

# Pendeteksian Harmonisa Arus Berbasis Feed Forward Neural Network Secara Real Time

Endro Wahjono<sup>1</sup>, Dimas Okky Anggriawan<sup>1</sup>, Achmad Luki Satriawan<sup>1</sup>, Aji Akbar Firdaus<sup>2</sup>, Eka Prasetyono<sup>1</sup>, Indhana Sudiharto<sup>1</sup>, Anang Tjahjono<sup>1</sup>, dan Anang Budikarso<sup>1</sup>

<sup>1</sup>Politeknik Elektronika Negeri Surabaya  
Jl. Raya ITS, Kampus PENS, Surabaya, 60111

<sup>2</sup>Universitas Airlangga  
Jl. Kampus C Mulyorejo, Surabaya, 60111  
e-mail: endro@pens.ac.id

**Abstrak**—Perkembangan konverter elektronika daya telah tersebar luas pada lingkup industri, komersial, dan aplikasi rumah. Perangkat tersebut menghasilkan harmonisa pada beban non linier. Harmonisa menyebabkan penurunan kualitas daya dalam sistem tenaga listrik. Untuk mencegah penurunan kualitas daya yang disebabkan harmonisa pada sistem tenaga listrik, pendeteksian harmonisa memiliki peran yang penting. Oleh karena itu, makalah ini mengusulkan feed forward neural network (FFNN) untuk mendeteksi harmonisa. Perancangan prototipe pendeteksian harmonisa dirancang dengan metode jaringan saraf tiruan tipe feed forward neural network yang memiliki dua tahap pemrosesan informasi yaitu tahap pelatihan dan tahap pengujian. FFNN memiliki input harmonisa dan output THDi. Untuk mendeteksi harmonisa dilakukan pelatihan dahulu dengan mengenali pola bentuk gelombang dan perhitungan proses fast fourier transform (FFT) secara offline. Pada perancangan prototipe menggunakan sensor arus AMC1100DUB, mikrokontroler dan display. Untuk memvalidasi algoritma yang diusulkan, dibandingkan dengan alat ukur standar dan FFT. Hasil menunjukkan algoritma yang diusulkan memiliki performa yang memuaskan dengan rata-rata error dibandingkan alat ukur standar adalah 5,33 %.

**Kata kunci:** *feed forward neural network, monitoring, fft, harmonisa, realtime*

**Abstract**—The development of power electronics converters has been widespread in the industrial, commercial, and home applications. The device is considered to produce harmonics in non-linear loads. Harmonics cause a decrease in power quality in the electric power system. To prevent a decrease in power quality caused by harmonics in the power system, the detection of harmonics has an important role. Therefore, this paper proposed feed forward neural network (FFNN) for harmonic detection. The design of harmonic detection device is designed with a feed forward neural network method that it has two stages of information processing, namely the training stage and the testing stage. FFNN has input harmonics and THDi as output. To detect harmonics, first training is conducted to recognize waveform patterns and calculate the fast fourier transform (FFT) process offline. Prototype using the AMC1100DUB current sensor, microcontroller and display. To validate the proposed algorithm, compared by standard measurement tool and FFT. The results show the proposed algorithm has good perform with the average percentage error compared by standard measurement tool and FFT of 5.33 %.

**Keywords:** *feed forward neural network, monitoring, fft, harmonic, realtime*

Copyright © 2020 Jurnal Rekayasa Elektrika. All right reserved

## I. PENDAHULUAN

Harmonisa merupakan gangguan pada sistem distribusi tenaga listrik akibat distorsi gelombang arus dan tegangan. Peningkatan penggunaan beban non linier seperti *uninterruptible power supply* (UPS), *variable frequency drive* (VFD), dan peralatan konverter *switching* telah menyebabkan harmonisa pada sistem tenaga listrik. Akibat distorsi harmonisa, menyebabkan kesalahan pembacaan alat ukur dan mengurangi umur pemakaian dari perangkat elektronik. Pemantauan kualitas daya pada sistem tenaga listrik memiliki peran yang sangat penting [1].

Pada masa lalu, untuk dapat mendeteksi harmonisa

banyak dilakukan dengan berbagai macam teknik. Metode seperti Fast Fourier Transform (FFT) merupakan salah satu metode yang menggunakan teknik sederhana dan perhitungan yang praktis. Penyimpangan frekuensi dasar dapat menyebabkan kesalahan estimasi. Utamanya dalam mengambil kecepatan sampling untuk analisis bisa menyebabkan kebocoran spektrum [2], [3]. Walaupun kelemahan ini bisa diperbaiki, tentunya membutuhkan biaya tambahan dalam memperbaiki [4], [5]. Pendekatan berbasis FFT konvensional dalam proses komputasi membutuhkan lebih dari satu siklus sampel sinyal. Akibatnya kemampuan komputasi secara *real time* dapat mengalami penurunan [6].

Metode *feed forward neural network* (FFNN) merupakan metode yang populer yang digunakan dalam berbagai penelitian. Diantara metode struktural FFNN, algoritma pelatihan *lavenberg marquardt backpropagation* adalah salah satu metode yang dapat menangani masalah kualitas daya [7]–[9]. Oleh karena itu, FFNN dapat digunakan untuk mendeteksi harmonisa [10]. Dengan metode FFNN telah terbukti memiliki tingkat akurasi pendeteksian harmonisa yang baik. Namun, pendeteksian harmonisa menggunakan metode FFNN belum diaplikasikan secara *real time*.

Pada makalah ini, penulis merancang prototipe sistem pendeteksi harmonisa arus dengan metode FFNN dan menerapkan pada sumber 220 V yang terhubung dengan beban non linier secara *real time*. Tujuannya adalah untuk mendeteksi harmonisa arus yang mengalir saat perangkat terhubung dengan beban non linier. Pemodelan perangkat terdiri dari sensor arus yang terintegrasi dengan mikrokontroler ARM STM32F7. Sensor yang di implementasikan pada perangkat adalah sensor arus AMC1100DUB untuk mengukur besaran nilai arus yang mengalir dalam sistem tenaga listrik dan menjadikan nilai pembacaan sebagai *input* pada proses FFNN setelah tahap pelatihan. Hasil dari pengukuran pembacaan dari sistem dianalisa dan dibandingkan dengan hasil perhitungan *Fast Fourier Transform* (FFT).

## II. DESAIN DAN PERANCANGAN SISTEM

### A. Karakteristik Harmonisa

Didalam saluran tenaga listrik bolak-balik (AC), terdapat sinyal periodik baik tegangan maupun arus pada beban non linier yang dapat diasumsikan dengan kuantitas dan sudut fasa yang acak dan dinyatakan dalam persamaan deret *fourier*.

$$S(t, \gamma) = \sum_{h=1}^H A_h(\gamma) \sin(2\pi f_h t + \theta_h(\gamma)) \quad (1)$$

dimana,  $h$  merupakan urutan harmonisa dan  $A_h$ ,  $f_h$ ,  $\theta_h$  adalah amplitudo, frekuensi, dan sudut fasa dari harmonisa. Koefisien  $\gamma$  adalah variabel gangguan yang mencakup sinyal terdistorsi.

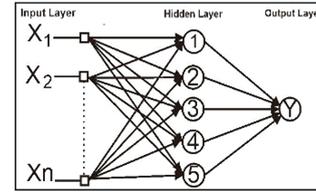
$$A_h(\gamma) = P_h(S(t_1, \gamma), S(t_2, \gamma), \dots, S(t_n, \gamma)) \quad (2)$$

$$\theta_h(\gamma) = Q_h(S(t_1, \gamma), S(t_2, \gamma), \dots, S(t_n, \gamma)) \quad (3)$$

Pada persamaan,  $P_h$  dan  $Q_h$  digunakan dalam memetakan fungsi non linier untuk amplitudo dan sudut fase pada harmonisa ke- $h$ .

Nilai harmonisa dapat diperoleh dari spektrum yang merepresentasikan nilai komponen harmonisa dalam daerah frekuensi. Indikator untuk menunjukkan nilai harmonisa adalah total harmonic distortion (THD). Di (4) menunjukkan persamaan untuk mendapatkan THD

$$THD_i = \frac{\sqrt{\sum_{n=2}^N I_n^2}}{I_1} \times 100\% \quad (4)$$



Gambar. 1 Struktur jaringan syaraf tiruan

Keterangan,  $I_n$  dan  $I_1$  adalah nilai arus dalam komponen harmonisa pada kelipatan frekuensi fundamental.

### B. Algoritma Feed Forward Neural Network

Jaringan syaraf tiruan terinspirasi seperti cara kerja otak pada manusia, seperti diperlihatkan pada Gambar 1. Setiap ujung jaringan saling terhubung satu sama lain untuk memproses suatu informasi. Setiap lapisan mengandung node atau *neuron* yang merupakan elemen informasi untuk pemrosesan suatu data. Setiap *neuron* saling terhubung dengan neuron lain yang direpresentasikan dengan *weight* (bobot). Sehingga *neuron* dalam setiap lapisan  $i$  terhubung ke setiap neuron di lapisan  $i+1$  pada sisi *hidden layer*. Setiap jaringan yang terhubung interkoneksi memiliki nilai bobot yang berbeda dan untuk menentukan nilai ini dapat ditentukan dari tahap *training* dan *learning* dari satu kali proses yang dilakukan. Pada FFNN, Proses *training* terbagi menjadi dua tahap yaitu tahap maju dan tahap mundur. Pada tahap maju berfungsi untuk mendapatkan nilai dari bobot dan bias dari perkalian nilai *input*, proses ini akan diteruskan hingga mendapat nilai akhir dari suatu pemrosesan data. Pada tahap mundur, berfungsi untuk mendapatkan nilai dari bobot dan bias baru, sehingga proses ini meminimalisir nilai *error* yang didapat dari tahapan pemrosesan awal. Tahap maju-mundur akan terjadi sebanyak perhitungan iterasi yang dibutuhkan [11]. Input FFNN untuk mendeteksi harmonisa adalah nilai magnitude arus pada setiap sampling data. Notasi input untuk proses FFNN adalah  $x_i$ .

$$Z_i = \sum x_i w_i + B_i \quad (5)$$

Dimana,  $Z_i$  adalah neuron  $i$  pada *hidden layer* dan  $X_i$ ,  $W_i$ ,  $B_i$  masing-masing merupakan variabel *input*, nilai bobot dan bias yang terdapat pada *hidden layer*. Nilai bias adalah penjumlahan dari perkalian variabel *input* dengan bobot.

$$u_i = \frac{1}{1 + e^{z_i}} \quad (6)$$

Pada (2),  $u_i$  merupakan fungsi aktivasi yang mengubah nilai dari neuron untuk dapat diproses. Fungsi aktivasi terdapat berbagai jenis. Akan tetapi, fungsi aktivasi yang digunakan yaitu sigmoid bipolar.

$$Y_{in} = \sum u_i v_i + D \quad (7)$$

Dimana  $Y_{in}$  adalah nilai *output* yang didapat dari proses tahap maju dan  $v_i$ ,  $D$  merupakan bobot dan bias yang terdapat pada *output layer*.

$$error = output - Y \quad (8)$$

Nilai *error* dibutuhkan sebagai pedoman dalam menentukan nilai bobot baru.

$$\delta = error.Y(1-Y) \quad (9)$$

Dimana  $\delta$  adalah invers aktivasi yang berfungsi sebagai pembalik dari fungsi aktivasi yang telah diberikan pada setiap *neuron* pada tahap maju.

$$\Delta B_i = \delta.\alpha \quad (10)$$

$$B_{baru} = B_{lama} + \Delta B_i \quad (11)$$

Dimana,  $\Delta B$  adalah perubahan dari bias pada masing-masing *neuron* dan  $B_{baru}$  merupakan nilai bias baru yang didapat dari tahap mundur.

$$\Delta w_i = \delta.\alpha.Z_i \quad (12)$$

$$w_{baru} = w_{lama} + \Delta w_{ii} \quad (13)$$

Dimana  $\Delta w$  adalah perubahan dari bobot dari masing-masing *neuron* dan  $w_{baru}$  adalah nilai bobot baru.

### C. Perencanaan Pencuplikan

Analisis suatu gelombang pada proses pencuplikan sangat diperlukan. Pencuplikan adalah proses pengambilan data analog secara periodik dengan rentan waktu tertentu. Penentuan Frekuensi sampling untuk proses pencuplikan dapat dilakukan dengan teknik perhitungan sederhana.

$$n = \frac{F_s}{f} \quad (14)$$

$$F_s = 128 \times 50 \quad (15)$$

$$F_s = 6400 \text{ Hz} \quad (16)$$

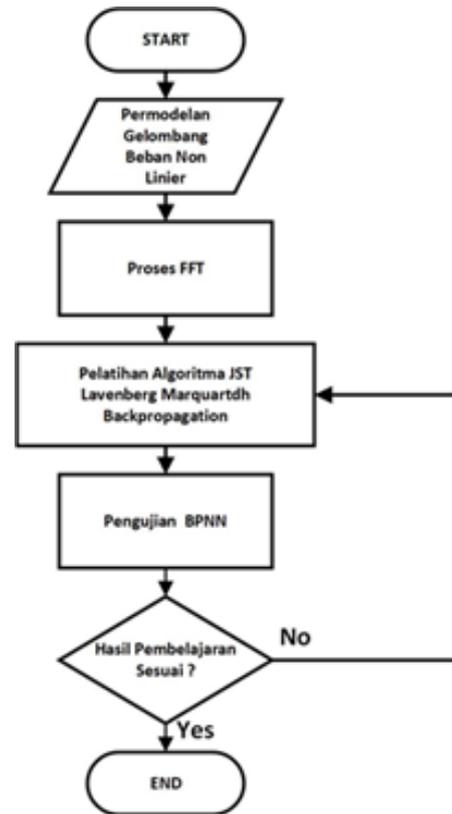
dimana  $F_s$  adalah frekuensi sampling (Hz),  $f$  frekuensi sinyal sinus (Hz), dan  $n$  jumlah banyak data yang diinginkan.

Persamaan 13 digunakan sebagai *setting value* pada proses pencuplikan di mikrokontroller. Proses pencuplikan terdapat di proses analog to digital (ADC). Pada mikrokontroller akan melakukan pencacahan data yang didapat dari pembacaan sensor arus. Data pencacahan dari gelombang beban non linier ini akan disimpan untuk proses selanjutnya yaitu pada proses pembelajaran.

### D. Flowchart Proses Pembelajaran Jaringan Syaraf Tiruan

Gambar 2 memperlihatkan alur proses pelatihan FFNN. Proses dimulai dengan memberikan data pembelajaran yang terdiri dari data sampling gelombang beserta data target yang digunakan sebagai tahap pembelajaran. Data sampling gelombang sebagai input FFNN adalah 128 data. Sedangkan, output FFNN adalah harmonisa. FFT digunakan untuk mendapatkan nilai harmonisa [12].

Tahap pembelajaran dimulai, yaitu pembelajaran dengan algoritma FFNN tipe *Lavenberg Marquardt*



Gambar 2. Flowchart proses pelatihan FFNN

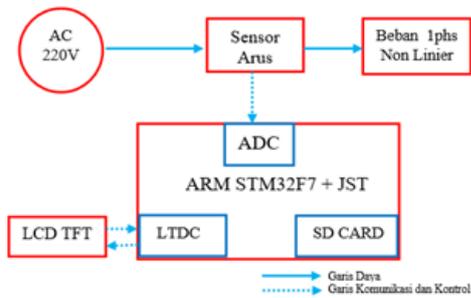
dengan mengolah data bobot dan bias dengan proses maju-mundur. Pada proses maju dilakukan untuk mendapatkan nilai *error* dari proses pengolahan bobot, bias dan nilai *output* nya. Pada proses mundur dilakukan untuk proses *update* bobot, bias dan proses mendapat nilai *error* seminimal mungkin.

Proses validasi dibutuhkan untuk mengecek hasil pembelajaran dari perangkat lunak apakah telah sesuai dengan yang diinginkan maka dilakukan tahap pengujian. Pengujian dilakukan dengan memasukan data *training* ke dalam data hasil pembelajaran. Pengujian dibandingkan Apabila hasil pengujian yang dilakukan tidak sesuai dengan yang diinginkan maka proses pembelajaran akan dilakukan kembali hingga mendapat nilai *output* yang sesuai.

### E. Hardware System

Implementasi digambarkan dalam bagian ini. Mikrokontroller ARM STM32F7 diaplikasikan sebagai *embedded system* untuk memproses algoritma yang diusulkan. Mikrokontroller ARM STM32F7 dilengkapi dengan ADC 12 bit. Frekuensi mikrokontroller ARM STM32F7 adalah 167 Mhz sehingga menyediakan performa tinggi untuk pemrosesan sinyal yang memiliki akurasi dan kecepatan tinggi.

Sistem hardware untuk pendeteksian harmonisa ditunjukkan pada Gambar 3. Sumber listrik 220 V mensuplai arus di beban non linier. Sensor arus mendeteksi sinyal arus dengan frekuensi sampling 6400 Hz dan



Gambar 3. Skema pendeteksian harmonisa

jumlah data untuk mengolah sinyal arus adalah 128 data dalam proses ADC. Data diolah dengan FFNN untuk pendeteksian harmonisa.

### III. PENGUJIAN DAN ANALISA SISTEM

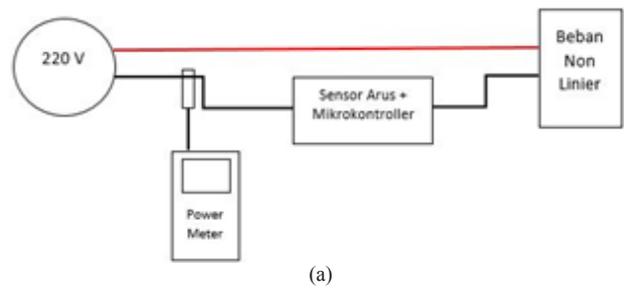
Untuk mengevaluasi algoritma yang diusulkan, Pengujian dilakukan dengan menghubungkan sumber 220 V dengan beban non linier secara seri seperti diperlihatkan pada Gambar 4. Pengujian dilakukan dengan berbagai tahapan yaitu pengujian sensor arus AMC1100DUB Sensor arus AMC1100DUB akan membaca secara analog dari nilai arus yang terukur pada sistem yang terhubung dengan ADC mikrokontroller. Nilai dari pengukuran pembacaan yang didapat kemudian digunakan sebagai *input* untuk diproses pada tahap analisa dan perhitungan pada mikrokontroller.

Pengujian kedua adalah pengujian pencuplikan gelombang dari masing-masing beban non linier untuk sebagai acuan dalam menentukan nilai yang ditampilkan dari hasil pembelajaran. Dalam proses ADC di mikrokontroller melakukan pencuplikan 128 data dari beban non linier yang terhubung dengan prototipe. Gelombang pencuplikan yang didapat tersebut digunakan sebagai bahan untuk proses pembelajaran secara *offline* untuk proses pengenalan pola. Pengujian gelombang pencuplikan dilakukan dengan membandingkan data yang didapat dari proses mikrokontroller dengan *oscilloscope*. Pengujian ketiga adalah pengujian pembelajaran FFNN dengan variasi beban. Terakhir, pengujian FFNN untuk pendeteksian harmonisa. Pengujian ini dibandingkan dengan FFT dan Fluke 43B.

#### A. Pengujian Sensor Arus AMC1100DUB

Gambar 5 merupakan perangkat sensor arus yang diimplementasikan pada sistem. Sensor arus menggunakan AMC1100DUB. Pengukuran yang dilakukan untuk mengetahui linieritas antara input sensor dengan output sensor AMC1100DUB. Sinyal arus diubah menjadi sinyal tegangan untuk diproses oleh sensor AMC1100DUB. Hasil pengujian yang didapat pada Tabel 1 akan digunakan untuk mengetahui karakteristik dari sensor yang digunakan apakah sesuai dengan karakteristik yang ada pada *datasheet*.

Berdasarkan hasil pengujian, kemudian dilakukan



(a)



(b)

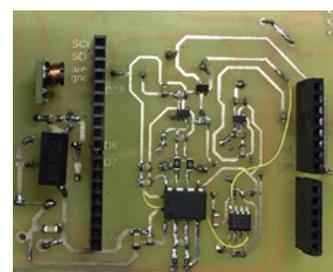
Gambar 4. Pengujian perangkat sistem (a) Blok diagram pengujian sistem (b) Pengujian sistem dengan beban non linier

plot grafik dari hasil pengukuran yang dilakukan. Hasil pengujian dari kaki pin pada sensor dapat diketahui bahwa nilai pengukuran yang terbaca oleh alat ukur bernilai relatif kecil. Hasil tersebut kemudian di plot ke dalam grafik untuk mengetahui bentuk antara tegangan keluaran terhadap tegangan masukan dari sensor.

Gambar 6 menunjukkan hasil perbandingan dari keluaran tegangan terhadap masukan tegangan sensor yang digunakan. Dari hasil yang didapat ini dapat diketahui bahwa grafik memiliki bentuk yang linier. Dibutuhkan alat ukur power meter yang cukup akurat untuk dapat membaca tingkat ketelitian dari nilai tegangan yang terbaca dari sensor yang digunakan.



(a)



(b)

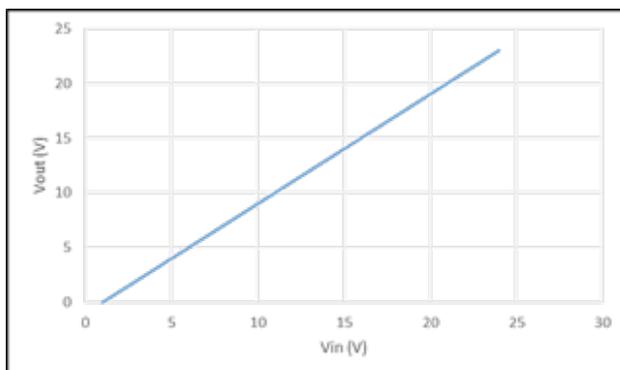
Gambar 5. Sensor arus AMC1100DUB (a) Sensor arus yang terintegrasi mikrokontroller (b) Rangkaian sensor arus pada board

Tabel 1. Hasil pengujian sensor arus pada AMC1100dub

Vin Sensor (V)	Vout Sensor (V)	Iin (A)
0,001	0	0
0,005	0,02	0,2
0,011	0,06	0,4
0,017	0,08	0,6
0,023	0,1	0,8
0,029	0,12	1
0,035	0,16	1,2
0,041	0,18	1,4
0,047	0,2	1,6
0,053	0,24	1,8
0,061	0,29	2
0,066	0,3	2,2
0,072	0,32	2,4
0,077	0,38	2,6
0,082	0,42	2,8
0,090	0,44	3
0,094	0,48	3,2
0,099	0,54	3,4
0,107	0,58	3,6
0,113	0,62	3,8
0,121	0,66	4
0,123	0,68	4,2
0,128	0,72	4,4
0,136	0,78	4,6

### B. Pengujian Pencuplikan Data

Pengambilan data dilakukan untuk keperluan pelatihan agar dapat di proses oleh jaringan syaraf tiruan pada tahap pembelajaran pengenalan masing-masing pola dan dibutuhkan *sample* gelombang pada masing-masing beban non linier. Jumlah kuantitas dari pengambilan *sample* gelombang pencuplikan dalam satu periode yang dibutuhkan yaitu sebanyak 128 data. Hasil pencuplikan data yang didapat pada masing- masing beban non linier dilakukan perbandingan dengan alat ukur osiloskop



Gambar 6. Perbandingan tegangan output terhadap tegangan input AMC1100DUB

sebagai validasi hasil.

Pengambilan pencuplikan data untuk beban non linier pertama dilakukan pada beban motor satu fasa 0,37 kW seperti diperlihatkan pada Gambar 7. Melalui program, mikrokontroller melakukan pengambilan data pencuplikan dari beban yang terhubung. Data pencuplikan disimpan dalam fasilitas SD Card yang kemudian dibandingkan dengan pembacaan *oscilloscope*.

Gambar 8 merupakan hasil pengambilan pencuplikan dari beban non linier lampu LHE. Dapat diketahui bahwa hasil pencuplikan dari mikrokontroller telah sesuai dengan gambar keluaran dari alat ukur osiloskop.

Pengambilan pencuplikan data dilakukan kembali untuk beban komputer 1100 W seperti pada Gambar 9. Setiap data yang diambil dilakukan perbandingan dengan osiloskop untuk memastikan bahwa proses pencuplikan berjalan dengan benar. Proses pengambilan data dilakukan secara manual melalui program pada setiap beban non linier yang terpasang pada perangkat.

Gambar 10 adalah proses pencuplikan pada beban motor  $\frac{1}{2}$  HP dimana proses untuk mendapatkan data karakteristik dari beban dilakukan dengan proses yang sama dengan sebelumnya yaitu pengambilan sebanyak 128 data. Data yang didapat juga dilakukan perbandingan dengan osiloskop untuk proses validasi.

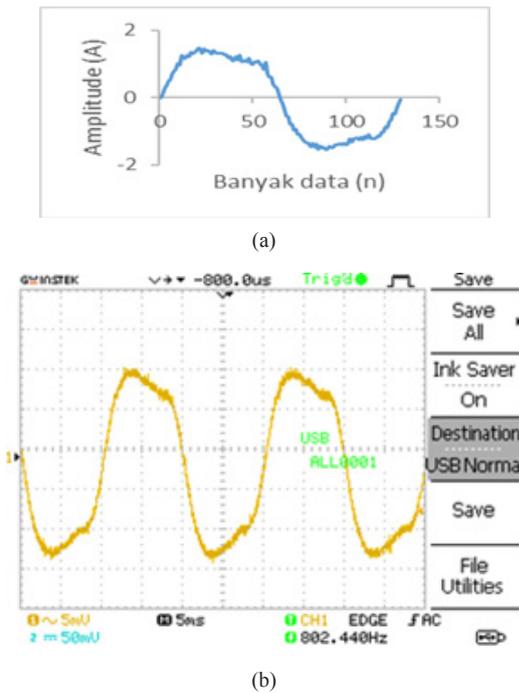
Hasil pencuplikan data dari masing-masing beban non linier terlebih dahulu diproses untuk keperluan pelatihan agar dapat mengenali pola bentuk gelombang sebelum proses pengujian dilakukan. Tahap selanjutnya adalah memasukkan data pencuplikan yang tersimpan di SD Card mikrokontroller ke dalam perangkat lunak MATLAB untuk dilakukan tahap pembelajaran secara *offline* untuk mendapatkan *update* dari bobot dan bias dari hasil pembelajaran.

### C. Pengujian Algoritma Feed Forward Neural Network

Gambar 11 merupakan perbandingan respon data THDi beban (garis berwarna biru) dengan respon data pembelajaran (garis berwarna merah) pada hasil proses pembelajaran. Dari perbandingan dari kedua grafik ini menunjukkan bahwa data pembelajaran telah dapat menyesuaikan dengan data target yang dituju sehingga proses pembelajaran secara simulasi dapat dikatakan berhasil. Untuk grafik pada Gambar 11 merupakan salah satu grafik hasil pembelajaran yang ditampilkan dari berbagai macam beban non linier salah satunya yaitu motor 0,37 kW.

Tabel 2 menunjukkan bahwa data pembelajaran parameter nilai THDi pada masing-masing beban non linier pada proses pengenalan pola bentuk gelombang yang dilakukan pada *software* Matlab telah sesuai dengan target. Hasil yang telah didapat ini kemudian ditransformasikan kedalam perangkat mikrokontroller dalam bentuk program.

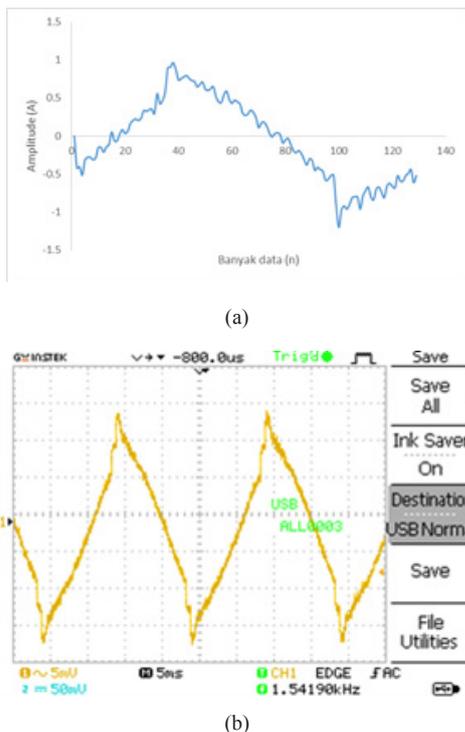
### D. Pengujian Prototipe saat Terhubung Beban



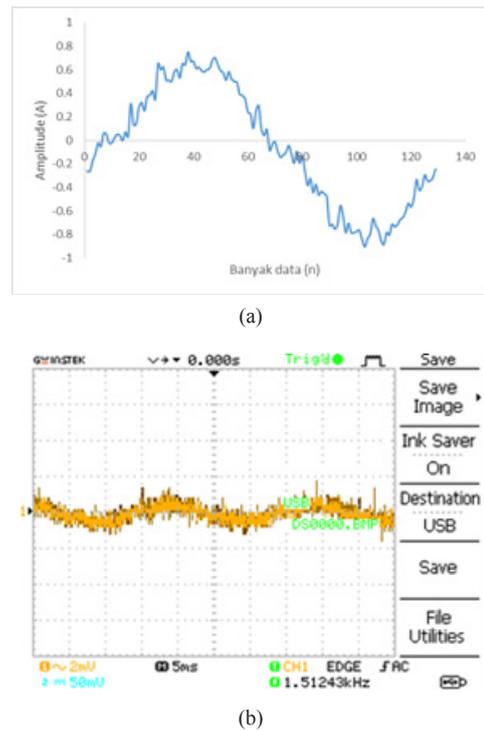
Gambar 7. Beban motor 1 phase 0,37 kW (a) Gelombang pencuplikan mikrokontroler (b) Pembacaan dari osiloskop

Pengujian dilakukan dengan memasukkan data hasil pembelajaran ke dalam perangkat mikrokontroler. Sumber terhubung dengan prototipe secara seri. Beban yang digunakan adalah beban non linier. Masing-masing beban di hubungkan pada sistem yang telah ada untuk dilakukan pengujian.

Berdasarkan Tabel 3, diketahui bahwa prototipe dapat melakukan pembacaan data parameter THDi dari beban non linier yang terhubung. Prototipe

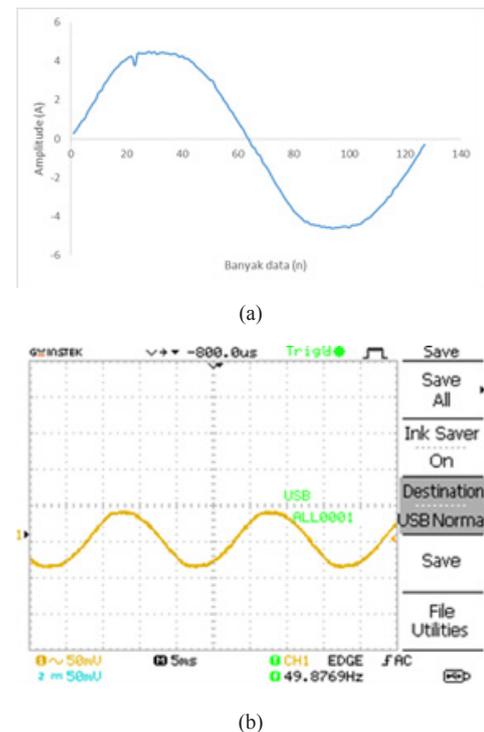


Gambar 8. Beban lampu LHE 25W dan lampu pijar 100W (a) Gelombang pencuplikan mikrokontroler (b) Pembacaan dari osiloskop

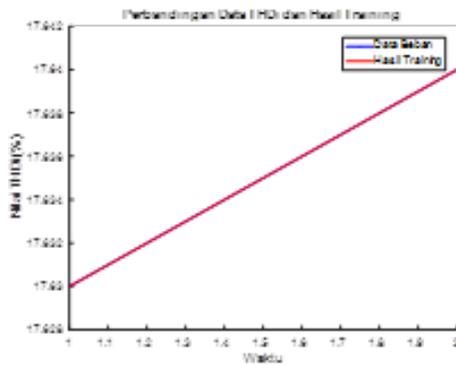


Gambar 9. Beban komputer 1100 W (a) Gelombang pencuplikan mikrokontroler (b) Pembacaan dari osiloskop

diimplementasikan secara realtime dengan memasukkan hasil proses pembelajari yaitu nilai bobot dan bias ke dalam mikrokontroler. Hasil pembacaan menunjukkan akurasi yang baik dan memuaskan dengan error rata-rata dibandingkan dengan FLUKE adalah 5,33%. Selain itu, proses untuk menampilkan hasil yang ditampilkan lebih cepat dari metode Fast Fourier Transform (FFT) karena



Gambar 10. Beban motor 1/2 HP (a) Gelombang pencuplikan mikrokontroler (b) Pembacaan dari osiloskop



Gambar 11. Perbandingan data beban dengan hasil pembelajaran

pada FFT membutuhkan proses komputasional terlebih dahulu. FFNN tidak memerlukan proses komputasi untuk mendeteksi harmonisa karena FFNN melakukan proses pembelajaran terlebih dahulu untuk mengenali harmonisa dari masing-masing beban non linie sehingga prototipe dalam mendeteksi harmonisa secara realtime memerlukan satu iterasi.

#### IV. KESIMPULAN

Makalah ini menyajikan metode FFNN untuk pendeteksian harmonisa. FFNN diimplementasikan oleh mikrokontroler ARM STM32F7. Beban non linier yang digunakan untuk proses pembelajaran algoritma yang diusulkan ada 6 beban non-linear. Pengujian dibandingkan dengan FLUKE 43B dan FFT untuk mengevaluasi performa FFNN. Hasil pengujian menunjukkan bahwa FFNN memiliki akurasi yang baik dan memuaskan dengan error rata-rata adalah 5,33% dibandingkan dengan FLUKE. Selain itu, proses untuk menampilkan hasil yang ditampilkan lebih cepat dari metode FFT karena pada FFT membutuhkan proses komputasional terlebih dahulu.

#### REFERENSI

- [1] C. F. Nascimento, A. A. Oliveira, A. Goedel, dan A. B. Dietrich, "Harmonic Distortion Monitoring for Non Linear Loads using Neural Network Method," *Applied Soft Comp.*, hal 475-482, Sept. 2012.
- [2] H. C. Lin, "Fast tracking of time-varying power system frequency and harmonics using iterative-loop approaching algorithm," *IEEE Trans. Ind. Electron.*, vol 54, no. 2, pp.974-983, Apr. 2007.
- [3] Pujiantara, M., Anggriawan, D. O., Tjahjono, A., Permadi,

Tabel 2. Hasil pembelajaran beban non linier secara software

No	Jenis Beban	THDi (%)
1	Motor 1 phase 0,37 kW	15,45
2	Lampu LHE	19,38
3	Komputer 1100 W	20,43
4	Motor 1 phase ½ HP	3,13
5	Motor 1 phase 0,37 kW + Motor 1 phase ½ HP	7,38
6	LHE 25W+24W+100W +100W	18,03

Tabel 3. Hasil pengujian pembacaan pada perangkat

Beban	THDi Alat Ukur FLUKE (%)	THDi FFT (%)	THDi FFNN (%)	Error	
				Error 1 (%)	Error 2 (%)
Motor 1 phase 0,37 kW	15,45	15,37	14,32	0,51	7,3
LHE 25W dan 100W	19,38	17,77	18,23	8,3	5,9
Komputer 1100 W	20,43	19,03	20,74	6,8	0,19
Motor 1 phase ½ HP	3,13	3,06	2,74	2,2	9,2
Motor 1 phase 0,37 kW + Motor 1 phase ½ HP	7,38	6,89	6,73	6,63	8,80
LHE 25W + 24W+100W +100W	18,03	16,96	17,92	5,93	0,61
Rata-rata	5,06	5,33			

- D., Priyadi, A., & Purnomo, M. H. A Real-Time Current Harmonic Monitoring System Based in Stockwell Transform Method. *International Review of Electrical Engineering*, 11(2).
- [4] R. M. Hidalgo, J. G. Fernandez, R. R. Rivera, and H. A. Larrondo, "A simple adjustable window algorithm to improve FFT measurements," *IEEE Trans. Instrum. Meas.*, vol 51, no. ,pp. 31-36, Feb. 2002.
- [5] D. Agrez, "Weighted multipoint interpolated DFT to improve amplitude estimation of multifrequency signal." *IEEE Trans. Instrum. Meas.*, vol. 51, no 2, pp. 287-292, Apr. 2002
- [6] G. W. Chang, C. I. Chen, dan Y. F. Teng, "Radial Basis Function Based Neural Network for Harmonic Detection," *IEEE Trans. Act. Ind. Elec.*, Vol. 57, no 6, pp. 2171-2173, Jun. 2010.
- [7] W. W. L. Keerthipala, L. T. Chong, dan T. C. Leong, "Artificial Neural Network Model for Analysis of Power System Harmonics" *Proceedings of ICNN'95*, 2002
- [8] I.S. Faradisa, D.O. Anggriawan, T.A. Sardjono, M.H. Purnomo, "Identification of Phonocardiogram Signal Based on STFT and Marquardt Lavenberg Backpropagation" *IEEE International Seminar on Intelligent and Its Applications*, 2016
- [9] Sudiharto, I., Anggriawan, D. O., & Tjahjono, A. (2017). Harmonic Load Identification Based on Fast Fourier Transform and Levenberg Marquardt Backpropagation. *Journal of Theoretical and Applied Information Technology*, 95(5), 1080
- [10] Anggriawan, D. O., Satriawan, A. L., Sudiharto, I., Wahjono, E., Prasetyono, E., & Tjahjono, A. (2018, October). Levenberg Marquardt Backpropagation Neural Network for Harmonic Detection. In *2018 International Electronics Symposium on Engineering Technology and Applications (IES-ETA)* (pp. 129-132). IEEE
- [11] Syafi'i, M. H. R. A., Prasetyono, E., Khafidli, M. K., Anggriawan, D. O., & Tjahjono, A. (2018, October). Real Time Series DC Arc Fault Detection Based on Fast Fourier Transform. In *2018 International Electronics Symposium on Engineering Technology and Applications (IES-ETA)* (pp. 25-30). IEEE.
- [12] Hassoun, M. H. (1995). *Fundamentals of artificial neural networks*. MIT press.