepatan rotor 1000 rpm



Gambar 4.10 Identifikasi kecepatan rotor 1200 rpm

Pengujian dilakukan dengan pengambilan kecepatan yang berbeda, gambar untuk masing-masing pengujian dapat dilihat secara lengkap pada lampiran C untuk simulasi fluksi direct, lampiran D untuk simulasi fluksi quadratur, dan lampiran E untuk simulasi kecepatan rotor motor induksi.

#### 4.5 Analisis

Dari gambar simulasi fluksi yang dilakukan memperlihatkan bahwa neural network observer dapat mengestimasi fluksi direct dan fluksi quadratur dengan nilai kesalahan yang relatif kecil yang ditunjukkan dengan berhimpitnya fluksi aktual dengan fluksi hasil estimasi.

Tabel 4.1 Pengujian neural network observer pada kecepatan yang berbeda

No	KECEPATAN ROTOR	STANDART ERROR ESTIMASI		
		FLUKSI DIRECT (Wb)	FLUKSI QUADRATUR (Wb)	KECEPATAN (RPM)
1	500 rpm	0,0380	0,0361	19,5077
2	800 rpm	0,0371	0,0343	18,7945
3	900 rpm	0,0388	0,0206	16,9156
4	1200 rpm	0,0290	0,0298	16,3298

Dari Tabel 4.1 dapat ditunjukkan bahwa nilai Standart Error Estimasi kecepatan yang terjadi relatif kecil berkisar antara 16,3298 (kecepatan 1200 rpm) sampai 19,5077 (kecepatan 500 rpm). Hal ini menunjukkan bahwa neural network observer yang dirancang mampu mengestimasi kecepatan rotor dengan baik.

Pada pengujian kecepatan 100 rpm didapat Standart Error Estimasi untuk fluksi direct dan quadratur adalah 0,082678 Wb dan 0,09706 Wb. Sedangkan untuk Standart Error Estimasi kecepatan rotor adalah 22,3478 rpm (22,34%). Dari data pengujian tersebut diketahui bahwa SEE kecepatan relative cukup besar dan terjadi riak (ripple) pada hasil estimasi namun neural network observer yang dirancang masih mampu mengikuti pola fluksi dan kecepatan rotor, hal ini disebabkan karena pembelajaran yang dilakukan cenderung spesifik terhadap data kecepatan tinggi sehingga neural network observer tidak dapat mengestimasi dengan tepat pada kecepatan dibawah 100 rpm.

#### Kesimpulan

Berdasarkan hasil simulasi dan analisis yang telah dilakukan terhadap neural network observer maka didapat kesimpulan sebagai berikut :

- Simulasi estimasi fluksi neural network observer dengan kecepatan yang berbeda diperoleh nilai Standar Error Estimasi (SEE) fluksi direct rotor berkisar antara 0,0188 Wb sampai 0,0380 Wb. Sedangkan untuk nilai Standar Error Estimasi (SEE) fluksi quadratur berkisar antara 0,0206 Wb sampai 0,0361 Wb.
- Simulasi identifikasi kecepatan rotor neural network observer dengan kecepatan yang berbeda diperoleh nilai Standar Error Estimasi (SEE) berkisar antara 16,3298 rpm sampai 19,5077rpm.

Neural network observer yang dirancang mampu mengestimasi fluksi dan kecepatan rotor dengan baik yaitu ditunjukkan dengan error yang kecil, sekitar 3,9%



(kecepatan 500rpm) sampai 1,36% (kecepatan 1200). Namun untuk estimasi kecepatan 100 rpm error yang didapat cukup besar yaitu 22,34%. Dari data pengujian tersebut diketahui bahwa SEE kecepatan relative cukup besar dan terjadi riak (ripple) pada hasil estimasi namun neural network observer masih mampu mengikuti pola fluksi dan kecepatan rotor.

#### REFERENSI

1. H. Kubota, K. Matsuse, and T. Nakano, DSP-Based speed adaptive flux observer of induction motor, *IEEE Trans. Ind. Applicat.*, vol 29, pp 344-348, Mar/Apr. 1993
2. Jehudi Maes and Jan A. Melkebeek, Speed Sensorless Direct Torque Control of Induction Motors Using an Adaptive Observer, *IEEE Trans. On Industry Application*, Vol. 36, No.3, May/June, 2000
3. Eng Kian Kenneth Sng, Ah-choy Liew, and Thomas A. Lipo, New Observer Based DFO Scheme for Speed Sensorless Field Oriented Drive for Low-Zero-Speed Operating, *IEEE Trans. On Industry Application*, Vol.13, No.5, Sep 1998
4. J. Thecharis and V. Petridis, Neural Network Observer for Induction Motor Control, *IEEE Control System*, April 1994
5. Kouki Matsuse, Shotaro Taniguchi, Tatsuya Yoshizumi, and Kazushige Namiki, A Speed Sensorless Vector Control of Induction Motor Operating at High Efficiency Taking Cre Loss Into Account, *IEEE Trans. On Industry application*, Vol.37, No.2, March/April, 2001
6. Seong-Hwan Kim, Tae-Sik Park, Ji-Yoon Too, and Gwi-Tae Park, Speed-Sensorless Vector Control of an Induction Motor Using Neural Network Speed Estimation, *IEEE Trans. On Industry application*, Vol.48, No.3, June 2001
7. Boldea, I., *Vector control of AC drive*, CRC Press, Inc., 1992
8. Lehtokangas, M., Modelling with Constructive Bacpropagation, *Neural Network*, No.12, p.707-716, 1999
9. Derong Liu, Tsu-Shuan Chang, and Yi Zhang, A Constructive Algorithm for Feedforward Neural Network With Incremental Training, *IEEE Trans. On Industry application*, Vol.49, No.12, December 2002
10. Iradiratu, Mauridhi Hery Purnomo, Era Purwanto, Perancangan Model Observer untuk Identifikasi Kecepatan Motor Induksi, *Proceedings SMED*, Sep 2002
11. Fauset, L., *Fundamental of Neural Network*, Prentice-Hall International 1994
12. *Neural Network Toolbox User's Guide, For Use With MATLAB*, in *Mathworks HandBook*, Math Works, January 1998
13. Krause Paul C., *Analysis of Electric Machinery*, McGraw-Hill Book Company, Singapore, 1987.
14. Khishman, *Electric Motor Drive*, Prentice Hall, New Jersey 2001.
15. Era Purwanto, Application of Adaptive Neuro Fuzzy Inference System on the Development of the Observer for Speed Sensorless Induction Motor, *IEEE Catalogue No. 01CH37239-7803-7101-1*, 2000
16. Nasuha A, Mauridhi Herry.P, Deteksi Kanker Paru Melalui Citra Dahak Pasien Dengan Menggunakan Constructive Backpropagation, *Proceeding SITIA*, April 2000.
17. Rajesh P, Jihoon Yang, and Vasant H, Constructive Neural Network Learning Algorithms for Pattern Classification, *IEEE Trans. On Neural Network*, Vol.11, No.2, March 2000