



DISERTASI - TE 143597

**SELF ADAPTABLE COORDINATION
OVERCURRENT DIGITAL PROTECTION RELAY
FOR POWER DISTRIBUTION NETWORK**

Anang Tjahjono
NRP: 2214 301 007

Dosen Pembimbing:
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Ir. Margo Pujiantara, MT.
Dr. Ardyono Priyadi, ST., M.Eng.

PROGRAM DOKTOR
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

Disertasi ini disusun untuk memenuhi salah satu syarat memperoleh gelar
Doktor (Dr)

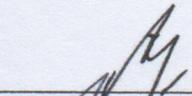
Di
Institut Teknologi Sepuluh Nopember

Oleh:
Anang Tjahjono
2214 301 007

Tanggal Ujian : 1 Agustus 2017
Periode Wisuda : September 2017

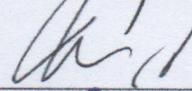
Disetujui oleh:

Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
NIP : 1958 09 16 1986 01 1001



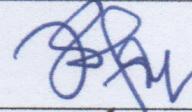
(Pembimbing I)

Dr. Ir. Margo Pujiantara, MT.
NIP : 1966 03 18 1990 10 1001



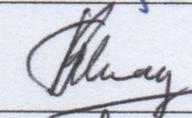
(Pembimbing II)

Dr. Ardyono Priyadi, ST., M.Eng.
NIP : 1973 09 27 1998 03 1004



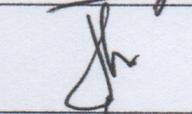
(Pembimbing III)

Prof. Dr. Ir. Rudy Setiabudy, DEA.
NIP : 1954 10 07 1984 03 1001



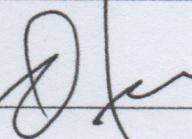
(Penguji I)

Dr. Rony Seto Wibowo, ST., MT.
NIP : 1974 11 29 2000 12 1001



(Penguji II)

Dr. Dimas Anton Asfani, ST., MT.
NIP : 1981 09 05 2005 01 1002



(Penguji III)



Mengetahui:
Dekan Fakultas Teknologi Elektro



Dr. In Arief Sardjono, ST., MT.
NIP. 1970 02 12 1995 12 1001

Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN DISERTASI

Dengan ini saya menyatakan bahwa isi sebagian maupun keseluruhan disertasi saya dengan judul “**Self Adaptable Coordination Overcurrent Digital Protection Relay for Power Distribution Network**” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka.

Apabila pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku.

Surabaya, Agustus 2017



Anang Tjahjono
NRP. 2214 301 007

Halaman ini sengaja dikosongkan

SELF ADAPTABLE COORDINATION OVERCURRENT DIGITAL PROTECTION RELAY FOR POWER DISTRIBUTION NETWORK

Nama Mahasiswa : Anang Tjahjono
NRP : 2214 301 007
Dosen Pembimbing : Prof. Ir. Mauridhi Hery Purnomo, M.Eng., Ph.D.
Dr. Ir. Margo Pujiantara, MT.
Dr. Ardyono Priyadi, ST., M.Eng.

ABSTRAK

Dengan terintegrasinya berbagai jenis sumber energi listrik dengan menggunakan *distributed generation* (DG) dalam satu sistem jaringan distribusi akan menimbulkan perubahan seting pada tiap perangkat rele, dimana mengikuti perubahan status dari DG yang mempunyai sifat *intermitten*. Pada penelitian ini telah dilakukan terobosan inovasi baru berupa pengembangan rele digital yang mempunyai fitur *user-defined characteristic curve* dengan cara memodelkan kurva karakteristik dengan menerapkan ujicoba algoritma *polynomial Lagrange* hingga algoritma *artificial intelligence*. Keberhasilan dalam memodelkan kurva karakteristik rele digital membawa dampak yang sangat luas, antara lain kemampuan perencanaan kurva non-standar, *multi curve* dalam satu rele serta kemampuan pemilihan kurva yang bersifat adaptif mengikuti kondisi atau status dari DG yang terdapat dalam jaringan distribusi. Inovasi terobosan baru selain pemodelan kurva adalah optimisasi parameter dari kurva karakteristik rele yakni *plug seting* (PS) dan *time multiplier seting* (TMS), dua parameter penting tersebut harus dicari nilai optimumnya agar dihasilkan koordinasi antar rele dalam satu jaringan distribusi yang maksimal dimana perangkat sumber energi listrik dan beban terlindungi dengan baik dengan bantuan algoritma optimisasi *firefly* yang dikembangkan, yakni *modified firefly algorithm* (MFA) serta *adaptive modified firefly algorithm* (AMFA). Ketercapaian pemodelan kurva karakteristik *user-defined* dengan menggunakan *artificial neural network* (ANN) mencapai nilai MSE=0,00010, sedang nilai optimisasi yang tertinggi mencapai 42,22% dengan menggunakan AMFA. Dengan keberhasilan ini maka kebutuhan akan *adaptive digital overcurrent relay* yang mampu beroperasi pada *active distribution network* telah terjawab dan siap untuk dikembangkan pada tataran implementasi.

Kata Kunci: *distributed generation, intermitten, digital relay, user-defined characteristic curve, artificial intelligence algorithm, LaGrange interpolation, ANN, ANFIS, MFA, AMFA, adaptive digital protection relay, active distribution network.*

SELF ADAPTABLE COORDINATION OVERCURRENT DIGITAL PROTECTION RELAY FOR POWER DISTRIBUTION NETWORK

Name : Anang Tjahjono
Student ID : 2214 301 007
Supervisor : Prof. Ir. Mauridhi Hery Purnomo, M.Eng., Ph.D.
Dr. Ir. Margo Pujiantara, MT.
Dr. Ardyono Priyadi, ST., M.Eng.

ABSTRACT

With the integration of various types of electrical energy sources by using distributed generation (DG) in a distribution network system will cause changes in settings in each relay device, which follows the change in status of DG that has intermittent properties. In this research, innovation of digital relay has been developed with user-defined curve capability by modeling characteristic curves using Lagrange polynomial interpolation algorithm and artificial intelligence algorithm. Success in modeling digital relay characteristic curves has a wide impact, such as the ability of non-standard curve planning, multi curve in one relay and adaptive curve selection capability following the condition or status of DG in the distribution network. New breakthrough innovations besides curve modeling are parameter optimization of relay characteristic curves ie plug setting (PS) and time multiplier setting (TMS), two important parameters must be obtained optimum value to generate coordination between relays in a distribution network as much as possible, where the device The source of electrical energy and load is well protected, with the help of modification firefly optimization algorithm, called modified firefly algorithm (MFA) and adaptive modified firefly algorithm (AMFA). The user-defined curve modeling results using artificial neural network (ANN) get MSE 0.00010, while the highest optimization value reached 42.22% using AMFA. With the success of this research, the need for adaptive digital overcurrent relay capable of operating on active distribution network has been answered and ready to be developed at the implementation level.

Keywords: distributed generation, intermitten, digital relay, user-defined characteristic curve, artificial intelligence algorithm, LaGrange interpolation, ANN, ANFIS, MFA, AMFA, adaptive digital protection relay, active distribution network.

KATA PENGANTAR

Puji syukur Kehadirat Illahi Robbi yang telah melimpahkan Ridho dan KaruniaNya sehingga penulis berhasil menyelesaikan studi program Doktor di Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember (ITS).

Buku disertasi ini merupakan laporan hasil penelitian yang telah penulis lakukan selama tiga tahun di Laboratorium Instrumentasi Pengukuran dan Identifikasi Sistem Tenaga (LIPIST) Departemen Teknik Elektro, Fakultas Teknologi Elektro, ITS. Topik riset yang kami teliti adalah turunan dari *Grand Design Research* pada laboratorium LIPIST dibawah bimbingan Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng., Dr. Ir. Margo Pujiantara, MT., Dr. Ardyono Priyadi, ST., M.Eng.,

Penulis menyampaikan ucapan terima kasih kepada Dekan Fakultas Teknologi Elektro, Kepala Departemen Teknik Elektro beserta jajarannya yang telah memberikan dukungan administrasi dan fasilitas sehingga kami berhasil menyelesaikan studi selama tiga tahun.

Apresiasi dan ucapan terima kasih dari hati yang tulus penulis haturkan kepada para promotor dan co-promotor, yang terhormat Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng., Dr. Ardyono Priyadi, ST., M.Eng., Dr. Ir. Margo Pujiantara, MT. yang telah mendampingi penulis dalam menimba ilmu dan pengalaman selama studi.

Ucapan terima kasih penulis sampaikan kepada Prof. Dr. Ir. Rudy Setiabudy, DEA., Dr. Rony Seto Wibowo, ST., MT., Dr. Dimas Anton Asfani, ST., MT. selaku dosen penguji yang telah memberikan koreksi, masukan dan saran untuk kesempurnaan penulisan buku disertasi ini.

Ucapan terima kasih penulis sampaikan kepada manajemen Progam Pasca Sarjana Teknik Elektro FTE – ITS, Dr. Ir. Wirawan, DEA. dan Dr. Rony Seto Wibowo, ST.,MT. beserta staf administrasi yang telah memberikan dukungan fasilitas dan administrasi.

Ucapan terima kasih penulis sampaikan kepada para Supervisor di California Polytechnic State University, San Luis Obispo, California, USA, kepada yang

terhormat Prof. Taufik, Prof. O. Shaban dan Prof. Helen Yu yang telah memberikan arahan dan bimbingan selama penulis melaksanakan program Sandwich-Like 2016.

Ucapan terima kasih penulis sampaikan kepada Kementerian Riset Teknologi dan Pendidikan Tinggi atas dukungan beasiswa selama penulis menempuh studi yang meliputi Beasiswa Pendidikan Pascasarjana Dalam Negeri (BPPDN 2014-2017), Bantuan Seminar Luar Negeri (BSLN-2015), Beasiswa Peningkatan Kualitas Publikasi Ilmiah (PKPI-2016).

Penulis mengucapkan terima kasih kepada manajemen Politeknik Elektronika Negeri Surabaya, Departemen Teknik Elektro dan Program Studi Elektro Industri yang telah memberikan ijin menempuh studi program Doktor.

Ucapan terima kasih penulis sampaikan kepada rekan-rekan mahasiswa S3, S2 dan S1 yang tergabung di laboratorium LIPIST yang telah membantu penulis selama melakukan kegiatan riset, ujicoba simulasi dan ujicoba perangkat keras.

Penulis mengucapkan terima kasih dan penghargaan kepada keluarga besar penulis yakni yang terhormat orang tua penulis yang selalu memberikan doa dan restu selama proses studi dan yang tercinta isteri serta anak-anak ku yang selalu memberikan dorongan serta semangat dalam menyelesaikan studi.

Penulis menyampaikan ucapan terima kasih dan permohonan maaf kepada semua pihak yang telah bersama-sama membantu menyelesaikan studi selama ini, semoga hasil penelitian yang ditulis dalam buku disertasi ini dapat memberikan kontribusi positif untuk kemajuan ilmu pengetahuan yang dapat diimplementasikan untuk meningkatkan kesejahteraan hidup umat manusia.

Surabaya, Agustus 2017

Penulis,

Anang Tjahjono.

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN	iii
PERNYATAAN KEASLIAN DISERTASI	v
ABSTRAK	vii
ABSTRACT	viii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xv
DAFTAR TABEL	xxi
DAFTAR ISTILAH DAN SIMBOL	xxiii

BAB I. PENDAHULUAN

1.1. Latar Belakang	1
1.2. Rumusan Masalah	2
1.3. Tujuan dan Manfaat Penelitian	3
1.4. Kontribusi dan Orisinalitas	3
1.5. <i>Roadmap</i> Penelitian	4

BAB II. KECERDASAN KOMPUTASIONAL UNTUK PEMODELAN KURVA DAN OPTIMISASI PARAMETER PADA *DIGITAL OVERCURRENT RELAY*

2.1. Konsep Dasar Sistem Proteksi	11
2.2. <i>Digital Overcurrent Relay</i>	14
2.3. Peran Kurva Karakteristik pada Relay Digital	16
2.4. <i>LaGrange Interpolation Polynomial Characteric Curve Modeling (LIP- CCV)</i>	22
2.5. <i>Artificial Neural Network Characteristic Curve Modeling (ANN-CCM)</i> ..	24
2.5.1. Model Neuron	24
2.5.2. Model Jaringan <i>Neural Feedwork Multi-Layer</i>	26
2.5.3. Formulasi Matematika untuk <i>Neural Network</i>	27
2.5.4. Algoritma Pelatihan <i>Backpropagation</i>	30

2.6. <i>Adaptive Neuro Fuzzy Inference System Characteristic Curve Modeling (ANFIS-CCM)</i>	32
2.6.1 Proses Pembelajaran dengan RLSE untuk Parameter Konsekuen	35
2.6.2 Proses Pembelajaran BAcKpropagationerror untuk Paraeter Premis.....	36
2.7. <i>Modified Firefly (MFA) dan Adaptive Modified Firefly Algoritma (AMFA)</i> parameter Seting Rele	38
2.7.1. Algoritma MFA	40
2.7.2. Algoritma AMFA	42

BAB III. PEMODELAN KURVA KARAKTERISTIK DIGITAL OVERCURRENT RELAY

3.1. Metode Pemodelan Kurva Karakteristik <i>Digital Overcurrent Relay</i>	45
3.2. Memodelkan Kurva Karakteristik Relay Digital dengan Interpolasi Polynomial Lagrange	46
3.3. Performansi Model Menggunakan Interpolasi Lagrange	52
3.4. Pemodelan Kurva Karakteristik Digital Overcurrent Relay Menggunakan Artificial Neural Network (ANN)	58
3.5. Performansi Model Menggunakan Artificial Neural Network (ANN)....	61
3.6. Pemodelan Kurva Karakteristik Digital Overcurrent Relay Menggunakan ANFIS	70
3.7. Performansi Model Menggunakan ANFIS	75

BAB IV. DIRECTIONAL DIGITAL PROTECTION RELAY DENGAN FITUR USER-DEFINED CHARACTERISTIC CURVE

4.1. Metode Pemodelan Kurva Karakteristik <i>Digital Overcurrent Relay</i> Non-standar	87
4.2. Pemodelan <i>User-defined Characteristic Curve</i>	88
4.3. Performansi Pemodelan <i>User-defined Characteristic Curve</i>	95
4.4. Performansi untuk Pemodelan Kurva Ekstrim	116

BAB V. OPTIMISASI PARAMETER PICKUP DAN TDS UNTUK KOORDINASI DIGITAL OVERCURRENT RELAY

5.1. Metode Optimisasi Parameter Seting <i>Digital Overcurrent Relay</i> DOCR	117
---	-----

5.2. Optimisasi Parameter Seting <i>Digital Overcurrent Relay</i> menggunakan <i>Modified Firefly Algorithm (MFA)</i>	118
5.2.1. Modified Firefly Algorithm (MFA)	119
5.3. Performansi Optimisasi Menggunakan <i>MFA</i>	123
5.3.1. Kasus 1	123
5.3.2. Kasus 2	125
5.3.3. Kasus 3	127
5.3.4. Kasus 4	129
5.4. Optimisasi Parameter Seting <i>Digital Overcurrent Relay</i> menggunakan <i>Adaptive Modified Firefly Algorithm (AMFA)</i>	132
5.5. Performansi Otimisasi Menggunakan <i>Adaptive Modified Firefly Algorithm</i> <i>AMFA</i>	134
5.5.1. Kasus 1	136
5.5.1. Kasus 2	138
5.5.1. Kasus 3	140
5.5.1. Kasus 4	142
 BAB VI. KESIMPULAN DAN PENELITIAN SELANJUTNYA	
6.1. Kesimpulan	145
6.2. Penelitian Selanjutnya	146
 DAFTAR PUSTAKA	147
BIOGRAFI PENULIS	153

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 1.1 <i>Fishbone Diagram</i>	6
Gambar 2.1 Pembagian <i>Overcurrent Relay</i>	13
Gambar 2.2. Bagan Rele Digital	15
Gambar 2.3. Peran Kurva Karakteristik pada Rele Digital	16
Gambar 2.4. Parameter Kurva Karakteristik Rele	17
Gambar 2.5. Kurva Karakteristik Rele	18
Gambar 2.6. Parameter Lengkap Pemodelan Rele Digital	20
Gambar 2.7. Timing Diagram Operasi Kerja Rele Digital	21
Gambar 2.8. Interpolasi Polinomial	22
Gambar 2.9. Struktur Dasar <i>Artificial Neuron Model</i>	24
Gambar 2.10. Tipikal Fungsi Aktivasi <i>Sigmoid Unipolar</i>	25
Gambar 2.11. Struktur Dasar Jaringan Syaraf Tiruan <i>Feedforward Multi Layer</i>	26
Gambar 2.12. Diagram Skematik Input-Output Sistem Aktual ANN	28
Gambar 2.13. Supervised Training Dari <i>Artificial Neural Networks</i>	30
Gambar 2.14. Arsitektur ANFIS	33
Gambar 2.15. Model Jaringan Syaraf <i>Feedforward</i>	36
Gambar 2.16 <i>Flowchart Firefly Algorithm</i>	40
Gambar 2.17. <i>Flowchart Modified Firefly Algorithm</i>	41
Gambar 2.18 <i>Flowchart Adaptive Modified Firefly Algorithm</i>	43
Gambar 3.1. Metode Pemodelan Kurva Karakteristik Rele Digital	46
Gambar 3.2 Pemodelan Kurva dengan Interpolasi Lagrange	47
Gambar 3.3 <i>Pseudo Code Model Kurva dengan Interpolasi Lagrange</i>	47
Gambar 3.4 Kurva Karakteristik <i>Standard Inverse</i> dengan Variasi TMS.....	50
Gambar 3.5 Kurva Karakteristik <i>Extremely Inverse</i> dengan Variasi TMS.....	51
Gambar 3.6. Kurva Karakteristik <i>Very Inverse</i> dengan Variasi TMS.....	51
Gambar 3.7 Kurva Karakteristik <i>Long Time Inverse</i> dengan Variasi TMS.....	52
Gambar 3.8 Blok Diagram Ujicoba Model Kurva dengan Lagrange.....	52
Gambar 3.9 Hasil Pemodelan Kurva Karakteristik <i>Standard Inverse</i>	53
Gambar 3.10 Hasil Pemodelan Kurva Karakteristik <i>Extremely Inverse</i>	54
Gambar 3.11 Hasil Pemodelan Kurva Karakteristik <i>Very Inverse</i>	55

Gambar 3.12 Hasil Pemodelan Kurva Karakteristik <i>Long Time Inverse</i>	56
Gambar 3.13 <i>Mean Absolute Deviation</i> Model Lagrange.....	57
Gambar 3.14. <i>Root Mean Square Error</i> Model Lagrange.....	57
Gambar 3.15 Posisi Model Lagrange pada Digital Rele.....	58
Gambar 3.16. Metode Pemodelan dengan ANN.....	59
Gambar 3.17 Konfigurasi ANN untuk Pemodelan Kurva Karakteristik.....	60
Gambar 3.18 Pemodelan Kurva SI dengan Jumlah Neuron=2.....	61
Gambar 3.19 Hasil Performansi MSE dan Regresi ANN.....	62
Gambar 3.20 Pengaruh Jumlah <i>Neuron</i> pada <i>Layer Input</i>	63
Gambar 3.21 Pengaruh Jumlah <i>Neuron</i> pada <i>Layer Input</i> terhadap nilai RMSE.	64
Gambar 3.22 Hasil Pemodelan Kurva SI dengan ANN.....	64
Gambar 3.23 Hasil Pemodelan Kurva EI dengan ANN.....	65
Gambar 3.24 Hasil Pemodelan Kurva VI dengan ANN.....	66
Gambar 3.25 Hasil Pemodelan Kurva LTI dengan ANN.....	67
Gambar 3.26 Performansi RMSE dan MAD Model Kurva dengan ANN.....	69
Gambar 3.27 Posisi Model ANN pada Rele Digital.....	69
Gambar 3.28 Metode Pemodelan dengan ANFIS.....	70
Gambar 3.29 Tahapan Pemodelan Kurva dengan ANFIS.....	71
Gambar 3.30 Tampilan GUI unyuk Ujicoba Pemodelan dengan ANFIS.....	72
Gambar 3.31 Fungsi Keanggotaan Sebelum dan Setelah Pembelajaran.....	72
Gambar 3.32 Tampilan <i>Rule Viewer</i>	73
Gambar 3.33 Tampilan <i>Surface</i> dari Fuzzy Inference System.....	73
Gambar 3.34 FIS sebagai Model Kurva Menggunakan ANFIS.....	74
Gambar 3.35 Bentuk Kurva Hasil Pembelajaran dan Check.....	74
Gambar 3.36 Grafik Error RMSE saat Pelatihan dan Check.....	65
Gambar 3.37 Tampilan GUI Hasil Pemodelan dengan MF=2.....	77
Gambar 3.38 Hasil Pemodelan dengan MF yang Berbeda	78
Gambar 3.39 Kurva Hasil Pemodelan dengan MF=8.....	78
Gambar 3.40 Tampilan Akhir GUI ANFIS Kurva SI dengan TMS=1.....	79
Gambar 3.41 Hasil Pemodelan Kurva SI dengan ANFIS.....	80
Gambar 3.42 Hasil Pemodelan Kurva EI dengan ANN.....	81
Gambar 3.43 Hasil Pemodelan Kurva VI dengan ANN.....	82

Gambar 3.44 Hasil Pemodelan Kurva LTI dengan ANN.....	83
Gambar 3.45 Performansi MAD Pemodelan Kurva dengan ANFIS.....	84
Gambar 3.46 Performansi RMSE Pemodelan Kurva dengan ANFIS.....	84
Gambar 3.47 Posisi Model ANFIS pada Rele Digital.....	85
Gambar 4.1. Metode Pemodelan <i>User-defined Characteristic Curve</i>	87
Gambar 4.2. <i>Digital Protection Relay</i> Berbasis <i>Microcontroller Unit (MCU)</i>	89
Gambar 4.3. <i>Flowchart Sistem User-defined Characteristic Curve</i>	90
Gambar 4.4. Proses Pemisahan data Hingga Pembelajaran dan Pemodelan	91
Gambar 4.5 Struktur ANN untuk Pemodelan <i>User-defined Curve</i>	92
Gambar 4.6. <i>User Interface</i> untuk Perencanaan Kurva Karakteristik	92
Gambar 4.7. Ujicoba Model dengan Simulink	93
Gambar 4.8. Performansi Pembelajaran ANN	93
Gambar 4.9. Visualisasi Kurva Hasil Model dan Perancangan Oleh <i>User</i>	94
Gambar 4.10 Urutan Data Model yang dikirim ke DPR	95
Gambar 4.11. <i>User Interface</i> untuk Kurva Dengan Referensi SI TMS=0.1	96
Gambar 4.12. Performansi Regresi Kurva user-defined basis SI dengan TMS=0.1.....	97
Gambar 4.13 Kurva Model dan Referensi Jenis Kurva SI TMS=0.1	97
Gambar 4.14 <i>User Interface</i> untuk Kurva Dengan Referensi SI TMS=1.0	98
Gambar 4.15 Performansi Regresi kurva Model SI TMS=1	98
Gambar 4.16 Kurva Model dan Referensi Jenis Kurva SI TMS=1	99
Gambar 4.17 <i>User Interface</i> untuk Kurva Dengan Referensi EI TMS=0.1.....	99
Gambar 4.18 Performansi Regresi kurva Model EI TMS=0.1	100
Gambar 4.19 Kurva Model dan Referensi Jenis Kurva EI TMS=0.1	100
Gambar 4.20 <i>User Interface</i> untuk Kurva Dengan Referensi EI TMS=1	101
Gambar 4.21 Performansi Regresi kurva Model EI TMS=1	101
Gambar 4.22 Kurva Model dan Referensi Jenis Kurva EI TMS=1	102
Gambar 4.23. <i>User Interface</i> untuk Kurva Dengan Referensi VI, TMS=0.1.....	103
Gambar 4.24. Performansi Regresi kurva Model VI, TMS=0.1	103
Gambar 4.25. Kurva Model dan Referensi Jenis Kurva VI, TMS=0.1	104
Gambar 4.26. <i>User Interface</i> untuk Kurva Dengan Referensi VI, TMS=1	104

Gambar 4.27. Performansi Regresi kurva Model VI, TMS=1	105
Gambar 4.28. Kurva Model dan Referensi Jenis Kurva VI, TMS=1	105
Gambar 4.29. <i>User Interface</i> untuk Kurva Dengan Referensi LTI, TMS=0.1 .	106
Gambar 4.30. Performansi Regresi kurva Model LTI, TMS=0.1	106
Gambar 4.31. Kurva Model dan Referensi Jenis Kurva LTI dengan TMS=0.1.	107
Gambar 4.32. <i>User Interface</i> untuk Kurva Model LTI dengan TMS=1	108
Gambar 4.33. Performansi Regresi kurva Model LTI dengan TMS=1	108
Gambar 4.34. Kurva Model dan Referensi Jenis Kurva LTI dengan TMS=1....	109
Gambar 4.35. Pengiriman Model ke <i>Digital Protection Relay</i>	110
Gambar 4.36 Uji Performansi Model didalam DPR.....	110
Gambar 4.37 Uji Performansi Menggunakan Arus Riel	112
Gambar 4.38 Blok Diagram Rinci Uji Performansi Terintegrasi.....	112
Gambar 4.39 Perekaman Sinyal Saat Terjadi Overload.....	113
Gambar 4.40 Prototipe <i>Digital Protection Relay</i>	114
Gambar 4.41 Ujicoba Integrasi di Laboratorium.....	115
Gambar 4.42 Terhubung dengan beban untuk Ujicoba Saat Overload	115
Gambar 4.43 Program Aplikasi untuk Merancang Kurva Karakteristik Ree	116
Gambar 4.44 Performansi Pemodelan dengan Jumlah Neuron Berbeda	117
Gambar 4.46 Performansi Pemodelan Untuk Kurva Ekstrim	118
Gambar 5.1. Metode Optimisasi Parameter Seting DOCR	117
Gambar 5.2. <i>Pseudo Code</i> MFA.....	121
Gambar 5.3 Jaringan Radial untuk Uji Simulasi	122
Gambar 5.4 Arus <i>Fault</i> pada setiap Bus	123
Gambar 5.5 Kurva Konvergensi Kasus 1 antara FA dan MFA	124
Gambar 5.6 Hasil Koordinasi (a) Konvensional (b) MFA	125
Gambar 5.7 Kurva Konvergensi Kasus 2 antara FA dan MFA	126
Gambar 5.8 Hasil Koordinasi (a) Konvensional (b) MFA	127
Gambar 5.9 Kurva Konvergensi Kasus 3	128
Gambar 5.10 Hasil Koordinasi kasus 3 (a) Konvensional (b) MFA	129
Gambar 5.11 Kurva Konvergensi Kasus 4	130
Gambar 5.12 Hasil Koordinasi Kasus 4 (a) Konvensional (b) MFA	131
Gambar 5.13. <i>Flowchart</i> AMFA	135

Gambar 5.14 Kurva Konvergensi Kasus 1 dengan FA, MFA,dan AMFA	137
Gambar 5.15 Hasil Koordinasi Kasus 1 (a) Konvensional (b) AMFA	137
Gambar 5.16 Kurva Konvergensi Kasus 2 antara FA, MFA dan AMFA	139
Gambar 5.17 Hasil Koordinasi Kasus 2 dengan AMFA	139
Gambar 5.18 Kurva Konvergensi Kasus 3 dengan FA, MFA dan AMFA	141
Gambar 5.19 Hasil Koordinasi Kasus 3 (a) Konvensional (b) AMFA	141
Gambar 5.20 Kurva Konvergensi Kasus 4 algoritma FA, MFA dan AMFA ...	143
Gambar 5.21 Hasil Koordinasi Kasus 4 (a) Konvensional (b) AMFA	143

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 1.1. Daftar Publikasi Peneliti.....	7
Tabel 1.2. Publikasi Peneliti Lain Terkait Pemodelan Kurva.....	8
Tabel 1.3. Publikasi Peneliti Lain Terkait Optimisasi Parameter.....	9
Tabel 1.4. Publikasi Peneliti Lain Terkait Koordinasi Adaptif.....	10
Tabel 2.1. Konstanta pada Kurva Karakteristik Relay	19
Tabel 3.1. Data Rasio dan Trip untuk Kurva <i>Standard Inverse</i>	48
Tabel 3.2. Data Rasio dan Trip untuk Kurva <i>Extremely Inverse</i>	48
Tabel 3.3. Data Rasio dan Trip untuk Kurva <i>Very Inverse</i>	49
Tabel 3.4. Data Rasio dan Trip untuk Kurva <i>Long Time Inverse</i>	49
Tabel 3.5. Performansi Model Lagrange Kurva <i>Standard Inverse</i>	53
Tabel 3.6. Performansi Model Lagrange Kurva <i>Extremely Inverse</i>	54
Tabel 3.7. Performansi Model Lagrange Kurva <i>Very Inverse</i>	55
Tabel 3.8. Performansi Model Lagrange Kurva <i>Long Time Inverse</i>	56
Tabel 3.9. Pengaruh Jumlah Neuron pada Layer Input terhadap RMSE.....	63
Tabel 3.10 Performansi Model Kurva SI dengan ANN.....	65
Tabel 3.11 Performansi Model Kurva EI dengan ANN.....	66
Tabel 3.12 Performansi Model Kurva VI dengan ANN.....	67
Tabel 3.13 Performansi Model Kurva LTI dengan ANN.....	68
Tabel 3.14 Resume <i>Error</i> Hasil Pemodelan dengan ANN.....	68
Tabel 3.15 Data untuk Pembelajaran dan <i>Check</i>	76
Tabel 3.16 RMSE hasil Pemodelan dengan MF berbeda.....	77
Tabel 3.17 Performansi Pemodelan Kurva SI dengan ANFIS.....	80
Tabel 3.18 Performansi Pemodelan Kurva EI dengan ANFIS.....	81
Tabel 3.19 Performansi Pemodelan Kurva VI dengan ANFIS.....	82
Tabel 3.20 Performansi Pemodelan Kurva LTI dengan ANFIS.....	83
Tabel 4.1 Resume Performansi Pemodelan <i>User-defined Curve</i>	109
Tabel 4.2 Hasil Pemodelan Simulasi dan Pemodelan di dalam MCU.....	111
Tabel 4.3 Performansi Model saat Terintegrasi.....	114
Tabel 5.1 Rincian Status Sumber pada Setiap Kasus	122
Tabel 5.2 Performansi dengan FA dan MFA pada Kasus 1	124

Tabel 5.3 Performansi dengan FA dan MFA pada Kasus 2	126
Tabel 5.4 Performansi dengan FA dan MFA pada Kasus 3	128
Tabel 5.5 Performansi dengan FA dan MFA pada Kasus 4	130
Tabel 5.6 Resume Performansi Optimisasi FA dan MFA	132
Tabel 5.7 Performansi Perbandingan hasil FA,MFA dan AMFA pada Kasus 1.	136
Tabel 5.9 Performansi Kasus 2 dengan FA, MFA dan AMFA	138
Tabel 5.10 Performansi Kasus 3 dengan FA, MFA dan AMFA	140
Tabel 5.11 Performansi Kasus 4 antara FA, MFA dan AMFA	142
Tabel 5.12 Performansi Total Menggunakan AMFA	144

DAFTAR ISTILAH DAN SIMBOL

ANFIS	<i>Adaptive Neuro Fuzzy Inference System</i>
AC	Adaptive Coordination
ACT	Actuator
ADC	Analog to Digital Converter
AI	Artificial Intelligence
AMFA	Adaptive Modified Firefly Algorithm
AND	Operator fuzzy AND
ANN	Artificial Neural Network
$\beta(\rho)$	Daya Tarik Kunang-kunang
b_0	Perpotongan y untuk regresi linear
CB	Circuit Breaker
CM	Curve Modeling
COMM	Communication
CT	Current Transformer
CTI	Clearing Time Interval
DG	Distributed Generation
DOCR	Digital Overcurrent Relay
DPR	Digital Protection Relay
EI	Extremely Inverse
epochs	Iterasi dalam proses pembelajaran
FA	Firefly Algorithm
FCM	Fuzzy Clustering Mean
FIS	Fuzzy Inference System
GA	Genetic Algorithm
GPIO	General Purpose Input Output
GUI	Graphical User Interface
η	Learning Rate
IEC	International Electrotechnical Commission
IED	Intelligence Electronic Device
IF	Arus Fault
I_h	Current High Setting
I_{hset}	Arus Short Circuit
IL	Arus Beban
I_{pick}	Arus Pickup
IPOT	Internet Protection of Things
IS	Arus Setup
L	Load
LCD	Liquid Crystal Display

LM	Leverberg Marquard
LTI	Long Time Inverse
MAD	Mean Absolute Deviation
MAPE	Mean Absolute Percentage Error
MCU	Microcontroller Unit
MF	Membership Function
MFA	Modified Firefly Algorithm
mo	Lereng Regresi Linear Simulasi Network
MSA	Multiple Sequence Alignment
MSE	Mean Square Error
NI	Normal Inverse
NOT	Operator fuzzy NOT
$O(s)$	Fungsi Sigmoid Unipolar
OC	Overcurrent
OCR	Overcurrent Relay
OCR	Overcurrent Relay
OF	Objective Function
o_j	Output Neuron ke j
OR	Operator fuzzy OR
Osc	Oscilloscope
e	Error training
$p(x)$	Nilai Fungsi Lagrange
PC	Personal Computer
PO	Parameter Optimization
PS	Plug Setting
r	Jarak Cartesian
Ref	Reference
RLY	Rele
RMSE	Root Mean Square Error
ro	Nilai Parameter Regresi
S	Source
SC	Short Circuit
SI	Standard Inverse
s_j	Nilai Fungsi Aktivasi j
SPI	Serial Peripheral Interface
TDS	Time Dial Setting
tF	Waktu Trip
TFT	Thin-Film Transistor
thset	Trip Saat Short Circuit
TIM	Timer
TMS	Time Multiplier Set
UI	User Interface

USART	<i>Universal Serial Asynchronous Receiver Transmitter</i>
VI	Very Inverse
w_j	Bobot ke j
WTG	Win Turbin Generator
α	Parameter Acak

BAB I

PENDAHULUAN

1.1. Latar Belakang

Pada abad ke-21 dan seterusnya, teknologi yang terkait dengan *smart grid* dan energi terbarukan merupakan isu penting berkaitan dengan masalah perubahan iklim global dan ketersediaan energi masa depan. Evolusi pembangkitan energi listrik secara konvensional atau terpusat akan mulai dikembangkan menuju bentuk pembangkit listrik tersebar atau *Distributed Generation* (DG) [1] dengan jaringan *microgrid*.

Dalam rangka memenuhi permintaan tenaga listrik yang semakin meningkat, tuntutan akan kualitas layanan dan produk yang tinggi serta target pengurangan kadar polusi udara yang tidak bisa dihindari, maka infrastruktur jaringan listrik yang ada harus dikembangkan menjadi *smart grid* yang fleksibel, dengan sistem jaringan yang terkoneksi dengan pembangkit energi listrik tersebar DG. Penelitian telah meramalkan bahwa sekitar 20% sumber energi untuk tahun 2010-2020 [2] akan dapat dipenuhi dari sumber energi yang dihasilkan dari DG dengan sistem *multisource*.

Namun, mengintegrasikan DG ke sistem jaringan distribusi menyebabkan beberapa masalah teknis, khususnya yang terkait dengan sistem proteksi. Sistem proteksi model lama yang dirancang untuk sistem distribusi jaringan pasif dan radial tidak memadai lagi untuk "*Emerging Distribution Grid*". Sebuah paradigma proteksi model baru beserta arsitektur jaringannya diperlukan dalam menjawab perubahan perilaku gangguan yang disebabkan oleh kondisi DG yang tidak menentu akibat dari kondisi cuaca atau kondisi alam yang selalu berubah. Hal ini berdampak pada setting parameter rele yang juga harus berubah mengikuti perubahan dari status DG.

Proteksi konvensional yang dirancang untuk jaringan radial dan pasif tidak mampu memenuhi jaringan yang semakin kompleks dan aktif tersebut, serta dimungkinkan memiliki topologi terintegrasi *radial* dan *ring* dengan beragam

sumber DG, penyimpanan, dan beban terkendali [3][4]. Desain sistem proteksi untuk sistem distribusi tersebut membutuhkan paradigma proteksi yang sama sekali baru, baik dari topologi jaringan, sistem monitoring dan kendali, sarana komunikasi, perangkat rele digital pintar serta dibantu dengan algoritma kecerdasan komputasional yang memadai.

Perkembangan teknologi mikro elektronika memberikan sumbangsih yang sangat besar dalam perkembangan perangkat proteksi cerdas dengan dukungan algoritma kecerdasan buatan sebagai perangkat lunak yang menentukan fungsi kerja perangkat. Pada disertasi ini telah dilakukan inovasi baru untuk memodelkan kurva karakteristik rele digital standar hingga kurva karakteristik *non-standard* yang bersifat *user-defined*, dengan bantuan algoritma cerdas. Sehingga dihasilkan prototipe *direction digital overcurrent relay* yang mampu menyimpan beberapa model kurva karakteristik *user-defined* yang dapat dipilih secara otomatis sesuai dengan kebutuhan oleh unit pengendali terpusat atau koordinasi pintar antar rele dalam suatu jaringan distribusi.

Dengan memanfaatkan *internal peripheral communication* yang terdapat didalam mikrokontroller sebagai sarana komunikasi untuk memilih kurva yang digunakan merupakan nilai lebih dari perangkat proteksi yang dibangun. Selain memodelkan kurva karakteristik juga telah dilakukan inovasi temuan baru untuk melakukan optimisasi parameter seting rele yang bekerja secara koordinatif dengan rele lainnya dalam satu jaringan distribusi.

Tindak lanjut kegiatan penelitian berikutnya adalah integrasi antara pemodelan kurva dan optimisasi menjadi satu kesatuan sistem yang mampu menjawab permasalahan sistem proteksi pada jaringan distribusi yang bersifat aktif.

1.2. Rumusan Masalah

Masalah yang dihadapi untuk menjawab tuntutan sistem proteksi yang mampu bersifat adaptif adalah:

- Algoritma atau metode *artificial intelligent* yang digunakan untuk menghasilkan model kurva karakteristik harus akurat dengan kecepatan eksekusi yang masih dapat diterima sebagai perangkat proteksi digital.

- Sensor dan *peripheral* yang digunakan untuk membaca besar dan arah arus harus menghasilkan data yang bebas dari gangguan.
- *Peripheral* konversi analog ke digital mempunyai kecepatan dan resolusi yang tinggi, paling tidak mampu melakukan *data capturing* satu periode sinyal gangguan.
- Algoritma koordinasi komunikasi data antar rele atau rele dengan *master control* kurang dari batas minimum waktu pemutusan rele.
- Algoritma optimisasi *grading value* antar rele menghasilkan nilai minimum namun masih memenuhi syarat koordinasi.
- Algoritma kecerdasan buatan yang mampu memproses semua parameter yang dibutuhkan untuk memutuskan nilai seting yang optimum sesuai dengan kondisi saat itu secara cepat dan akurat.

1.3. Tujuan dan Manfaat Penelitian

Tujuan penelitian adalah untuk membangun prototipe perangkat proteksi rele digital arus lebih dengan kurva karakteristik yang dapat dimodelkan, baik berupa kurva standar maupun *user-defined curve* yang disimpan didalam rele dan dapat dipilih jenis kurva yang sesuai dengan kondisi jaringan distribusi saat itu, selanjutnya parameter yang ada pada masing-masing rele dilakukan optimisasi untuk keperluan koordinasi proteksi dalam satu jaringan distribusi.

Manfaat penelitian yang akan dihasilkan adalah mampu menjawab ketersediaan perangkat proteksi digital dengan kurva proteksi yang dimodelkan dan dapat melakukan keputusan secara mandiri maupun koordinatif terkait dengan nilai setting parameter proteksi yang sesuai dengan kondisi sistem jaringan distribusi saat itu.

1.4. Kontribusi dan Orisinalitas

Kontribusi dari penelitian adalah terciptanya perangkat proteksi digital terprogram, adaptif serta optimal dalam seting parameternya yang mampu memenuhi kebutuhan yang sangat mendesak terkait dengan perkembangan jaringan distribusi aktif saat ini dan masa mendatang.

Orisinalitas dari penelitian ini adalah pemanfaatan algoritma kecerdasan buatan untuk merubah paradigma kurva berdasar persamaan standar pada rele digital menjadi kurva dalam bentuk model yang akan memperluas fungsi rele semakin *advanced* serta memberi keleluasaan kepada para *user* untuk merancang kurva sesuai yang dibutuhkan dan dampak secara luas adalah berubahnya fitur rele pasif menjadi rele adaptif yang mampu berkoordinasi dalam jaringan *active distribution* dengan parameter rele yang dioptimisasikan.

1.5. Roadmap Penelitian

Roadmap atau peta jalan penelitian secara keseluruhan yang dilakukan oleh peneliti diberikan pada Gambar 1.1 dalam bentuk *fishbone diagram*. Untuk menghasilkan target “*self-adaptable coordination overcurrent digital protection relay for power distribution network*” didukung oleh tiga sub topik yang terdiri dari pemodelan kurva atau *curve modeling*, optimisasi parameter seting rele atau *parameter optimization* serta koordinasi adaptif atau *adaptive coordination*.

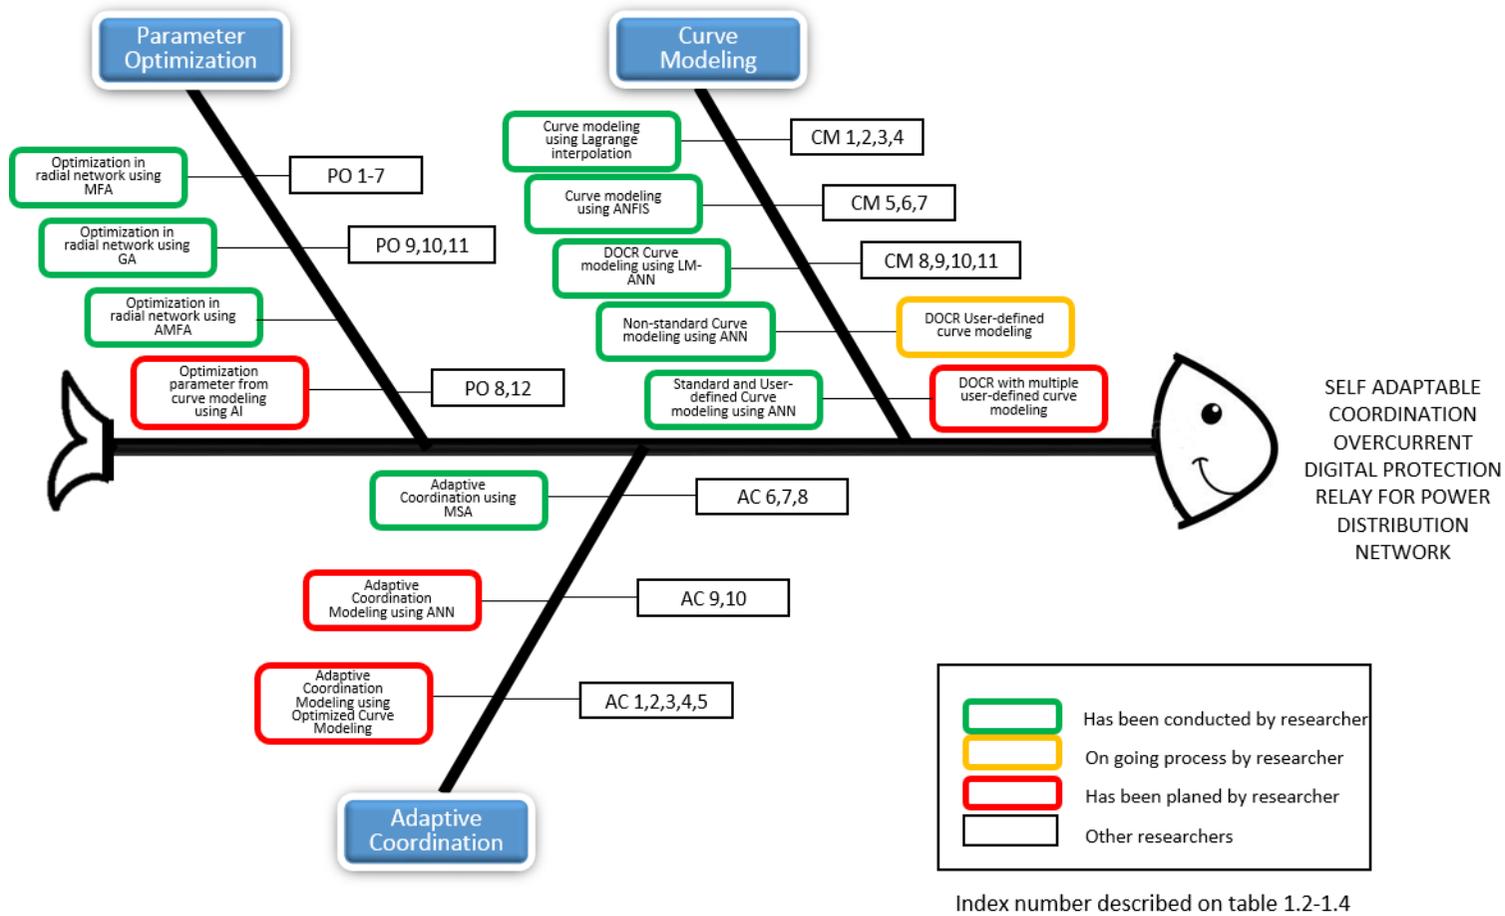
Pada sub topik pemodelan kurva dilakukan upaya untuk merancang bangun kurva karakteristik yang biasanya berbasis persamaan kurva standar dirubah menjadi suatu model yang mampu berfungsi sama dengan saat menggunakan persamaan standar. Pemodelan dimulai dengan menggunakan metode sederhana seperti interpolasi *polynomial* Lagrange hingga algoritma kecerdasan buatan seperti *adaptive neuro fuzzy inference system* (ANFIS) serta *artificial neural network* (ANN). Pemodelan kurva karakteristik tidak hanya diuji coba untuk kurva standar atau konvensional namun juga diuji coba memodelkan kurva karakteristik rele digital non-konvensional, dengan harapan para operator peralatan proteksi dapat dengan leluasa merancang kurva sesuai dengan kebutuhan lapangan atau disebut dengan *user-defined curve*. Hal ini sebagai langkah terobosan cerdas untuk mengembangkan rele digital yang bersifat adaptif, dimana dalam satu rele terdapat beberapa model kurva yang dirancang oleh operator dimana penggunaannya tergantung dari kebutuhan saat itu yang dapat dipilih secara otomatis.

Pada setiap kurva terdapat beberapa parameter penentu operasi kerja rele, seperti misalnya arus *pickup* atau *plug setting* (PS) dan *time multiplier setting*

(TMS) atau *time dial setting* (TDS). Dimana kedua parameter tersebut akan menjadi parameter penentu saat rele berkoordinasi dengan rele-rele lain atau perangkat pengaman lainnya dalam satu jaringan distribusi. *Grading time* antar kurva perlu dicari yang paling optimum, sehingga perangkat yang diamankan betul-betul dijamin tidak mendapatkan aliran arus yang sangat besar dalam waktu yang lama. Beberapa algoritma optimisasi telah diujicoba untuk membantu mendapatkan nilai yang optimum seperti *firefly algorithm* (FA), *modified firefly algorithm* (MFA) serta *adaptive modified firefly algorithm* (AMFA).

Sub topik penelitian lanjutan adalah memodelkan koordinasi rele dalam satu jaringan distribusi sehingga perangkat pengaman bersifat adaptif pada jaringan yang bersifat dinamis dikarenakan penggunaan DG. Terdapat dua usulan yang akan dikerjakan pada masa datang yakni berbentuk *master-slave* serta *autonomous*. Pada konsep *master-slave*, dimana semua perangkat rele digital yang ada dalam satu jaringan dianggap sebagai *slave* yang bertugas untuk mengumpulkan kondisi saat itu dan mengirimnya ke *master control*, setelah semua informasi pada sisi *slave* terkumpul di *master control*, kemudian master akan melakukan proses perhitungan nilai seting untuk masing-masing rele dengan menggunakan model yang telah dikembangkan serta mengirimnya balik ke masing-masing rele hasil dari keluaran model. Sedangkan *autonomous coordination* adalah algoritma cerdas dengan cara membagi atau *share* informasi kondisi riel dari masing-masing *slave* rele sebagai dasar untuk memutuskan aksi pada masing-masing rele.

Pada *fish bone diagram* terdapat tanda kotak berwarna dengan judul penelitian yang dilakukan, kotak warna hijau merupakan kegiatan yang telah dilakukan, kotak warna kuning sedang dilakukan serta kotak warna merah adalah rencana kegiatan penelitian selanjutnya serta warna hitam adalah penelitian atau publikasi terkait yang telah dilakukan oleh peneliti lain. Judul publikasi secara rinci diberikan pada Tabel 1.1 hingga Tabel 1.4.



Gambar 1.1 Fishbone Diagram

Tabel 1.1 Daftar Publikasi Peneliti

Hasil riset yang telah dilakukan dan dipublikasikan oleh Peneliti
A. Tjahjono, D. O. Anggriawan, A. K. Faizin, A. Priyadi, M. Pujiantara, and M. H. Purnomo, “Optimal Coordination of Overcurrent Relays in Radial System with Distributed Generation Using Modified Firefly Algorithm,” <i>International Journal Electrical Engineering Informatics.</i> , vol. 7, no. 4, p. 691, 2015.
A. Tjahjono, M. Pujiantara, J. Taufik, M. H. Purnomo, and others, “Adaptive Modified Firefly Algorithm for Optimal Coordination of Overcurrent Relays”, <i>IET Generation Transmission Distribution</i> , DOI: 10.1049/iet-gtd.2016.1563 2017.
A. Tjahjono, A. Priyadi, M. H. Purnomo, and M. Pujiantara, “Overcurrent relay curve modeling using adaptive neuro fuzzy inference system,” in 2014 Makassar International Conference on Electrical Engineering and Informatics (MICEEI), 2014, pp. 103–108.
A. Tjahjono, D. O. Anggriawan, A. Priyadi, M. Pujiantara, and M. H. Purnomo, “Overcurrent relay curve modeling and its application in the real industrial power systems using adaptive neuro fuzzy inference system,” in 2015 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA), 2015, pp. 1–6.
A. Tjahjono, D. O. Anggriawan, A. Priyadi, M. Pujiantara, and M. H. Purnomo, “Digital overcurrent relay with conventional curve modeling using Levenberg-Marquardt backpropagation,” in 2015 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2015, pp. 171–176.
D. Irawan, A. Tjahjono, M. Pujiantara, and P. M. Hery, “Adaptive overcurrent relays coordination based on multiple sequence alignment algorithm (MSA),” in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 101–106.
A. Tjahjono et al., “Modeling Characteristic Curves of Digital Overcurrent Relay (DOCR) for User-Defined Characteristic Curve Using Artificial Neural Network,” in 2016 International Conference on Computational Science and Computational Intelligence (CSCI), 2016, pp. 478–483.
A. Tjahjono, I. Sudiharto, Suryono, and D. O. Anggriawan, “Modelling non-standard over current relay characteristic curves using combined lagrange polynomial interpolation and curve fitting,” in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 589–594.
M. Pujiantara et al., “Optimization technique based adaptive overcurrent protection in radial system with DG using genetic algorithm,” in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 83–88.

Tabel 1.2. Publikasi Peneliti Lain Terkait Pemodelan Kurva

Penelitian/Publikasi yang telah dilakukan oleh Peneliti lain [Curve Modeling/CM]	
1	G. Benmouyal, "Design of a digital multi-curve time-overcurrent relay," IEEE Trans. Power Deliv., vol. 5, no. 4, pp. 1725–1731, Oct. 1990.
2	K. Balasubramanian, "EPROM-based overcurrent relays," in ,Proceedings of the Thirty-Eighth IEEE Holm Conference on Electrical Contacts, 1992, 1992, pp. 203–207.
3	H. A. Darwish, M. A. Rahman, A. I. Taalab, and H. Shaaban, "Digital model of overcurrent relay characteristics," in , Conference Record of the 1995 IEEE Industry Applications Conference, 1995. Thirtieth IASAnnual Meeting, IAS '95, 1995, vol. 2, pp. 1187–1192 vol.2.
4	H. A. Darwish, A. I. Taalab, and H. Assal, "A novel overcurrent relay with universal characteristics," in Transmission and Distribution Conference and Exposition, 2001 IEEE/PES, 2001, vol. 1, pp. 53–58 vol.1.
5	J. C. Tan, P. G. McLaren, R. P. Jayasinghe, and P. L. Wilson, "Software model for inverse time overcurrent relays incorporating IEC and IEEE standard curves," in Canadian Conference on Electrical and Computer Engineering, 2002. IEEE CCECE 2002, 2002, vol. 1, pp. 37–41 vol.1.
6	K. Shehata, A. Bahaa, K. Morad, and A. Sharaf, "Design and implementation of FPGA based and microcontroller based current relay," in The 16th International Conference on Microelectronics, 2004. ICM 2004 Proceedings, 2004, pp. 783–786.
7	C. J. Mozina, "Advances in Multifunction Digital Transformer Relays," in 2005/2006 IEEE/PES Transmission and Distribution Conference and Exhibition, 2006, pp. 858–862.
8	G. V. Kshirsagar, G. N. Mulay, and S. Yeolekar, "TMS320F28335 based single phase overcurrent protection Implementation using Numerical Relay," in 2014 6th IEEE Power India International Conference (PIICON), 2014, pp. 1–5.
9	D. N. Vishwakarma and Z. Moravej, "ANN based directional overcurrent relay," in Transmission and Distribution Conference and Exposition,2001 IEEE/PES, 2001, vol. 1, pp. 59–64 vol.1.
10	H. A. Abyaneh, H. K. Karegar, and M. Al-Dabbagh, "Interpolation of measured data based on neural network to model overcurrent relays in power systems," in Control Conference, 2004. 5th Asian, 2004, vol. 3, p. 1393–1397 Vol.3.
11	Y. L. Goh, A. K. Ramasamy, A. A. Z. Abidin, and F. H. Nagi, "Modelling of overcurrent relay using digital signal processor," in 2010 IEEE Symposium on Industrial Electronics Applications (ISIEA), 2010, pp.367–370.

Tabel 1.3. Publikasi Peneliti Lain Terkait Optimisasi Parameter

Penelitian/Publikasi yang telah dilakukan Peneliti lain [Parameter Optimization/PO]	
1	Chen, C.R., Lee, C.H., Chang, C.J. “Optimal overcurrent relay coordination in power distribution system using a new approach”, <i>Electr. Power Energy Syst.</i> , 2013, pp. 217–222
2	Razavi, F., Abyaneh, H.A., Al-Dabbagh, M., <i>et al.</i> “A new comprehensive genetic algorithm method for optimal overcurrent relays coordination”, <i>Electr. Power Syst. Res.</i> , 2008, pp. 713–720
3	Mohammadi, R., Abyaneh, H.A., Razavi, F., <i>et al.</i> “Optimal relays coordination efficient method in interconnected power systems”, <i>J. Elect. Eng.</i> , 2010, (2), pp. 75–83
4	Zeineldin, H.H., Sharaf, H.M., Ibrahim, D.K., <i>et al.</i> “Optimal protection coordination for meshed distribution systems with DG using dual setting directional over-current relays”, <i>IEEE Trans. Smart Grid</i> , 2015, (1)
5	Bedekar, P.P., Bhide, S.R., Vijay, S.K. “Optimum coordination of overcurrent relay timing using simplex method”, <i>Electr. Power Compon. Syst.</i> , 2010, (10), pp. 1175–1193
6	Abyaneh, H.A., Keyhani, R. “Optimal coordination of overcurrent relays in power system by dual simplex method”. Proc. AUPEC Conf., Perth, Australia, 1995, vol. 3, pp. 440–445
7	Bedekar, P.P., Bhide, S.R., Kale, V.S. “Optimum time coordination of overcurrent relays in distribution system using big-M method”, <i>WSEAS Trans. Power Syst.</i> , 2009.
8	Zeineldin, H.H., El-Saadany, E.F., Salama, M.M.A. “Optimal coordination of overcurrent relays using a modified particle swarm optimization”, <i>Electr. Power Syst. Res.</i> , 2006, pp. 988–995
9	Singh, M., Panigrahi, B.K., Abhyankar, A.R. “Optimal coordination of directional overcurrent relays using teaching learning-based optimization (TLBO) algorithm”, <i>Electr. Power Energy Syst.</i> , 2013, pp. 33–41
10	Bedekar, P.P., Bhide, S.R. “Optimum coordination of directional overcurrent relays using the hybrid GA-NLP approach”, <i>IEEE Trans. Power Deliv.</i> , 2011.
11	Thangaraj, R., Pant, M., Deep, K. “Optimal coordination of overcurrent relays using modified differential evolution algorithms”, <i>Eng. Appl. Artif. Intell.</i> , 2010, pp. 820–829
12	Gokhale, S.S., Kale, V.S. “Application of the FA to optimal overcurrent relay coordination”. IEEE Int. Conf. on Optimization of Electrical and Electronic Equipment, 2014

Tabel 1.4. Publikasi Peneliti Lain Terkait Koordinasi Adaptif

Penelitian/Publikasi yang telah dilakukan Peneliti lain [Adaptive Coordination/AC]	
1	Conti, S. “Analysis of distribution network protection issues in presence of dispersed generation”, <i>Electr. Power Syst. Res.</i> , 2009, 79, pp. 49–56
2	Tuitemwong, K., Premrudeepreechacharn, S. “Expert system for protection coordination of distribution system with distributed generators”, <i>Electr. Power Energy Syst.</i> , 2011, 33, pp. 466–471
3	Conti, S., Nicotra, S. “Procedures for fault location and isolation to solve protection selectivity problems in MV distribution networks with dispersed generation”, <i>Electr. Power Energy Syst.</i> , 2009, 79, pp. 57–64
4	Gopalan, S.A., Sreeram, V., Lu, H.H.C. “A review of coordination strategies and protection schemes for microgrids”, <i>Renew. Sustain. Energy Rev.</i> , 2014,32, pp. 222–228
5	Mohammadi, R., Abyaneh, H.A., Rudsari, A.M., <i>et al.</i> “Overcurrent relays coordination considering the priority of constraints”, <i>IEEE Trans. Power Deliv.</i> , 2013, 26.
6	Urdaneta, A.J., Resterbo, H., Sanchez, J., <i>et al.</i> “Coordination of directional overcurrent relays timing using linear programming”, <i>IEEE Trans. Power Deliv.</i> , 2002, 11, (1), pp. 122–129
7	So, C.W., Li, K.K. “Overcurrent relay coordination by evolutionary programming”, <i>Electr. Power Syst. Res.</i> , 2000, 53, pp. 83–90
8	Amraee, T. “Coordination of directional overcurrent relays using seeker algorithm”, <i>IEEE Trans. Power Deliv.</i> , 2012, 27.
9	Noghabi, A.S., Sadeh, J., Mashhadi, H.R. “Considering different network topologies in optimal overcurrent relay coordination using a hybrid GA”, <i>IEEE Trans. Power Deliv.</i> , 2009, 24, pp. 1857–1863
10	Zellagui, M., Benabid, R., Boudour, M., <i>et al.</i> “Application of FA for optimal coordination of directional overcurrent protection relays in presence of series compensation”, <i>J. Autom. Syst. Eng.</i> , 2014, 8, pp. 92–107

BAB II

KECERDASAN KOMPUTASIONAL UNTUK PEMODELAN KURVA DAN OPTIMISASI PARAMETER PADA *DIGITAL OVERCURRENT RELAY*

2.1. Konsep Dasar Sistem Proteksi

Ketergantungan pasokan energi listrik terus meningkat dari masa ke masa baik di Negara sedang berkembang maupun telah berkembang, pemenuhan energi listrik terkait dengan reliabilitas, kualitas serta keamanan dengan harga ekonomis menjadi hal yang sangat penting bagi pelanggan. Keberlangsungan pasokan energi listrik menjadi hal yang sangat penting, dengan terus berupaya mengurangi kesalahan yang terjadi pada sistem pasokan energi listrik dengan menempatkan keamanan pasokan energi listrik pada tingkat yang paling tinggi [5].

Terkait dengan pasokan energi pada sistem jaringan distribusi perlu sejumlah dukungan untuk memenuhi persyaratan keselamatan, keandalan dan kualitas pasokan listrik dengan memasang perangkat proteksi atau pengaman yang terpasang pada sistem jaringan untuk mengeliminasi kesalahan dan membatasi gangguan pada peralatan jaringan distribusi.

Diantara penyebab gangguan utama adalah adanya petir, kerusakan isolasi, vandalisme serta terhubungnya saluran karena ranting pohon atau hewan. Mayoritas gangguan bersifat sementara tanpa menghilangkan pasokan listrik sedangkan gangguan lainnya bersifat permanen yang menyebabkan pemadaman pasokan listrik.

Sistem pengaman yang terkoordinasi dengan baik dapat menjamin ketersediaan pasokan listrik yang memadai sesuai ketentuan standar operasi, yang mampu dengan cepat secara otomatis melakukan isolasi pada lokasi gangguan sehingga dapat meminimalkan kerusakan peralatan serta menjaga ketersediaan pasokan pada lokasi lainnya.

Prinsip dasar saat menerapkan perangkat pengaman pada sistem jaringan adalah kecepatan mendeteksi adanya gangguan atau kondisi abnormal dan segera

melakukan isolasi pada daerah gangguan agar tidak mempengaruhi ketersediaan pasokan listrik pada area yang tidak terjadi gangguan. Pemutusan peralatan harus dibatasi pada jumlah minimum yang diperlukan untuk mengisolasi gangguan sistem. Perangkat pengaman harus cukup sensitif untuk beroperasi bila terjadi kesalahan pada kondisi gangguan minimum, namun cukup stabil agar tidak beroperasi bila peralatan yang terkait memberikan arus maksimum, yang mungkin merupakan aliran arus yang sangat singkat.

Perlindungan pengaman cadangan untuk menutupi kemungkinan kegagalan pengaman utama diberikan pada kebanyakan rangkaian untuk meningkatkan keandalan sistem pengaman. Dibeberapa lokasi masih ditemukan rele elektromekanis sebagai perangkat pengaman namun cenderung untuk menggantinya dengan mikroprosesor dan rele numerik, terutama pada pengaturan pengamanan yang lebih kompleks.

Kriteria dan perencanaan sistem proteksi harus memperhitungkan prinsip dasar sebagai berikut [5] [6]:

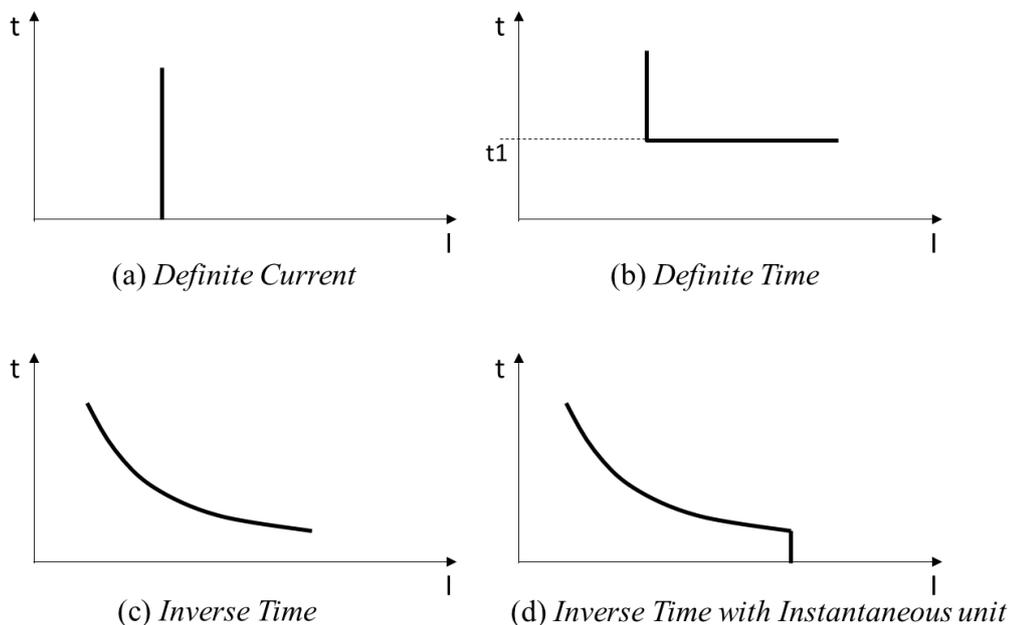
- *Reliability*: kemampuan proteksi untuk beroperasi dengan benar saat terjadi kesalahan.
- Kecepatan: waktu pengoperasian minimum untuk menyelesaikan saat terjadi kesalahan agar terhindar dari kerusakan pada peralatan.
- Selektivitas: sistem proteksi harus memutuskan hanya komponen yang salah atau bagian terkecil yang mungkin mengandung kesalahan dari sistem untuk meminimalkan konsekuensi kesalahan.
- Redundansi: sistem proteksi harus memperhatikan fungsi redundan rele agar dapat meningkatkan keandalan. Fungsi redundan direncanakan dan disebut sebagai perlindungan cadangan.
- Keamanan: kemampuan untuk menolak semua kejadian sistem tenaga dan transien yang bukan kesalahan sehingga bagian sistem tenaga yang tidak ada gangguan tidak perlu terputus.
- Ketergantungan: kemampuan untuk mendeteksi dan melepaskan semua kesalahan dalam zona yang dilindungi
- Biaya: maksimum perlindungan dengan biaya serendah mungkin.

Karena praktis tidak mungkin untuk memenuhi semua poin yang disebutkan di atas secara bersamaan, mau tidak mau kompromi diperlukan untuk mendapatkan sistem perlindungan yang optimal.

Jenis rele berdasar besaran ukur dan prinsip kerja adalah[7]:

- Rele arus lebih (*Overcurrent relay*)
- Rele tegangan kurang (*Under voltage relay*)
- Rele jarak (*Distance relay*)
- Rele arah (*Direction relay*)
- Rele hubung tanah (*Ground fault relay*)
- Rele arus hubung tanah terbatas (*Restricted Earth Fault*)
- Rele diferensial (*Differential relay*)

Berdasarkan karakteristik operasi rele, *overcurrent relay* dapat diklasifikasikan menjadi tiga kelompok: *definite current* atau *instantaneous*, *definite time*, *inverse time* serta kombinasi *inverse time* dengan *instantaneous*. Keempat jenis kurva karakteristik ditunjukkan pada Gambar 2.1 [6] [7].



Gambar 2.1 Pembagian *Overcurrent Relay*

Pengaturan rele ditentukan untuk memberikan waktu operasi terpendek pada tingkat kesalahan maksimum dan kemudian diperiksa untuk melihat apakah operasi juga memenuhi kesalahan minimum dari yang diharapkan. Selalu dianjurkan untuk merencanakan kurva rele dan perangkat perlindungan lainnya, seperti sekering, yang beroperasi secara seri dalam skala yang sama, biasanya lebih mudah menggunakan skala yang sesuai dengan arus yang diharapkan pada basis tegangan terendah atau menggunakan basis *main voltage*.

Aturan dasar untuk koordinasi rele yang benar umumnya dapat dinyatakan sebagai berikut [7] [8]:

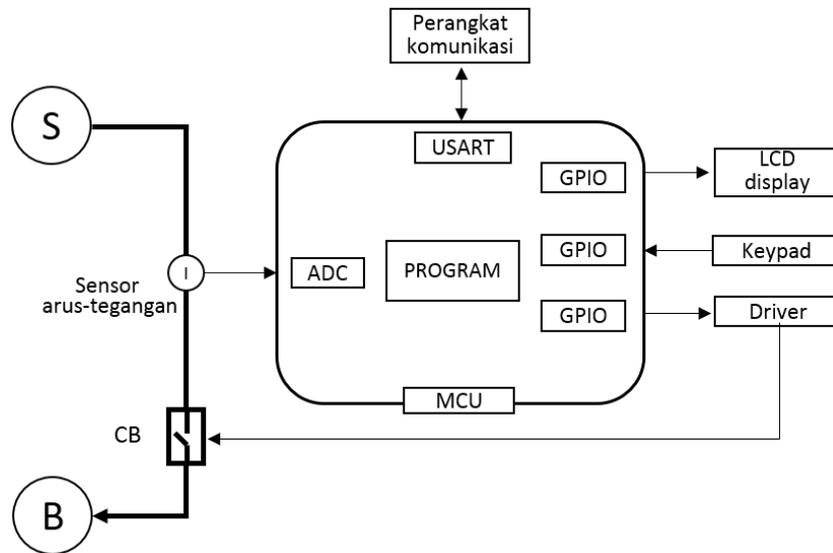
- Bila memungkinkan, gunakan rele dengan karakteristik operasi yang sama secara seri satu sama lain
- Pastikan rele yang terjauh dari sumber memiliki pengaturan arus sama dengan atau kurang dari rele di belakangnya, yaitu arus utama yang diperlukan untuk mengoperasikan rele di depan selalu sama atau kurang dari arus utama yang diperlukan untuk beroperasi rele di belakangnya

2.2. Digital Overcurrent Relay

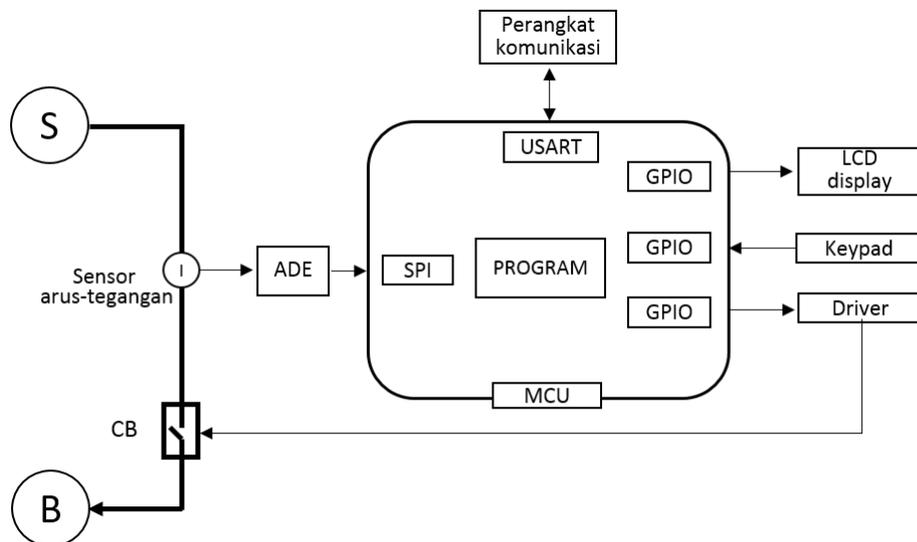
Perangkat proteksi atau pengaman rele digital merupakan jenis akhir dari revolusi pengembangan pengaman dengan bantuan *microprosesor* atau *microcontroller*, dimana mempunyai fungsi yang sama dengan jenis rele mekanik dengan perbedaan yang cukup signifikan, mulai dari cara pembacaan nilai arus atau tegangan, pemrosesan sinyal hingga eksekusi berdasarkan algoritma [9][10].

Gambar 2.2.(a) ditunjukkan bagan umum dari rele digital yang berfungsi untuk melakukan proteksi pada beban listrik (B) yang diberi sumber arus bolak balik (S) dengan pengendali utama *microcontroller*, dengan bantuan sensor arus yang kemudian dibaca oleh perubah analog ke digital atau *analog to digital converter* (ADC) yang akan menjadi nilai masukan pada program yang berfungsi sebagai perangkat proteksi dengan keluaran berupa sinyal *trip* melalui *general purpose input output* (GPIO) dibantu dengan *driver*, untuk keperluan interaksi dengan pengguna dipergunakan *display* dan *keypad* yang terhubung ke GPIO. Untuk keperluan komunikasi dengan perangkat lain baik komputer maupun sesama rele menggunakan *universal serial asynchronous receiver transmitter* (USART).

Pada Gambar 2.2.(b) ditunjukkan alternatif pemrosesan sinyal digunakan *chip* tambahan diluar *microcontroller* yakni *chip digital signal processing* ADE, dimana terhubung secara serial melalui *serial peripheral interface* (SPI) pada *microcontroller* [11][12].



(a) Rele Digital Menggunakan ADC Internal



(b) Rele Digital Menggunakan ADE

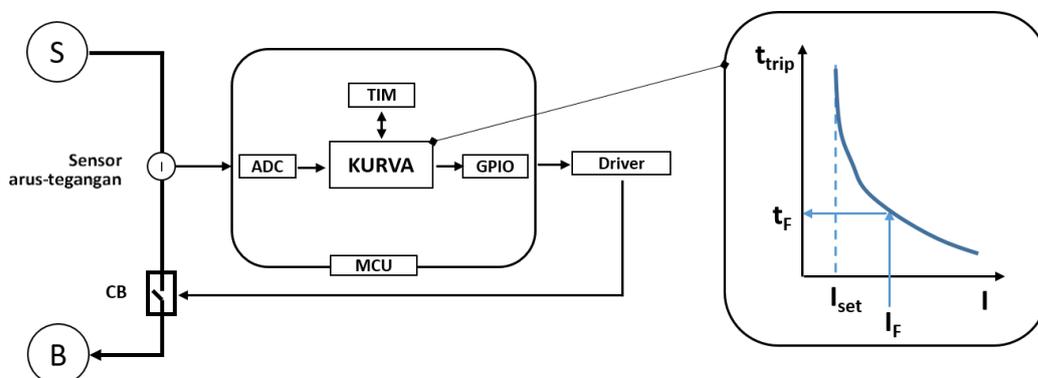
Gambar 2.2. Bagan Rele Digital

2.3. Peran Kurva Karakteristik pada Rele Digital

Pada Gambar 2.2 terdapat bagian yang memegang peran penting untuk fungsi kerja rele yakni bagian program, dimana didalamnya disusun serangkaian alur program berupa persamaan kurva karakteristik rele serta program pendukung. Pada rele tipe *overcurrent relay* (OCR) kurva karakteristik yang dipilih akan menentukan fungsi atau operasi dari rele tersebut, pada Gambar 2.3 diberikan penjelasan secara umum bagaimana kurva karakteristik menentukan operasi kerja dari rele digital.

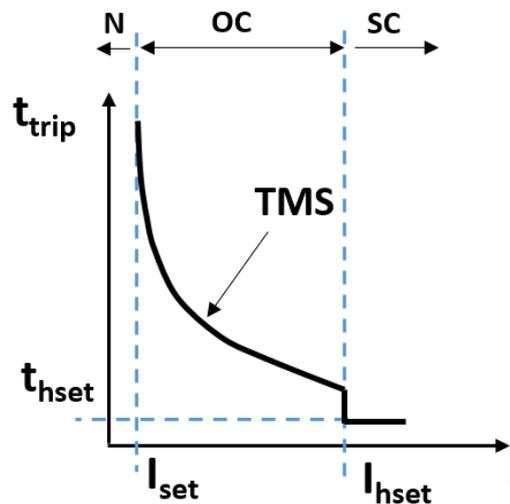
Pada saat arus *fault* I_F yang dibaca oleh unit ADC melebihi arus setup (I_{set}) yang diakibatkan adanya gangguan maka dilakukan perhitungan waktu *trip* dengan menggunakan kurva karakteristik yang saat itu digunakan, setelah mendapatkan waktu *trip* (t_{trip}) atau *trip circuit breaker* (tcb) maka *timer* (TIM) akan mulai bekerja sesuai dengan nilai t_{trip} , jika waktu *trip* telah terlampaui maka *microcontroller* akan mengirim sinyal *trip* lewat GPIO untuk membuka *circuit breaker* (CB).

Kecepatan *microcontroller* untuk mendapatkan nilai arus yang saat itu lewat pada beban dengan ketelitian yang tinggi serta kurva yang menjadi referensi adalah kunci dari keberhasilan kerja rele digital, sehingga banyak dilakukan penelitian terkait dengan metode untuk meningkatkan kecepatan dalam mendapatkan nilai arus oleh ADC dengan tanpa diikuti dengan gangguan atau *noise*. Selain kecepatan mendapatkan nilai arus, hal lain yang terus diteliti adalah terkait dengan kurva yang akan digunakan, mengingat saat implementasi akan ditemukan berbagai hal terkait dengan bentuk dan posisi kurva yang harus mengikuti kebutuhan sistem, atau dikenal dengan *user-defined curve* [9][15].



Gambar 2.3. Peran Kurva Karakteristik pada Rele Digital

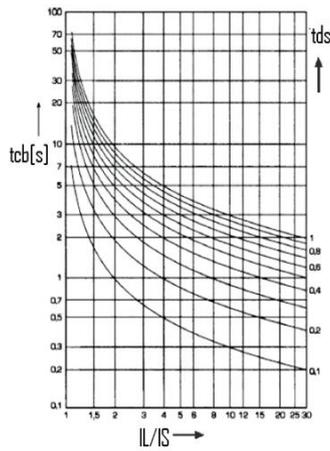
Ada beberapa parameter penting dalam kurva karakteristik rele digital seperti ditunjukkan pada Gambar 2.4. terdapat tiga bagian, yakni kondisi normal (N) dimana arus yang lewat pada beban tidak melebihi I_{SET} sehingga rele tidak bekerja, kondisi berikutnya adalah saat arus beban melebihi I_{SET} dan kurang dari I_{hset} disebut dengan *overcurrent* (OC), pada kondisi ini nilai *trip* dicari dengan menggunakan persamaan kurva dengan masukan arus beban yang lewat saat itu, sedang kondisi dimana arus beban melebihi I_{hset} disebut dengan kondisi arus hubung singkat atau *short circuit* (SC) dimana nilai waktu *trip* adalah t_{hset} . *Time dial setting* (TDS) atau *time multiplier setting* (TMS) adalah parameter terkait dengan kelengkungan kurva.



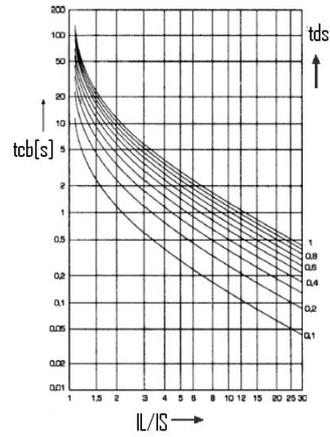
Gambar 2.4. Parameter Kurva Karakteristik Rele

Parameter PS serta TMS merupakan parameter penting saat digunakan di lapangan, sehingga banyak riset yang dilakukan untuk mendapatkan nilai optimum saat melakukan koordinasi dengan rele lain saat beroperasi dalam suatu jaringan distribusi dengan jumlah rele lebih dari satu unit.

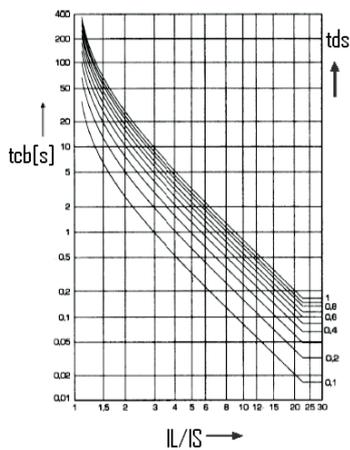
Jenis rele sesuai standar IEC 60255 ditunjukkan pada Gambar 2.5, terdiri dari *standard inverse*, *very inverse*, *extremely inverse* dan *long time inverse*, diberikan contoh kurva karakteristik rele dengan beberapa nilai TMS. Masih banyak jenis atau tipe kurva karakteristik rele yang tidak disebutkan dalam Gambar 2.5, empat jenis ini yang akan dipakai dalam pemodelan kurva standar [13][14].



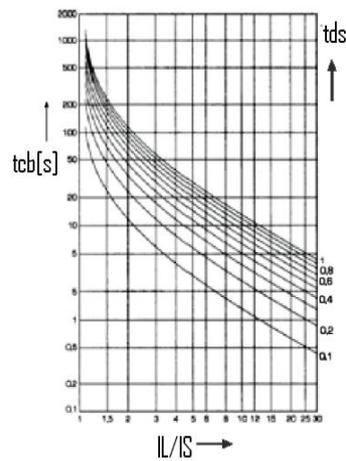
(a). Standard Inverse



(b). Very Inverse



(c). Extremely Inverse



(d). Long Time Inverse

Gambar 2.5. Kurva Karakteristik Rele

Persamaan masing-masing kurva karakteristik rele adalah sebagai berikut:

$$\text{Standard Inverse} \quad t_{trip} = \frac{0,14}{\left(\frac{I_L}{I_S}\right)^{0,02} - 1} \times TMS \quad (2.1)$$

$$\text{Very Inverse} \quad t_{trip} = \frac{13,5}{\left(\frac{I_L}{I_S}\right) - 1} \times TMS \quad (2.2)$$

$$\text{Extremely Inverse} \quad t_{trip} = \frac{80}{\left(\frac{I_L}{I_S}\right)^2 - 1} \times TMS \quad (2.3)$$

$$\text{Long Time Inverse } t_{trip} = \frac{120}{\left(\frac{I_L}{I_S}\right)^{-1}} \times TMS \quad (2.4)$$

Pada persamaan kurva karakteristik rele untuk mendapatkan nilai *trip* terdapat perbandingan rasio I_L/I_S , merupakan perbandingan arus yang melewati beban dibanding dengan arus set atau arus *pickup*, kemudian dikalikan dengan nilai TMS serta dikalikan dengan beberapa konstanta yang dapat dirumuskan sebagai berikut:

$$t_{trip} = \frac{A}{\left(\frac{I_L}{I_S}\right)^B - 1} \times TMS \quad (2.5)$$

Dari persamaan (2.5) dapat disusun nilai konstanta yang membedakan keempat jenis kurva karakteristik rele seperti pada Tabel 2.1.

Tabel 2.1. Konstanta pada Kurva Karakteristik Rele

Jenis Kurva	A	B
<i>Standard Inverse</i>	0,14	0,02
<i>Very Inverse</i>	13,5	1
<i>Extremely Inverse</i>	80	2
<i>Long Time Inverse</i>	120	1

Dengan semakin berkembangnya teknologi perangkat keras terutama *microcontroller* berdampak pada perkembangan rele digital, sehingga muncul banyak ide dan gagasan untuk mengembangkan rele digital yang sesuai keperluan dilapangan, salah satu contohnya adalah bagaimana agar pengguna bisa merancang kurva karakteristik sesuai kehendak dan keperluannya.

Dengan latar belakang tersebut maka penulis melakukan penelitian terobosan baru sehingga menghasilkan penelitian yang bermanfaat sebagai berikut:

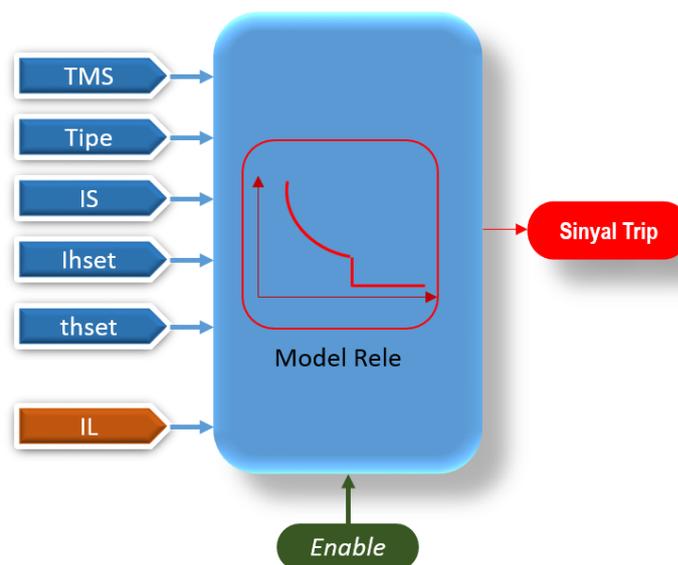
- Menjawab kebutuhan adanya solusi dari kasus *overlapping* kurva beberapa rele yang tergabung dalam satu jaringan distribusi dalam

skala besar, dengan cara merubah kurva yang semula berdasar persamaan standar menjadi kurva yang non-standar.

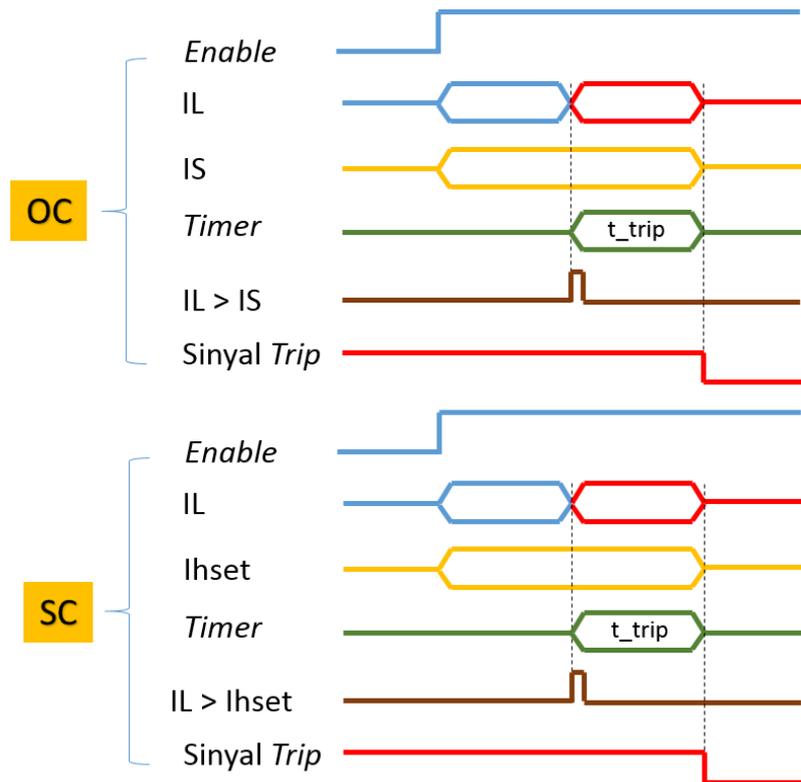
- Pengguna diberi kebebasan untuk merancang kurva karakteristik rele varian baru yang belum ada hingga saat ini atau disebut dengan *un-conventional curve*.
- Pengembangan rele digital dengan fitur multi kurva, sehingga mampu diakses pemilihan kurvanya sesuai keperluan saat itu, sehingga bisa digunakan untuk koordinasi secara adaptif.

Untuk mewujudkan hal tersebut maka kurva harus dapat dimodelkan dan disimpan pada rele digital dimana dirancang oleh pengguna sendiri, Gambar 2.6 memberikan penjelasan dari ide global bagaimana melakukan pemodelan rele digital. Secara lengkap parameter masukan untuk menyusun model adalah nilai TDS atau TMS, tipe kurva, arus setting atau *plug setting*, arus *high set* dan nilai *trip* saat *high set* dengan parameter keluaran model adalah waktu *trip*. Sedangkan masukan setelah menjadi model adalah arus beban yang mengalir saat itu.

Gambar 2.7 ditunjukkan secara timing diagram operasi kerja rele digital saat berfungsi sebagai *overcurrent relay* (OC) maupun saat *short circuit* (SC) dengan memanfaatkan kurva yang telah dimodelkan dan ditanam didalam rele digital.



Gambar 2.6. Parameter Lengkap Pemodelan Rele Digital



Gambar 2.7. Timing Diagram Operasi Kerja Rele Digital

Sesuai Gambar 2.7 terdapat dua operasi kerja rele, yaitu kondisi *overcurrent* (OC) dan kondisi *short circuit* (SC), operasi OC adalah kondisi dimana arus beban I_L melebihi arus *pick-up* I_S dan arus beban tidak lebih dari arus *high-set*, dimana nilai *trip* didapatkan dari perhitungan persamaan atau model kurva yang digunakan saat itu. Sedangkan operasi SC akan bekerja saat nilai I_L lebih atau sama dengan arus *high-set*, dimana nilai *trip* berupa konstanta yang telah direncanakan. Sehingga dapat dituliskan tiga syarat operasi kerja yakni saat kondisi normal, saat kondisi *overload* OC serta saat hubung singkat SC sebagai berikut:

$$\text{kondisi Normal:} \quad \text{jika } I_L < I_S \quad (2.6)$$

$$\text{kondisi OC:} \quad \text{jika } I_S < I_L < I_{HSET} \quad (2.7)$$

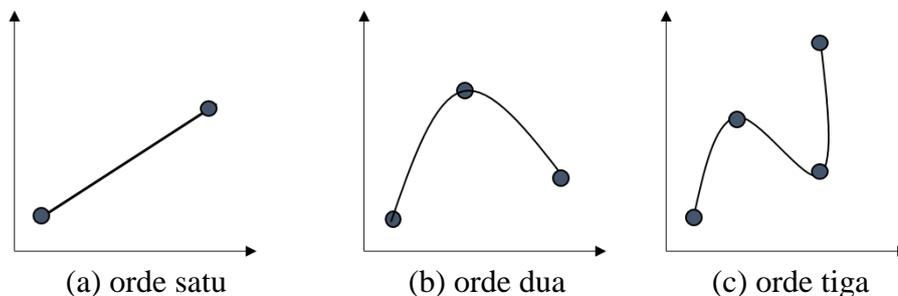
$$\text{kondisi SC:} \quad \text{jika } I_L > I_{HSET} \quad (2.8)$$

2.4. *LaGrange Interpolation Polynomial Characteristic Curve Modeling (LIP-CCV)*

Untuk memperkirakan nilai suatu titik diantara dua titik dengan tepat secara umum digunakan metode interpolasi polinomial, dengan rumus umum untuk orde polinomial ke n adalah:

$$f(x) = a_0 + a_1x + a_2x^2 + \dots + a_nx^n \quad (2.9)$$

Untuk $n + 1$ titik data, ada satu dan hanya satu polinomial orde ke- n yang melewati semua titik. Interpolasi polinomial terdiri dari penentuan polinomial orde ke- n yang unik sesuai dengan $n + 1$ titik data. Polinomial ini kemudian memberikan rumus untuk menghitung nilai antara. Meskipun ada satu dan hanya satu orde polinomial ke- n yang sesuai $n + 1$ titik, ada beragam format matematis dimana polinomial ini dapat diekspresikan. Dua alternatif yang sesuai untuk implementasi komputer adalah: Newton dan Lagrange polinomial. Contoh polinomial interpolasi ditunjukkan pada Gambar 2.8: (a) orde pertama (linier) yang menghubungkan dua titik, (b) orde kedua (kuadrat atau parabola) yang menghubungkan tiga titik, dan (c) orde ketiga yang menghubungkan empat titik, dengan contoh titik-titik seperti yang ditunjukkan pada Gambar 2.8.



Gambar 2.8. Interpolasi Polinomial

Prinsip interpolasi Lagrange adalah bahwa fungsi $f(x)$ yang nilainya diberikan pada kumpulan titik diasumsikan oleh polinomial $p(x)$ yang melewati setiap titik. Polinomial ini disebut polinomial interpolasi dan derajatnya kurang dari jumlah titik yang diberikan. Untuk dua titik data polinomial interpolasi diambil menjadi polinomial linier. Untuk tiga titik data, polinomial interpolasi diambil menjadi

kuadrat, empat titik data polinomial interpolasi diambil menjadi kubik, dan seterusnya.

Pada garis linier $p(x)=a_0+a_1x$ yang melewati dua titik $(x_0,f(x_0))$ dan titik $(x_1,f(x_1))$, dimana a_0 dan a_1 adalah konstanta, maka persamaan garisnya:

$$p(x) = \frac{x-x_1}{x_0-x_1} f(x_0) + \frac{x-x_0}{x_1-x_0} f(x_1) \quad (2.10)$$

Untuk persamaan garis kuadrat $p(x)=a_0+a_1x+a_2x^2$ yang melewati titik-titik $(x_0,f(x_0))$, $(x_1,f(x_1))$, serta $(x_2,f(x_2))$ maka persamaan garisnya:

$$p(x) = \frac{(x-x_1)(x-x_2)}{(x_0-x_1)(x_0-x_2)} f(x_0) + \frac{(x-x_0)(x-x_2)}{(x_1-x_0)(x_1-x_2)} f(x_1) + \frac{(x-x_0)(x-x_1)}{(x_2-x_0)(x_2-x_1)} f(x_2) \quad (2.11)$$

Untuk persamaan garis kubik $p(x)=a_0+a_1x+a_2x^2+a_3x^3$ yang melewati titik-titik $(x_0,f(x_0))$, $(x_1,f(x_1))$, $(x_2,f(x_2))$ serta $(x_3,f(x_3))$ maka persamaan garisnya:

$$p(x) = \frac{(x-x_1)(x-x_2)(x-x_3)}{(x_0-x_1)(x_0-x_2)(x_0-x_3)} f(x_0) + \frac{(x-x_0)(x-x_2)(x-x_3)}{(x_1-x_0)(x_1-x_2)(x_1-x_3)} f(x_1) + \frac{(x-x_0)(x-x_1)(x-x_3)}{(x_2-x_0)(x_2-x_1)(x_2-x_3)} f(x_2) + \frac{(x-x_0)(x-x_1)(x-x_2)}{(x_3-x_0)(x_3-x_1)(x_3-x_2)} f(x_3) \quad (2.12)$$

Interpolasi Lagrange hanyalah sebuah perumusan dari polinomial Newton yang menghindari perhitungan perbedaan yang terbagi. Hal ini juga dapat diwakili secara ringkas dengan rumus:

$$f_n(x) = \sum_{i=0}^n L_i(x) f(x_i) \quad (2.13)$$

dengan

$$L_i(x) = \prod_{\substack{j=0 \\ j \neq i}}^n \frac{x-x_j}{x_i-x_j} \quad (2.14)$$

Dengan menggunakan algoritma Lagrange akan dilakukan pemodelan dengan cara memberikan sebagian titik-titik pasangan data kurva rasio dan waktu *trip*, selanjutnya akan didapatkan titik-titik lainnya yang mampu mewakili kurva secara keseluruhan [15].

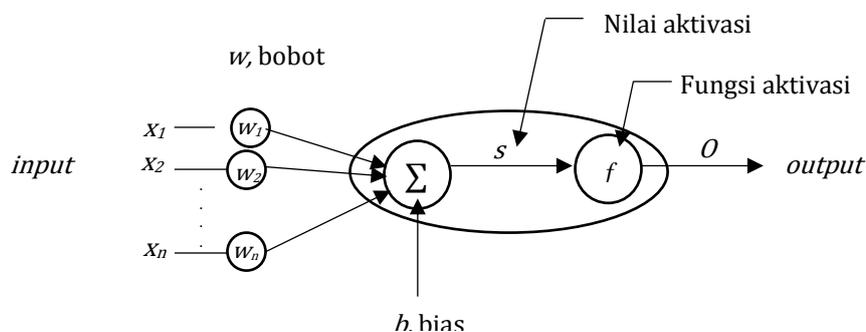
2.5. Artificial Neural Network Characteristic Curve Modeling (ANN-CCM)

ANN atau dalam bahasa Indonesia disebut dengan jaringan syaraf tiruan merupakan salah satu jenis algoritma cerdas yang mampu untuk memodelkan suatu fungsi dimana terdapat hubungan antara *input* dan *output* dalam suatu fungsi. Pada bagian ini akan dijelaskan bagaimana jaringan syaraf tiruan belajar dari pengetahuan para ahli, struktur dan pelatihan jaringan syaraf tiruan dalam istilah matematika, serta gambaran umum deskripsi matematis jaringan umpan balik atau *feedforwards networks* dan algoritma pelatihan [16] [17].

2.5.1. Model Neuron

Bagian fundamental dari jaringan syaraf biologis adalah *neuron*, yang juga dikenal sebagai sel syaraf elementer atau *elementary nerve cell*. Sebuah *neuron* menerima sinyal dari *neuron* lain melalui interkoneksi yang kompleks. Keluaran *neuron* adalah fungsi dari sinyal yang diterima dan karakteristik internal *neuron*.

Sebuah jaringan syaraf biologis memproses informasi dengan cara yang cukup kompleks. Model *neuron* yang ditunjukkan pada Gambar 2.9 dikembangkan oleh McCulloch dan Pitts, dan telah dimodifikasi untuk digunakan di banyak bidang rekayasa. Model ini adalah versi sederhana dari bentuk biologisnya, namun mampu menangkap beberapa karakteristik penting dari *neuron* biologis [18].



Gambar 2.9. Struktur Dasar Artificial Neuron Model

Unit pemroses masing-masing *neuron* juga dikenal sebagai simpul yang menerima sinyal *input* $x = [x_1, x_2, \dots, x_n]^T \in X$, dengan X adalah ruang *input*, serta bias dengan simbol b . Sinyal masukan x diperkecil oleh bobot $w = [w_1, w_2, \dots, w_n]^T \in W$, di mana W adalah ruang bobot. Bias bisa dilihat sebagai masukan dengan bobot koneksi $+1$. Semua sinyal masukan tertimbang dijumlahkan untuk membentuk nilai aktivasi, yang didefinisikan sebagai:

$$s = \sum_{i=1}^n (w_i x_i) + b = w^T x + b \quad (2.15)$$

Sinyal *output neuron* o , adalah fungsi dari s digambarkan sebagai:

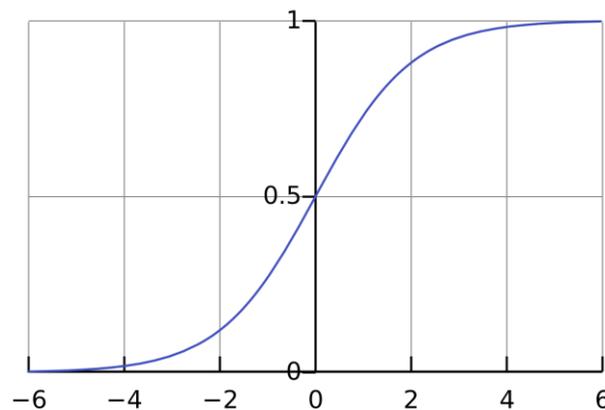
$$o = f(s) \quad (2.16)$$

dengan f adalah fungsi aktivasi.

Fungsi aktivasi biasanya dipilih sebagai fungsi *monoton non-decreasing* dan *differentiable*. Fungsi *sigma* merupakan satu fungsi aktivasi yang paling populer karena menyerupai perilaku *neuron* biologis. Fungsi *sigmoid unipolar* dapat dinyatakan sebagai:

$$o(s) = \frac{1}{1 + e^{-s}} \quad (2.17)$$

Seperti yang terlihat pada Gambar 2.10.



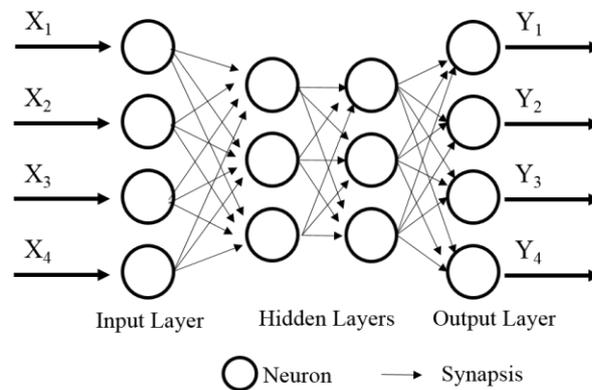
Gambar 2.10. Tipikal Fungsi Aktivasi *Sigmoid Unipolar*

Dengan fungsi aktivasi dan berdasarkan struktur model ini, x dan w sendiri dapat sepenuhnya menggambarkan perilaku *input-output neuron*.

2.5.2. Model Jaringan Neural Feedforward Multi-layer

Dasar jaringan *multi-layer feedforward* berisi tiga komponen, yakni *input layer*, satu atau beberapa lapisan tersembunyi atau *hidden layer*, dan lapisan keluaran atau *output layer*, seperti yang ditunjukkan pada Gambar 2.11, dimana setiap lapisan jaringan berisi seperangkat unit pengolahan yang disebut *node* atau *neuron*, seperti yang dijelaskan pada bagian sebelumnya. Setiap *node* dalam lapisan jaringan akan mengirimkan keluarannya ke semua simpul dari lapisan berikutnya secara *uni-directionally*. Pada lapisan *input*, *node* menerima sinyal eksternal dari dunia luar.

Input layer jaringan syaraf berfungsi sebagai antarmuka yang mengambil informasi dari dunia luar dan mentransmisikannya ke unit pemroses internal jaringan, analog dengan bagian antarmuka manusia seperti mata kita dan sel penginderaan jari-jari kita. Demikian pula lapisan *output* dari jaringan syaraf tiruan berfungsi sebagai antarmuka yang mengirimkan informasi dari unit pemroses internal unit syaraf ke dunia luar. Simpul di *hidden layer* adalah unit pemroses internal jaringan syaraf tiruan.



Gambar 2.11. Struktur Dasar Jaringan Syaraf Tiruan *Feedforward Multi Layer*

Dalam jaringan syaraf *feedforward*, *neuron* di lapisan yang sama tidak memiliki hubungan satu sama lain, tidak seperti jenis jaringan syaraf lainnya seperti jaringan rekuren, dan biasanya semua simpul pada *hidden* dan *output layer* memiliki struktur yang sama seperti yang ditunjukkan pada Gambar 2.9, setiap simpul j di *hidden layer* dan keluaran menerima sinyal $v = [v_1, v_2 \dots, v_k]^T$ dari

simpul lapisan sebelumnya, diskalakan oleh bobot $w_j = [w_{j1}, w_{j2}, \dots, w_{jk}]^T$ simpul ke j pada lapisan l , untuk menghitung keluaran s :

$$s_j = \sum_{i=1}^k w_{ji} v_i + b_j = w_j^T x + b_j \quad (2.18)$$

dengan b_j adalah istilah bias *neuron* ke j . Kuantitas s_j akan diproses oleh fungsi aktivasi biasanya *nonlinear* dan akan memberikan *output* o_j dari *neuron* ke j :

$$o_j = f(s_j) \quad e_p = e(x_p, w) = \|y(x_p, w) - y(x_p)\| \quad (2.19)$$

Tidak seperti *node hidden layer* dan *output layer*, *node* lapisan *input* secara konvensional menggunakan fungsi aktivasi linier dan bukan fungsi *sigmoid*, dan setiap *node* lapisan hanya menerima satu sinyal masukan, $v = [x_j]$, seperti yang ditunjukkan pada Gambar 2.11 yang mewakili setiap pengukuran sinyal secara konvensional dari dunia luar. Masukan ke jaringan syaraf normal dinormalisasi antara $[0, 1]$ untuk alasan stabilitas numerik.

Dalam jaringan syaraf *feedforward*, masing-masing *neuron* individu tidak terlalu kuat dalam hal perhitungan atau representasi. Namun, dengan menghubungkan *neuron* bersama-sama untuk membentuk jaringan besar, para periset telah membuktikan bahwa jaring pengaman dapat mengkodekan pemetaan *input-output* kontinyu yang kompleks. *Neuron* yang berada di lapisan yang sama tidak memiliki hubungan satu sama lain, namun mereka menerima sinyal dari lapisan sebelumnya dan mengirimkan sinyal ke lapisan berikutnya setelah sinyal masukan telah diproses. Setiap koneksi yang menghubungkan *node* ke *node* lain memiliki bobot yang terkait dengannya. Hal ini dengan mengubah nilai bobot ini sehingga jaringan syaraf dapat belajar atau dilatih melalui algoritma pelatihan yang tepat.

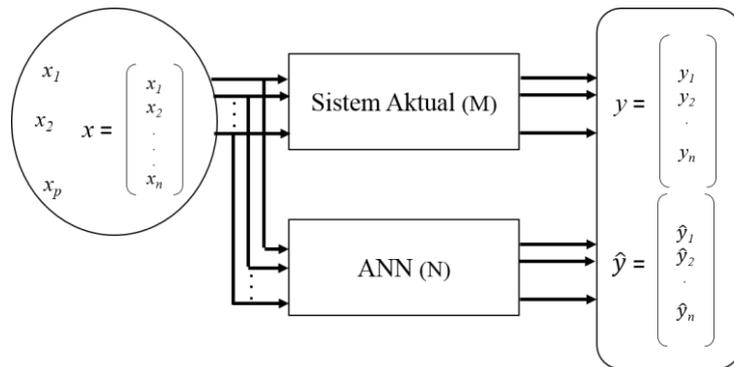
2.5.3. Formulasi Matematika untuk Neural Network Training

Ada berbagai cara untuk melihat jaringan syaraf tiruan. Dari sudut pandang teknik, mungkin lebih mudah untuk memvisualisasikan jaringan syaraf tiruan sebagai pembelajaran pemetaan *input-output* suatu sistem [19]. Kemampuan belajar ini bisa digunakan untuk melakukan pemodelan kurva karakteristik rele. Bagian ini akan menyajikan deskripsi matematis untuk melatih jaringan syaraf tiruan mempelajari hubungan *input-output* dari sistem yang diberikan.

Misalkan sebuah sistem seperti ditunjukkan pada Gambar 2.12, dimana memiliki *input* $x = [x_1, x_2, \dots, x_n]^T$, seperti pengukuran sensor, dan keluaran yang sesuai $y(x) = [y_1, y_2, \dots, y_m]^T$. Lebih mudah merepresentasikan sistem sebagai hubungan M antara ruang *input* $X: \{x \in X \mid x \text{ adalah } \textit{input} \text{ ke sistem}\}$ dan ruang *output* $Y: \{y(x) \in Y \mid Y \text{ adalah } \textit{output} \text{ dari sistem dengan } \textit{input} \ x\}$, seperti yang dinyatakan dalam persamaan:

$$M: X \rightarrow Y \quad (2.20)$$

Selanjutnya jaringan syaraf tiruan mempelajari hubungan semacam M . *Output* sebenarnya dari jaringan syaraf tiruan dinotasikan sebagai $\hat{y}(x|w)$, yang termasuk dalam ruang keluaran Y , yang diberi parameter dengan bobot $w \in W$, bobot ruang, dan masukan yang diberikan x .



Gambar 2.12. Diagram Skematik *Input-output* Sistem Aktual dan ANN

Proses pelatihan jaringan dapat dianggap sebagai pelatihan jaringan untuk mewakili M melalui hubungan *input-output* sedekat mungkin dengan menyesuaikan parameter internal jaringan atau bobot w , yang ditunjukkan secara matematis sebagai:

$$\min_{w \in W} \|y(x|w) - y(x)\|, x \in X \quad (2.21)$$

Biasanya, ukuran yang berbeda digunakan untuk memantau proses pelatihan. Ukuran yang populer adalah perbedaan antara *output* jaringan $\hat{y}(x,w)$ dan keluaran aktual $y(x)$ dengan *input* yang sama x , yaitu $\|\hat{y}(x|w) - y(x)\|$, di mana $\|\cdot\|$ adalah beberapa norma yang sesuai. Diinginkan $\|\hat{y}(x|w) - y(x)\| \leq \epsilon$, di mana ϵ nilai toleransi kesalahan kecil preset yang tepat dari perbedaan antara $\hat{y}(x,w)$ dan $y(x)$.

Jika ε sangat kecil, maka \hat{y} dikatakan telah dilatih untuk mewakili secara dekat terhadap y .

Relasi yang pasti dari sistem $M(x)$ biasanya tidak diketahui secara pasti. Jika $M(x)$ diketahui secara pasti, maka tidak perlu melatih jaringan syaraf untuk mempelajari relasinya, secara umum pengukuran beberapa *input* P diambil dari pemetaan M dan digunakan sebagai contoh pelatihan untuk jaringan syaraf tiruan, [20] membahas penggunaan teori pembelajaran untuk memperkirakan jumlah contoh pelatihan P yang dibutuhkan untuk melatih jaringan ke dalam nilai ambang batas tertentu. Pengukuran diskrit $\{(x_1, y_1), (x_2, y_2), \dots, (x_p, y_p)\}$ dari x dan $y(x) = M(x)$ biasanya dapat diperoleh dengan mudah. Proses pelatihan jaringan terdiri dari pelatihan jaringan untuk belajar M berdasarkan seperangkat pengukuran *input-output* diskrit. Dalam hal terminologi jaringan syaraf tiruan, x_p adalah pola masukan ke- p , $y_p = y(x_p)$ adalah pola *output* yang sesuai, dan (x_p, y_p) adalah pola latihan ke- p .

Misalkan ada pola pelatihan *input-input* P yang tersedia untuk melatih jaringan syaraf tiruan, dan dua ukuran normalnya digunakan. Proses pelatihan dapat diwakili secara matematis sebagai berikut:

$$\begin{aligned} & \min_{w \in W} \| y(x_p, w) - y(x_p) \|_2 \\ & = \min_{w \in W} \frac{1}{P} \sum_{p=1}^P \left(y(x_p, w) - y(x_p) \right)^2, \quad p = 1, \dots, P \end{aligned} \quad (2.22)$$

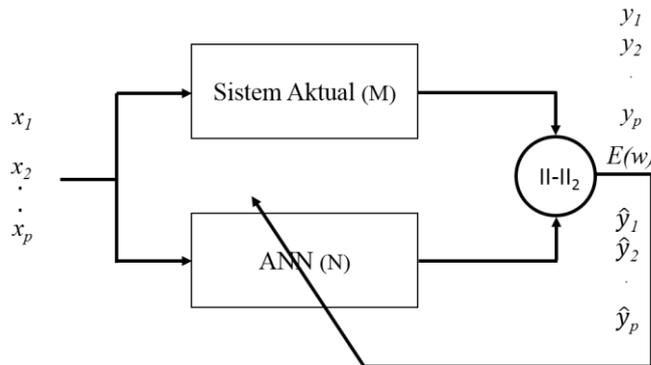
Parameter ε adalah toleransi kesalahan untuk menunjukkan keberhasilan pelatihan. Jika $\| \cdot \| \leq \varepsilon$, maka jaringan dikatakan telah mengetahui pemetaan sistem yang sebenarnya, yaitu $\| \hat{y}(x|w) - y(x) \| \leq \varepsilon$ pada persamaan 2.21, asalkan data pelatihan mewakili perilaku sistem [20]. Ukuran dua norma, yang merupakan salah satu ukuran paling populer yang digunakan dalam pelatihan jaringan syaraf tiruan digunakan dalam persamaan 2.22, namun ukuran norma lain yang sesuai juga dapat digunakan untuk memenuhi aplikasi spesifik pengguna, misal e_p sebagai kesalahan pelatihan dari pola pelatihan p , yaitu perbedaan antara *output* dari jaringan dan *output* dari sistem dengan *input* x_p dan bobot jaringan saat ini w :

$$e_p = e(x_p, w) = \| y(x_p, w) - y(x_p) \| \quad (2.23)$$

Selama pelatihan jaringan meminimalkan kesalahan untuk semua pola pelatihan daripada meminimalkan kesalahan untuk pola pelatihan tunggal. Oleh karena itu kesalahan pelatihan jaringan didefinisikan sebagai kuantitas E :

$$E(w) = \frac{1}{p} \sum_{p=1}^p e(x_p, w) \quad (2.24)$$

Blok diagram proses pelatihan ditunjukkan pada Gambar 2.13.



Gambar 2.13. *Supervised Training* dari *Artificial Neural Networks*

Metode untuk melatih jaringan *feedforward network* dengan meminimalkan E dalam persamaan 2.24 yang merupakan blok utama untuk keberhasilan penerapan jaringan syaraf tiruan. Pada tahun 1970an, beberapa terobosan dilakukan dalam pengembangan algoritma pelatihan untuk jaring umpan maju multi lapis [16]. Saat ini, algoritma pelatihan yang lebih terkenal mencakup algoritma *backpropagation* [21] dan simulasi *annealing* [20]. Metode ini melatih jaringan dengan secara iteratif menyesuaikan bobot jaringan untuk meminimalkan E . Algoritma *backpropagation* sejauh ini merupakan algoritma pelatihan yang paling populer untuk jaring umpan maju.

2.5.4. Algoritma Pelatihan *Backpropagation*

Algoritma pelatihan *backpropagation* pada dasarnya adalah metode turunan cerdas yang mencari nilai optimal w untuk meminimalkan kesalahan E dalam persamaan 2.22. Prosedur umumnya adalah sebagai berikut:

1. Berikan bobot awal $w^q, q = 0$, dengan q menunjukkan nomor iterasi pelatihan saat ini.

2. Temukan $\frac{\partial E}{\partial w}$, yang merupakan kemiringan E sehubungan dengan w .
3. Carilah perubahan bobot untuk memberi E yang lebih kecil dengan algoritma *steepest descent*:

$$\Delta w^q = -\eta \frac{\partial E(w)}{\partial w} \Big|_{w=w^q} \quad (2.25)$$

Dengan η adalah tingkat belajar atau ukuran langkah dalam algoritma *steepest descent*, biasanya angka positif kecil misal 0,1 tanda minus menunjukkan arah negatif.

4. *Update* bobot w^q ke w^{q+1} sebagai:

$$w^{q+1} = w^q + \Delta w^q \quad (2.26)$$

5. Ulangi langkah-langkah ke-2 sampai ke-4 hingga $\frac{\partial E(w)}{\partial w} \approx 0$, yang berarti bahwa sedang berada pada nilai di mana itu adalah solusinya.

Untuk lapisan *output*, kuantitas $\frac{\partial E(w)}{\partial w}$ dalam persamaan 2.25 dapat dengan mudah dihitung dengan mengambil turunan E berkenaan dengan bobot w dari lapisan keluaran, sedangkan $\frac{\partial E(w)}{\partial w}$ untuk bobot pada *hidden layer* memerlukan penggunaan aturan rantai untuk membalikkan kembali sinyal kesalahan yang dituju pada *output layer* ke *hidden layer*.

Aturan delta yang digunakan untuk menyesuaikan bobot jaringan telah diturunkan secara rinci [21] [17] dan telah ditulis dalam persamaan untuk referensi.

$$\delta_j = o_j (1 - o_j) (y_{pj} - o_j) \text{ untuk } \textit{ouput layer node } j \quad (2.27)$$

$$\delta_j = o_j (1 - o_j) \sum \delta_k w_{kj} \text{ untuk } \textit{hidden layer node } j \quad (2.28)$$

$$\Delta w_{ji}^{q+1} = \eta \delta_j o_i + \alpha \Delta w_{ji}^q \quad (2.29)$$

$$w_{ji}^{q+1} = w_{ji}^n + \Delta w_{ji}^q \quad (2.30)$$

dengan $\delta_j o_j = -\frac{\partial E(w)}{\partial w}$ adalah kemiringan proses iterasi pada persamaan 2.25.

Di persamaan 2.30 η disebut tingkat pembelajaran atau *learning rate*, setara dengan ukuran langkah dalam algoritma *steepest descent* dan α disebut *momentum rate*. Istilah tambahan $\alpha \Delta w_{ji}^q$ dalam persamaan 2.30 dibandingkan dengan persamaan

2.29 disebut istilah *momentum term*, termasuk dalam persamaan pembaruan bobot untuk menghindari standar lokal [21] [17]

Dimana pemetaan yang diinginkan dijelaskan oleh serangkaian data *input-output*, bobotnya dimodifikasi secara empiris setelah penyajian setiap rangkaian pola *input-output*, metode ini disebut sebagai pembaharuan pola atau *pattern update* dan merupakan perkiraan kemiringan gradien sejati yang umumnya berlaku bila ukuran yang cukup kecil adalah ukuran yang digunakan. Pembaruan secara *batch*, yang mana perubahan bobot terakumulasi di atas satu sapuan keseluruhan rangkaian pola pelatihan sebelum diterapkan, kadang-kadang digunakan untuk meniru kemiringan gradien.

2.6. Adaptive Neuro Fuzzy Inference System untuk Characteristic Curve Modeling (ANFIS-CCM)

Adaptive Neuro-Fuzzy Inference System (ANFIS) merupakan metode *fuzzy inference system* (FIS) yang diadaptasikan ke dalam arsitektur jaringan syaraf. Pada penelitian ini digunakan sistem inferensi *fuzzy* model Tagaki-Sugeno-Kang (TSK) orde satu yang bertujuan untuk memudahkan serta meminimalisir kesalahan pada saat komputasi [22] [23] [24].

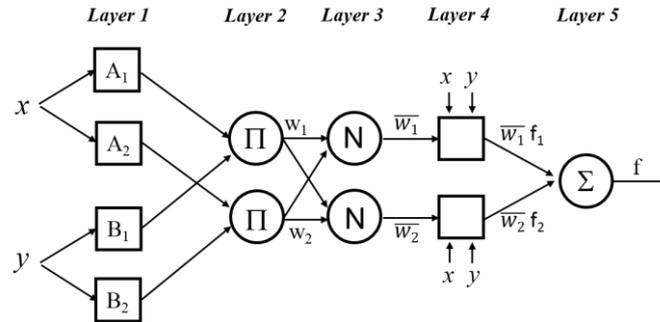
Adaptive Neuro Fuzzy Inference System (ANFIS) merupakan gabungan antara *Artificial Neural Network* dan *Fuzzy Inference System*, yang diadaptasi dari model inferensi Sugeno. Pada FIS diberikan nilai *input* dan *output* dengan permisalan x dan y untuk *input* dan z untuk *output*. Dengan mengadaptasi model Sugeno orde satu diberlakukan aturan sebagai berikut:

$$\begin{aligned} \text{IF } x \text{ is } A_1 \text{ AND } y \text{ is } B_1 \text{ THEN } f_1 &= p_1x+q_1y+r_1 \\ \text{IF } x \text{ is } A_2 \text{ AND } y \text{ is } B_2 \text{ THEN } f_2 &= p_2x+q_2y+r_1 \end{aligned}$$

Sehingga di dapatkan fungsi seperti yang di tunjukkan pada Persamaan 2.31 ini:

$$f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} = w'_1 f_1 + w'_2 f_2 \quad (2.31)$$

Untuk memudahkan pemahaman, dibuat arsitektur ANFIS dengan permisalan yang telah di jabarkan sebelumnya, yakni menggunakan 2 *input* dan 1 *ouput*. Pada Gambar 2.14 digambarkan arsitektur ANFIS yang terdiri atas 5 *layer*. Masing– masing *layer* mempunyai fungsi yang berbeda-beda [25][26][27][28][29].



Gambar 2.14. Arsitektur ANFIS

- **Layer 1 :** Pada *layer* 1 terdapat proses *fuzzyfication* yang masing-masing *node* nya berfungsi untuk membangkitkan derajat keanggotaan atau biasa disebut juga *premis*. A_i dan B_i merupakan himpunan *fuzzy*. Sedangkan O_{li} merupakan *output* dari *node* i pada *layer* ke-1 dinotasikan. Setiap *node* pada *layer* ke- i bersifat adaptif. Aturan yang diterapkan pada *layer* ini dapat dilihat pada Persamaan 2.32:

$$O_{li} = \mu A_i, i = 1, 2$$

$$O_{li} = \mu B_{i-2}, i = 3, 4 \quad (2.32)$$

- **Layer 2:** Pada *layer* 2, *node* yang ada berfungsi untuk menghitung *firing strength* atau fungsi untuk menghitung nilai keanggotaan baru hasil operasi dua himpunan pada setiap rule sebagai *output* dari semua *input* yang masuk. Aturan yang digunakan terdapat pada Persamaan 2.33 di bawah ini:

$$w_1 = \mu A_1(x) \text{ AND } \mu B_1(y)$$

$$w_2 = \mu A_2(x) \text{ AND } \mu B_2(y) \quad (2.33)$$

- **Layer 3:** Pada *layer* 3 setiap *node* yang ada berfungsi untuk menghitung perbandingan antara *firing strength* pada aturan yang berlaku pada tiap aturan ke- i terhadap total nilai *firing strength* secara keseluruhan. Setiap

node pada lapisan ini bersifat *non- adaptif*. Aturan yang digunakan dapat dilihat pada Persamaan 2.34:

$$O_{3i} = w_i' = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (2.34)$$

- **Layer 4 :** Pada *layer 4* menerima *output* hasil dari *layer 3* yang dituliskan dengan w_i' . Pada Persamaan 2.35 dituliskan aturan untuk *layer* ini, dimana $(p_i x + q_i y + r_i)$ adalah himpunan parameter pada *fuzzy model* Sugeno orde satu. *Node* pada *layer 4* bersifat adaptif:

$$O_{4i} = w_i' \cdot f_i = w_i' (p_i x + q_i y + r_i) \quad (2.35)$$

- **Layer 5 :** Pada *layer 5* terdapat proses yakni mengumpulkan seluaruh *output* hasil dari *layer 4* yang merupakan penjumlahan dari semua sinyal yang masuk. Aturan pada *layer* ini di tuliskan pada Persamaan 2.36, dimana \sum merupakan satu *node* tunggal:

$$O_5 = \sum_i w_i' \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad i = 1, 2 \quad (2.36)$$

Kelima *layer* tersebut akan membentuk suatu *adaptive network* yang secara fungsional sama dengan *fuzzy model* Sugeno orde satu. Digunakan *Fuzzy Clustering Mean* (FCM) untuk memberi nilai awal pada parameter premis pada bagian *membership function*.

Pada arsitektur ANFIS, *node* yang bersifat adaptif terdapat pada *layer* ke-1 dan ke-4, *node* pada *layer* ke-1 mengandung parameter premis yang nonlinier sedangkan pada *layer* ke-4 mengandung parameter konsekuen yang linier. Untuk memperbaharui parameter-parameter tersebut diperlukan proses *learning* atau *training*. ANFIS menggunakan *hybrid supervised method* yang berbasis pada dua metode, yaitu *least squares* dan *gradient descent*.

Untuk arah maju atau *forward*, parameter premis tidak dirubah-rubah. Dengan menggunakan metode *Least Square Estimator* (LSE), parameter konsekuen diperbaiki berdasarkan pasangan data pada *training* set. Metode LSE dapat diterapkan karena parameter konsekuen yang diperbaiki bersifat linier. Setelah parameter konsekuen diperoleh, data masukan dilewatkan ke jaringan

adaptif kembali dan hasil keluaran jaringan adaptif ini dibandingkan dengan keluaran yang diharapkan.

Pada arah mundur atau *backward*, parameter konsekuen dibuat tetap. Kesalahan atau *error* antara keluaran jaringan adaptif dan target dipropagasikan balik menggunakan *gradient descent* untuk memperbarui parameter premis. Satu tahap pembelajaran maju–mundur ini dinamakan satu *epoch*.

2.6.1. Proses Pembelajaran dengan RLSE untuk Parameter Konsekuen

Dari arsitektur ANFIS yang ditunjukkan pada Gambar 2.14 sebelumnya, dapat diamati bahwa ketika nilai parameter premis telah ditetapkan dan tidak berubah, *output* secara keseluruhan dapat dinyatakan sebagai kombinasi linier dari parameter konsekuen. Dalam simbol, *output* "*f*" yang terdapat pada Gambar 2.14, dapat ditulis ulang dengan Persamaan 2.37 berikut:

$$\begin{aligned} f &= \overline{w_1}f_1 + \overline{w_2}f_2 \\ &= \overline{w_1}(p_1x + q_1y + r_1) + \overline{w_2}(p_2x + q_2y + r_2) \\ &= (\overline{w_1}x)p_1 + (\overline{w_1}y)q_1 + (\overline{w_1})r_1 + (\overline{w_2}x)p_2 + (\overline{w_2}y)q_2 + (\overline{w_2})r_2 \end{aligned} \quad (2.37)$$

Beberapa parameter konsekuen yang terdapat pada Persamaan 2.37 merupakan parameter yang linier terhadap *output* dari sistem. Jika sejumlah *N* data *training* diaplikasikan pada Persamaan 2.37, didapat persamaan baru, yakni:

$$\begin{aligned} (\overline{w_1}x)_1 p_1 + (\overline{w_1}y)_1 q_1 + (\overline{w_1})_1 r_1 + (\overline{w_2}x)_2 p_2 + (\overline{w_2}y)_2 q_2 + (\overline{w_2})_2 r_2 &= y_1 \\ \vdots & \\ \vdots & \\ (\overline{w_1}x)_n p_1 + (\overline{w_1}y)_n q_1 + (\overline{w_1})_n r_1 + (\overline{w_2}x)_n p_2 + (\overline{w_2}y)_n q_2 + (\overline{w_2})_n r_2 &= y_n \end{aligned} \quad (2.38)$$

Sehingga jika diubah dalam bentuk matriks akan terlihat seperti pada Persamaan 2.39:

$$A\theta = y \quad (2.39)$$

Variabel θ merupakan vektor 6x1 yang terdiri atas elemen-elemen dari himpunan parameter konsekuen, sedangkan *y* merupakan vektor *output* yang elemen-elemennya merupakan data *output* dari sistem. Untuk mendapatkan hasil terbaik untuk θ adalah dengan meminimumkan nilai pada persamaan $\|A\theta - y\|^2$, dengan teori LSE, sehingga didapat θ^* :

$$\theta^* = (A^T A)^{-1} A^T y \quad (2.40)$$

Variabel θ^* dihitung menggunakan rumus *Recursive LSE* (RLSE). Sehingga menghasilkan persamaan baru, yakni:

$$\begin{aligned} \theta_{i+1} &= \theta_i + P_{i+1} a_{i+1} (y_{i+1}^T - a_{i+1}^T \theta_i) \\ P_{i+1} &= P_i - \frac{P_i a_{i+1} a_{i+1}^T P_i}{1 + a_{i+1}^T P_i a_{i+1}}, i = 0, 1, \dots, P-1 \end{aligned} \quad (2.41)$$

Variabel a_i^T merupakan vektor baris dari matriks A pada persamaan 2.39, y_i adalah elemen ke- i dari y . Dan P_i disebut matriks kovariansi yang didefinisikan dengan:

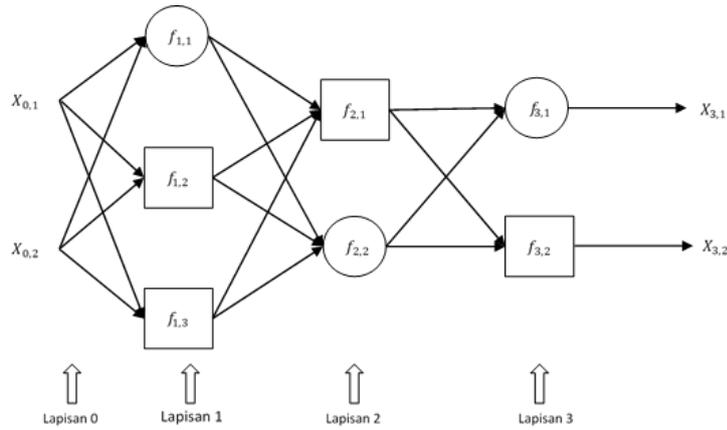
$$P_i = (A^T A)^{-1} \quad (2.42)$$

2.6.2. Proses Pembelajaran *Backpropagation-error* untuk Parameter Premis

Parameter premis yang digunakan dalam proses *learning* untuk algoritma *backpropagation* merupakan parameter adaptif dimana proses pembelajarannya menggunakan metode sistem jaringan syaraf *feedforward learning* dengan *gradient descent*. Dimisalkan sebuah sistem jaringan adaptif direpresentasikan dengan L lapisan dan lapisan ke- l dituliskan dengan ($l = 0, 1, \dots, L; l = 0$) yang menyatakan *input layer* yang mempunyai $N(l)$ *node*. *Output* yang dihasilkan dan fungsi *node* ke- l [$l = 1, \dots, N(l)$] pada lapisan ke- l dinyatakan dengan $x_{l,i}$ dan $f_{l,i}$ yang digambarkan pada Gambar 2.15. *Output node* merupakan fungsi dari sinyal *input* dan parameter sistem, sehingga diperoleh persamaan:

$$x_{l,i} = f_{l,i} (x_{l-1,1}, \dots, x_{l-1,N(l-1)}, \alpha, \beta, \gamma, \dots) \quad (2.43)$$

Dengan α, β, γ adalah parameter *node*.



Gambar 2.15. Model jaringan syaraf *feedforward*.

Untuk proses *learning* jaringan adaptif, dimisalkan sejumlah pasangan data yakni P , yang selanjutnya dapat didefinisikan untuk menghitung dan mengukur nilai *error* pada data *training* ke- p yang merupakan jumlah kuadrat kesalahan yang didefinisikan dengan Persamaan 2.44:

$$E_p = \sum_{k=1}^{N(L)} (d_k^p - x_{L,k}^p)^2 \quad (2.44)$$

Variabel d_k^p merupakan elemen ke- k dari vektor *output* yang dibutuhkan dan $x_{L,k}^p$ adalah vektor *output* aktual yang dihasilkan dari sistem jaringan adaptif dengan *input* yang berasal dari vektor *input* ke- p dari himpunan P data *training*. Tujuan dari sistem adaptif adalah untuk meminimalisir kesalahan dalam menghitung maupun mengukur nilai *error* pada Persamaan (2.44) dengan mengubah parameter-parameter adaptifnya. Dengan mendefinisikan *signal error* atau kesalahan sinyal $\varepsilon_{l,i}$ sebagai *ordered derivative* terhadap *output node* ke- i , pada lapisan ke- l , maka *ordered derivative* dapat direpresentasikan dengan Persamaan 2.45:

$$\varepsilon_{l,i} = \frac{\partial^+ E_p}{\partial x_{l,i}} \quad (2.45)$$

Kesalahan sinyal untuk *output node* ke- i pada lapisan ke- l dapat dihitung dengan Persamaan 2.46 berikut:

$$\varepsilon_{l,i} = \frac{\partial^+ E_p}{\partial x_{l,i}} = \frac{\partial E_p}{\partial x_{L,i}} \quad (2.46)$$

Jika terjadi pengukuran kesalahan seperti yang dituliskan pada Persamaan 2.44 maka persamaan sebelumnya akan berubah menjadi:

$$\varepsilon_{L,i} = -2(d_i^p - x_{L,i}^p) \quad (2.47)$$

Untuk *node* pada lapisan ke- l dan posisi ke- i , sinyal kesalahan dapat diraih menggunakan aturan rantai yang didefinisikan pada Persamaan 2.48:

$$\varepsilon_{l,i} = \underbrace{\frac{\partial^+ E_p}{\partial x_{l,i}}}_{\substack{\text{sinyal kesalahan} \\ \text{pada lapisan } l}} = \sum_{m=1}^{N(l+1)} \underbrace{\frac{\partial^+ E_p}{\partial x_{l+1,m}}}_{\substack{\text{sinyal kesalahan} \\ \text{pada lapisan } l+1}} \frac{\partial f_{l+1,m}}{\partial x_{l,i}} = \sum_{m=1}^{N(l+1)} \varepsilon_{l+1,m} \frac{\partial f_{l+1,m}}{\partial x_{l,i}} \quad (2.48)$$

Variabel $0 \leq l \leq L-1$ merupakan sinyal kesalahan *node* pada lapisan ke- l dan dapat dinyatakan sebagai kombinasi linier dari sinyal kesalahan simpul pada lapisan ke $(l+1)$. Sehingga untuk menghitung sinyal kesalahan pada simpul ke- i lapisan ke- l ($l < L$), yang pertama dilakukan adalah menghitung dengan menggunakan Persamaan 2.46 untuk mendapatkan sinyal kesalahan pada lapisan *output* kemudian Persamaan 2.48 dilakukan secara terus menerus hingga mencapai lapisan yang diinginkan. Langkah-langkah diatas disebut *feed-forward backpropagation* dikarenakan sinyal kesalahan dihitung secara mundur atau berkebalikan yakni dihitung dari lapisan *output* hingga lapisan *input*. Vektor *gradient* diinterpretasikan sebagai *ordered derivative* dari pengukuran kesalahan terhadap tiap parameternya. Jika α adalah parameter simpul ke- l , lapisan ke- l , maka diperoleh persamaan:

$$\frac{\partial^+ E_p}{\partial \alpha} = \frac{\partial E_p}{\partial x_{l,i}} \frac{\partial f_{l,i}}{\partial \alpha} = \varepsilon_{l,i} \frac{\partial f_{l,i}}{\partial \alpha} \quad (2.49)$$

Jika terbukti α merupakan parameter yang ada pada beberapa simpul maka Persamaan 2.49 menjadi:

$$\frac{\partial^+ E_p}{\partial \alpha} = \sum_{x^* \in S} \frac{\partial^+ E_p}{\partial x^*} \frac{\partial f^*}{\partial \alpha} \quad (2.50)$$

Dengan S merupakan himpunan simpul yang berisikan α sebagai parameter, sedangkan x^* dan f^* adalah *output* dan fungsi dari simpul yang bersangkutan. Turunan masing-masing secara keseluruhan yang dihasilkan dari pengukuran kesalahan akan menghasilkan Persamaan 2.51 berikut:

$$\frac{\partial^+ E_p}{\partial \alpha} = \sum_{p=1}^p \frac{\partial^+ E_p}{\partial \alpha} \quad (2.51)$$

Dengan metode *gradient simple steepest descent*, j memperbaiki parameter α dengan Persamaan 2.52 berikut:

$$\Delta \alpha = -\eta \frac{\partial^+ E}{\partial \alpha} \quad (2.52)$$

Dimana η adalah *learning rate* yang dirumuskan dengan:

$$\eta = \frac{k}{\sqrt{\sum_r \left(\frac{\partial E}{\partial \alpha} \right)^2}} \quad (2.53)$$

Sedangkan k merupakan ukuran dari langkah atau *step size* dari aturan yang ada yang dapat diubah untuk mempercepat konvergensi.

2.7. Modified Firefly (MFA) dan Adaptive Modified Firefly Algoritma (AMFA) Parameter Seting Rele

Berbagai macam algoritma optimisasi telah digunakan untuk membantu menyelesaikan problem secara khusus terkait koordinasi proteksi [30]-[44] maupun *electrical engineering* secara umum [45]. Xin She Yang mengusulkan algoritma FA [46]-[51] dari Universitas Cambridge, yang terinspirasi oleh perilaku kunang-kunang. FA dapat digambarkan dengan tiga karakteristik. Yang pertama, dua kunang-kunang tertarik satu sama lain terlepas dari jenis kelamin mereka karena semua kunang-kunang adalah unisex. Yang kedua, daya tarik sebanding dengan kecerahannya, dimana kunang-kunang terang akan menarik kunang-kunang dengan lebih rendah. Yang ketiga, fungsi objektifnya adalah kecerahan kunang-kunang. Dalam masalah minimisasi, *brightness firefly* memiliki fungsi obyektif yang lebih rendah. Secara matematis, daya tarik dapat ditunjukkan dengan persamaan sebagai berikut:

$$\beta(r) = \beta_0 e^{(-\gamma r^m)} \quad m \geq 1 \quad (2.54)$$

jarak antara dua kunang-kunang i dan j dihitung dengan jarak Cartesian adalah r , yang ditunjukkan dengan persamaan sebagai berikut:

$$r_{ij} = \|X_j - X_i\| = \sqrt{\sum_{m=1}^k (x_{j,m} - x_{i,m})^2}$$

$$X_j = [x_{j,1}, x_{j,2}, x_{j,3}, \dots, x_{j,k}]$$

$$X_i = [x_{i,1}, x_{i,2}, x_{i,3}, \dots, x_{i,k}] \quad (2.55)$$

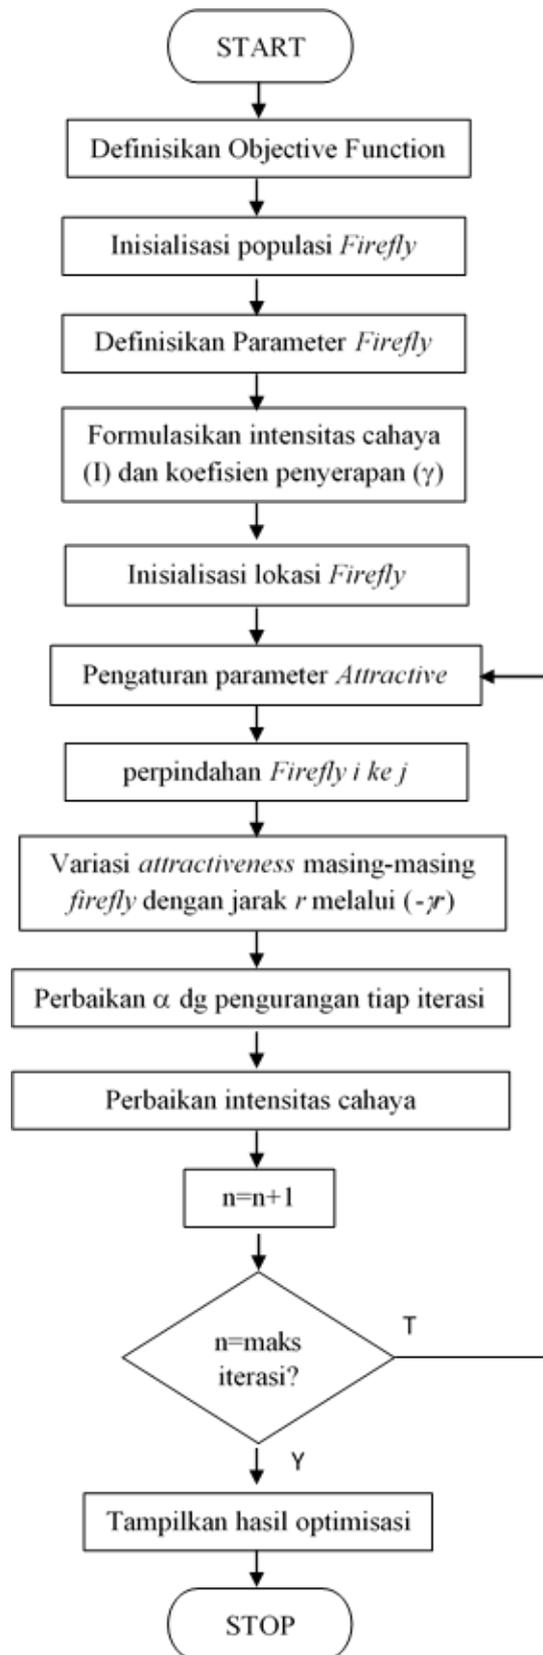
Gerakan kunang-kunang dengan kecerahan yang lebih rendah (X_i) tertarik kunang-kunang lain yang lebih terang (X_j) ditentukan oleh:

$$X_i = X_i + \beta_0 e^{(-\gamma r^m)} (X_j - X_i) + \alpha \varepsilon_i \quad (2.56)$$

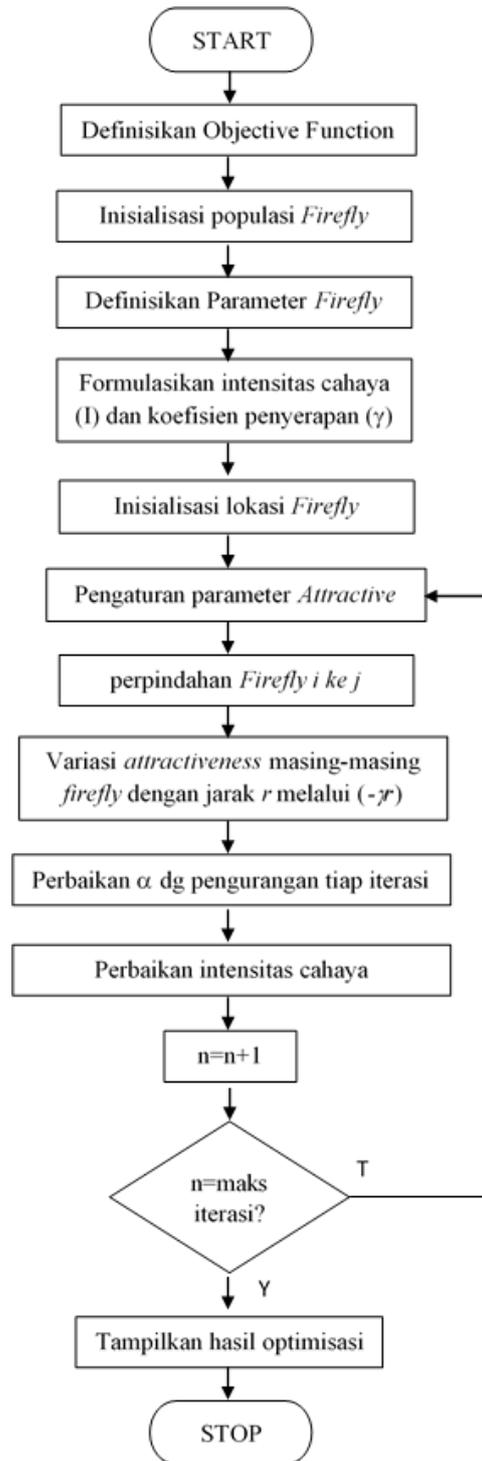
Dengan ε_j adalah nilai acak distribusi Gaussian. Dalam persamaan 2.56, menunjukkan bahwa pergerakan kunang-kunang terdiri dari tiga hal. Yang pertama, gambaran posisi sekarang dari kunang-kunang. Yang kedua, gerakan kunang-kunang dengan kecerahan rendah tertarik ke yang lain yang lebih cerah. Yang ketiga, menggambarkan pergerakan acak kunang-kunang dengan nilai dari interval [0,1]. *Flowchart* FA ditunjukkan pada Gambar 2.16.

2.7.1. Algoritma MFA

Algoritma *modified firefly algorithm* (MFA) [52]-[56] adalah algoritma FA yang dimodifikasi digunakan untuk menghilangkan kelemahan FA dengan meningkatkan keacakan kunang-kunang karena mempengaruhi kunang-kunang dalam eksplorasi solusi optimal. MFA mengurangi keacakan kunang-kunang dengan menggunakan parameter pengacakan α . Dalam proses FA, mutasi sederhana dari parameter pengacakan α sesuai dengan perubahan iterasi. Dalam setiap iterasi, parameter pengacakan α berkurang sebesar 0,001. MFA akan membantu dalam mendapatkan konvergensi dengan cepat. *Flowchart* MFA ditunjukkan pada Gambar. 2.17.



Gambar 2.16 Flowchart Firefly Algorithm



Gambar 2.17. Flowchart Modified Firefly Algorithm

2.7.2 Algoritma AMFA

Berbagai metode telah diadopsi untuk memperbaiki kinerja FA, dua parameter yang sering diatur adalah faktor pergerakan acak (α) dan koefisien

penyerapan (γ). Namun, jika nilai ini dipilih dengan tidak tepat maka konvergensi lambat untuk dicapai, hasilnya tidak optimal dan mungkin terjebak dalam optima lokal.

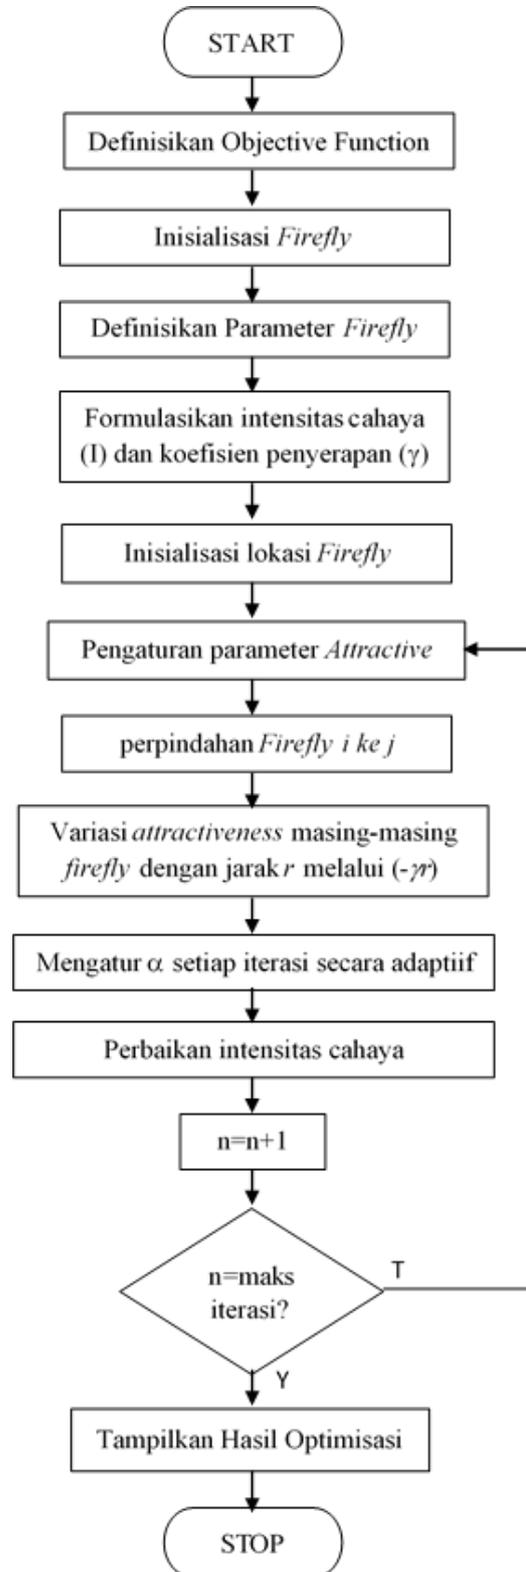
Parameter α memainkan peran penting dalam mengendalikan pergerakan acak untuk mendapatkan solusi, dan umumnya mengambil nilai antara 0 dan 1. Nilai α yang tinggi akan memiliki tingkat akurasi yang rendah untuk mencari nilai optimal karena perpindahan acak kunang-kunang menjadi terlalu lebar sehingga gerakan kunang-kunang tidak mengarah ke titik yang diinginkan. Sebuah α kecil di sisi lain akan menghasilkan tingkat konvergen yang baik untuk perpindahan kunang-kunang menuju titik yang diinginkan. Namun, jika nilai awal α diatur ke nilai kecil, maka α akan berkurang menjadi nilai yang hampir sama dengan menghilangkan perpindahan acak dari kunang-kunang. Hal ini tidak diinginkan karena perpindahan acak membantu menemukan koordinasi yang lebih baik. Selain itu, memodifikasi α dengan mengurangi nilainya menjadi menghambat kemampuan untuk memperoleh konvergensi maksimum karena nilai iterasi maksimum yang dikurangi sehingga sulit ditemukan konvergensi. Oleh karena itu, memodifikasi nilai α secara adaptif akan memecahkan masalah ini. Meskipun kunang-kunang memiliki nilai acak, namun tetap bisa bergerak menuju titik optimal karena nilai α akan berubah sesuai jarak. Seiring jarak mendekati optimal, α akan menjadi lebih kecil untuk meminimalkan nilai acak.

Algoritma yang diusulkan bertujuan untuk secara dinamis menyesuaikan nilai α dalam iterasi dan menghilangkan kelemahan FA [57] dengan mengelola α yang mempengaruhi kunang-kunang untuk mengeksplorasi koordinasi OCR yang optimal. Karena memiliki sifat adaptif maka algoritma yang diusulkan disebut dengan algoritma *adaptive modified firefly algorithm* (AMFA).

AMFA menjamin konvergensi yang lebih cepat untuk menemukan solusi optimum global. AMFA menurunkan pergerakan acak kunang-kunang dengan menerapkan m pergerakan acak α yang dikontrol secara adaptif sesuai dengan perubahan iterasi. Faktor pergerakan acak α disetel secara dinamis pada setiap iterasi berikut persamaannya:

$$\alpha^{k+1} = \alpha^k \times \left(\frac{1}{2 \times k_{max}} \right)^{\frac{1}{k_{max+1}}} \quad (2.57)$$

k adalah urutan iterasi, k_{\max} adalah iterasi maksimum. Gambar 2.18 ditunjukkan diagram alir AMFA.



Gambar 2.18 Flowchart Adaptive Modified Firefly Algorithm

BAB III

PEMODELAN KURVA KARAKTERISTIK *DIGITAL OVERCURRENT RELAY*

3.1 Metode Pemodelan Kurva Karakteristik *Digital Overcurrent Relay*

Kurva karakteristik suatu rele memegang peran yang sangat vital, fungsi dasar rele terletak pada kurva yang digunakan didalam rele tersebut, pada rele digital modern dengan basis *embedded microcontroller unit* akan sangat mudah merancang suatu *digital protection relay* yang bersifat *programmable* dari sisi kurva karakteristik didalamnya [58] [59].

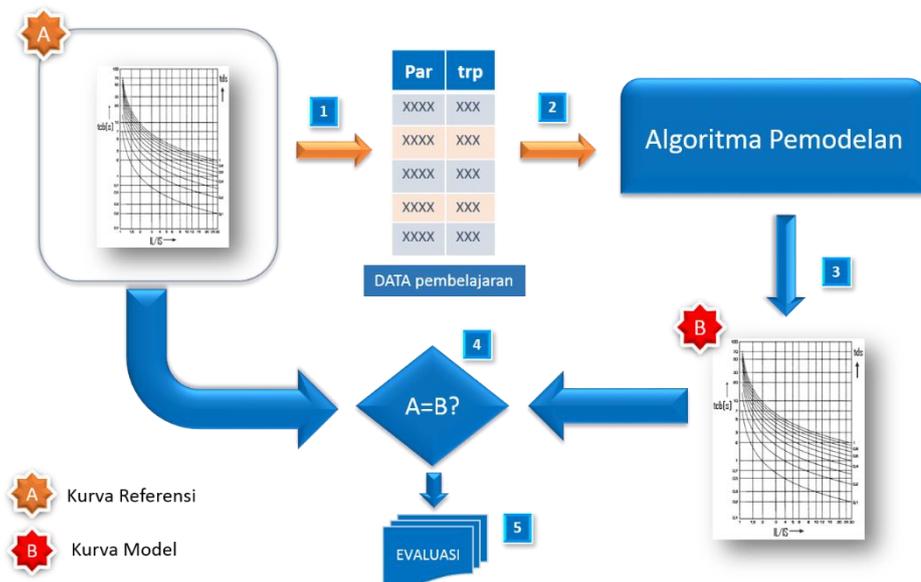
Dengan berkembangnya teknologi perangkat keras dengan proses waktu eksekusi semakin cepat dengan jumlah memori semakin besar kapasitasnya serta didukung kemudahan implementasi algoritma cerdas menggunakan mikrokontroler sangat terbuka lebar ide-ide inovasi untuk pengembangan rele digital terkait dengan pemodelan kurva karakteristik untuk kebutuhan khusus dimana tidak mampu lagi digunakan kurva standar [60]-[65].

Ide menggantikan kurva karakteristik yang berdasarkan pada persamaan standar menjadi bentuk model adalah terobosan yang dilakukan untuk memberikan kebebasan para user untuk membuat kurva karakteristik baik standar maupun *non-standard* dengan jumlah model yang memadai dalam satu rele, maka akan menjawab jaringan distribusi yang bersifat dinamis atau jaringan distribusi yang bersifat aktif.

Gambar 3.1 diberikan alur metodologi pemodelan yang dilakukan, pada langkah ke-1 dengan menggunakan data-data parameter masukan model dan parameter keluaran model, selanjutnya dihasilkan data pembelajaran yang didapat dari kurva karakteristik standar. Selanjutnya pada langkah ke-2 dengan menggunakan data-data tersebut dilakukan pemodelan dengan beberapa algoritma regresi polinomial maupun algoritma kecerdasan komputasional, dan langkah ke-3 akan menghasilkan model kurva karakteristik, pada langkah ke-4 dilakukan evaluasi performansi dengan membandingkan hasil waktu trip hasil dari pemodelan

kurva dibanding dengan nilai waktu trip berdasar kurva standar, langkah ke-5 melakukan analisis dan modifikasi untuk menghasilkan pemodelan yang semakin akurat.

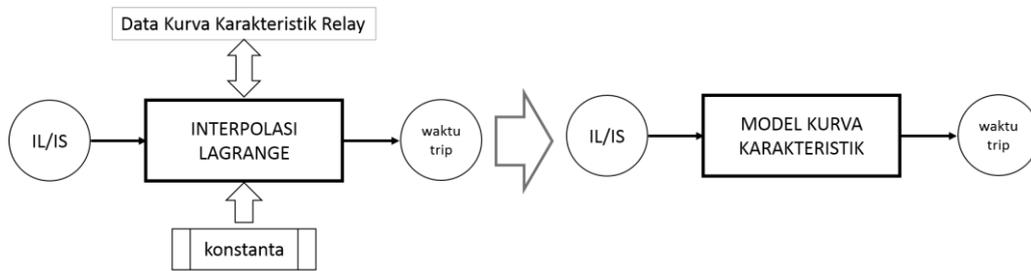
Telah dilakukan ujicoba pemodelan kurva karakteristik rele menggunakan tiga jenis algoritma, yakni dengan menggunakan *interpolasi polynomial Lagrange* [15], *adaptive neuro fuzzy inference system* (ANFIS) dan *artificial neural network* (ANN) yang akan dipaparkan pada bab ini.



Gambar 3.1. Metode Pemodelan Kurva Karakteristik Rele Digital

3.2. Memodelkan Kurva Karakteristik Rele Digital dengan Interpolasi *Polynomial Lagrange*

Kemampuan interpolasi *polynomial* [66] adalah untuk mendapatkan titik-titik lainnya jika kita mempunyai beberapa titik disekitarnya, dengan dasar ini maka akan dilakukan ujicoba untuk membentuk sebuah model untuk kurva karakteristik rele digital. Gambar 3.2 adalah penjelasan bagaimana membuat model kurva karakteristik dari interpolasi Lagrange, yakni dengan menggunakan data-data dan konstanta yang berasal dari persamaan standar menjadi sebuah model.



Gambar 3.2 Pemodelan Kurva dengan Interpolasi Lagrange

Menggunakan persamaan interpolasi Lagrange sebagai berikut:

$$f_n(x) = \sum_{i=0}^n L_i(x) f(x_i) \quad (3.1)$$

dengan $L_i(x)$:

$$L_i(x) = \prod_{\substack{j=0 \\ j \neq i}}^n \frac{x - x_j}{x_i - x_j} \quad (3.2)$$

Dari persamaan tersebut dirancang *pseudo code* untuk program simulasi, seperti ditunjukkan pada Gambar 3.3.

```

1. read x, n
2. for i=1 to (n+1) step=1
   read xi, dan fi
   end for i
3. sum=0
4. for i=1 to (n+1) step=1
5. function=1
6.   for j=1 to (n+1) step=1
7.     if (j≠i) then
       function=function * (x-xj)/(xi-xj)
     end for j
8. sum=sum+fi*function
   end for i
9. write x,sum
10. end
  
```

Gambar 3.3 *Pseudo Code* Model Kurva dengan Interpolasi Lagrange

Selanjutnya dirancang tabel data untuk empat kurva pada Tabel 3.1 hingga 3.4.

Tabel 3.1. Data Rasio dan Trip untuk Kurva *Standard Inverse*

Kurva Karakteristik <i>Extremely Inverse</i> /trp/TMS						
rasio	trp/1,0	trp/0,8	trp/0,6	trp/0,4	trp/0,2	trp/0,1
1,1	67,006	53,604	40,203	26,802	13,401	6,701
1,2	38,324	30,659	22,994	15,329	7,665	3,832
1,7	13,122	10,498	7,873	5,249	2,624	1,312
2,2	8,808	7,047	5,285	3,523	1,762	0,881
2,7	6,978	5,582	4,187	2,791	1,396	0,698
3,2	5,948	4,759	3,569	2,379	1,190	0,595
3,7	5,281	4,225	3,168	2,112	1,056	0,528
4,2	4,808	3,846	2,885	1,923	0,962	0,481
4,7	4,454	3,563	2,672	1,781	0,891	0,445
5,2	4,176	3,341	2,506	1,671	0,835	0,418
5,7	3,952	3,162	2,371	1,581	0,790	0,395
6,2	3,767	3,014	2,260	1,507	0,753	0,377
6,7	3,611	2,888	2,166	1,444	0,722	0,361
7,2	3,476	2,781	2,086	1,391	0,695	0,348
7,7	3,360	2,688	2,016	1,344	0,672	0,336
8,2	3,257	2,606	1,954	1,303	0,651	0,326
8,7	3,166	2,533	1,900	1,267	0,633	0,317
9,2	3,085	2,468	1,851	1,234	0,617	0,308
9,7	3,011	2,409	1,807	1,205	0,602	0,301
10,2	2,945	2,356	1,767	1,178	0,589	0,294
10,7	2,884	2,307	1,730	1,154	0,577	0,288
11,2	2,828	2,262	1,697	1,131	0,566	0,283
11,7	2,777	2,221	1,666	1,111	0,555	0,278
12,2	2,729	2,183	1,637	1,092	0,546	0,273

Tabel 3.2. Data Rasio dan Trip untuk Kurva *Extremely Inverse*

Kurva Karakteristik <i>Extremely Inverse</i> /trp/TMS						
rasio	trp/1,0	trp/0,8	trp/0,6	trp/0,4	trp/0,2	trp/0,1
1,1	344,679	275,743	206,807	137,872	68,936	34,468
1,2	181,818	145,455	109,091	72,727	36,364	18,182
1,7	39,468	33,862	25,397	16,931	8,466	4,233
2,2	19,619	16,667	12,500	8,333	4,167	2,083
2,7	12,202	10,175	7,631	5,087	2,544	1,272
3,2	8,363	6,926	5,195	3,463	1,732	0,866
3,7	6,125	5,043	3,783	2,522	1,261	0,630
4,2	4,688	3,846	2,885	1,923	0,962	0,481
4,7	3,710	3,035	2,276	1,517	0,759	0,379
5,2	3,012	2,458	1,843	1,229	0,614	0,307
5,7	2,495	2,032	1,524	1,016	0,508	0,254
6,2	2,102	1,709	1,282	0,855	0,427	0,214
6,7	1,795	1,458	1,094	0,729	0,365	0,182
7,2	1,551	1,259	0,944	0,629	0,315	0,157
7,7	1,355	1,098	0,823	0,549	0,274	0,137
8,2	1,193	0,966	0,725	0,483	0,242	0,121
8,7	1,059	0,857	0,643	0,428	0,214	0,107
9,2	0,946	0,765	0,574	0,383	0,191	0,096
9,7	0,851	0,688	0,516	0,344	0,172	0,086
10,2	0,765	0,621	0,466	0,311	0,155	0,078
10,7	0,716	0,564	0,423	0,282	0,141	0,070
11,2	0,621	0,514	0,386	0,257	0,129	0,064
11,7	0,610	0,471	0,353	0,235	0,118	0,059
12,2	0,541	0,433	0,325	0,216	0,108	0,054

Tabel 3.3 Data Rasio dan Trip untuk Kurva *Very Inverse*

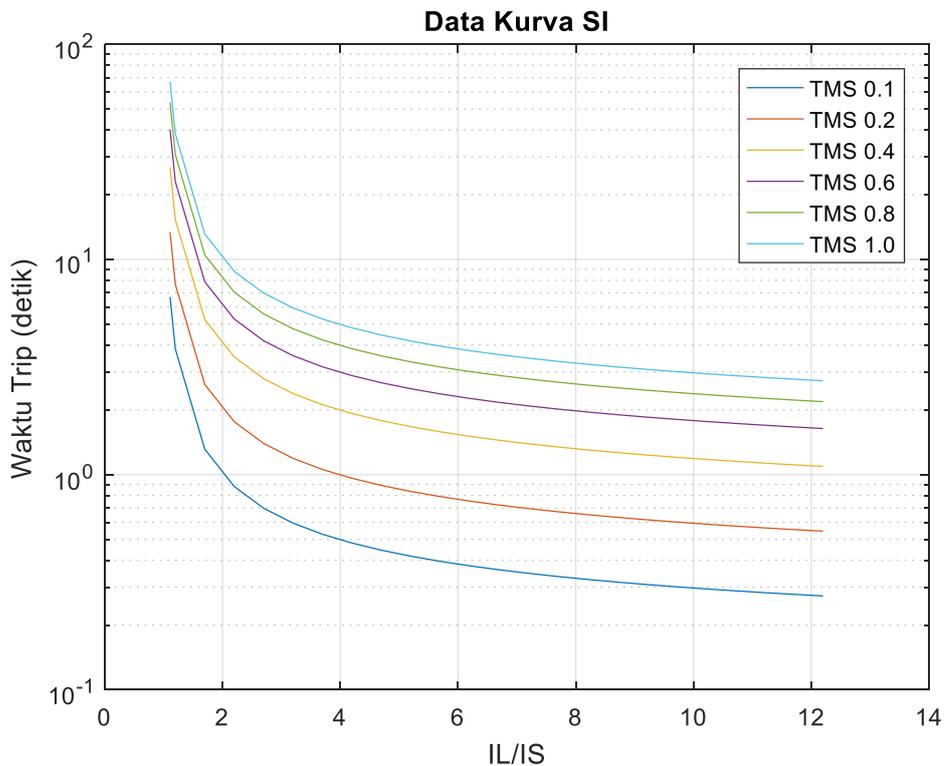
Kurva Karakteristik <i>Very Inverse</i> /trp/TMS						
rasio	trp/1,0	trp/0,8	trp/0,6	trp/0,4	trp/0,2	trp/0,1
1,11	122,727	98,182	73,636	49,091	24,545	12,273
1,2	67,500	54,000	40,500	27,000	13,500	6,750
1,7	19,286	15,429	11,571	7,714	3,857	1,929
2,2	11,250	9,000	6,750	4,500	2,250	1,125
2,7	7,941	6,353	4,765	3,176	1,588	0,794
3,2	6,136	4,909	3,682	2,455	1,227	0,614
3,7	5,000	4,000	3,000	2,000	1,000	0,500
4,2	4,219	3,375	2,531	1,688	0,844	0,422
4,7	3,649	2,919	2,189	1,459	0,730	0,365
5,2	3,214	2,571	1,929	1,286	0,643	0,321
5,7	2,872	2,298	1,723	1,149	0,574	0,287
6,2	2,596	2,077	1,558	1,038	0,519	0,260
6,7	2,368	1,895	1,421	0,947	0,474	0,237
7,2	2,177	1,742	1,306	0,871	0,435	0,218
7,7	2,015	1,612	1,209	0,806	0,403	0,201
8,2	1,875	1,500	1,125	0,750	0,375	0,188
8,7	1,753	1,403	1,052	0,701	0,351	0,175
9,2	1,646	1,317	0,988	0,659	0,329	0,165
9,7	1,552	1,241	0,931	0,621	0,310	0,155
10,2	1,467	1,174	0,880	0,587	0,293	0,147
10,7	1,392	1,113	0,835	0,557	0,278	0,139
11,2	1,324	1,059	0,794	0,529	0,265	0,132
11,7	1,262	1,009	0,757	0,505	0,252	0,126
12,2	1,205	0,964	0,723	0,482	0,241	0,121

Tabel 3.4 Data Rasio dan Trip untuk Kurva *Long Time Inverse*

Kurva Karakteristik <i>Long Time Inverse</i> /trp/TMS						
rasio	trp/1,0	trp/0,8	trp/0,6	trp/0,4	trp/0,2	trp/0,1
1,11	1090,909	872,727	654,545	436,364	218,182	109,091
1,2	600,000	480,000	360,000	240,000	120,000	60,000
1,7	171,429	137,143	102,857	68,571	34,286	17,143
2,2	100,000	80,000	60,000	40,000	20,000	10,000
2,7	70,588	56,471	42,353	28,235	14,118	7,059
3,2	54,545	43,636	32,727	21,818	10,909	5,455
3,7	44,444	35,556	26,667	17,778	8,889	4,444
4,2	37,500	30,000	22,500	15,000	7,500	3,750
4,7	32,432	25,946	19,459	12,973	6,486	3,243
5,2	28,571	22,857	17,143	11,429	5,714	2,857
5,7	25,532	20,426	15,319	10,213	5,106	2,553
6,2	23,077	18,462	13,846	9,231	4,615	2,308
6,7	21,053	16,842	12,632	8,421	4,211	2,105
7,2	19,355	15,484	11,613	7,742	3,871	1,935
7,7	17,910	14,328	10,746	7,164	3,582	1,791
8,2	16,667	13,333	10,000	6,667	3,333	1,667
8,7	15,584	12,468	9,351	6,234	3,117	1,558
9,2	14,634	11,707	8,780	5,854	2,927	1,463
9,7	13,793	11,034	8,276	5,517	2,759	1,379
10,2	13,043	10,435	7,826	5,217	2,609	1,304
10,7	12,371	9,897	7,423	4,948	2,474	1,237
11,2	11,765	9,412	7,059	4,706	2,353	1,176
11,7	11,215	8,972	6,729	4,486	2,243	1,121
12,2	10,714	8,571	6,429	4,286	2,143	1,071

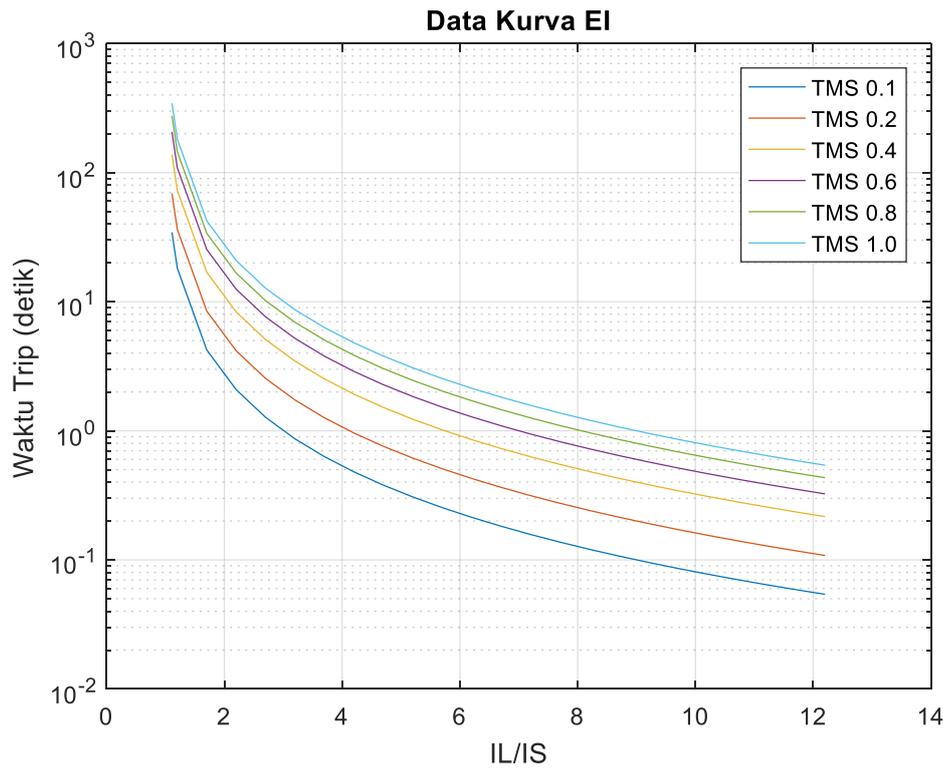
Dari data-data yang telah dihasilkan dengan beberapa TMS yang berbeda selanjutnya ditunjukkan dalam bentuk kurva karakteristik dan ditampilkan pada Gambar 3.4 sampai dengan Gambar 3.7 untuk kurva karakteristik SI, EI, VI serta LTI secara berurutan.

Terlihat bentuk kurva yang berbeda karena perbedaan TMS, dipilih hanya beberapa nilai TMS untuk ujicoba. Selanjutnya bentuk kurva ini digunakan sebagai kurva referensi untuk program algoritma Lagrange.

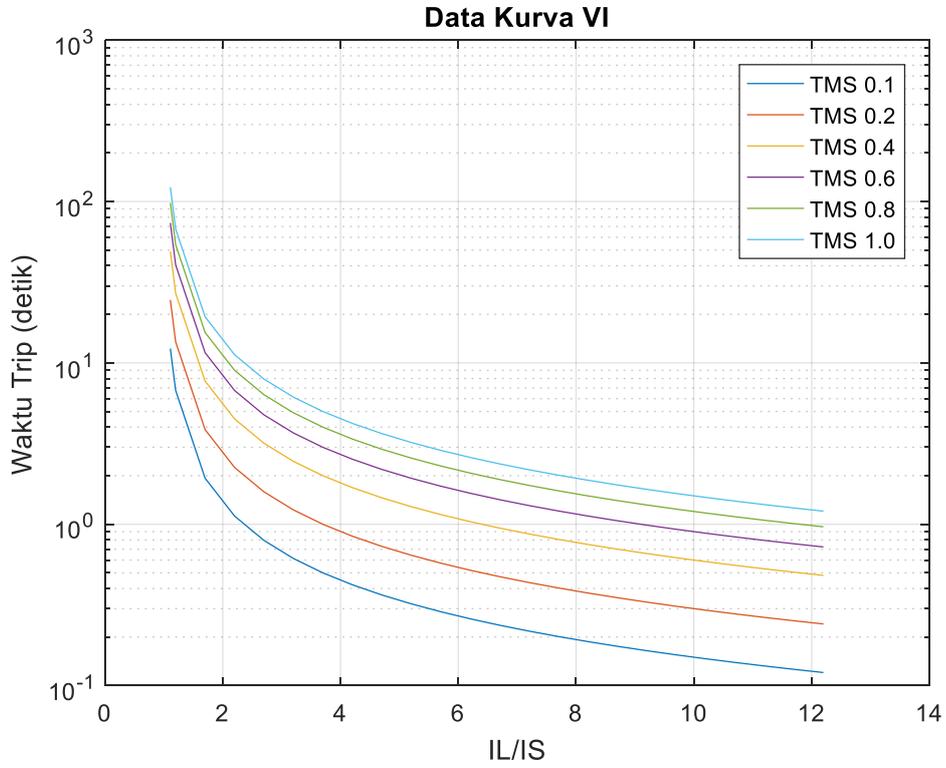


Gambar 3.4. Kurva Karakteristik *Standard Inverse* dengan Variasi TMS

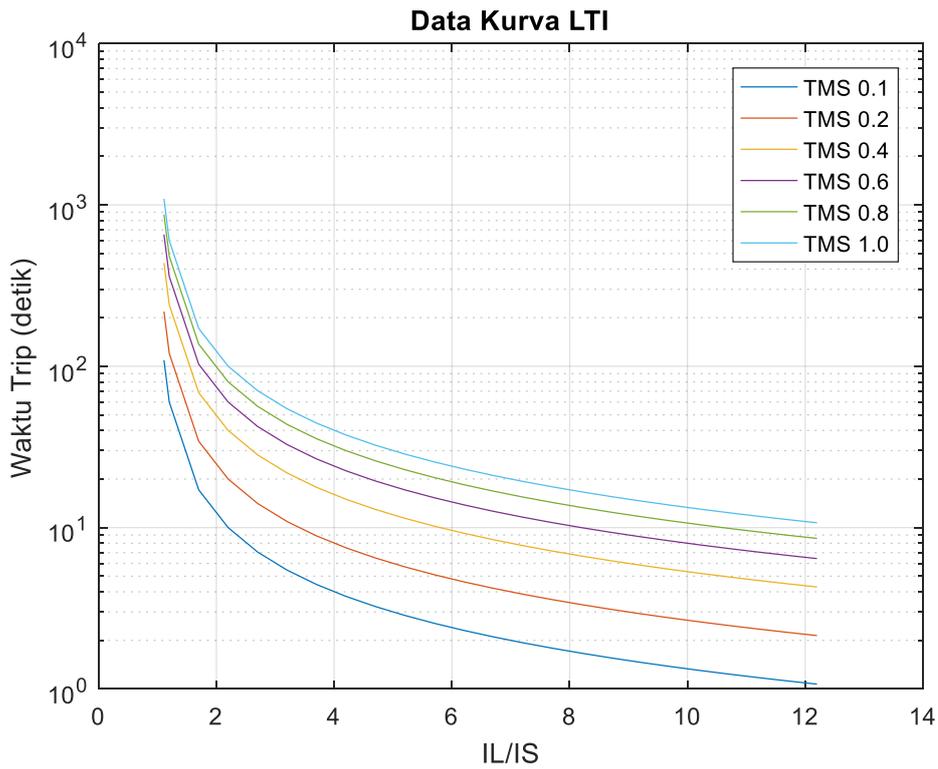
Perbedaan bentuk grafik akan membentuk jarak antara satu kurva dengan kurva lain, ini disebut dengan *grading time*, parameter ini penting diperhatikan saat rele melakukan koordinasi dengan sesama rele atau perangkat proteksi lainnya. Untuk ujicoba dipilih rasio arus beban dan arus *pickup* sebesar 1,1 sampai dengan 12,2.



Gambar 3.5. Kurva Karakteristik *Extremely Inverse*



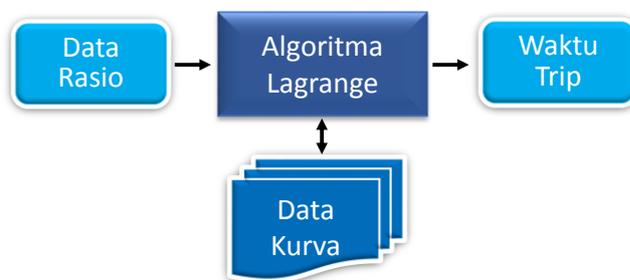
Gambar 3.6. Kurva Karakteristik *Very Inverse*



Gambar 3.7. Kurva Karakteristik *Long Time Inverse*

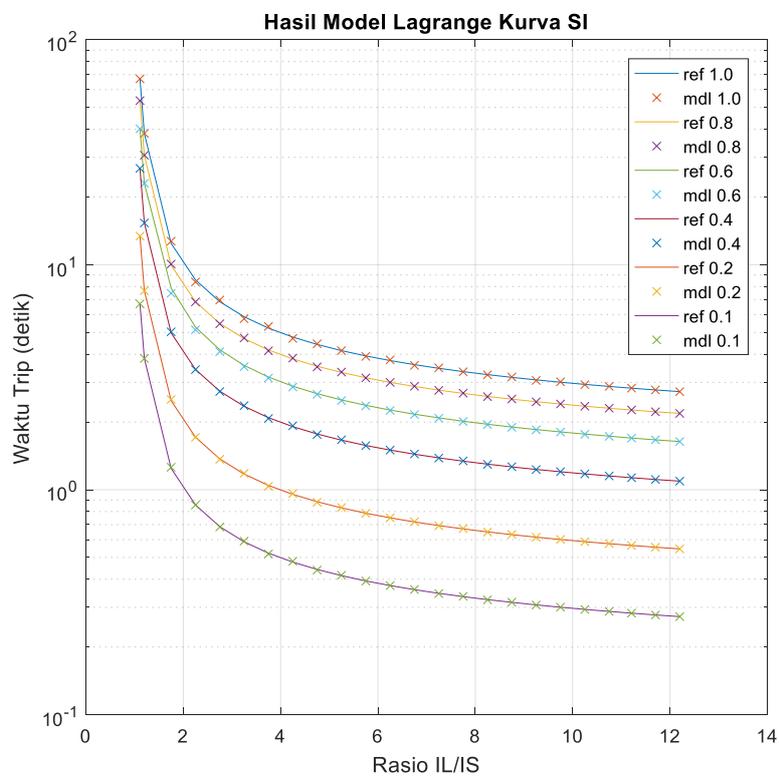
3.3. Performansi Model Menggunakan Interpolasi Lagrange

Dengan menggunakan data kurva rasio sebagai masukan dari fungsi model Lagrange selanjutnya didapatkan hasil waktu trip, hasil pemodelan kurva karakteristik ditampilkan pada Gambar 3.9 sampai dengan Gambar 3.12.



Gambar 3.8. Blok Diagram Ujicoba Model Kurva dengan Lagrange

Performansi model yang dihasilkan dengan menggunakan interpolasi polinomial Lagrange pada kurva *standar inverse* dengan beberapa TMS secara grafik diberikan pada Gambar 3.9, tanda garis lurus adalah grafik menggunakan persamaan standar sedang tanda silang adalah hasil pemodelan dengan Lagrange, warna grafik menunjukkan nilai dari TMS. Performansi model dihitung dengan *mean absolute deviation* (MAD), *mean square error* (MSE), *root mean square error* (RMSE) serta *mean absolute percentage error* (MAPE) ditunjukkan pada Tabel 3.5. Semakin kecil nilai TMS menghasilkan nilai *error* yang cenderung kecil, dikarenakan bentuk kurva dengan lengkung yang semakin lentur.

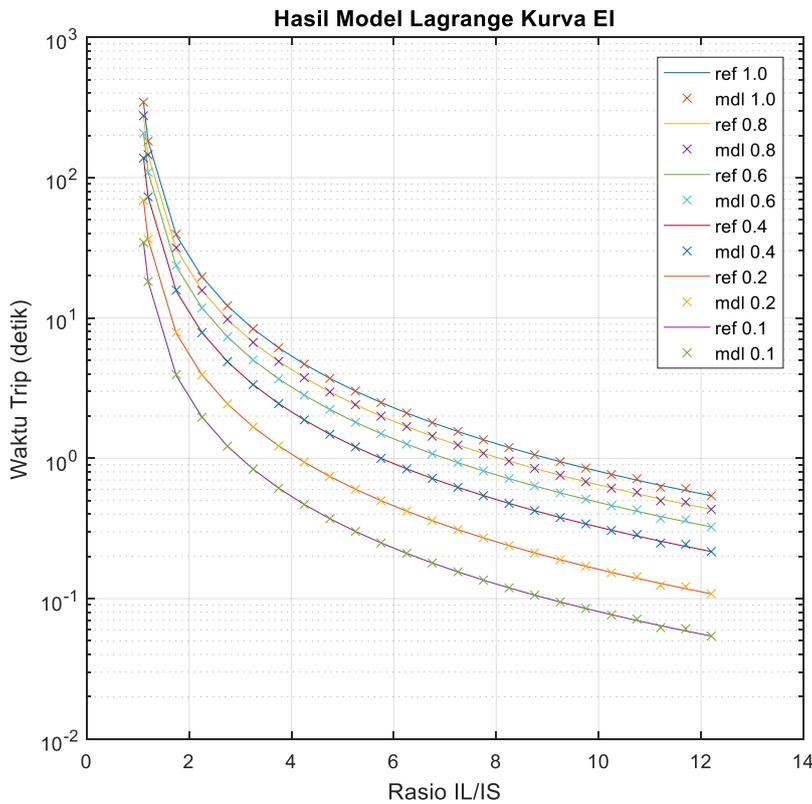


Gambar 3.9. Hasil Pemodelan Kurva Karakteristik *Standard Inverse*

Tabel 3.5. Performansi Model Lagrange Kurva *Standard Inverse*

TMS	MAD	MSE	RMSE	MAPE
1,0	0,043	0,00715	0,085	0,675
0,8	0,014	0,00076	0,028	0,280
0,6	0,010	0,00043	0,021	0,280
0,4	0,007	0,00019	0,014	0,280
0,2	0,003	0,00005	0,007	0,280
0,1	0,002	0,00001	0,003	0,280

Gambar 3.10 ditunjukkan hasil performansi dari kurva *extremely inverse* dengan beberapa nilai TMS, hasilnya dapat dilihat pada Tabel 3.6, baik MAD, MSE serta RMSE menunjukkan nilai yang semakin kecil sesuai nilai TMS, semakin kecil nilai TMS semakin kecil *error* yang didapat. Pola kurva mirip dengan kurva SI namun nilai trip maksimum pada kurva EI melebihi dari kurva SI. Hasil pemodelan dengan algoritma Lagrange mampu mengikuti bentuk kurva referensi yang digunakan sebagai target, tanda silang adalah hasil pemodelan dan tanda garis adalah referensi.

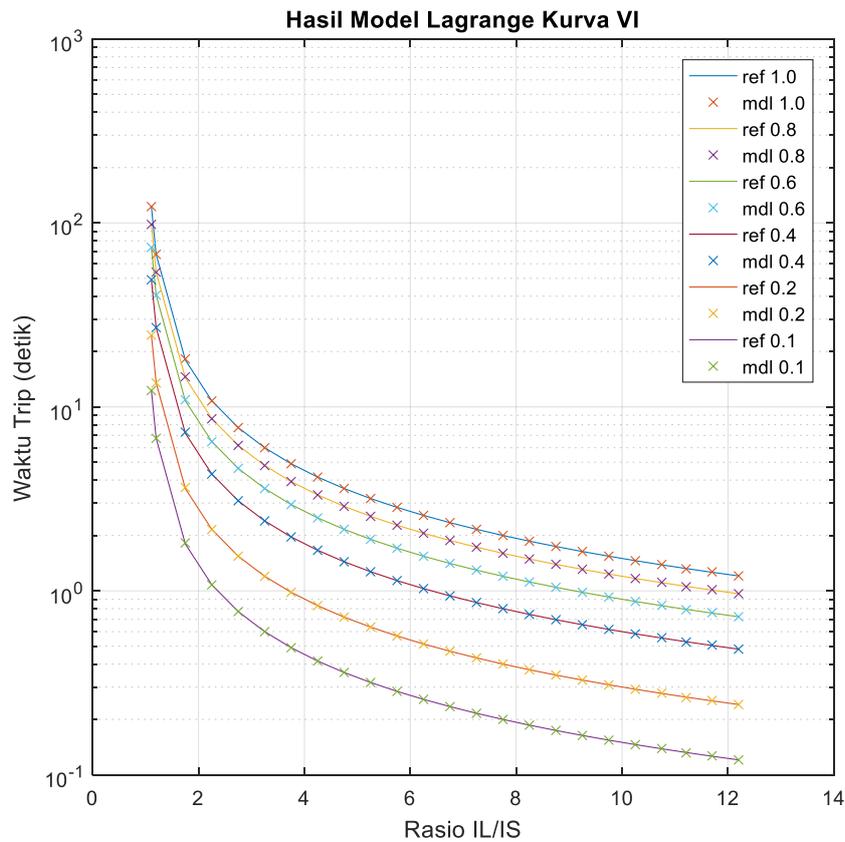


Gambar 3.10. Hasil Pemodelan Kurva Karakteristik *Extremely Inverse*

Tabel 3.6. Performansi Model Lagrange Kurva *Extremely Inverse*

TMS	MAD	MSE	RMSE	MAPE
1,0	0,035	0,0213	0,146	0,507
0,8	0,028	0,0125	0,112	0,507
0,6	0,021	0,0070	0,084	0,507
0,4	0,014	0,0031	0,056	0,507
0,2	0,007	0,0008	0,028	0,507
0,1	0,003	0,0002	0,014	0,507

Gambar 3.11 adalah hasil pemodelan kurva karakteristik kurva *very inverse* dengan beberapa nilai TMS, performansi menunjukkan hasil dengan pola yang hampir sama dengan karakteristik sebelumnya, yakni semakin kecil nilai TMS semakin kecil *error* yang dihasilkan, dengan nilai performansi *error* pada tabel 3.7, hasil kurva pemodelan Lagrange dengan tanda silang terbukti mampu mengikuti pola kurva referensi dengan tanda garis lurus sebagai target. Warna kurva menunjukkan nilai TMS yang berbeda.

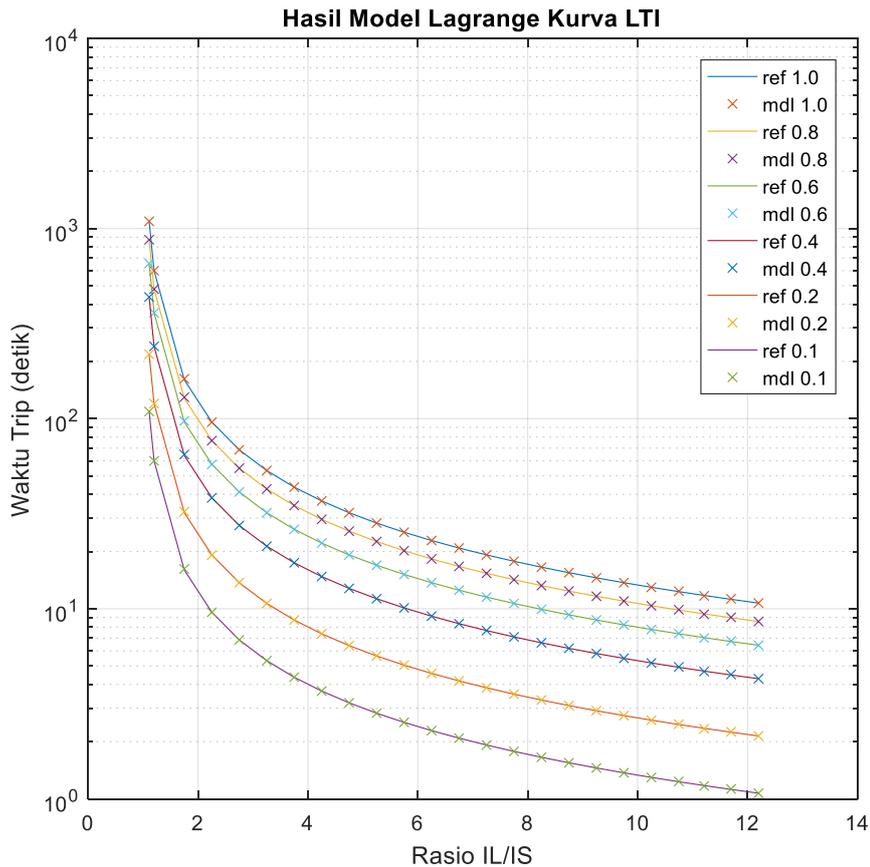


Gambar 3.11. Hasil Pemodelan Kurva Karakteristik *Very Inverse*

Tabel 3.7. Performansi Model Lagrange Kurva *Very Inverse*

TMS	MAD	MSE	RMSE	MAPE
1,0	0,012	0,00243	0,049	0,1335
0,8	0,009	0,00142	0,038	0,1335
0,6	0,007	0,00080	0,028	0,1335
0,4	0,005	0,00036	0,019	0,1335
0,2	0,002	0,00009	0,009	0,1335
0,1	0,001	0,00002	0,005	0,1335

Gambar 3.12 dan Tabel 3.8 adalah hasil pemodelan untuk kurva *long time inverse* dengan beberapa TMS, *error* menunjukkan nilai yang semakin kecil untuk nilai TMS yang semakin kecil. Kurva hasil pemodelan Lagrange dengan tanda silang secara runtut mampu mengikuti pola kurva referensi sebagai target dengan tanda garis lurus, perbedaan nilai trip pada kurva jenis LTI lebih tinggi jika dibanding dengan jenis kurva VI.

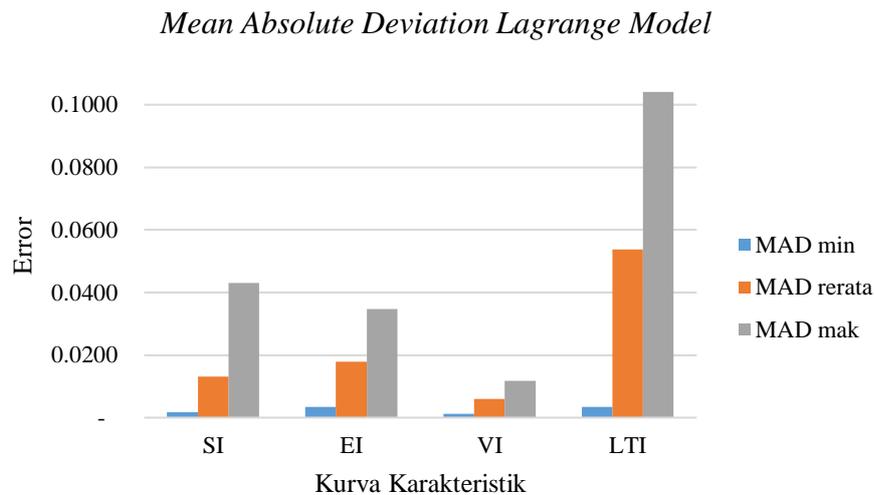


Gambar 3.12. Hasil Pemodelan Kurva Karakteristik *Long Time Inverse*

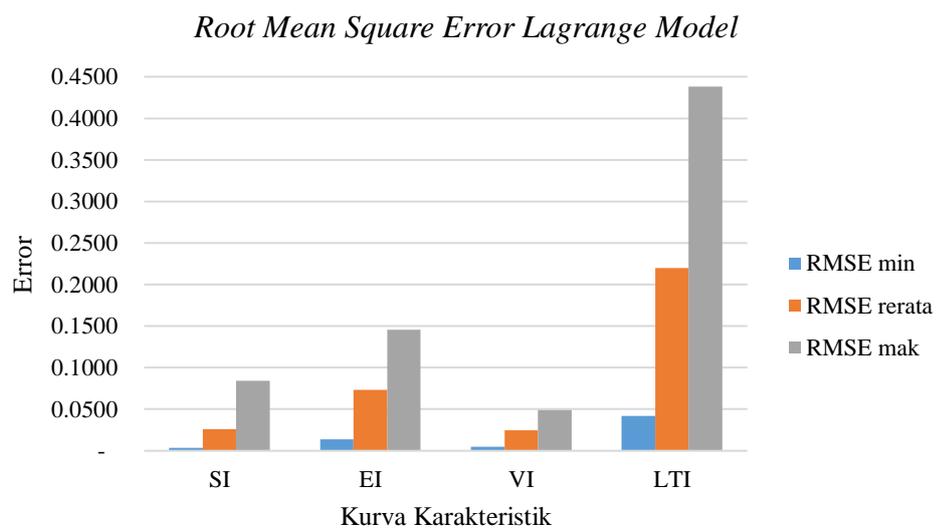
Tabel 3.8. Performansi Model Lagrange Kurva *Long Time Inverse*

TMS	MAD	MSE	RMSE	MAPE
1,0	0,104	0,192	0,438	0,1335
0,8	0,083	0,112	0,335	0,1335
0,6	0,062	0,063	0,252	0,1335
0,4	0,042	0,028	0,168	0,1335
0,2	0,021	0,007	0,084	0,1335
0,1	0,010	0,002	0,042	0,1335

Sebagai konklusi dari hasil pemodelan menggunakan algoritma Lagrange untuk kurva karakteristik SI, EI, VI dan LTI diberikan pada gambar 3.13 untuk performansi dari sisi *mean absolute deviation*, serta Gambar 3.14 untuk performansi dari sisi *root mean square error*. Kurva karakteristik jenis LTI mempunyai nilai *error* paling tinggi diantara jenis kurva lainnya, dan kurva VI mempunyai nilai *error* yang paling kecil secara keseluruhan.

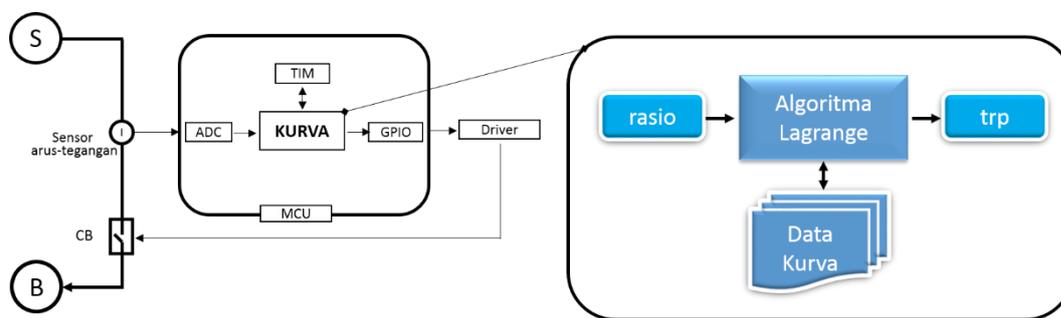


Gambar 3.13. *Mean Absolute Deviation Model Lagrange*



Gambar 3.14. *Root Mean Square Error Model Lagrange*

Untuk memberikan penjelasan terkait dengan model kurva dengan algoritma Lagrange pada Gambar 3.15 diberikan blok diagram penerapan model pada rele digital. Pada sisi *microcontroller* yang digunakan sebagai *digital protection relay* menggunakan algoritma yang telah di *deploy* didalam memori program *microcontroller* sebagai dasar perhitungan waktu trip, saat ada nilai rasio yang masuk saat kurva bekerja, selanjutnya nilai keluaran dari model merupakan nilai *on-delay* dari *timer* yang akan digunakan untuk memerintahkan *circuit breaker* pada kondisi *trip*.



Gambar 3.15 Posisi Model Lagrange pada Rele Digital

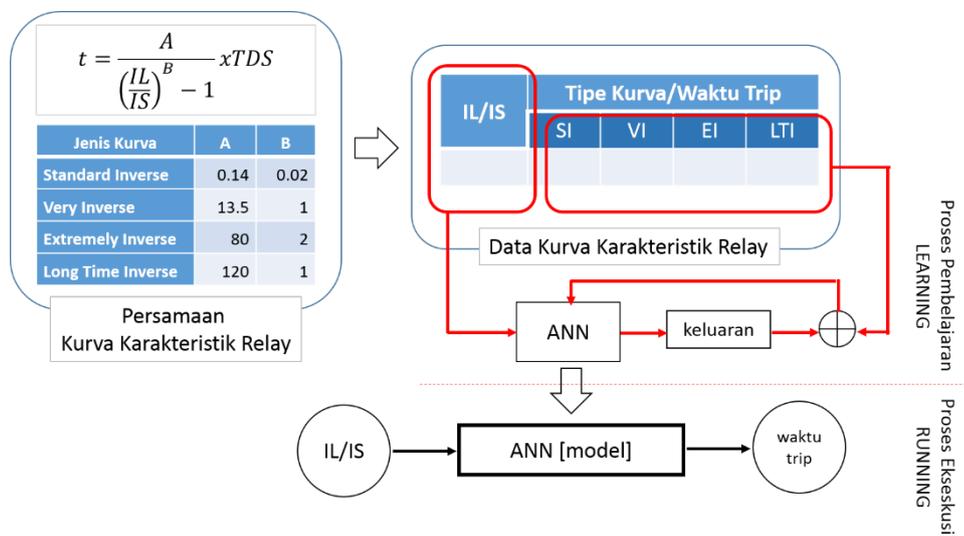
3.4. Pemodelan Kurva Karakteristik *Digital Overcurrent Relay* Menggunakan *Artificial Neural Network*

Setelah berhasil melakukan pemodelan dengan algoritma interpolasi Lagrange pemodelan dilanjutkan dengan menggunakan *artificial neural network* (ANN) seperti pada Gambar 3.16. Dengan menerapkan langkah yang hampir sama dengan saat menggunakan interpolasi Lagrange, data-data dari perbandingan IL/IS digunakan sebagai data masukan dan waktu trip masing-masing jenis kurva sebagai data target untuk membuat model.

Selama melakukan pembelajaran dilakukan perbandingan antara keluaran ANN dengan data target, jika belum sesuai maka akan dilakukan proses iterasi berulang hingga didapatkan hasil yang dikehendaki, dengan merubah parameter bobot dan bias serta menghitungnya kembali sebanyak *epoch* yang ditentukan. Jika

telah didapatkan nilai yang sesuai target maka akan didapatkan nilai bobot dan bias yang yang sesuai.

Selama pembelajaran dilakukan perbaikan atau *tuning* dengan merubah parameter dalam jaringan misal jumlah *neuron* dalam *input layer*, atau parameter konstanta yang lain. Setelah selesai proses pembelajaran maka nilai parameter seperti bobot dan bias yang didapatkan akan menjadi konstanta tetap sewaktu melakukan eksekusi algoritma ANN, yang selanjutnya disebut dengan model kurva yang dicari.



Gambar 3.16. Metode Pemodelan dengan ANN

Pembuatan data pembelajaran dirancang seperti pada Tabel 3.1 hingga Tabel 3.4. dengan tetap menggunakan persamaan standar, dimana sebagai data masukan adalah rasio I_L/I_S dan target adalah waktu trip. Sedang persamaan standar yang digunakan adalah sebagai berikut:

Standard inverse:

$$t_{trip} = \frac{0,14}{\left(\frac{I_L}{I_S}\right)^{0,02} - 1} \times TMS \quad (3.3)$$

Very inverse:

$$t_{trip} = \frac{13,5}{\left(\frac{I_L}{I_S}\right)^{-1}} \times TMS \quad (3.4)$$

Extremely inverse:

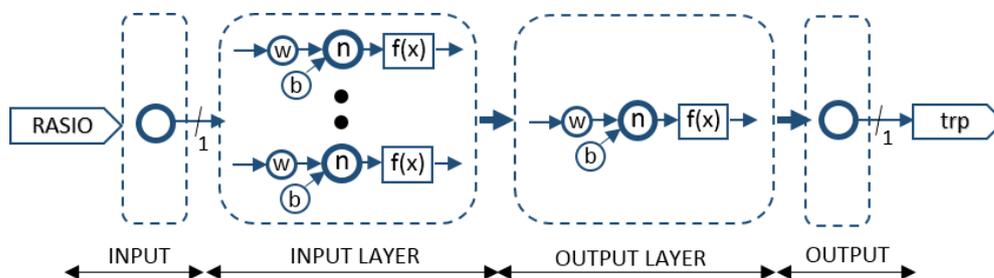
$$t_{trip} = \frac{80}{\left(\frac{I_L}{I_S}\right)^2 - 1} \times TMS \quad (3.5)$$

Long time inverse:

$$t_{trip} = \frac{120}{\left(\frac{I_L}{I_S}\right)^{-1}} \times TMS \quad (3.6)$$

Untuk perencanaan ANN digunakan konfigurasi seperti pada Gambar 3.17, dengan rincian seting parameter sebagai berikut:

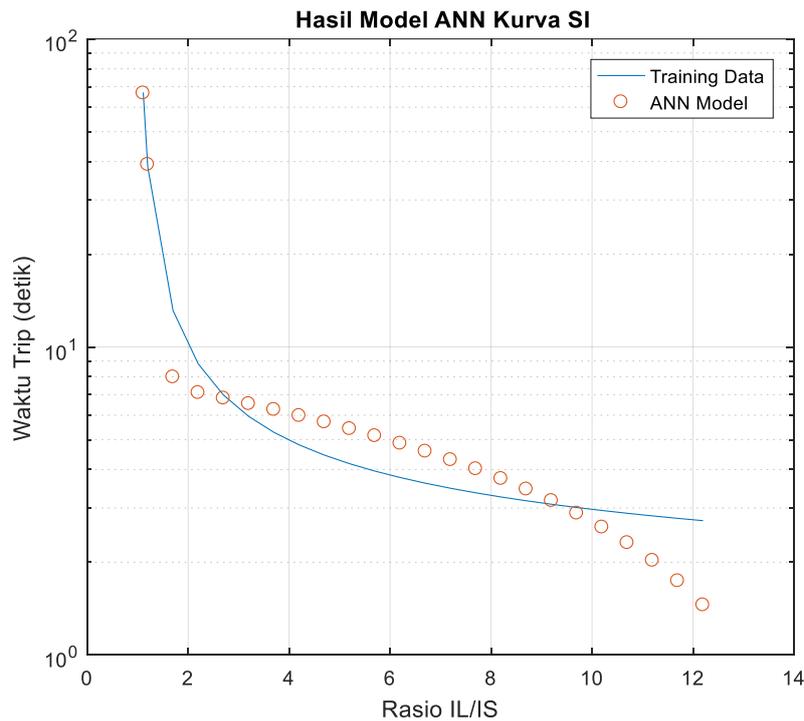
- Menggunakan satu masukan dan satu keluaran
- Multi *perceptron* dua *layer*, *layer input* dan *layer output*
- Jumlah *Neuron* $n=2$ sampai $n=8$, *epoch* 100
- Fungsi aktivasi *sigmoid* untuk *input layer* dan linier untuk *output layer*
- Fungsi *learning* Levenberg Marquardt
- Jaringan *feedforward backpropagation*



Gambar 3.17 Konfigurasi ANN untuk Pemodelan Kurva Karakteristik

3.5. Performansi Model Menggunakan *Artificial Neural Network* (ANN)

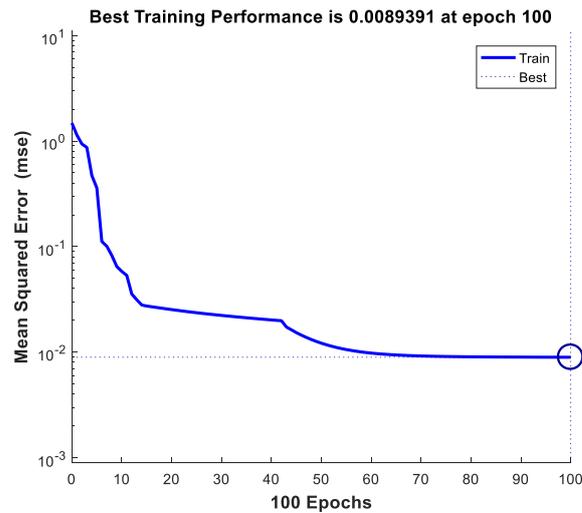
Dengan menggunakan data kurva SI seperti ditunjukkan pada Tabel 3.1, dan dengan menggunakan konfigurasi pada Gambar 3.17 dengan jumlah *neuron* pada *input layer* sejumlah dua *neuron* dan pada *layer output* satu *neuron*, didapatkan hasil seperti pada Gambar 3.18. Hanya ada dua data hasil pemodelan ANN dengan tanda lingkaran merah yang mendekati dengan data training bertanda garis lurus



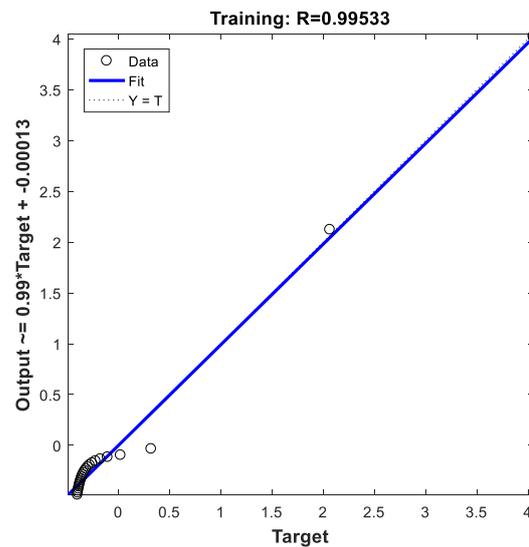
biru.

Gambar 3.18. Pemodelan Kurva SI dengan Jumlah *Neuron*=2

Hasil performansi dan regresi dengan menggunakan *neuron* pada sisi *input layer*=2 ditunjukkan pada Gambar 3.19 (a) dengan nilai *epoch*=1000 dan iterasi berhenti pada saat nilai *epoch* tercapai dengan nilai MSE=0,0089391, ditinjau dari regresi seperti ditunjukkan pada Gambar 3.19 (b) mempunyai R=0,99533 serta perbandingan antara target dan keluaran yang dihasilkan dapat dinyatakan dengan persamaan $output=0,996 \times Target + 0,00013$, sehingga dapat dinyatakan bahwa pemodelan belum berhasil, karena hasil keluaran model belum mendekati target yang diinginkan pada saat pembelajaran.



(a). Performansi Training

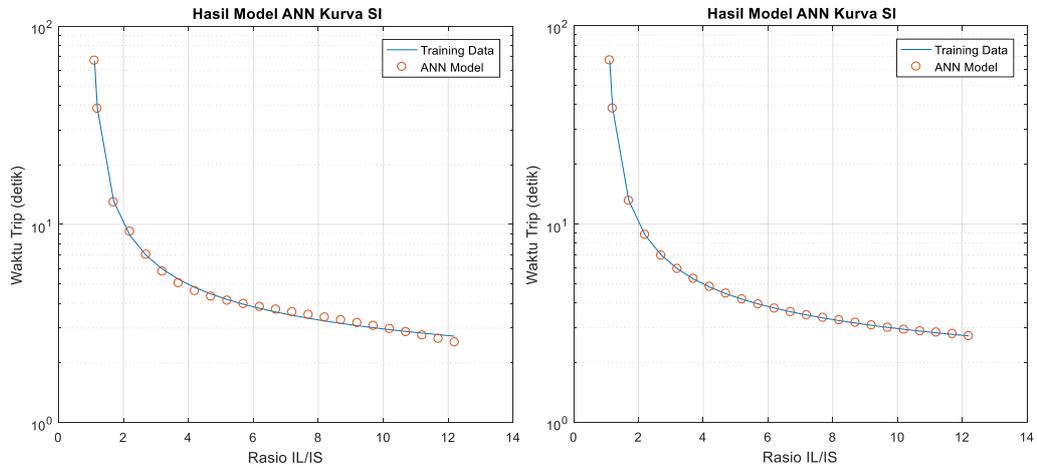


(b) Performansi Regresi

Gambar 3.19. Hasil Performansi MSE dan Regresi ANN

Salah satu cara untuk meningkatkan performansi hasil dengan cara menambah jumlah *neuron* hingga didapat nilai yang hampir mendekati nilai target dengan cara melakukan observasi performansi MSE dan regresi, pada Gambar 3.20(a) diberikan kurva hasil pemodelan dengan jumlah *neuron*=3 dan pada Gambar 3.20(b) dengan jumlah *neuron*=5, peningkatan performansi sudah mulai

kelihatan dengan semakin banyaknya data berimpit antara data training dan data hasil model.



(a) Jumlah *Neuron*=3

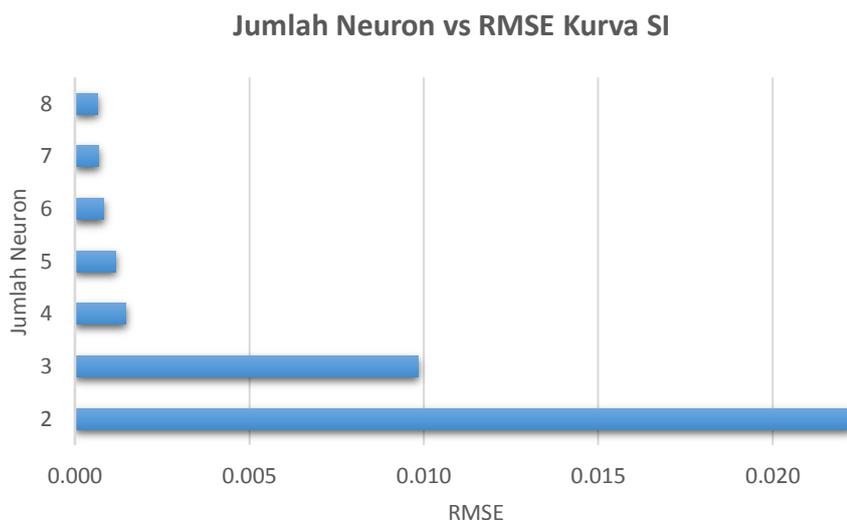
(b) Jumlah *Neuron*=5

Gambar 3.20 Pengaruh Jumlah *Neuron* pada *Layer Input*

Pada Tabel 3.9 dan grafik Gambar 3.21 diberikan data pengaruh peningkatan jumlah *neuron* pada *layer input* terhadap nilai RMSE, terlihat pada jumlah *neuron*=7 dan *neuron*=8 mempunyai nilai RMSE yang hampir sama, hal ini memberikan tanda bahwa pemilihan jumlah *neuron* yang optimum adalah *neuron*=7, karena semakin banyak jumlah *neuron* maka semakin banyak memori yang dibutuhkan sewaktu menjalankan program perangkat lunak, dampak lain adalah pada waktu eksekusi yang semakin lama.

Tabel 3.9 Pengaruh Jumlah *Neuron* pada *Layer Input* terhadap RMSE

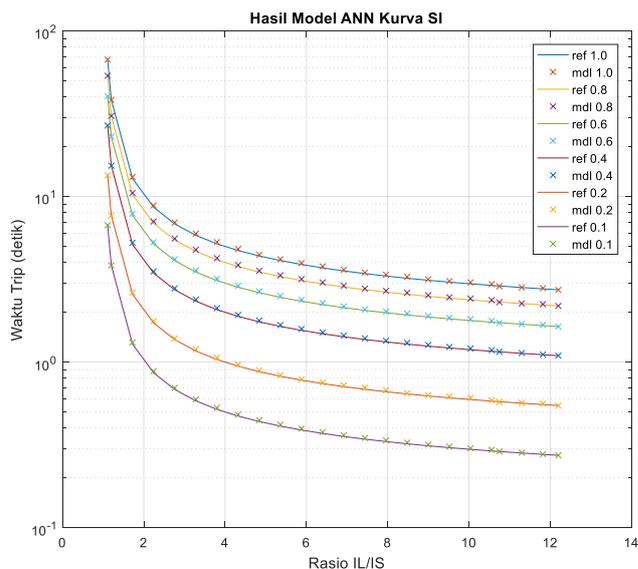
<i>Neuron</i>	RMSE
2	0,02226
3	0,00984
4	0,00146
5	0,00118
6	0,00083
7	0,00068
8	0,00065



Gambar 3.21 Pengaruh Jumlah *Neuron* pada *Layer Input* Terhadap Nilai RMSE

Selanjutnya untuk melihat keberhasilan pemodelan dilihat dari performansi dengan *mean absolute deviation* (MAD), *mean square error* (MSE), *root mean square error* (RMSE) serta *mean absolute percentage error* (MAPE), Gambar 3.22 dan Tabel 3.10 adalah hasil performansi pemodelan kurva karakteristik SI.

Untuk ujicoba pemodelan digunakan *epoch*=100, jumlah *neuron*=7, untuk training digunakan fungsi Levernberg-Marqaurdt, uji performansi digunakan MSE.



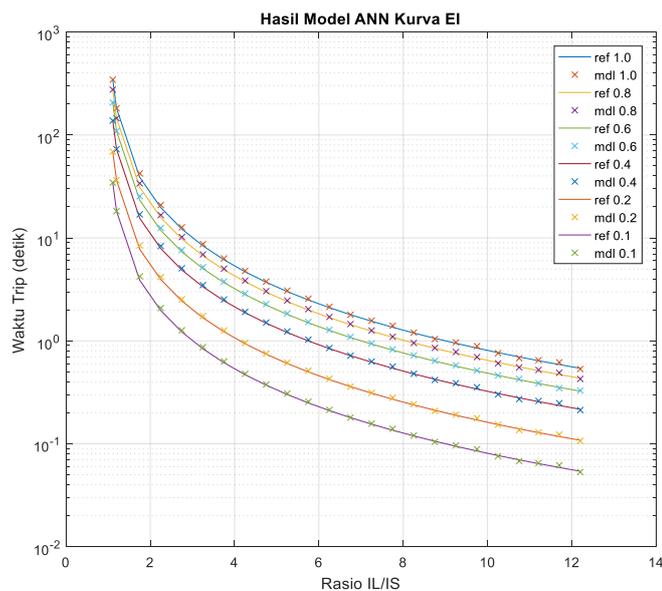
Gambar 3.22 Hasil Pemodelan Kurva SI dengan ANN

Kurva karakteristik SI dengan TMS semakin besar ternyata cenderung mempunyai nilai *error* yang semakin besar. Dilihat dari bentuk kurva hasil pemodelan ANN dengan tanda silang mampu mengikuti bentuk kurva target dengan tanda garis lurus menunjukkan keberhasilan hasil pemodelan

Tabel 3.10 Performansi Model Kurva SI dengan ANN

TMS	MAD	MSE	RMSE	MAPE
1,0	0,072	0,01028	0,101	1,474
0,8	0,057	0,00603	0,078	1,463
0,6	0,043	0,00340	0,058	1,473
0,4	0,028	0,00149	0,039	1,430
0,2	0,015	0,00039	0,020	1,494
0,1	0,007	0,00009	0,010	1,430

Untuk kurva karakteristik yang lain akan dilakukan uji performansi yang sama untuk melihat keberhasilan pemodelan yang dihasilkan, pada Gambar 3.23 ditunjukkan hasil perormansi kurva *extremely inverse*. Hampir sama pola *error* yang didapatkan, semakin kecil TMS akan cenderung mempunyai nilai *error* yang kecil. Jenis kurva ini agak berkurang kelengkungannya dibanding dengan jenis kurva SI.



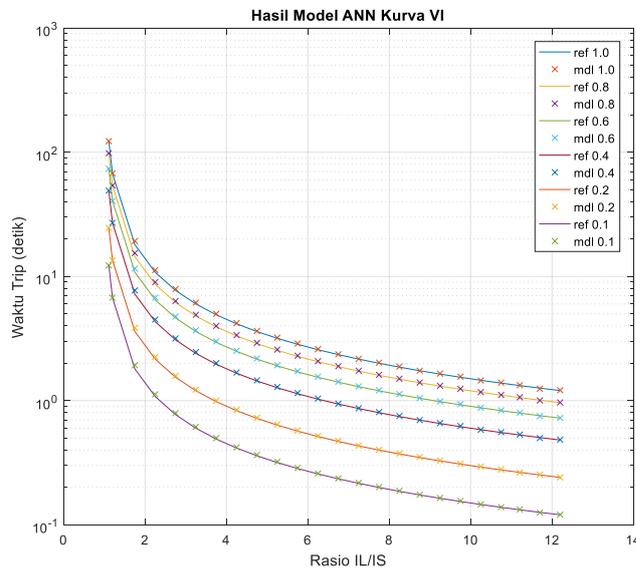
Gambar 3.23 Hasil Pemodelan Kurva EI dengan ANN

Nilai RMSE yang ditunjukkan pada Tabel 3.11 mempunyai nilai *error* yang cenderung semakin kecil mengikuti nilai TMS, hal ini dipengaruhi dari bentuk kurva yang cenderung landai pada jenis kurva EI.

Tabel 3.11 Performansi Model Kurva EI dengan ANN

TMS	MAD	MSE	RMSE	MAPE
1,0	0,261	0,648	0,805	2,602
0,8	0,207	0,380	0,616	2,334
0,6	0,154	0,214	0,462	2,093
0,4	0,105	0,095	0,308	2,651
0,2	0,052	0,024	0,154	2,477
0,1	0,026	0,006	0,077	2,578

Hasil performansi untuk kurva jenis VI ditunjukkan pada Gambar 3.24, dimana bentuk kurva mendekati SI. Kurva dengan TMS yang berbeda akan mempengaruhi bentuk yang agak signifikan sehingga akan berpengaruh terhadap *error* performansi yang dihasilkan.



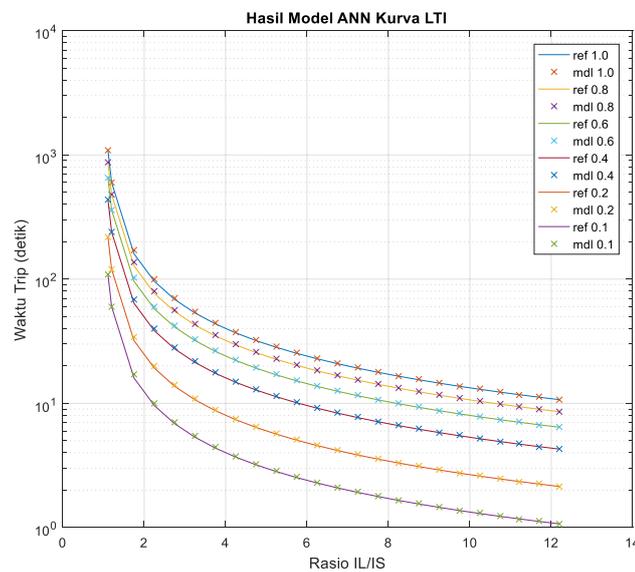
Gambar 3.24 Hasil Pemodelan Kurva VI dengan ANN

Tabel 3.12 adalah pola *error* dengan nilai TMS yang berbeda untuk kurva VI, hasil yang sama dengan bentuk kurva yang lainnya dimana *error* semakin kecil untuk nilai TMS yang semakin kecil.

Tabel 3.12 Performansi Model Kurva VI dengan ANN

TMS	MAD	MSE	RMSE	MAPE
1,0	0,1060	0,0884	0,2974	1,3936
0,8	0,0840	0,0519	0,2277	1,3204
0,6	0,0632	0,0291	0,1706	1,3582
0,4	0,0423	0,0130	0,1139	1,3816
0,2	0,0209	0,0032	0,0568	1,3126
0,1	0,0105	0,0008	0,0285	1,3145

Yang terakhir adalah performansi untuk kurva karakteristik LTI, dimana bentuk kurva cenderung mempunyai karakteristik delay yang agak lama sehingga akan berpengaruh terhadap *error* performansi yang didapat yakni tidak begitu besar perbedaanya.



Gambar 3.25 Hasil Pemodelan Kurva LTI dengan ANN

Performansi *error* kurva LTI ditunjukkan pada Tabel 3.13 memberikan informasi kecenderungan *error* yang semakin kecil dengan nilai yang cukup signifikan saat TMS=0,1.

Tabel 3.13 Performansi Model Kurva LTI dengan ANN

TMS	MAD	MSE	RMSE	MAPE
1,0	0,940	6,987	2,643	1,371
0,8	0,743	4,096	2,024	1,275
0,6	0,563	2,306	1,518	1,355
0,4	0,375	1,025	1,012	1,351
0,2	0,188	0,256	0,506	1,371
0,1	0,094	0,064	0,253	1,371

Dari semua hasil performansi kurva yang telah dilakukan eksperimen maka dapat diberikan resume dari empat jenis kurva seperti ditunjukkan pada Tabel 3.14, kurva VI mempunyai nilai rerata RMSE yang paling kecil diantara empat jenis kurva, sedang nilai terbesar rerata RMSE adalah kurva karakteristik LTI. Demikian juga untuk MAD mempunyai pola yang sama dengan RMSE, nilai rerata MAD terkecil adalah VI dan terbesar adalah LTI. Secara grafik ditunjukkan pada Gambar 3.26 (a) dan 3.26 (b).

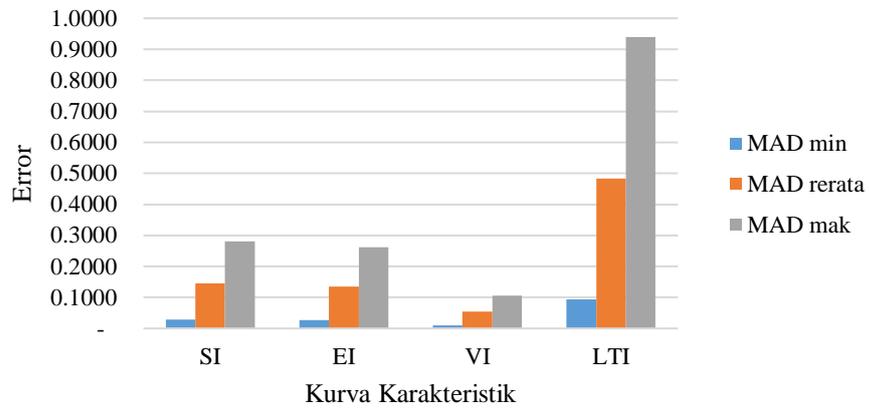
Tabel 3.14 Resume *Error* Hasil Pemodelan dengan ANN

Tipe	MAD min	MAD rerata	MAD mak	RMSE min	RMSE rerata	RMSE mak
SI	0,0280	0,1453	0,2815	0,1094	0,5734	1,1427
EI	0,0261	0,1341	0,2611	0,0771	0,4039	0,8051
VI	0,0105	0,0545	0,1060	0,0285	0,1491	0,2974
LTI	0,0940	0,4839	0,9402	0,2531	1,3262	2,6433

Sama dengan pemodelan menggunakan algoritma Lagrange, dimana kurva jenis VI mempunyai nilai *error* terkecil diantara empat jenis kurva lainnya, sedang kurva LTI mempunyai *error* terbesar, hal ini dipengaruhi dari bentuk kelandaian dari masing-masing jenis kurva.

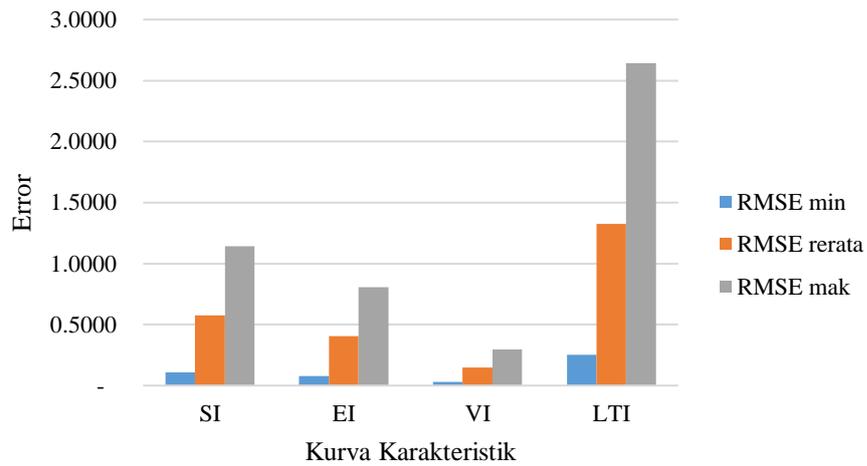
Pada saat digunakan sebagai model kurva karakteristik, model ANN menggantikan kurva yang sebelumnya menggunakan persamaan standar. Dengan masukan model adalah rasio I_I/I_S dan keluaran model berupa nilai waktu trip yang akan digunakan oleh *timer* untuk melakukan *on delay*, Gambar 3.27 ditunjukkan gambar posisi model pada rele digital.

Mean Absolute Deviation ANN Model



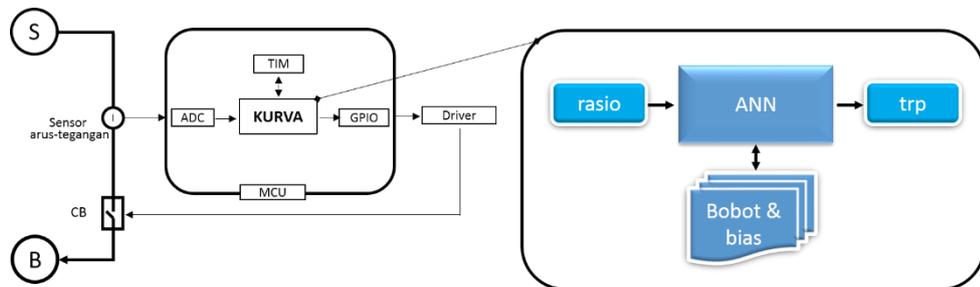
(a) Performansi RMSE Model dengan ANN

Root Mean Square ANN Model



(b) Performansi MAD

Gambar 3.26 Performansi RMSE dan MAD Model Kurva dengan ANN



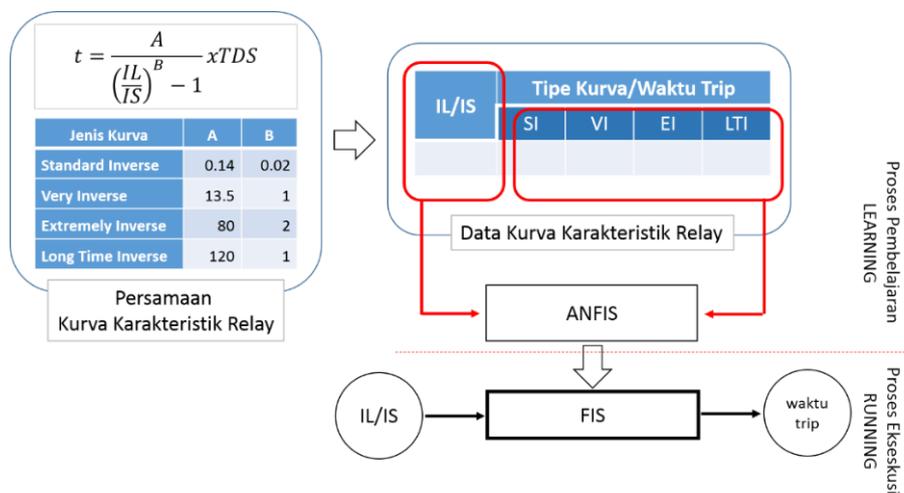
Gambar 3.27 Posisi Model ANN pada Rele Digital

3.6. Pemodelan Kurva Karakteristik *Digital Overcurrent Relay* Menggunakan ANFIS

Algoritma ketiga yang akan diujicoba memodelkan kurva karakteristik adalah algoritma *adaptive neuro fuzzy inference system* (ANFIS), data rasio IL/IS digunakan sebagai parameter masukan model dan data waktu trip dari keempat jenis kurva sebagai data target, keluaran dari algoritma ini adalah *fuzzy inference system* (FIS) dimana didalamnya telah berisi sejumlah fungsi keanggotaan atau *membership function* (MF) beserta *rule* yang telah terbentuk saat melakukan pembelajaran. FIS yang telah didapatkan akan menjadi model kurva karakteristik rele yang dikehendaki pada saat proses eksekusi atau *running*. Gambar 3.28 diberikan blok fungsi pemodelan kurva karakteristik saat proses pembelajaran dan proses *running* dengan menggunakan ANFIS.

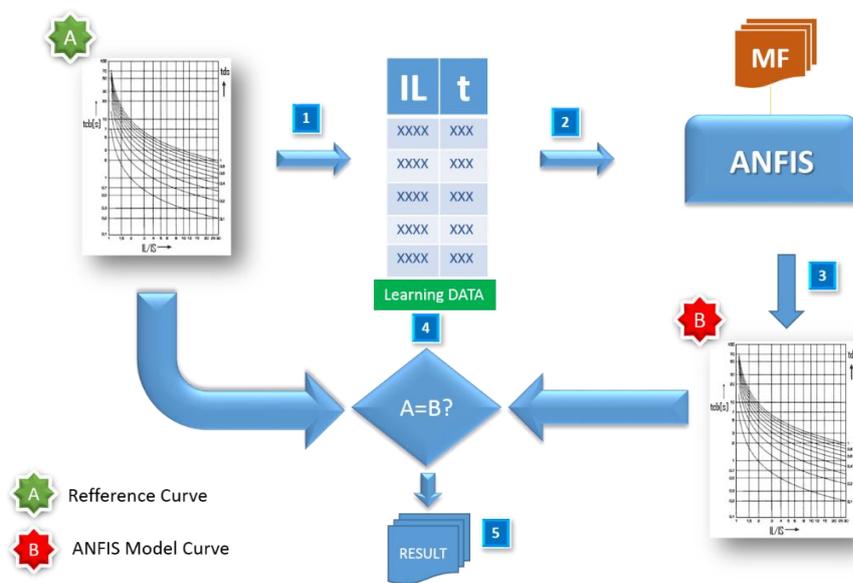
Saat proses pembelajaran ANFIS digunakan data yang sama dengan saat ujicoba algoritma lainnya yakni menggunakan data pada Tabel 3.1 sampai dengan Tabel 3.4, selanjutnya akan dilakukan pemodelan untuk masing-masing jenis kurva dan masing-masing nilai TMS.

Saat proses *running* model akan bekerja sebagai kendali logika *fuzzy* dengan fungsi keanggotaan dan *rule* dari hasil pembelajaran ANFIS. Perbedaan dengan kontrol logika *fuzzy* umum adalah tidak perlu merancang posisi fungsi keanggotaan dan menyusun *rule* serta tuning yang memakan waktu lebih lama, FIS yang dihasilkan dari ANFIS hanya membutuhkan data masukan dan data target untuk keperluan pembelajaran.



Gambar 3.28 Metode Pemodelan dengan ANFIS

Untuk keperluan pemodelan kurva proteksi rele digital digunakan *personal computer* sebagai pemroses utama dengan menggunakan algoritma ANFIS. Aplikasi perangkat lunak sudah dibuat dan telah digunakan untuk proses *learning* dan *running* dengan data-data dari kombinasi arus beban dan waktu trip dari persamaan standar. Gambar 3.29. Menunjukkan proses tahapan untuk melakukan pemodelan kurva dengan menggunakan *Levenberg-Marquardt Backpropagation* (LMBP).

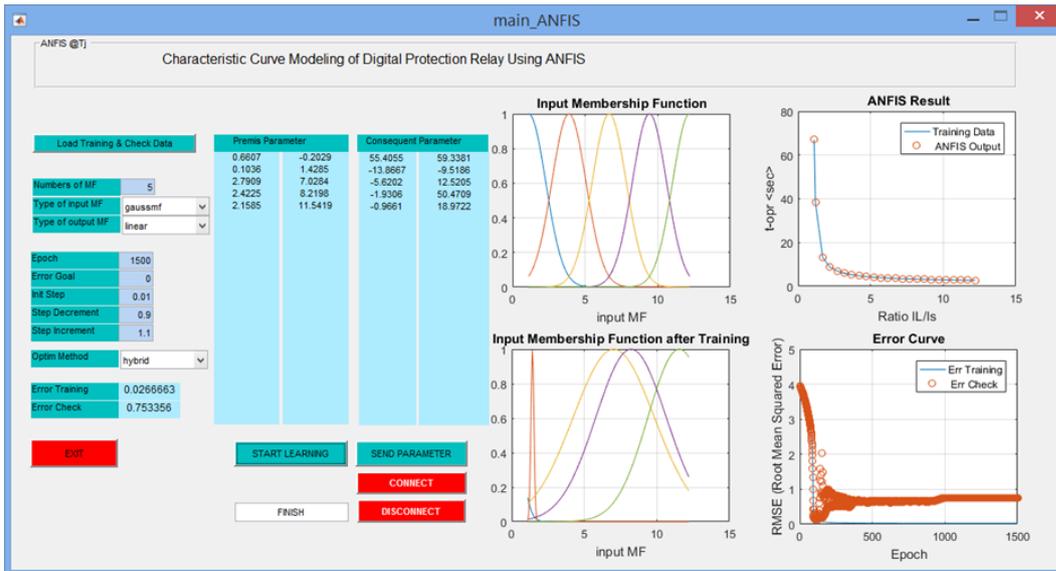


Gambar 3.29. Tahapan Pemodelan Kurva dengan ANFIS

Untuk melakukan ujicoba pemodelan menggunakan ANFIS, telah dikembangkan modul aplikasi GUI berbasis Matlab dengan tampilan seperti pada Gambar 3.30. Sehingga pengguna dengan leluasa dapat melakukan seting parameter pembelajaran dan melihat hasilnya.

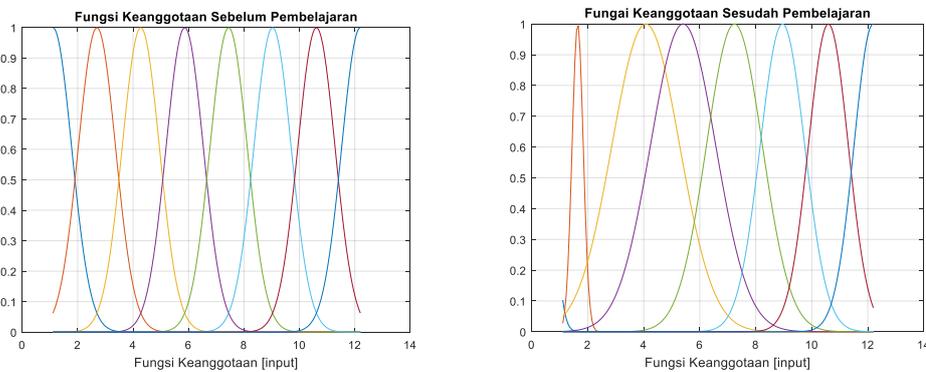
Tampilan di GUI dilengkapi dengan seting jumlah MF dan *epoch* yang diinginkan, jenis fungsi keanggotaan yang akan digunakan baik disisi *input* maupun disisi *output*, juga parameter yang dibutuhkan saat pembelajaran serta metode untuk optimisasi yang digunakan.

Ditampilkan gambar grafik untuk fungsi keanggotaan saat sebelum pembelajaran dan setelah pembelajaran juga ditampilkan, grafik hasil pemodelan dan *error* kurva, tampilan berupa nilai *error* diberikan dalam text box.



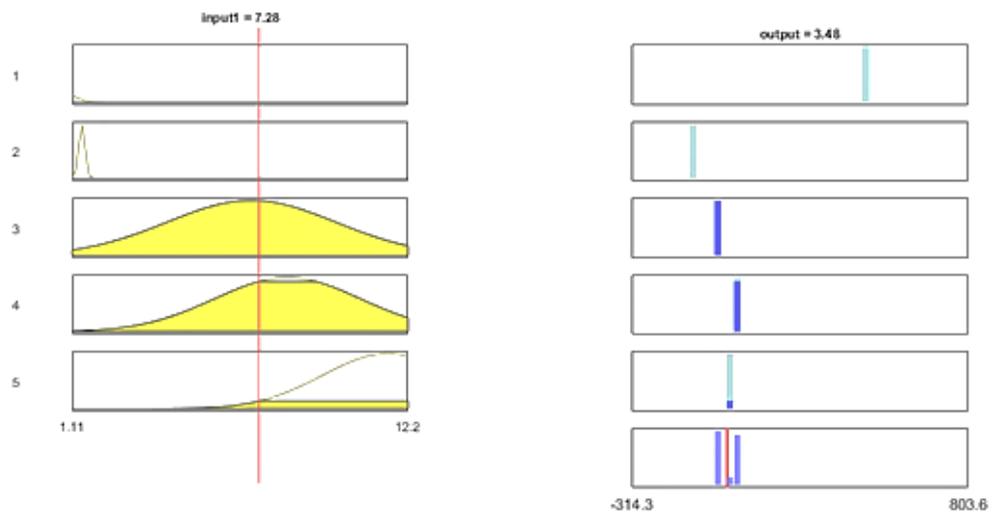
Gambar 3.30 Tampilan GUI untuk Ujicoba Pemodelan dengan ANFIS

Setelah melakukan seting parameter dan memilih file *input* dan target kemudian dijalankan akan didapat bentuk fungsi keanggotaan logika *fuzzy* sebelum dan setelah pembelajaran, seperti ditunjukkan pada Gambar 3.31.



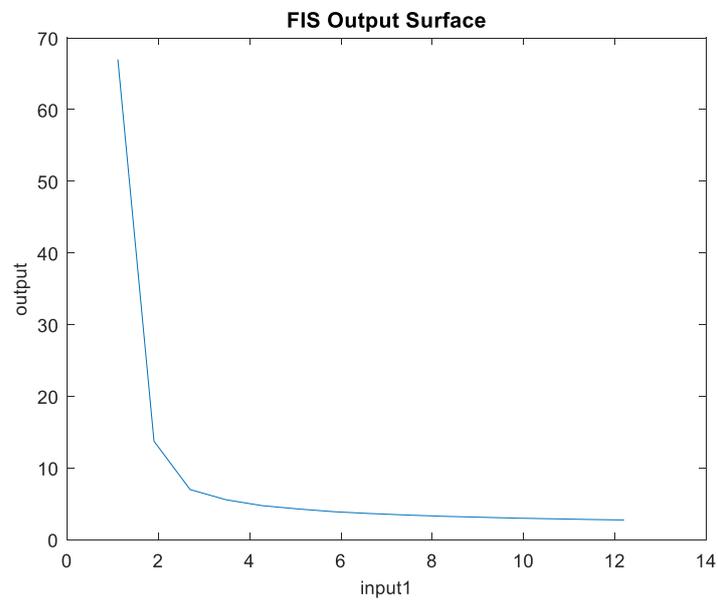
Gambar 3.31 Fungsi Keanggotaan Sebelum dan Setelah Pembelajaran

Setelah melakukan pembelajaran dilakukan observasi menggunakan *rule viewer*, dimana bisa diketahui fungsi kerja dari *rule* berdasar fungsi keanggotaan dari sisi masukan dan keluaran, seperti ditunjukkan pada Gambar 3.32.



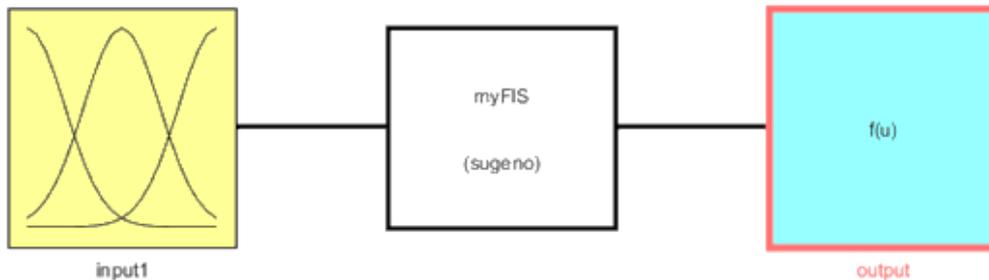
Gambar 3.32 Tampilan Rule Viewer

Bentuk *fuzzy inference system* (FIS) yang dihasilkan dapat diobservasi dengan FIS *output surface*, karena kasus yang sedang diuji coba hanya mempunyai satu *input* dan satu *output* sehingga menghasilkan *surface* satu dimensi seperti ditunjukkan pada Gambar 3.33.



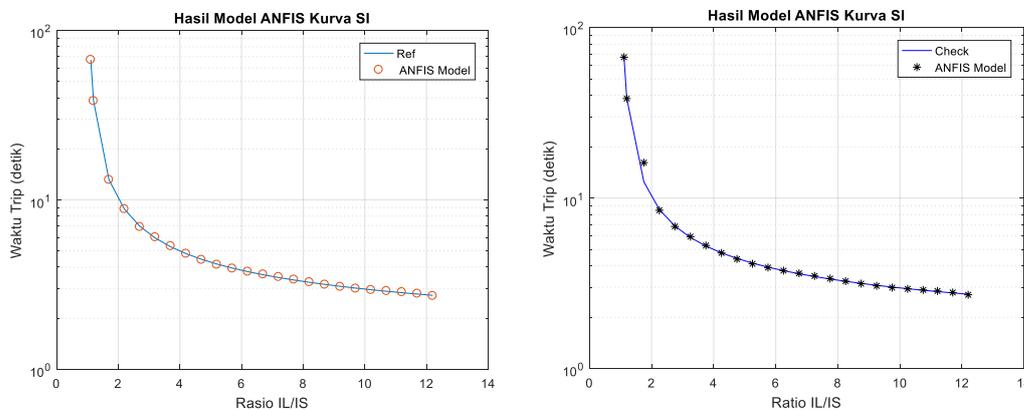
Gambar 3.33 Tampilan *Surface* dari *Fuzzy Inference System*

Sebagai hasil akhir berupa FIS yang siap digunakan untuk operasi rele digital yang dapat menggantikan persamaan standar, seperti ditunjukkan pada Gambar 3.34.



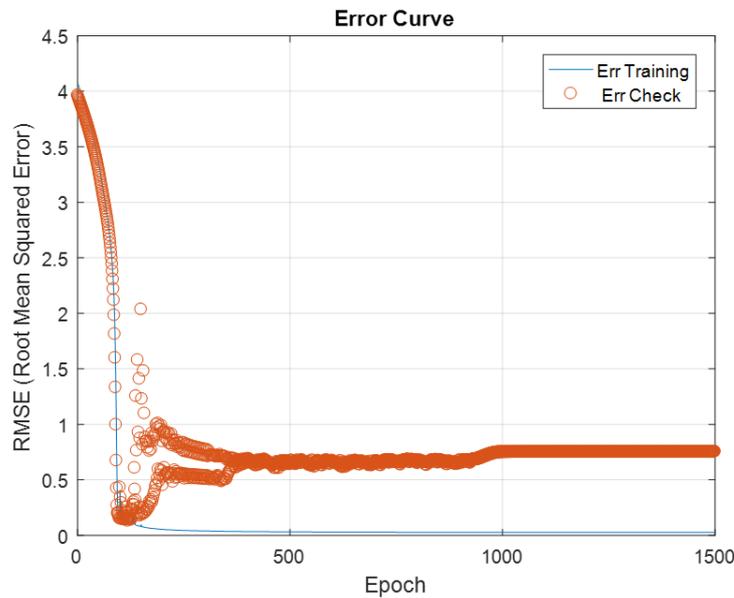
Gambar 3.34. FIS sebagai Model Kurva Menggunakan ANFIS

Untuk melihat hasil pemodelan kurva karakteristik dari proses pembelajaran dan proses *check* dapat diketahui dari grafik yang dirancang seperti pada Gambar 3.35.



Gambar 3.35 Bentuk Kurva Hasil Pembelajaran dan *Check*

Untuk melihat *error* dalam bentuk RMSE saat pembelajaran dan saat *check* dapat ditampilkan secara grafis seperti ditunjukkan pada Gambar 3.36. Juga ditampilkan nilai RMSE yang dihasilkan pada GUI saat pelatihan dan saat *check* dalam bentuk text box dengan label *error training* dan *error check*, dengan harapan para pengguna bisa melakukan *tuning* sesuai dengan performansi yang diinginkan.



Gambar 3.36 Grafik *Error* RMSE saat Pelatihan dan *Check*

3.7. Performansi Model Menggunakan ANFIS

Untuk melakukan pemodelan kurva dengan menggunakan ANFIS digunakan data-data pada Tabel 3.1 sampai dengan Tabel 3.4 sama seperti yang digunakan saat melakukan pemodelan menggunakan Lagrange dan ANN, dengan penambahan data *check* seperti ditunjukkan pada Tabel 3.15 kolom data rasio [*check*].

Sehingga terdapat dua grup data, menggunakan kolom rasio [*ref*] dan *trp* [*persamaan*] untuk pembelajaran dan rasio [*check*] untuk melakukan test hasil model, dimana hasilnya akan nampak pada kolom *trp* model ANFIS.

Seting saat melakukan ujicoba pemodelan digunakan fungsi keanggotaan Gaussian untuk sisi *input* dan linier untuk sisi *output*, dengan optimisasi mode *hybrid*, *epoch* 1500, *error goal*=0, *init step*=0,01, *step decrement*=0,9 serta *step increment*=1,1, data yang digunakan sebanyak 24 buah.

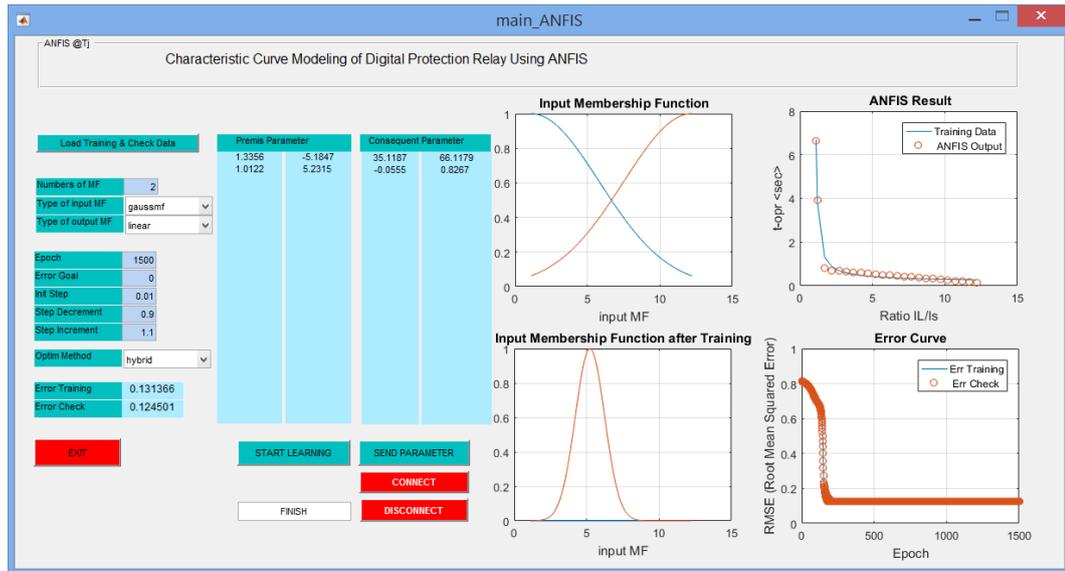
Selanjutnya akan dilakukan ujicoba pemodelan dengan satu jenis kurva dengan perubahan jumlah fungsi keanggotaan, untuk dilakukan observasi dampak dari perubahan fungsi keanggotaan, sehingga bisa digunakan untuk referensi penentuan jumlah fungsi keanggotaan yang sesuai.

Tabel 3.15 Data untuk Pembelajaran dan *Check*

Rasio [ref]	Trp [persamaan]	Rasio [<i>check</i>]	Trp [persamaan]	Trp model ANFIS
1,11	67,01	1,11	67,01	67,0055
1,2	38,32	1,2	38,32	38,3237
1,7	13,12	1,75	12,44	12,7237
2,2	8,81	2,25	8,56	8,3825
2,7	6,98	2,75	6,85	6,9702
3,2	5,95	3,25	5,87	5,7526
3,7	5,28	3,75	5,23	5,3157
4,2	4,81	4,25	4,77	4,7037
4,7	4,45	4,75	4,42	4,4511
5,2	4,18	5,25	4,15	4,1521
5,7	3,95	5,75	3,93	3,9125
6,2	3,77	6,25	3,75	3,7756
6,7	3,61	6,75	3,60	3,5702
7,2	3,48	7,25	3,46	3,4799
7,7	3,36	7,75	3,35	3,3440
8,2	3,26	8,25	3,25	3,2424
8,7	3,17	8,75	3,16	3,1695
9,2	3,08	9,25	3,08	3,0609
9,7	3,01	9,75	3,00	3,0173
10,2	2,94	10,25	2,94	2,9303
10,7	2,88	10,75	2,88	2,8794
11,2	2,83	11,21	2,83	2,8278
11,7	2,78	11,701	2,78	2,7763
12,2	2,73	12,2	2,73	2,7290

Ujicoba awal dilakukan dengan menggunakan data kurva SI dengan TMS=1,0, untuk jumlah fungsi keanggotaan atau *membership function* (MF) dimulai dengan MF=2 pada sisi *input*, fungsi aktivasi menggunakan gaussian, dan fungsi aktivasi linier untuk fungsi keanggotaan *output*. Dengan menggunakan aplikasi GUI yang telah dirancang didapatkan hasil seperti pada Gambar 3.37.

Dengan memilih dua fungsi keanggotaan, terlihat sebelum dan sesudah pembelajaran terjadi pergeseran dengan nilai-nilai tertera pada tabel tampilan GUI, serta nampak hasil kurva pemodelan dan *error* kurva, nilai *error* saat pembelajaran menghasilkan 0,131366 dan saat *check* model 0,124501.



Gambar 3.37 Tampilan GUI Hasil Pemodelan dengan MF=2

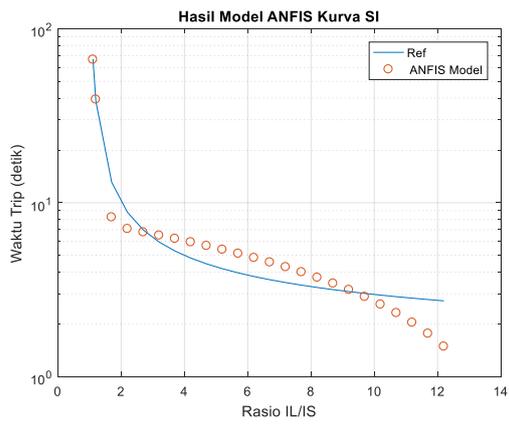
Untuk melakukan observasi hasil pemodelan dengan perubahan MF maka telah dicoba dengan merubah mulai MF=2 hingga MF=8, dihasilkan bentuk kurva pemodelan dibanding dengan referensi ditunjukkan pada Gambar 3.38.

Hasil pemodelan dengan MF=2 terdapat beberapa data pemodelan yang sama dengan referensi dengan *error* RMSE=1,314 saat pembelajaran dan RMSE=1,245 pada saat *check*. Dengan meningkatkan jumlah MF=3 terdapat delapan data model yang sama dengan data referensi dengan *error* RMSE=0,200 saat pembelajaran dan RMSE=0,267 saat *check* model.

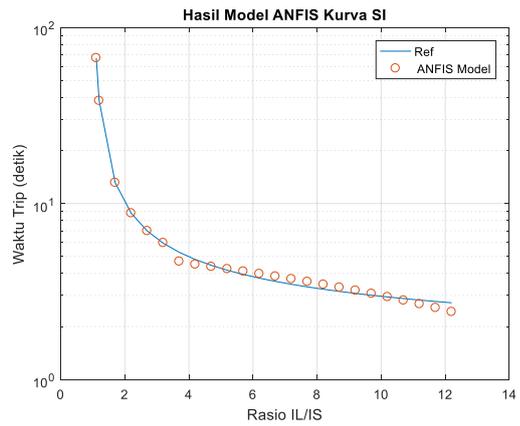
Pada MF=4 terlihat banyak data model yang mendekati data referensi dimana menghasilkan *error* RMSE=0,074 saat pembelajaran. Semakin meningkat jumlah MF maka akan menurun *error* yang dihasilkan, seperti ditunjukkan pada Tabel 3.16. Pada Gambar 3.39 ditunjukkan kurva hasil pemodelan dengan MF=8, menunjukkan hasil yang sangat baik dengan RMSE=0,012 saat pembelajaran dan *rmse*=0,218 saat *check* data.

Tabel 3.16 RMSE hasil Pemodelan dengan MF berbeda

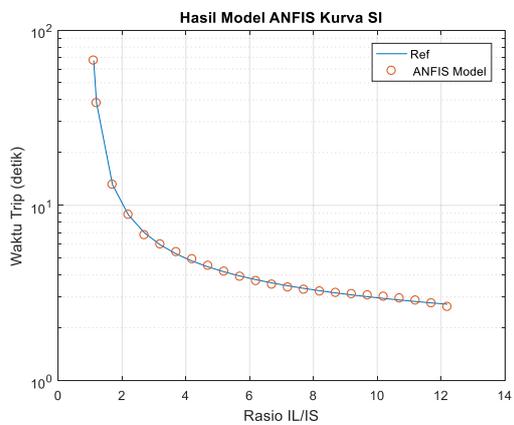
MF	2	3	4	5	6	7	8
<i>err train</i>	1,314	0,200	0,074	0,027	0,025	0,018	0,012
<i>err check</i>	1,245	0,267	0,803	0,753	0,286	0,244	0,218



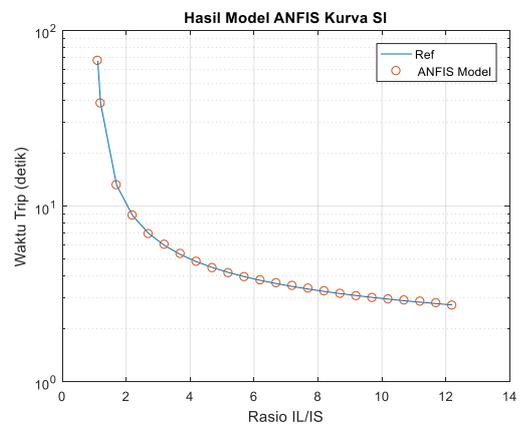
(a) MF=2



(b) MF=3

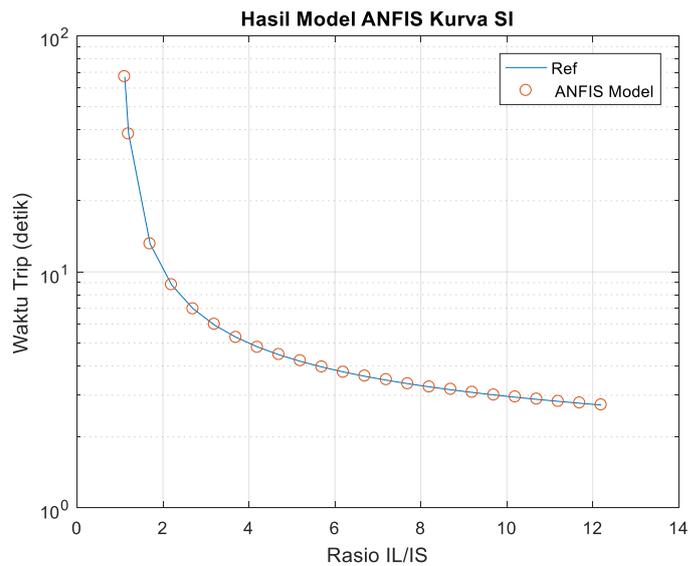


(c) MF=4



(d) MF=5

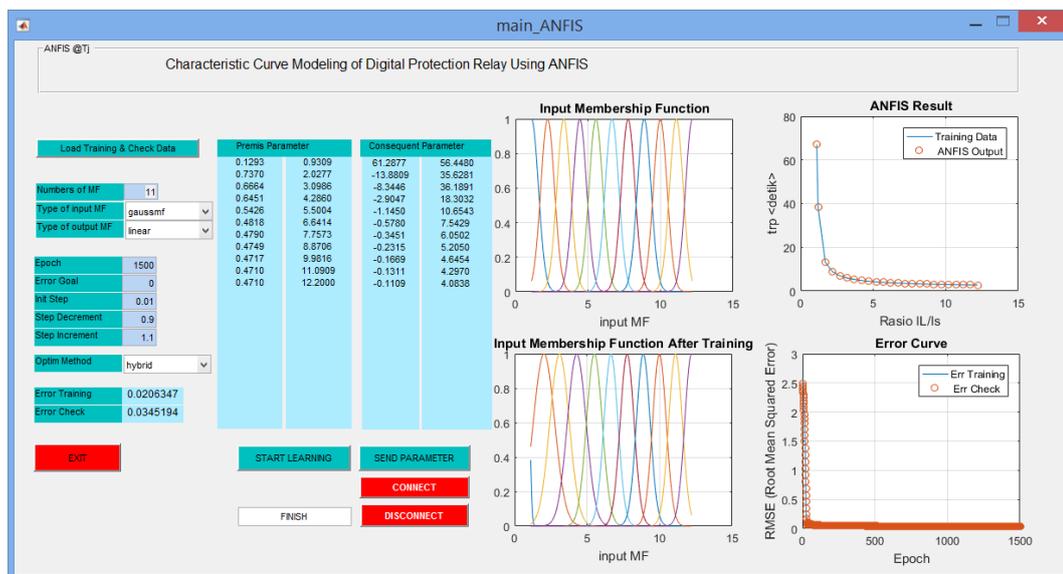
Gambar 3.38 Hasil Pemodelan dengan MF yang berbeda



Gambar 3.39 Kurva Hasil Pemodelan dengan MF=8

Selanjutnya akan diberikan hasil pemodelan dengan ANFIS untuk kurva karakteristik SI, EI, VI dan LTI dengan berbagai TMS. Pada Gambar 3.40 ditunjukkan tampilan GUI yang merupakan hasil akhir pemodelan kurva SI dengan TMS=1 dengan seting parameter sebagai berikut:

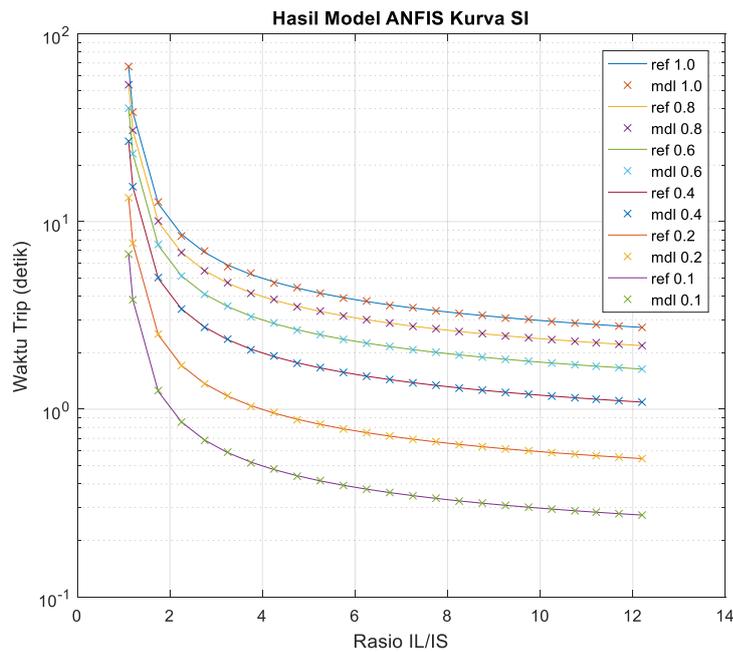
- Jumlah data pembelajaran=24, data *check*=24
- Jumlah MF=11
- *Input* MF=Gaussian
- *Output* MF=linier
- *Epoch*=1500
- *Error goal*=0
- *Optimum mode*=*hybrid*



Gambar 3.40 Tampilan Akhir GUI ANFIS Kurva SI dengan TMS=1

Pada Gambar 3.41 ditunjukkan hasil akhir dari pemodelan kurva SI dengan beberapa TMS, tanda 'x' adalah hasil model dengan ANFIS dan '-' adalah data referensi atau target. Setiap kurva mempunyai warna yang berbeda untuk membedakan nilai TMS yang diujicoba.

Tabel 3.17 adalah hasil performansi model kurva SI, dapat disimpulkan bahwa pemodelan dengan ANFIS telah memenuhi syarat untuk dijadikan model kurva karakteristik rele digital dengan RMSE terbesar adalah 0,085.



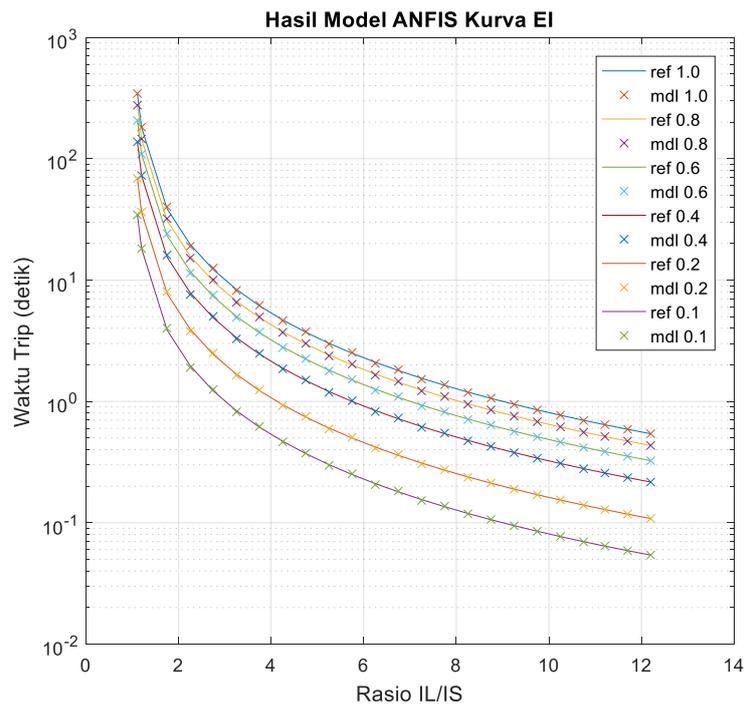
Gambar 3.41 Hasil Pemodelan Kurva SI dengan ANFIS

Tabel 3.17 Performansi Pemodelan Kurva SI dengan ANFIS

TMS	MAD	MSE	RMSE	MAPE
1,0	0,043	0,00715	0,085	0,675
0,8	0,014	0,00076	0,028	0,280
0,6	0,010	0,00043	0,021	0,280
0,4	0,007	0,00019	0,014	0,280
0,2	0,003	0,00005	0,007	0,280
0,1	0,002	0,00001	0,003	0,280

Gambar 3.42 adalah hasil akhir dari pemodelan kurva EI dengan beberapa nilai TMS, garis lurus adalah data target yang akan dicapai dan tanda silang adalah hasil pemodelan dengan warna grafik menunjukkan nilai TMS. Bentuk kurva yang berbeda dengan kurva SI sehingga berbeda pula untuk performansi yang dihasilkan.

Tabel performansi diberikan pada Tabel 3.18, TMS semakin kecil menghasilkan *error* yang cenderung kecil, nilai RMSE paling kecil adalah 0,033 dan paling besar RMSE=0,340 pada TMS=1,0. dengan demikian masih dimungkinkan untuk melakukan peningkatan jumlah MF untuk mendapatkan nilai *error* yang semakin kecil.



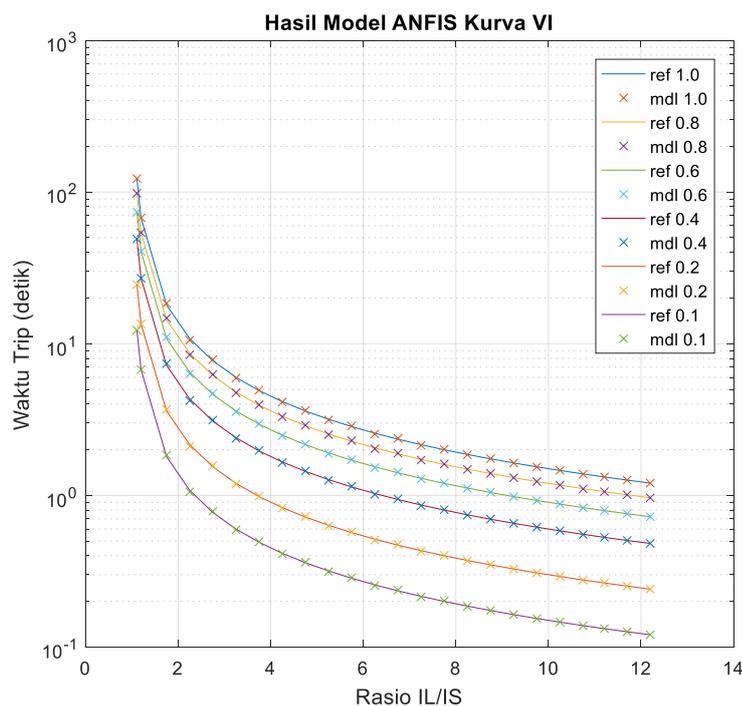
Gambar 3.42 Hasil Pemodelan Kurva EI dengan ANFIS

Tabel 3.18 Performansi Pemodelan Kurva EI dengan ANFIS

TMS	MAD	MSE	RMSE	MAPE
1,0	0,127	0,115	0,340	1,186
0,8	0,101	0,068	0,260	1,184
0,6	0,076	0,038	0,196	1,182
0,4	0,051	0,017	0,130	1,184
0,2	0,025	0,004	0,065	1,184
0,1	0,013	0,001	0,033	1,184

Untuk pemodelan kurva karakteristik VI ditunjukkan pada Gambar 3.43, mempunyai karakteristik kurva yang mirip dengan EI namun tidak terlalu tajam lengkung kurvanya. Titik kurva data target diberikan tanda minus dan data-data hasil model ANFIS diberi tanda silang, nilai TMS yang berbeda ditunjukkan dengan warna yang berbeda.

Hasil performansi pemodelan kurva karakteristik VI diberikan pada Tabel 3.19, dengan nilai RMSE terbesar 0,120 pada TMS=1,0 dan nilai RMSE terkecil 0,011 yang masih memenuhi untuk model kurva karakteristik kurva rele digital.



Gambar 3.43 Hasil Pemodelan Kurva VI dengan ANFIS

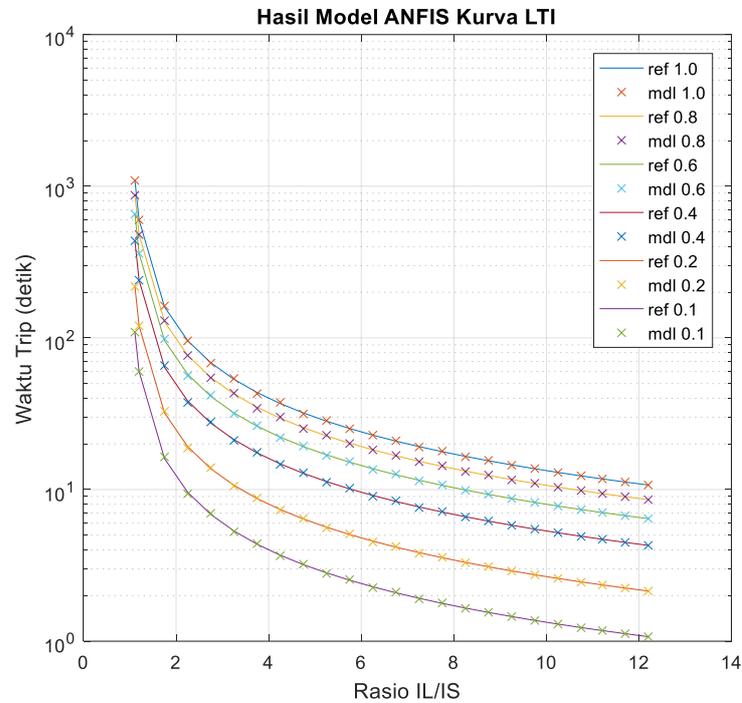
Tabel 3.19 Performansi Pemodelan Kurva VI dengan ANFIS

TMS	MAD	MSE	RMSE	MAPE
1,0	0,050	0,0143	0,120	0,7402
0,8	0,040	0,0084	0,092	0,7403
0,6	0,030	0,0047	0,069	0,7403
0,4	0,020	0,0021	0,046	0,7403
0,2	0,010	0,0005	0,023	0,7403
0,1	0,005	0,0001	0,011	0,7403

Gambar 3.44 adalah hasil akhir pemodelan kurva karakteristik LTI, bentuk kurva cenderung mempunyai nilai trip yang lebih lama dibanding dengan jenis kurva yang lainnya. Tanda minus merupakan data-data referensi atau target sedang tanda silang adalah data-data hasil pemodelan dengan warna yang berbeda untuk nilai TMS yang berbeda.

Performansi hasil model kurva LTI diberikan pada Tabel 3.20, dengan nilai RMSE terkecil 0,102 untuk TMS=0,1 dan nilai RMSE terbesar 0,612 untuk

TMS=1,0. secara keseluruhan untuk model kurva karakteristik rele digital masih dapat diterima.



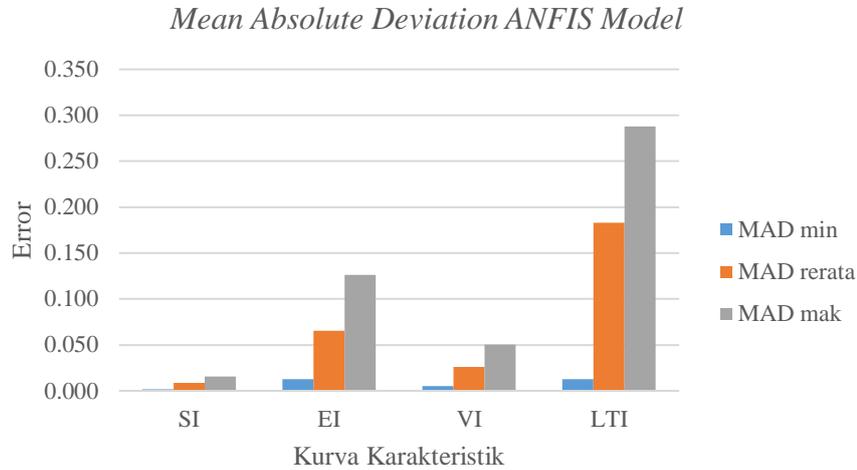
Gambar 3.44 Hasil Pemodelan Kurva LTI dengan ANFIS

Tabel 3.20 Performansi Pemodelan Kurva SI dengan ANFIS

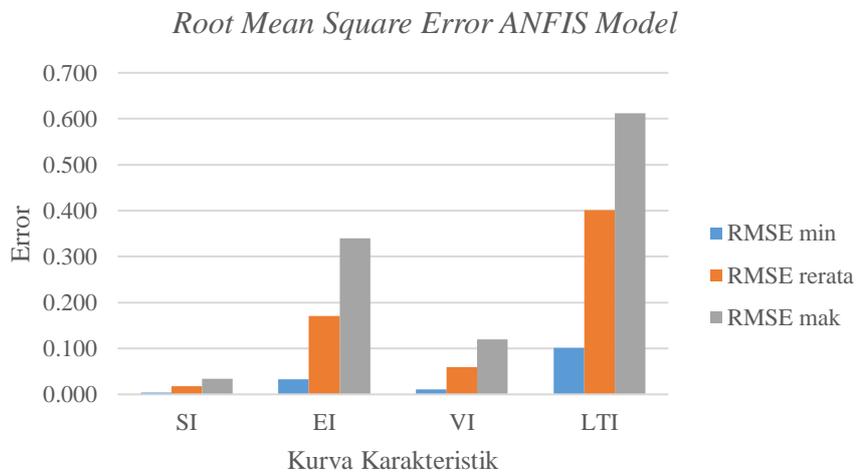
TMS	MAD	MSE	RMSE	MAPE
1,0	0,288	0,374	0,612	0,616
0,8	0,230	0,220	0,469	0,616
0,6	0,267	0,374	0,611	0,740
0,4	0,178	0,166	0,407	0,741
0,2	0,089	0,041	0,203	0,741
0,1	0,045	0,010	0,102	0,741

Evaluasi secara keseluruhan untuk pemodelan kurva karakteristik dengan algoritma ANFIS dilihat dari sisi MAD dan RMSE ditunjukkan pada Gambar 3.45 dan Gambar 3.46. dimana nilai MAD terkecil adalah kurva karakteristik jenis SI dan nilai MAD terbesar adalah jenis kurva karakteristik LTI. Demikian juga untuk nilai RMSE, nilai terkecil adalah kurva karakteristik SI dan terbesar adalah LTI. Secara keseluruhan dengan nilai *error* tersebut dapat diterima sebagai model kurva

untuk digunakan pada rele digital, syarat untuk nilai trip pada rele digital adalah satu digit dibelakang koma dengan satuan dalam orde detik.



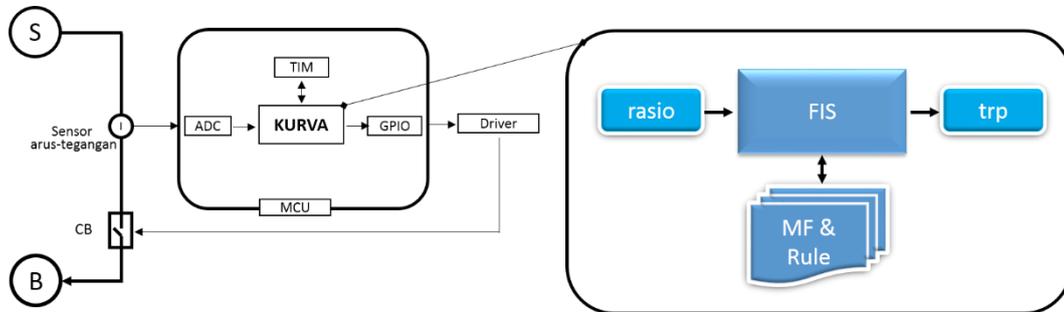
Gambar 3.45 Performansi MAD Pemodelan Kurva dengan ANFIS



Gambar 3.46 Performansi RMSE Pemodelan Kurva dengan ANFIS

Pada Gambar 3.47 ditunjukkan posisi model kurva karakteristik yang dihasilkan dengan algoritma ANFIS pada rele digital sebenarnya. Yang digunakan adalah model *fuzzy inference system* (FIS) yang dihasilkan selama proses pembelajaran dengan ANFIS, dengan basis kontrol logika *fuzzy* model akan bekerja membaca nilai rasio saat itu untuk mendapatkan nilai waktu trip yang selanjutnya

menjadi masukan dari *timer* yang digunakan didalam rele digital. Setelah mencapai nilai *overflow timer* maka *circuit breaker* akan trip melalui GPIO.



Gambar 3.47 Posisi Model ANFIS pada Rele Digital

Tinjauan dari sisi model yang nantinya akan ditanam didalam rele digital saat eksekusi atau menjalankan model, ketiga jenis algoritma akan mempunyai karakteristik masing-masing sebagai berikut:

- Algoritma Lagrange memerlukan waktu eksekusi panjang karena harus menggunakan semua pasangan data kurva untuk mendapatkan satu titik data model, selain program perlu menyimpan data pasangan kurva didalam memori, sehingga memerlukan memori yang cukup banyak.
- Algoritma ANN memerlukan waktu yang cepat karena model berbentuk persamaan dan hanya memerlukan data bobot dan bias yang didapat saat pembelajaran, satu model bisa mewakili empat jenis model kurva karakteristik mengingat sifat ANN yang bisa multi *input* dan multi *output*.
- Algoritma ANFIS yang dikembangkan hanya bisa satu *output*, artinya satu jenis model memerlukan satu FIS.

Mengingat masing-masing algoritma mempunyai kelebihan dan kekurangan, maka keputusan akhir adalah kembali pada tujuan awal yakni membangun *digital protection relay* dengan menggunakan mikorokntroller sebagai unit utama pemroses dan penentu keputusan, dimana operasi kerja rele berbentuk program

yang harus disimpan pada unit memori mikrokontroller dan dibutuhkan kecepatan eksekusi yang cepat.

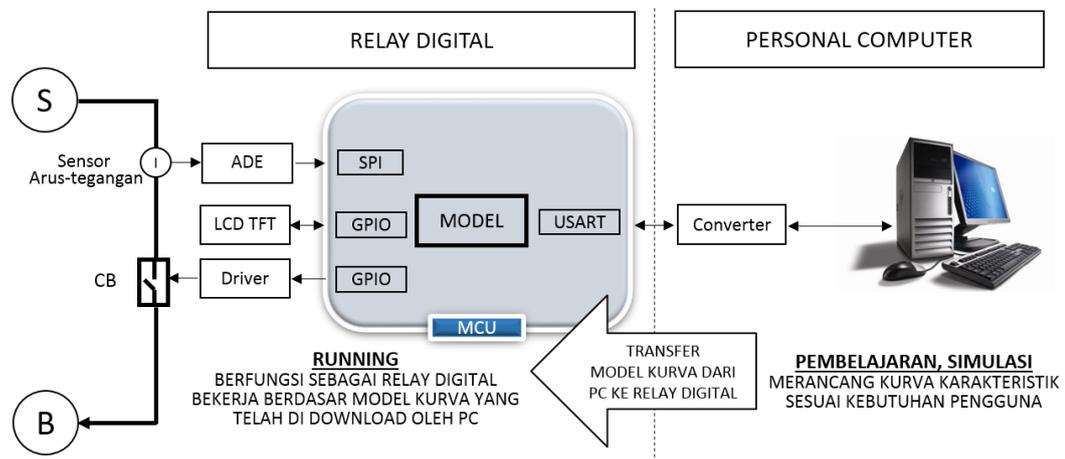
Dengan mempertimbangkan evaluasi tersebut maka dipilih algoritma ANN untuk implementasi *user-defined curve* pada uji coba selanjutnya, dengan harapan sedikit memori yang diperlukan sehingga bisa mencapai kecepatan yang maksimum.

BAB IV

DIRECTIONAL DIGITAL PROTECTION RELAY DENGAN FITUR USER-DEFINED CHARACTERISTIC CURVE

4.1. Metode Pemodelan Kurva Karakteristik *Digital Overcurrent Relay* Non-standar

Kurva karakteristik yang tidak sesuai dengan standar persamaan atau disebut dengan *unconventional curve* diperlukan pada saat-saat tertentu, misal pada saat integrasi perencanaan sistem proteksi dilapangan dimana diperlukan bentuk kurva khusus atau saat dilakukan penggabungan dengan beberapa rele ternyata ditemukan adanya interseksi antar kurva, hal ini akan mempengaruhi sistem proteksi secara keseluruhan dalam suatu jaringan distribusi. Maka pengguna harus merancang atau merubah bentuk kurva karakteristik yang ada saat itu, hal ini yang menjadi kontribusi dan keterbaruan dari penelitian ini.



Gambar 4.1. Metode Pemodelan *User-defined Characteristic Curve*

Gambar 4.1. diberikan ilustrasi bagaimana mengembangkan rele digital dimana kurva karakteristik ditentukan oleh *user* secara mandiri. Pada sisi *personal computer* pihak *user* melakukan perancangan kurva dengan modul aplikasi yang

telah dibuat, *user* dapat melakukan pemilihan jenis kurva standar sebagai referensi, kemudian melakukan perencanaan kurva secara mandiri dengan bantuan ANN akan dihasilkan model kurva yang telah dirancang.

Setelah mendapat model yang sesuai dengan yang dikehendaki, selanjutnya model ditransfer ke perangkat rele digital. Karena model telah terbenam didalam rele maka pada saat running, rele digital akan menjadi *intelligent electronic device (IED)* yang berfungsi sebagai rele digital dengan kurva karakteristik diprogram oleh *user*.

Dengan keberhasilan *user-defined curve* maka telah terbuka jalan untuk mengembangkan pada riset selanjutnya yakni rele yang bersifat adaptif, dimana dalam satu rele tersimpan beberapa model yang siap digunakan secara terkontrol sesuai dengan kebutuhan saat itu, hal ini sangat diperlukan pada sistem jaringan distribusi yang bersifat aktif, dimana sumber energi listrik bersifat *intermittent*. Sehingga dapat memenuhi kebutuhan sistem jaringan dengan jumlah rele yang banyak dimana membutuhkan koordinasi secara adaptif pada setiap rele yang ada.

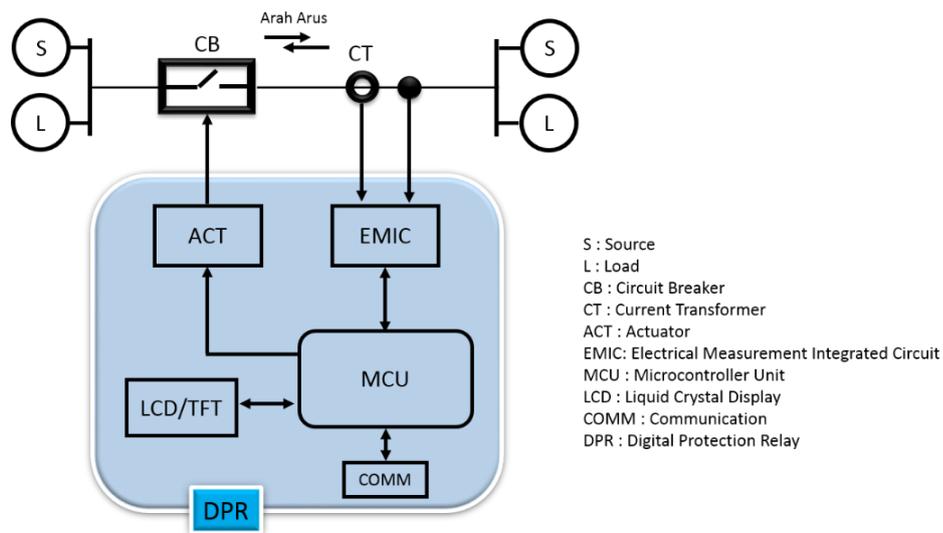
4.2. Pemodelan *User-defined Characteristic Curve*

Rele digital yang telah dibuat sebagai prototype *digital protection relay (DPR)* dikembangkan sesuai dengan fungsional blok diagram pada Gambar 4.2, dengan basis *microcontroller* keluarga ARM STM32F7 serta dengan bantuan chip ADE 7080 sebagai *electrical measurement integrated circuit (EMIC)* melalui *serial parallel interface (SPI)* saat berkomunikasi dengan *microcontroller*.

Perangkat EMIC bertugas membaca arus dan tegangan sehingga mampu mengenali arah aliran daya, pembacaan data arus digunakan *current transformer (CT)* dengan perbandingan 2000:1, serta data tegangan dengan bantuan pembagi tegangan menggunakan resistor, didalam EMIC telah dilengkapi dengan filter sebelum dikonversi oleh ADC yang menyatu dalam satu chip tersebut. Untuk memproses sinyal-sinyal arus dan tegangan hingga menjadi nilai siap diproses oleh unit *microcontroller* didalam EMIC digunakan *digital signal processor (DSP)*.

DPR dilengkapi dengan perangkat komunikasi serial *communication device (COMM)* RS-232C yang digunakan untuk menerima model yang telah dirancang dari sisi *personal computer*. Dengan menggunakan model yang telah ditanam di

microcontroller unit (MCU) maka kerja DPR akan sesuai dengan kurva didalam model, untuk melakukan aksi pemutusan arus digunakan *actuator* (ACT) berupa rele daya rendah yang terhubung dengan *parallel port* yang merupakan bagian dari *general purpose input output* (GPIO), rele daya rendah tersebut akan menggerakkan *circuit breaker* (CB). Sebagai sarana *user interface* digunakan LCD *touch screen*.

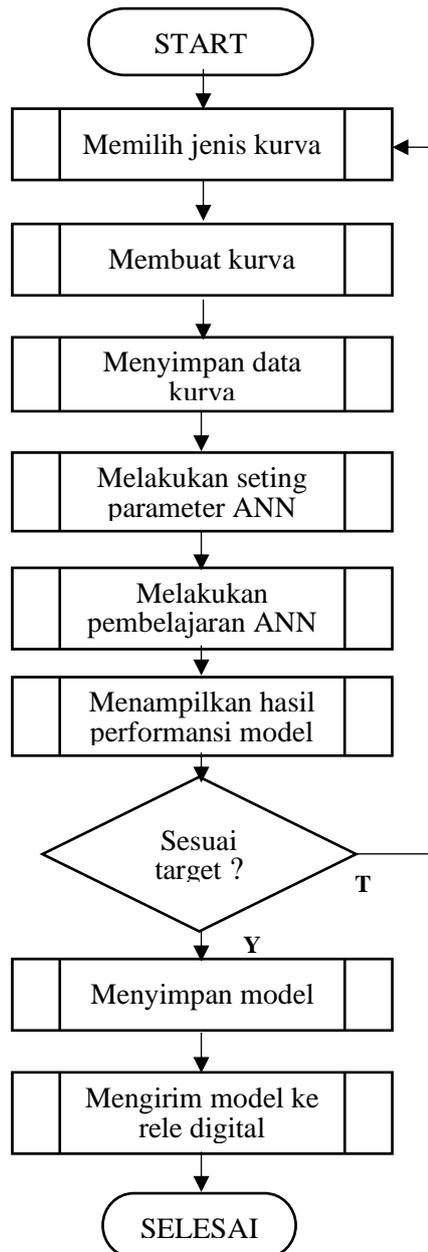


Gambar 4.2. *Digital Protection Relay* Berbasis *Microcontroller Unit* (MCU)

Untuk merencanakan DPR secara lengkap termasuk perangkat lunak disisi komputer dan di sisi *microcontroller*, perlu disusun secara utuh *flowchart* urutan operasi kerja secara sistem seperti ditunjukkan pada Gambar 4.3. Perangkat lunak pada sisi komputer berupa aplikasi untuk merancang kurva, pembelajaran ANN hingga menghasilkan model dan pengiriman model ke DPR. Sedang pada sisi *microcontroller* perlu disusun perangkat lunak untuk menerima model, menjalankan fungsi sebagai DPR saat dihubungkan dengan jaringan distribusi.

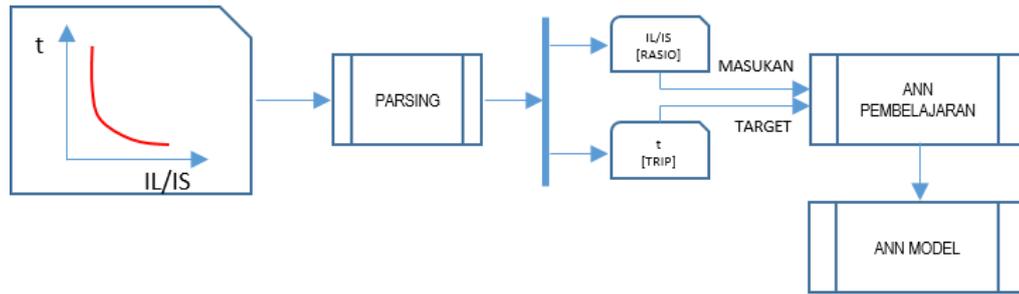
Sesuai Gambar 4.3 *user* akan melakukan perencanaan kurva dengan menentukan titik-titik kurva, dari titik-titik kurva tersebut akan dilakukan pembelajaran menggunakan ANN hingga didapatkan model yang sesuai dengan *user*. Selanjutnya kurva yang telah menjadi model dikirim ke DPR.

Pada sisi DPR yang merupakan IED yang berfungsi sebagai perangkat proteksi akan bekerja sesuai dengan kurva karakteristik berupa model yang telah ditanam didalam MCU. Jika didalam DPR ditanam beberapa model yang telah dihasilkan selama perencanaan maka diperlukan perangkat komunikasi untuk memilih model yang sesuai saat itu, dimana pemilihan bisa dikendalikan oleh *master control* atau sesama rele pada pengembangan riset selanjutnya.



Gambar 4.3. Flowchart Sistem User-defined Characteristic Curve

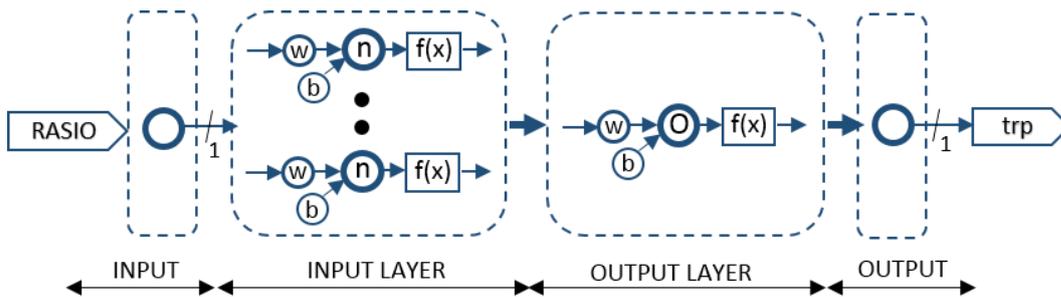
Kurva yang telah direncanakan oleh *user* selanjutnya dilakukan pemisahan atau *parsing*, sehingga menjadi dua grup data yakni data rasio I_L/I_S serta data *trip*. Data rasio sebagai data masukan dan data *trip* sebagai data target untuk pembelajaran ANN yang akan menghasilkan model seperti ditunjukkan pada Gambar 4.4.



Gambar 4.4. Proses Pemisahan Data Pembelajaran dan Pemodelan

Untuk pemodelan kurva dipilih ANN *multi-layer perceptron* sebanyak dua layer, *input layer* dan *output layer* seperti ditunjukkan pada Gambar 4.5, n adalah jumlah *neuron* pada *input layer* sedangkan O adalah jumlah *neuron* pada *output layer*. Penentuan jumlah *neuron* didasarkan atas hasil evaluasi dari beberapa ujicoba, sedangkan konfigurasi ANN yang digunakan dengan rincian sebagai berikut:

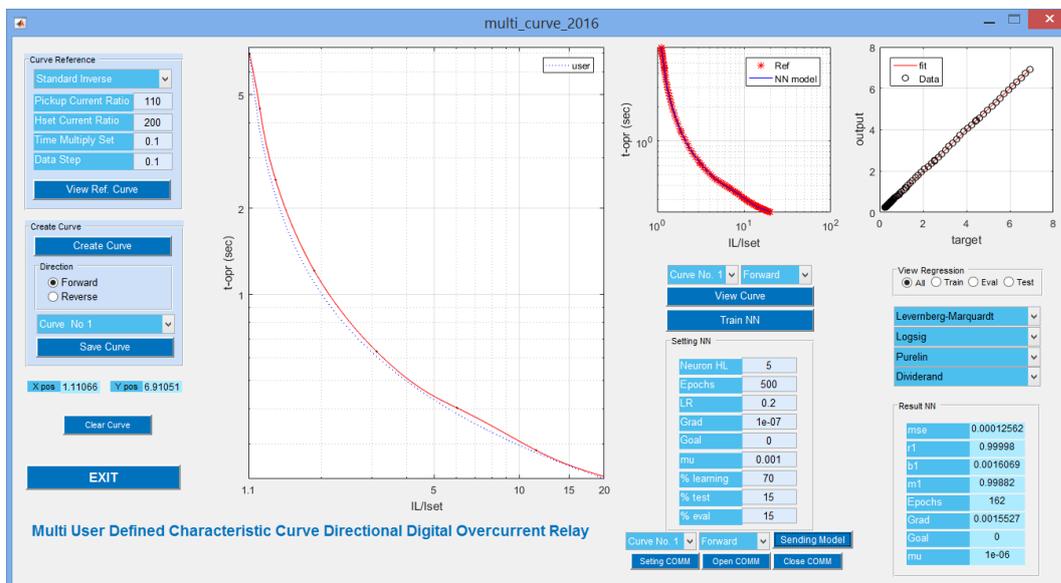
<i>Neuron</i>	<i>input layer=5, Output layer=1</i>
<i>Type NN</i>	<i>Feedforward Backpropagation</i>
<i>Total layer</i>	2
<i>Input, output</i>	1, 1
<i>Activation function</i>	<i>Log sigmoid pada output layer, linier untuk output layer</i>
<i>Learning function</i>	<i>Levernberg Marquardt</i>
<i>Data Normalization</i>	<i>mapminmax</i>
<i>Divide function</i>	<i>Random</i>
<i>Percentage of dividend</i>	<i>Training=70%, Validation=15%, Test=15%</i>
<i>Performance</i>	<i>Mean Squared Error (MSE)</i>
<i>Epochs max</i>	500



Gambar 4.5 Struktur ANN untuk Pemodelan *User-defined Curve*

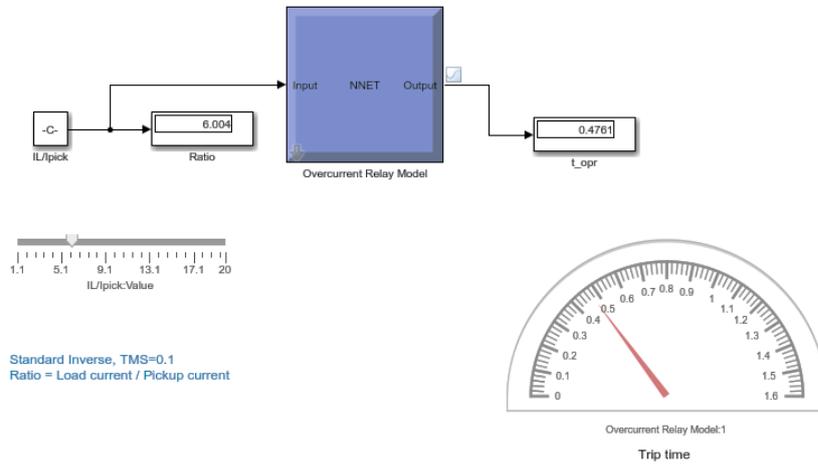
Modul aplikasi untuk merencanakan kurva oleh *user* ditunjukkan pada Gambar 4.6, yang pertama dipilih adalah pemandu basis tipe kurva yang akan dirancang, apakah SI, EI, VI atau LTI. Kemudian *user* membuat kurva sendiri pada halaman layar.

Setelah selesai dibuat kurvanya, selanjutnya dilakukan pemilihan parameter seting pembelajaran dari ANN. Langkah berikutnya adalah melakukan pembelajaran hingga didapatkan performansinya, jika telah sesuai dengan kebutuhan maka model telah selesai dan siap dikirim ke DPR.



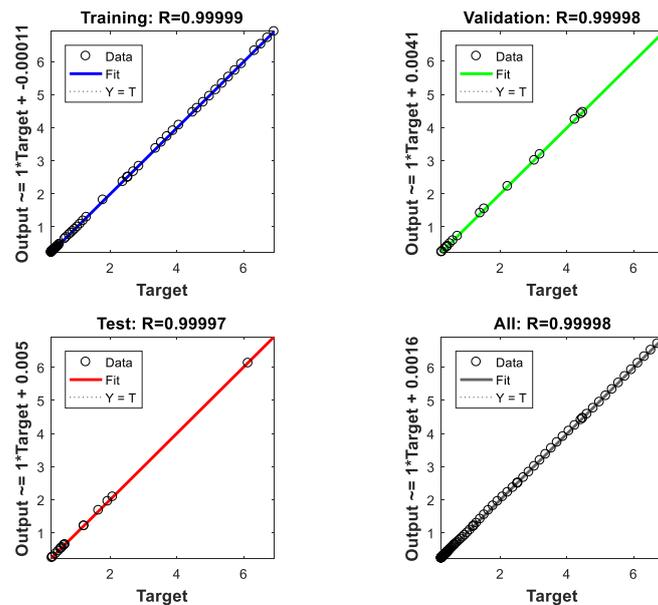
Gambar 4.6. *User Interface* untuk Perencanaan Kurva Karakteristik

Model yang telah selesai dilakukan ujicoba dengan Simulink, seperti ditunjukkan pada Gambar 4.7, bagian ini juga merupakan cara uji performansi dari model yang telah dibuat.



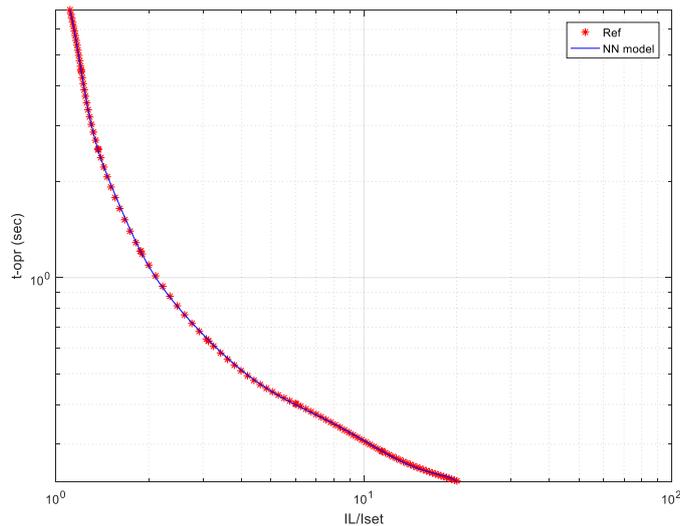
Gambar 4.7. Ujicoba Model dengan Simulink

Ujicoba hasil pembelajaran diketahui dari performansi selama pembelajaran dengan grafik relasi antara data target dan output selama *training*, validasi dan *testing* seperti ditunjukkan pada Gambar 4.8.



Gambar 4.8. Performansi Pembelajaran ANN

Secara visual hasil kurva yang dibentuk oleh *user* dibandingkan dengan hasil model, Gambar 4.9 adalah contoh hasil pemodelan untuk kurva karakteristik *standard invers* dengan $TMS=0,1$, tanda merah adalah kurva yang dirancang oleh *user* dan garis biru adalah hasil model dengan menggunakan ANN.

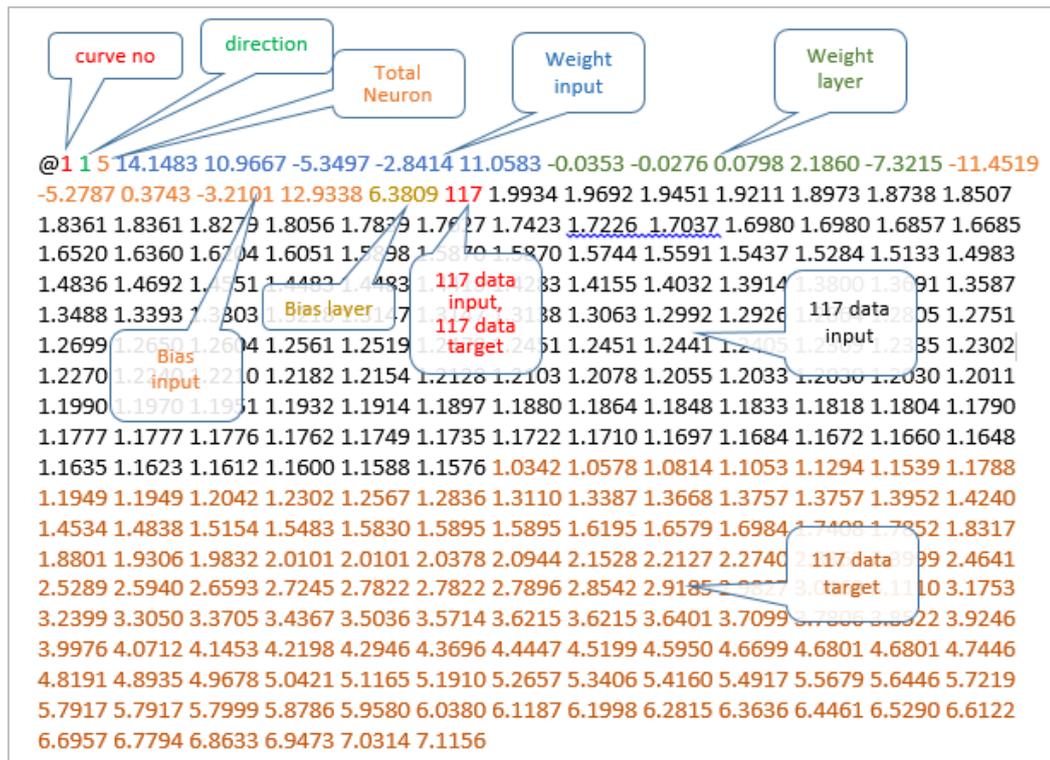


Gambar 4.9. Visualisasi Kurva Hasil Model dan Perancangan oleh *User*

Hasil pemodelan adalah berupa nilai-nilai yang telah disusun sedemikian rupa sehingga sewaktu dikirim ke DPR akan mudah untuk diterjemahkan oleh *microcontroller* untuk diintegrasikan dengan *library* yang sudah disusun.

Pada Gambar 4.10 ditunjukkan protokol komunikasi yang telah disusun untuk bisa berkomunikasi dengan DPR, nilai-nilai tersebut adalah data model yang mengandung jumlah data, jumlah *neuron*, nilai *bias* dan nilai bobot atau *weight* baik pada *output layer* maupun pada *output layer* yang diperoleh saat pembelajaran.

Nilai-nilai tersebut akan dibaca dan ditaruh pada bagian konstanta *library* program *microcontroller*, sedangkan program untuk menjalankan ANN pada *microcontroller* telah didapatkan *source code* saat terbentuk model dengan kemampuan *generation code* oleh program Simulink dengan memilih target *microcontroller* ARM STM32F7, data-data untuk keperluan *display* pada sisi DPR juga dikirim. Pada bagian ini merupakan hasil inovasi keterbaruan pada pemodelan kurva karakteristik rele digital yang belum dilakukan pada riset sebelumnya.



Gambar 4.10 Urutan Data Model yang Dikirim ke DPR

4.3. Performansi Pemodelan *User-defined Characteristic Curve*

Selanjutnya akan dilakukan ujicoba dengan menggunakan GUI yang telah dibuat untuk perancangan kurva karakteristik *user-defined* dengan basis kurva SI, EI, VI serta LTI dengan nilai TMS=1,0 dan nilai TMS=0,1.

Pada Gambar 4.11 ditunjukkan hasil pemodelan setelah dilakukan perancangan kurva dengan bantuan kurva SI dengan TMS=0,1, sebelum melakukan eksekusi pembelajaran *user* terlebih dahulu merancang kurva kemudian melakukan seting parameter pada grup seting *curve reference*, yakni jenis kurva sebagai referensi, nilai *pickup*, nilai *short circuit*, nilai TMS dan nilai *step data*.

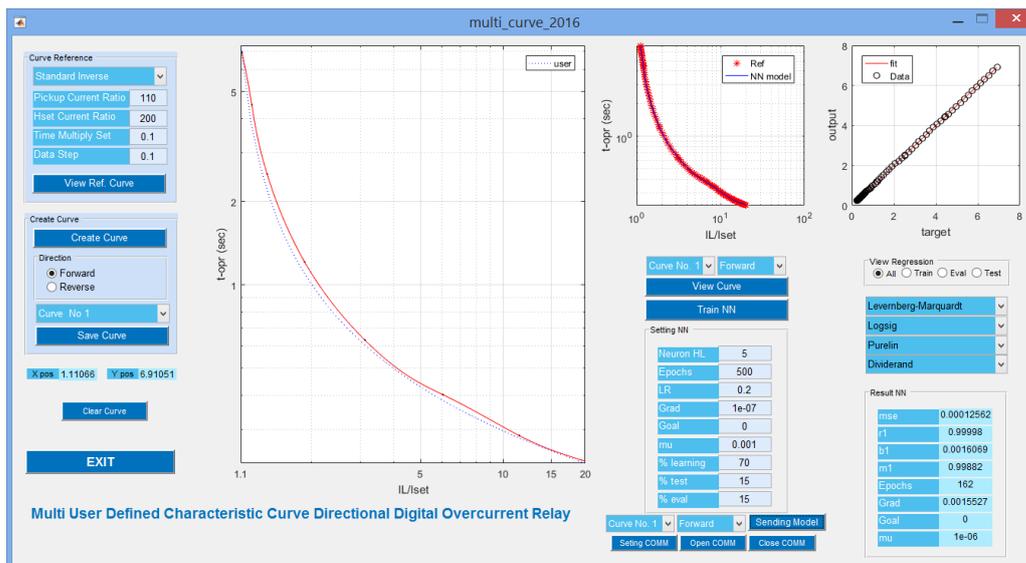
Setelah mengisi parameter tersebut baru dilihat model kurva sebagai referensinya dengan cara menekan tombol *view reference curve*, setelah muncul kurva SI sebagai *guidance* pembuatan kurva, maka selanjutnya mulai membuat

titik-titik pembentuk kurva dengan terlebih dahulu menekan tombol *create curve*. Pada Gambar GUI ditunjukkan kurva hasil perancangan *user* dengan warna merah.

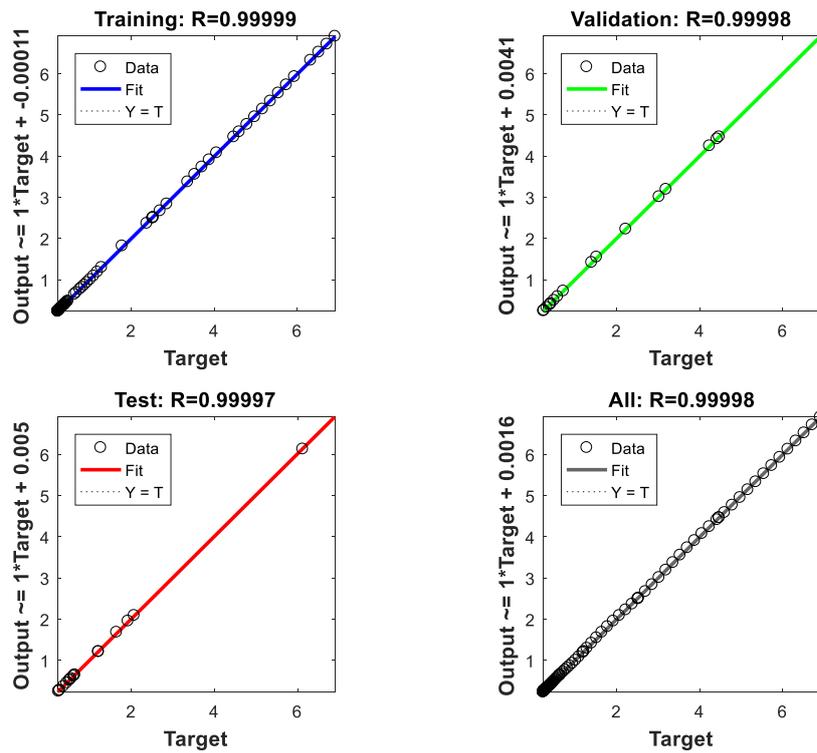
Sebelum melakukan pembelajaran parameter seting untuk ANN perlu dipilih, mulai dari jumlah *neuron* pada *output layer*, jumlah *epochs*, nilai *learning rate*, nilai *gradient*, nilai *goal*, nilai *mu* serta prosentase pembagian data untuk *learning*, *testing* dan *evaluation*. Juga parameter ANN yang lain yang bisa dipilih adalah fungsi *learning* dan dipilih *Levenberg Marquardt*, jenis fungsi keanggotaan untuk input dan output serta mode pemisahan data dipilih *log sigmoid* untuk input, *linier* untuk output dan *random* untuk pemisahan data.

Setelah pembelajaran didapatkan hasil $mse=0,00012562$, dengan nilai regresi antara target dan keluaran model adalah $r_0=0,99998$ $b_0=0,0016069$ $m_0=0,99882$. jika dikehendaki dapat dilakukan tuning untuk mendapatkan nilai *mse* yang lebih kecil dengan beberapa strategi pemilihan nilai parameter pembelajaran.

Performansi pemodelan terkait dengan evaluasi regresi antara target dibanding dengan hasil pemodelan diberikan pada Gambar 4.12, untuk evaluasi data *training*, *validasi* dan *test* dengan hasil yang sangat baik dengan nilai regresi $training=0,99999$, $validation=0,99998$, $test=0,99997$, untuk meningkatkan hasil yang lebih akurat masih bisa dilakukan dengan menambah jumlah *neuron* atau menambah jumlah iterasi, namun yang lebih signifikan adalah dengan melakukan penambahan jumlah *neuron* dengan dampak menambah ruang memori pada DPR.

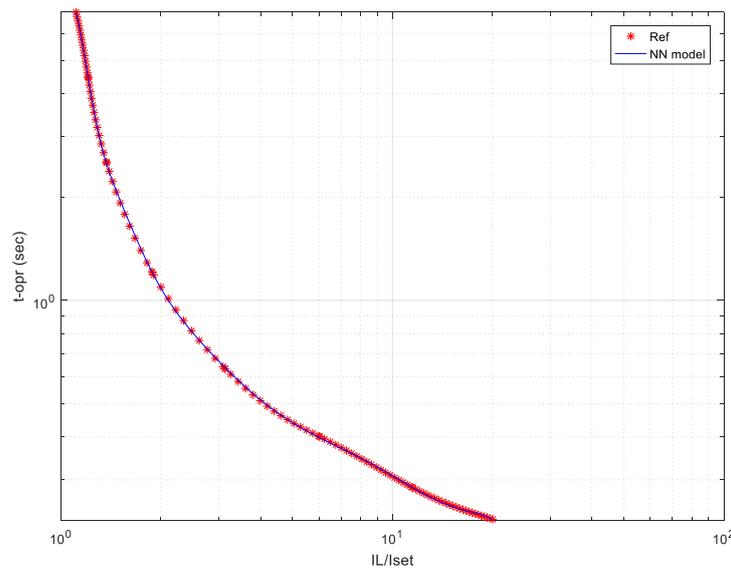


Gambar 4.11. *User Interface* untuk Kurva Dengan Referensi SI TMS=0,1



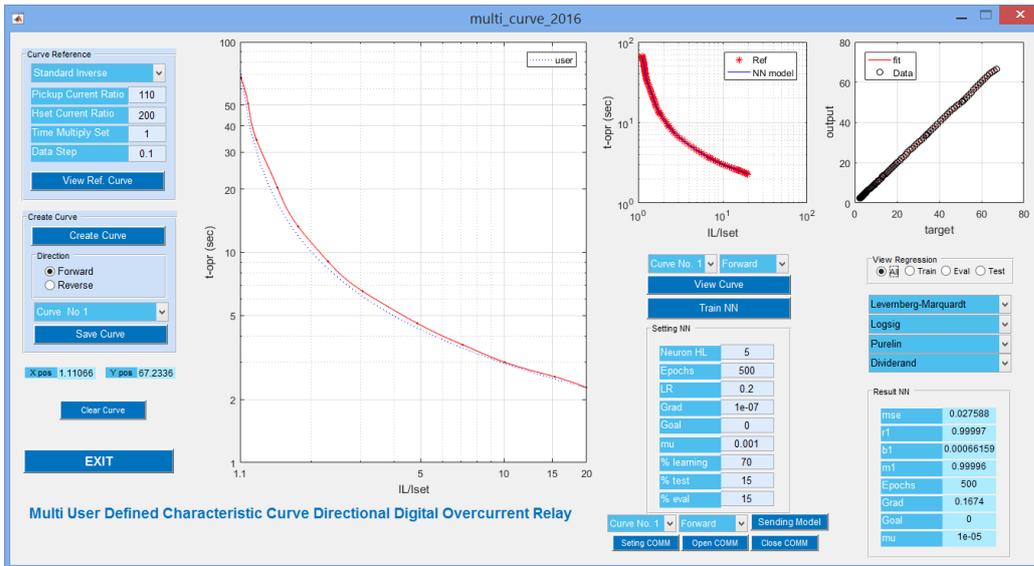
Gambar 4.12. Performansi Regresi kurva *user-defined* basis SI dengan TMS=0,1

Pada Gambar 4.13 diberikan bentuk kurva hasil pembelajaran dibanding dengan kurva target, dimana kurva hasil model ANN mengikuti kurva referensi, hal ini telah menunjukkan pemodelan telah berhasil mengikuti target yang diinginkan.

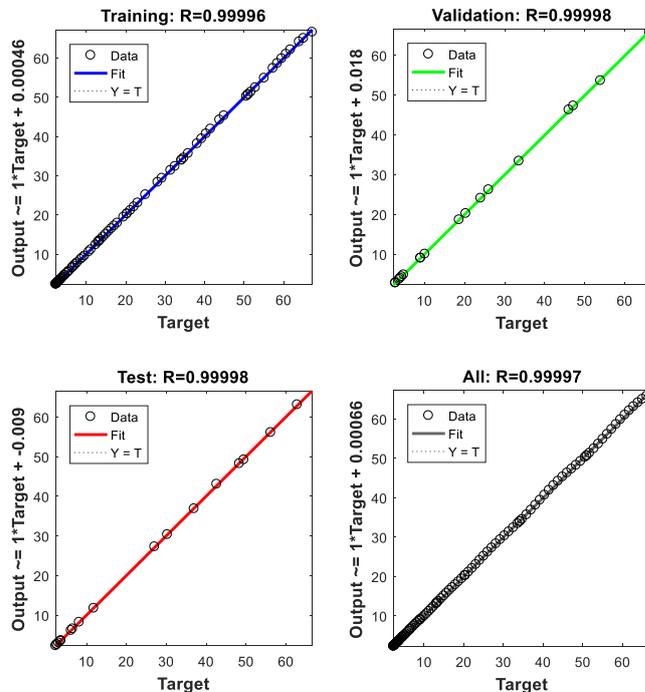


Gambar 4.13 Kurva Model dan Referensi Jenis Kurva SI TMS=0,1

Untuk ujicoba berikutnya adalah kurva karakteristik SI dengan TMS=1,0, setelah dilakukan proses pembelajaran untuk membangun model didapat nilai MSE=0,027588, ro=0,99997, bo=0,00066159, mo=0,99996 seperti ditunjukkan pada Gambar 4.14. Sedangkan performansi terkait dengan hubungan target dan hasil pemodelan diberikan pada Gambar 4.15, dengan nilai rerata 0,99997.

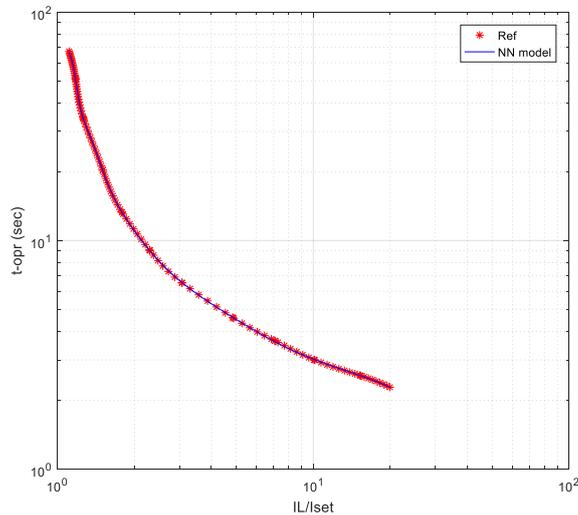


Gambar 4.14 User Interface untuk Kurva Dengan Referensi SI TMS=1,0



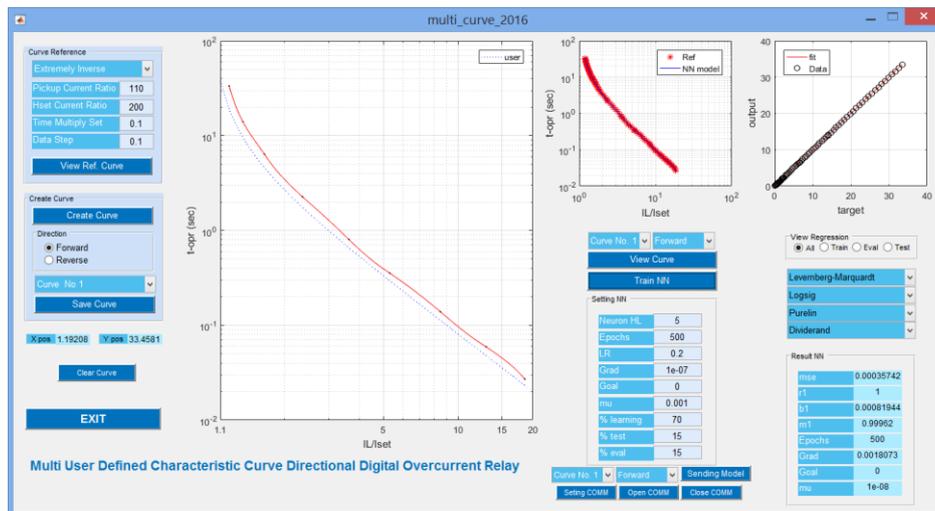
Gambar 4.15 Performansi Regresi Kurva Model SI TMS=1,0

Gambar 4.16 adalah hasil kurva pemodelan dibanding dengan referensi kurva yang telah dirancang oleh *user*, tanda bintang merah adalah kurva target dan kurva gasris berwarna biru adalah hasil pemodelan dengan ANN.

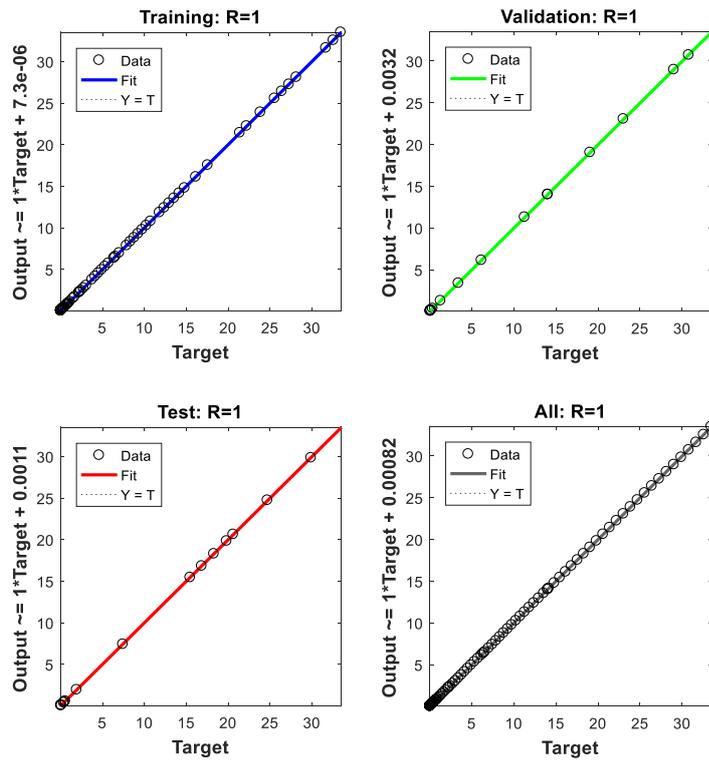


Gambar 4.16 Kurva Model dan Referensi Jenis Kurva SI TMS=1,0

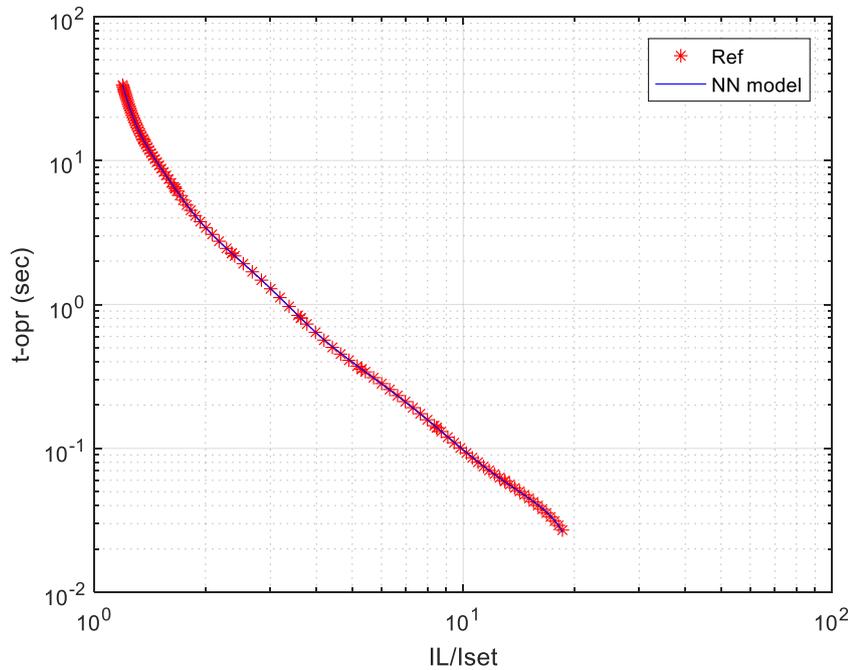
Ujicoba berikutnya adalah kurva karakteristik EI dengan nilai TMS=0,1, hasil dari pemodelan adalah MSE=0,00035742, ro=1, bo=0,00081944, mo=0,99962 seperti ditunjukkan pada Gambar 4.17, performansi pada masing-masing data regresi *training=validation=test=1*, hal ini menunjukkan bahwa antara target dan model telah sama hasilnya, dengan bentuk kurva hasil pemodelan ditunjukkan pada Gambar 4.19, dimana kurva model mampu mengikuti kurva target.



Gambar 4.17 User Interface untuk Kurva Dengan Referensi EI TMS=0,1

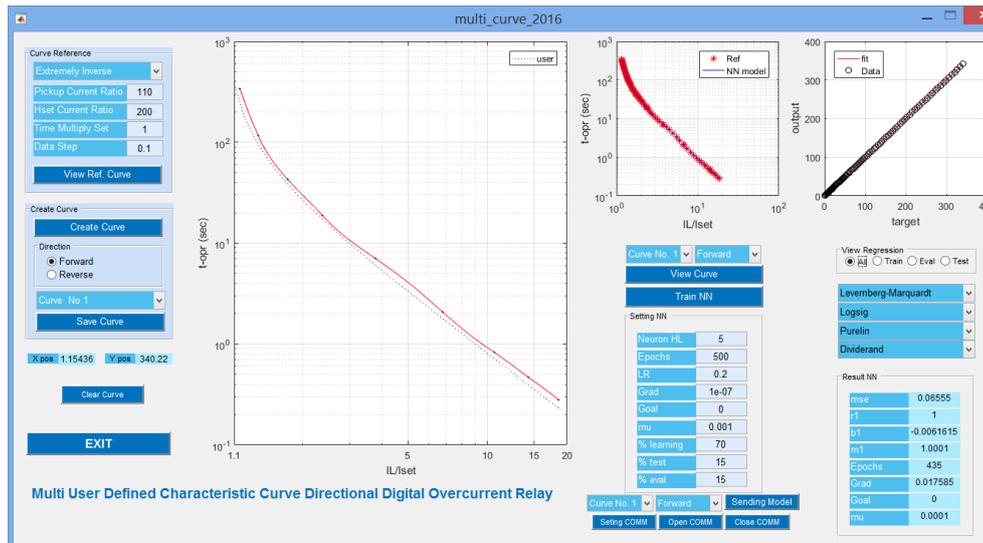


Gambar 4.18 Performansi Regresi Kurva Model EI TMS=0,1

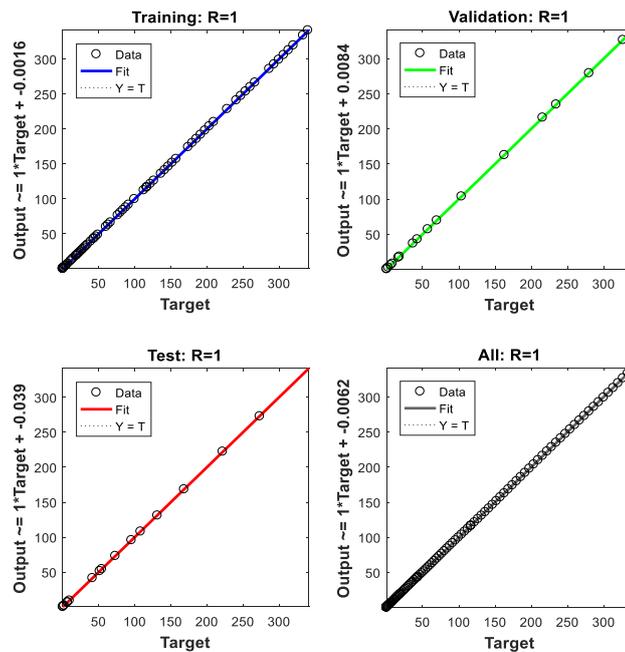


Gambar 4.19 Kurva Model dan Referensi Jenis Kurva EI TMS=0,1

Ujicoba untuk jenis kurva karakteristik EI dengan $TMS=1,0$ hasilnya ditunjukkan pada Gambar 4.20, capaian hasil pemodelan dengan $MSE=0,06555$, nilai parameter regresi $r_0=1$, perpotongan y untuk regresi linear $b_0=0.0061615$, lereng regresi linear simulasi *network* $m_0=1,001$ dengan jumlah *neuron* pada *output layer* adalah 5. Gambar 4.21 diberikan grafik performansi target dan hasil keluaran model untuk tiga jenis data, dimana semuanya menunjukkan hasil signifikan=1.

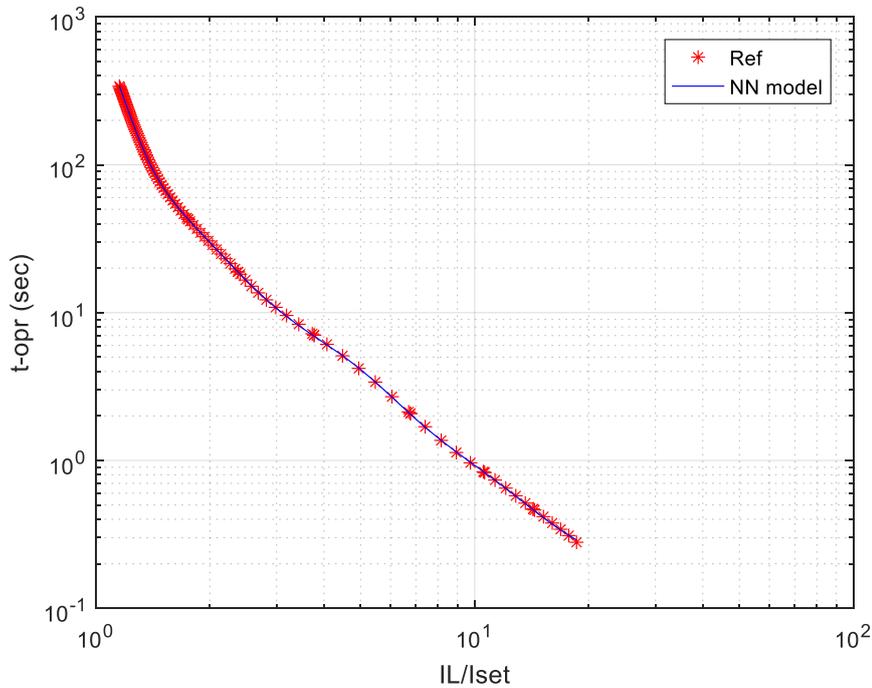


Gambar 4.20 *User Interface* untuk Kurva Dengan Referensi EI TMS=1



Gambar 4.21 Performansi Regresi Kurva Model EI TMS=1

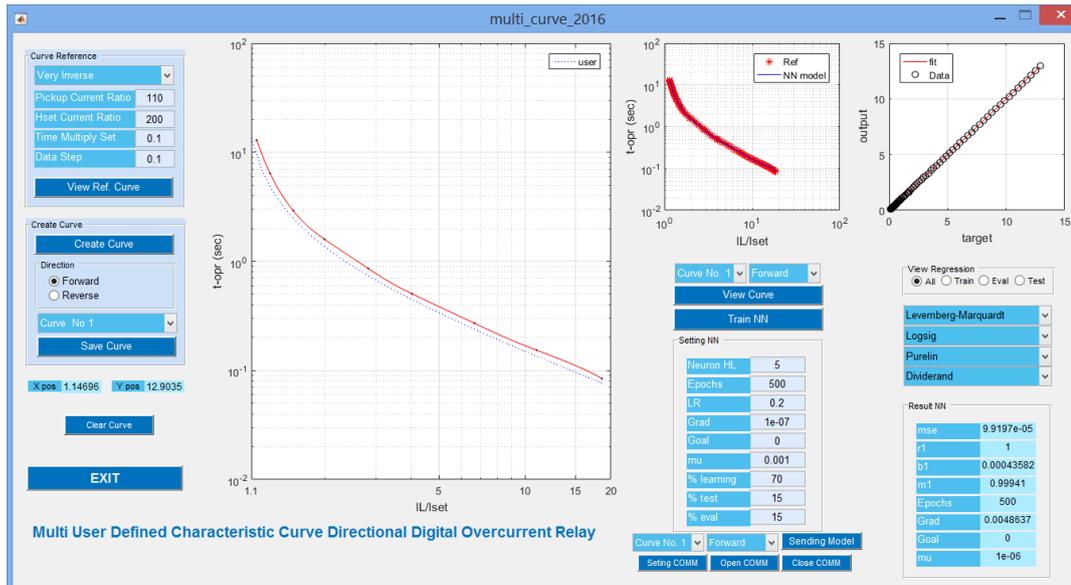
Gambar 4.22 adalah kurva hasil pemodelan, dimana tanda arteristik merah adalah nilai referensi dan garis biru adalah keluaran model ANN, dimana model mampu mengikuti titik-titik data referensi yang menunjukkan keberhasilan pemodelan dengan nilai-nilai parameter *error* seperti yang telah dihasilkan.



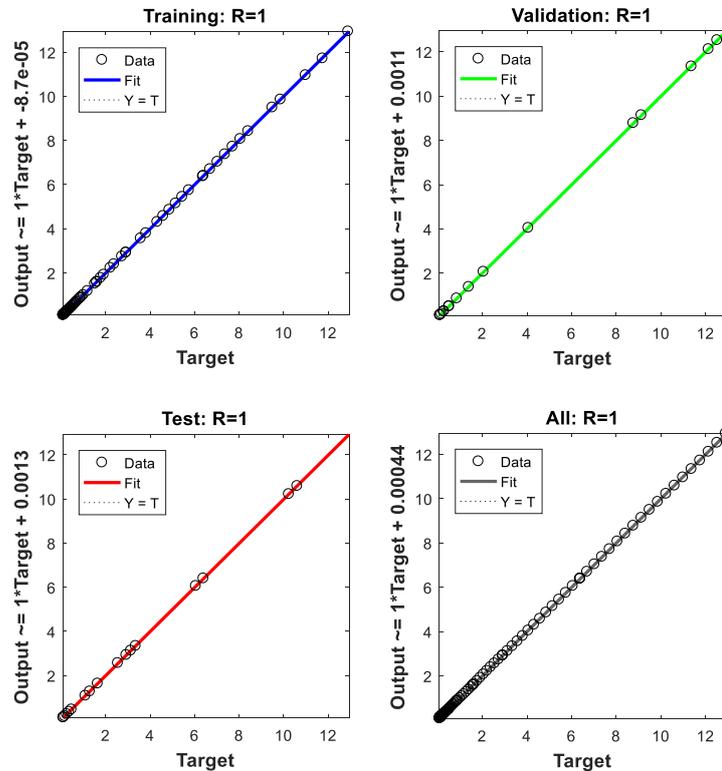
Gambar 4.22 Kurva Model dan Referensi Jenis Kurva EI TMS=1,0

Untuk pemodelan kurva karakteristik VI dengan TMS=0,1 hasilnya ditunjukkan pada Gambar 4.23, dengan hasil capaian pemodelan nilai MSE=9,9197e-05, ro=1, bo=0,00043582, mo=0,99941, performansi regresi antara target dan keluaran model diberikan pada Gambar 4.24, dimana nilai hubungan antara target dan model untuk semua jenis data *training*, validasi dan *test* semuanya menunjukkan angka signifikan sama dengan 1, yang berarti nilai target sama dengan nilai model.

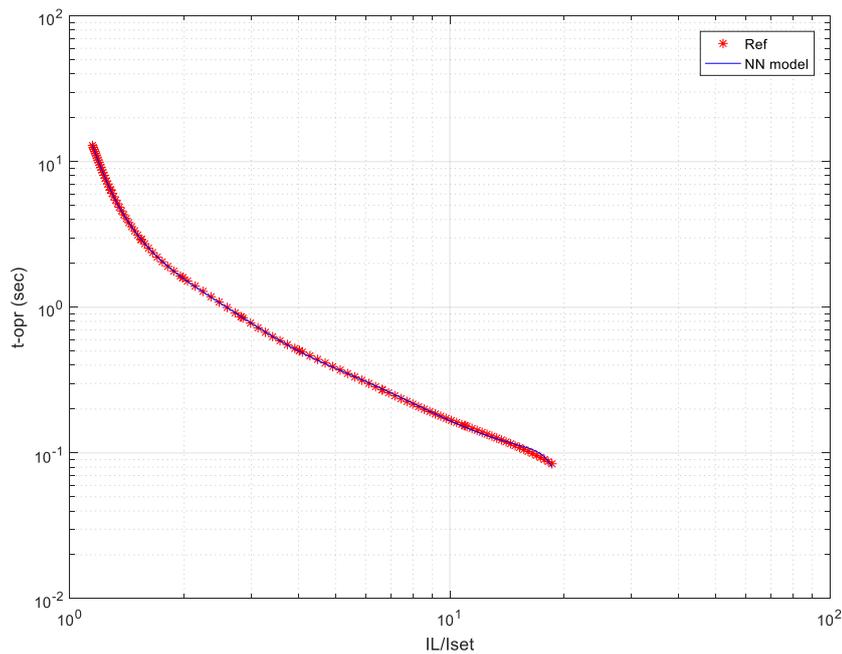
Bentuk kurva karakteristik VI dengan TMS=0,1 ditunjukkan pada Gambar 4.25, titik-titik model berhasil mengikuti titik-titik kurva referensi yang menunjukkan keberhasilan dari pemodelan dengan ANN.



Gambar 4.23. User Interface untuk Kurva Dengan Referensi VI, TMS=0,1

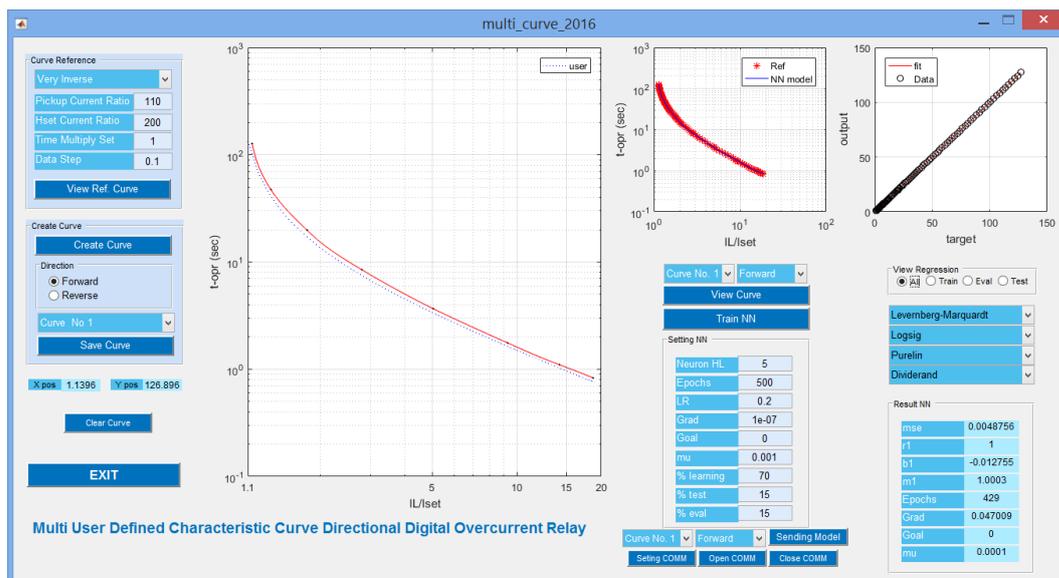


Gambar 4.24. Performansi Regresi Kurva Model VI, TMS=0,1



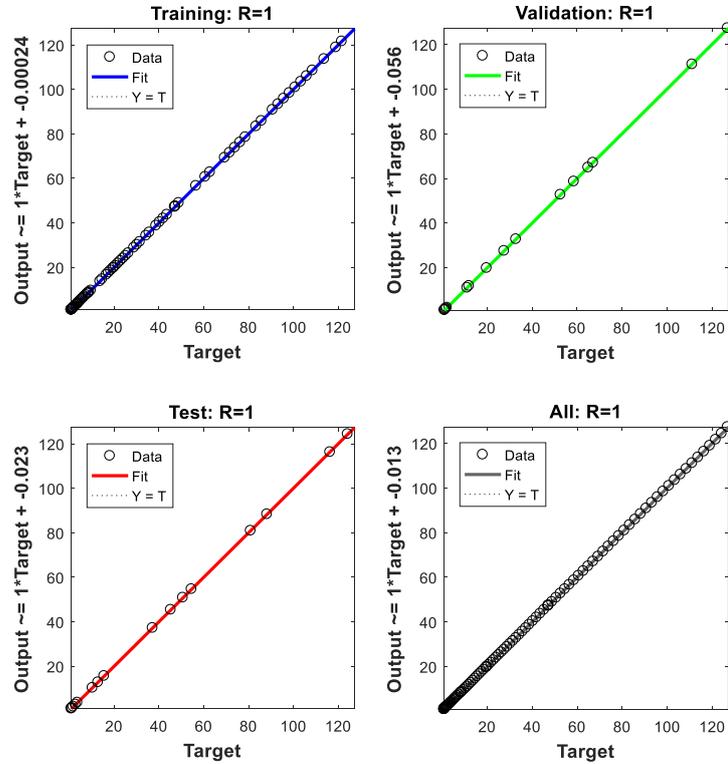
Gambar 4.25. Kurva Model dan Referensi Jenis Kurva VI, TMS=0,1

Untuk pemodelan kurva karakteristik VI dengan TMS=1,0 hasilnya ditunjukkan pada Gambar 4.26 dengan hasil capaian pemodelan nilai MSE=0,0048756, $r_0=1$, $b_0=-0,012755$, $m_0=1,0003$, dengan performansi regresi semua nilai R=1 pada Gambar 4.27.

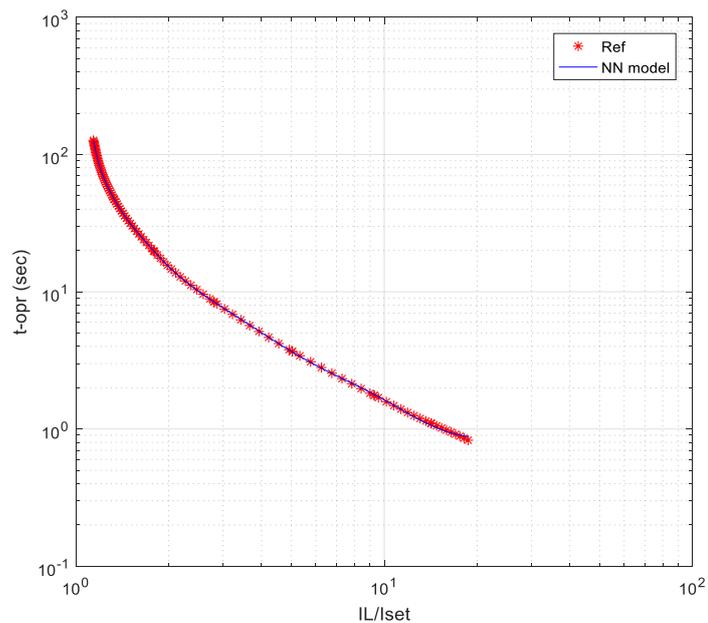


Gambar 4.26. User Interface untuk Kurva Dengan Referensi VI, TMS=1,0

Demikian juga bentuk kurva pada Gambar 4.28 menunjukkan keberhasilan dalam pemodelan dengan bukti dua jenis titik-titik berimpit, antara target dan model.

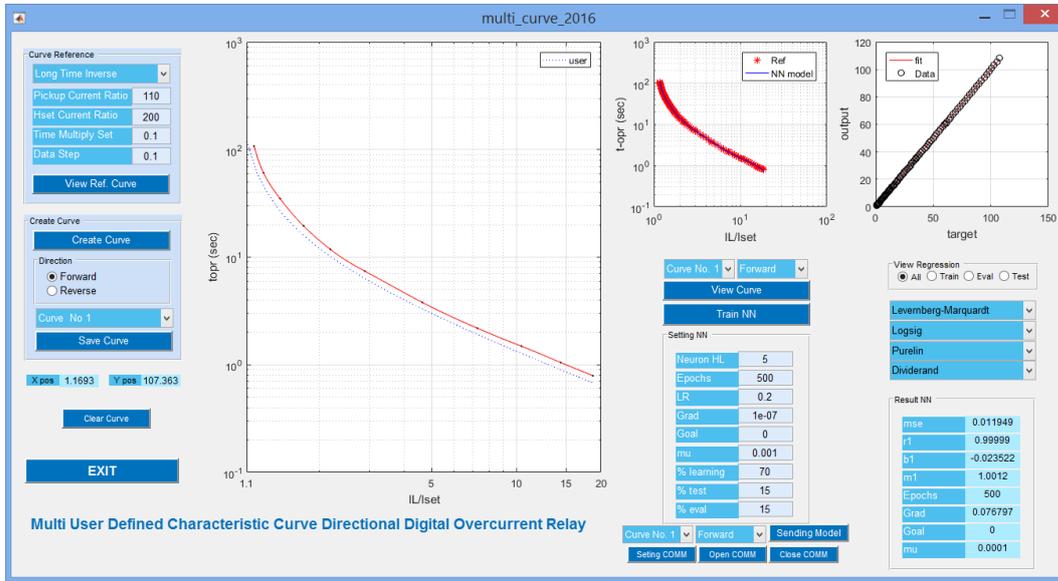


Gambar 4.27. Performansi Regresi Kurva Model VI, TMS=1,0

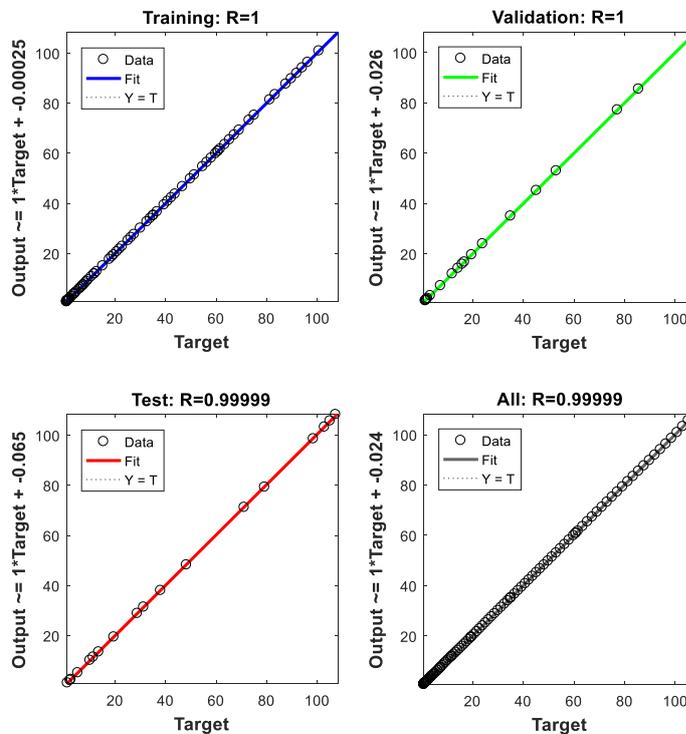


Gambar 4.28. Kurva Model dan Referensi Jenis Kurva VI, TMS=1,0

Ujicoba dengan kurva karakteristik LTI dengan TMS=0,1 diberikan pada Gambar 4.29 dengan hasil MSE=0,011949, $r_0=0,99999$, $b_0=-0,023522$, $m_0=1,0012$, dengan performansi regresi adalah $R=1$ untuk *training* dan validasi dan $R=0,99999$ untuk data *test* ditunjukkan pada Gambar 4.30.

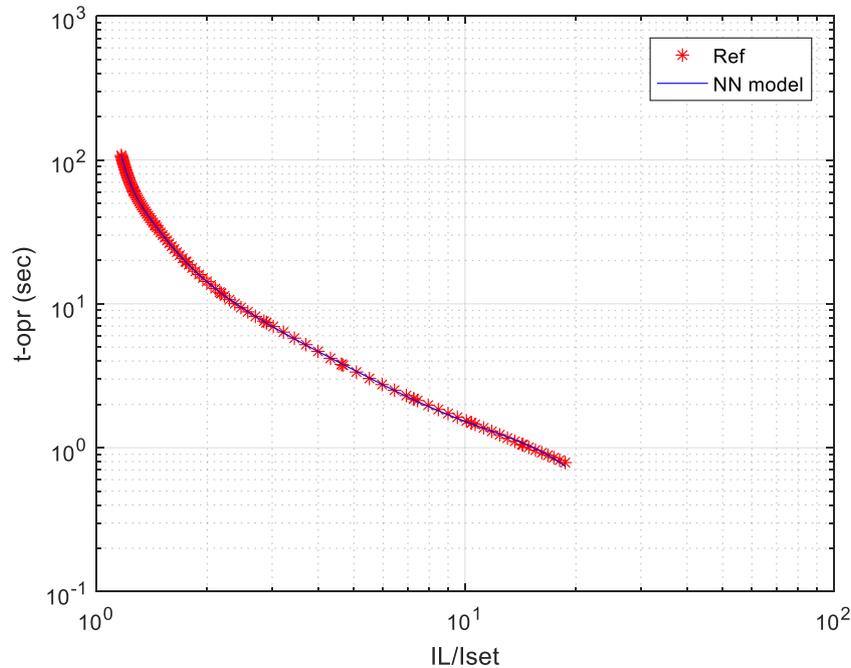


Gambar 4.29. User Interface untuk Kurva Dengan Referensi LTI, TMS=0,1



Gambar 4.30. Performansi Regresi Kurva Model LTI, TMS=0,1

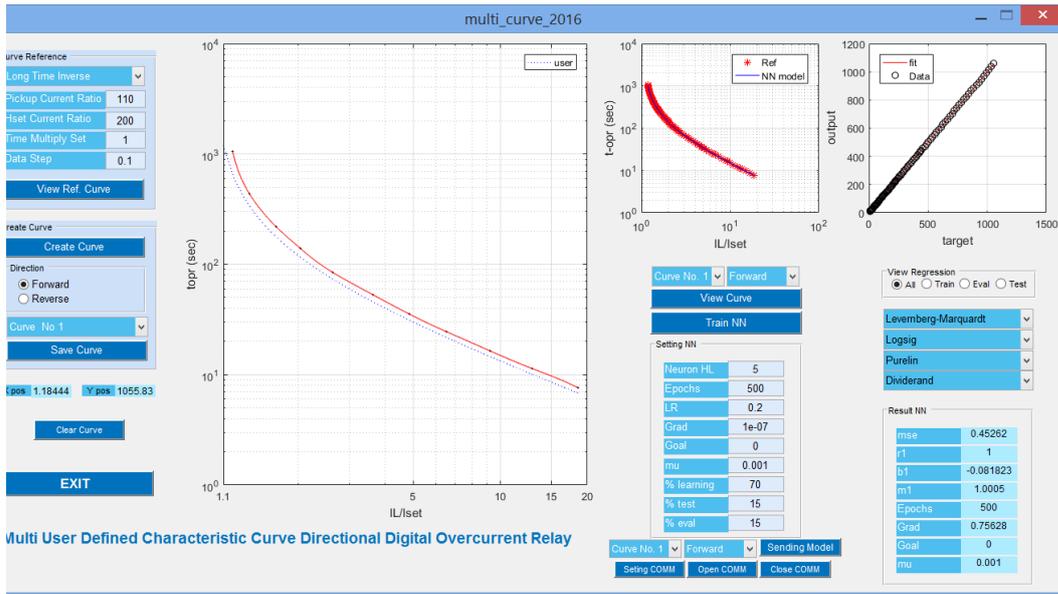
Gambar 4.31 ditunjukkan bentuk kurva karakteristik antara target atau referensi dengan hasil model kurva dengan ANN, dengan hasil yang signifikan bahwa model mengikuti referensi sepenuhnya.



Gambar 4.31. Kurva Model dan Referensi Jenis Kurva LTI dengan TMS=0,1

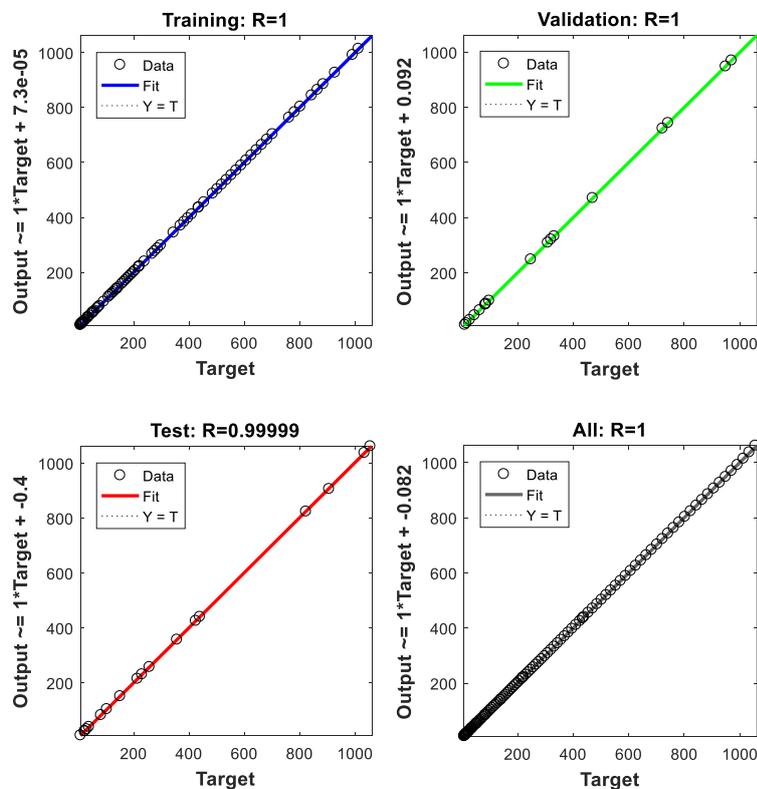
Untuk pemodelan kurva karakteristik LTI dengan TMS=1,0 ditunjukkan pada Gambar 4.32 dengan hasil keluaran MSE=0,45262, $ro=1$, $bo=-0,081823$, $mo=1,0005$, dengan menggunakan *neuron* pada sisi input $n=5$. Terlihat titik-titik kurva hasil rancangan *user* diberikan warna merah, untuk memperbaiki nilai-nilai tersebut masih terbuka lebar dengan merubah beberapa parameter seting ANN, namun pada ujicoba ini telah cukup dengan $n=5$, mengingat semakin banyak jumlah *neuron* maka akan menyebabkan bertambahnya memori saat program running, selain juga akan memperlambat proses kalkulasi matematikanya.

Performansi regresi Gambar 4.33 menunjukkan hubungan antara data referensi yang diberikan oleh *user* dibanding dengan data model mempunyai nilai $R=1$ saat *training* dan validasi, nilai $R=0,99999$ untuk *test*. Hal ini menunjukkan kemiripan yang sangat signifikan untuk data-data referensi dan data-data model.

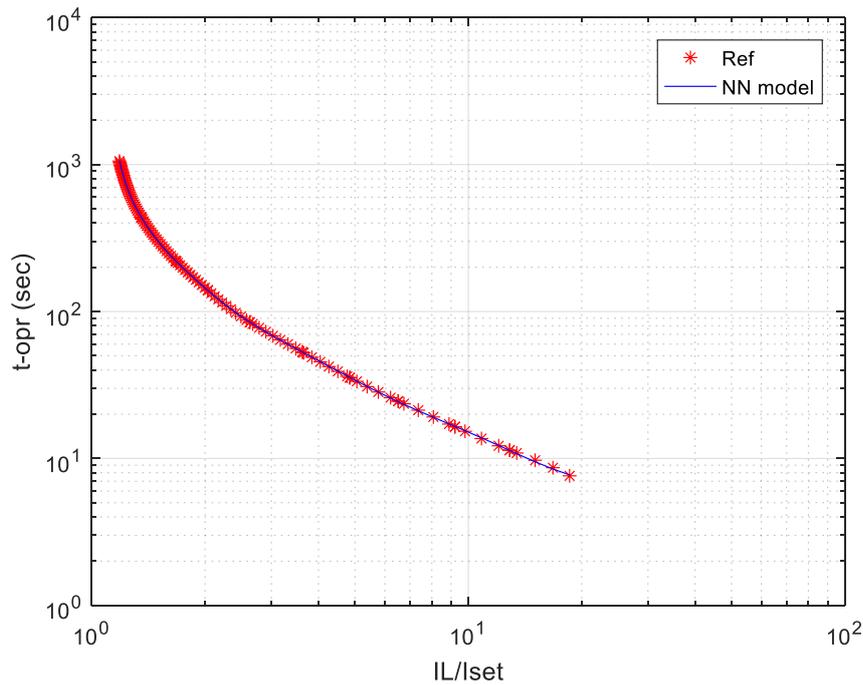


Gambar 4.32. User Interface untuk Kurva Model LTI dengan TMS=1,0

Bentuk kurva hasil pemodelan kurva LTI dengan TMS=1,0 ditunjukkan pada Gambar 4.34, dimana titik-titik referensi dan model selalu berimpit.



Gambar 4.33. Performansi Regresi Kurva Model LTI dengan TMS=1,0



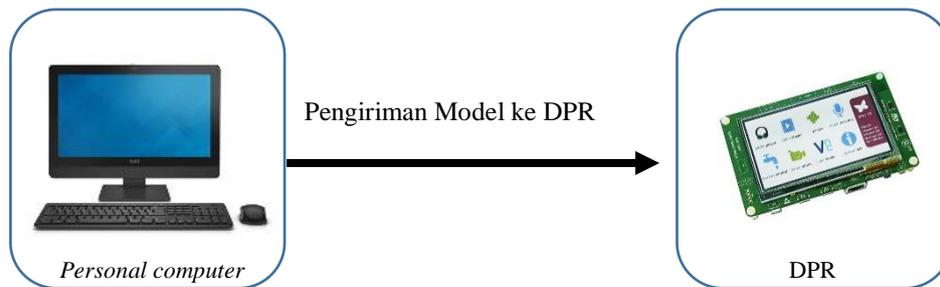
Gambar 4.34. Kurva Model dan Referensi Jenis Kurva LTI dengan TMS=1,0

Secara keseluruhan ujicoba pemodelan kurva dengan metode *user-defined curve* dengan menggunakan algoritma ANN menghasilkan Tabel 4.1, pada kurva dengan karakteristik LTI pada TMS=1,0 mempunyai nilai MSE yang paling besar. Walaupun begitu nilai regresi untuk semua ujicoba mempunyai nilai yang semuanya mendekati nilai=1, hal ini menunjukkan ada hubungan atau relasi yang sangat kuat antara target dengan hasil pemodelan menggunakan algoritma ANN.

Tabel 4.1 Resume Performansi Pemodelan *User-defined Curve*

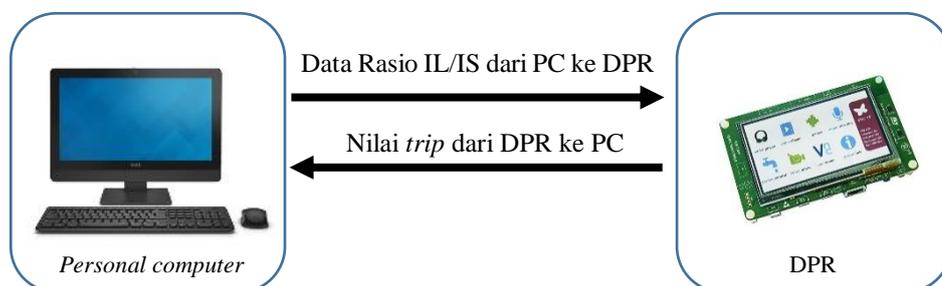
Kurva TMS	MSE	ro	bo	mo	R Train	R Validation	R Test
SI/0,1	0,00013	0,9999	0,00161	0,9989	1	1	1
SI/1,0	0,02759	0,9999	0,00066	0,9999	0,9999	0,9999	0,9999
EI/0,1	0,00036	1	0,00082	0,9997	1	1	1
EI/1,0	0,06555	1	0,00616	1,001	1	1	1
VI/0,1	0,00010	1	0,00044	0,9995	1	1	1
VI/1,0	0,00488	1	-0,01276	1,0003	1	1	1
LTI/0,1	0,01195	0,9999	-0,0235	1,0012	1	1	0,9999
LTI/1,0	0,45262	1	-0,0818	1,0005	1	1	0,9999

Uji performansi berikutnya dilakukan dengan cara mengirim model kurva yang dihasilkan dari simulasi untuk ditanam di rele digital seperti ditunjukkan pada Gambar 4.35, parameter model berupa nilai bobot dan bias serta informasi parameter lainnya ditanam di DPR.



Gambar 4.35 Pengiriman Model ke *Digital Protection Relay*

Setelah model terikirim dan tertanam didalam DPR maka ujicoba dilakukan dengan cara mengirim nilai rasio lewat serial komunikasi *personal computer* menuju ke rele digital, selanjutnya hasil keluaran berupa nilai *trip* dari model kurva didalam digital rele dikirim balik ke *personal computer*, untuk dilakukan analisa dengan mengirim sejumlah data *test*, Gambar 4.36 menunjukkan aliran data saat uji performansi model yang tertanam didalam rele digital.



Gambar 4.36. Uji Performansi Model didalam DPR

Setelah dilakukan ujicoba dengan empat buah jenis kurva dengan beberapa TMS didapatkan data seperti ditunjukkan pada Tabel 4.2, kolom simulasi adalah

hasil ujicoba dengan simulasi pemodelan menggunakan program di personal komputer, sedang kolom DPR adalah hasil pemodelan saat model ditanam di unit *microcontroller*, pada umumnya nilai TMS=0,1 mempunyai nilai *error* yang lebih kecil daripada model dengan nilai TMS=1,0. nilai RMSE yang paling besar adalah kurva LTI pada saat ujicoba di DPR RMSE 0,35, sedang RMSE LTI pada saat ujicoba simulasi menunjukkan hasil *error* yang lebih kecil yakni 0,11.

Hasil tersebut telah membuktikan bahwa nilai *error* masih dalam range yang memenuhi syarat menjadi model kurva rele digital, dengan menambahkan jumlah *neuron* akan memperkecil nilai *error* pada kurva LTI baik pada saat simulasi maupun saat uji coba model di tanam di DPR.

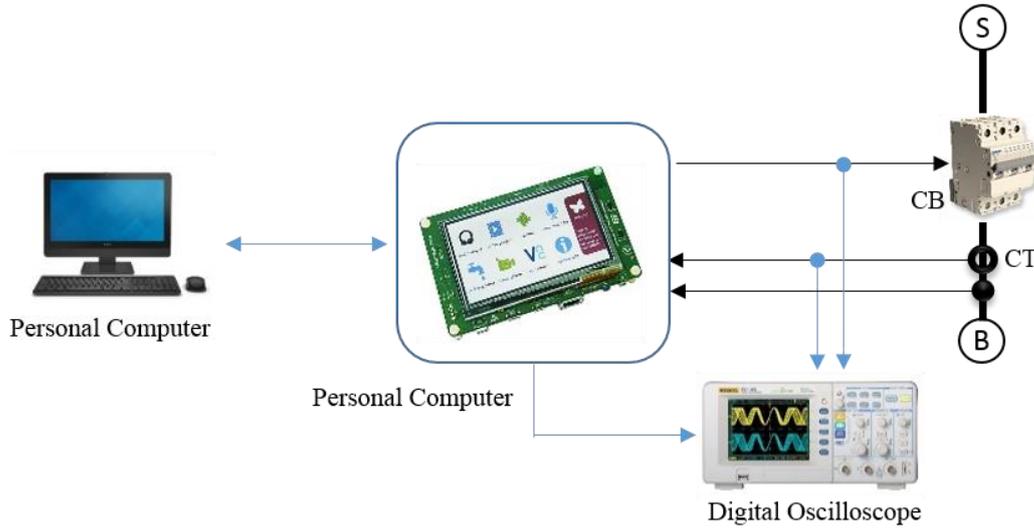
Tabel 4.2 Hasil Pemodelan Simulasi dan Pemodelan di dalam MCU

Tipe Kurva	TMS	SIMULASI		DPR	
		MSE	RMSE	MSE	RMSE
SI	0,1	0,000125	0,011176	0,000172	0,013127
	1,0	0,030475	0,174572	0,027825	0,166808
EI	0,1	0,000359	0,018943	0,000382	0,019534
	1,0	0,063377	0,251749	0,064205	0,253387
VI	0,1	0,000100	0,010023	0,000375	0,019364
	1,0	0,063377	0,251749	0,064205	0,253387
LTI	0,1	0,012333	0,111053	0,123071	0,350815
	1,0	0,020745	0,144030	0,035837	0,189308

Setelah berhasil melakukan ujicoba model dengan simulasi menggunakan program maupun ujicoba model yang ditanam di *microcontroller*, maka langkah selanjutnya adalah melakukan ujicoba menggunakan nilai rasio perbandingan I_L/I_s yang berasal dari hasil pengukuran riel yang berasal dari trafo arus CT dan diproses oleh DPR dengan terlebih dahulu mengirimkan model dari personal komputer ke DPR.

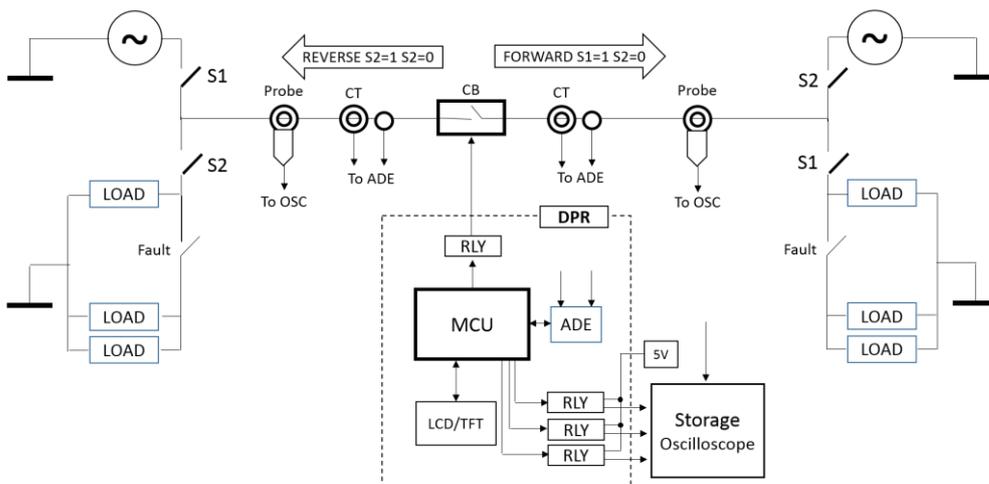
Dengan menggunakan pengaturan arus pada sisi beban maka dapat disimulasikan berapa nilai arus *overcurrent* yang melewati DPR saat itu, pada saat nilai *overcurrent* melebihi arus *pickup* maka kurva yang telah dimodelkan akan mampu memberikan nilai *trip* yang selanjutnya akan memerintahkan *timer* untuk mulai menghitung mundur, dan jika telah mencapai nilai *trip* maka *microcontroller*

akan memerintahkan CB melalui GPIO dan *driver* untuk memutuskan arus yang lewat saat itu, perekaman sinyal input dan output DPR direkam menggunakan *digital oscilloscope*, seperti yang ditunjukkan pada Gambar 4.37. dengan demikian fungsi IED sebagai perangkat pengaman atau proteksi telah dipenuhi.



Gambar 4.37 Uji Performansi Menggunakan Arus Riel

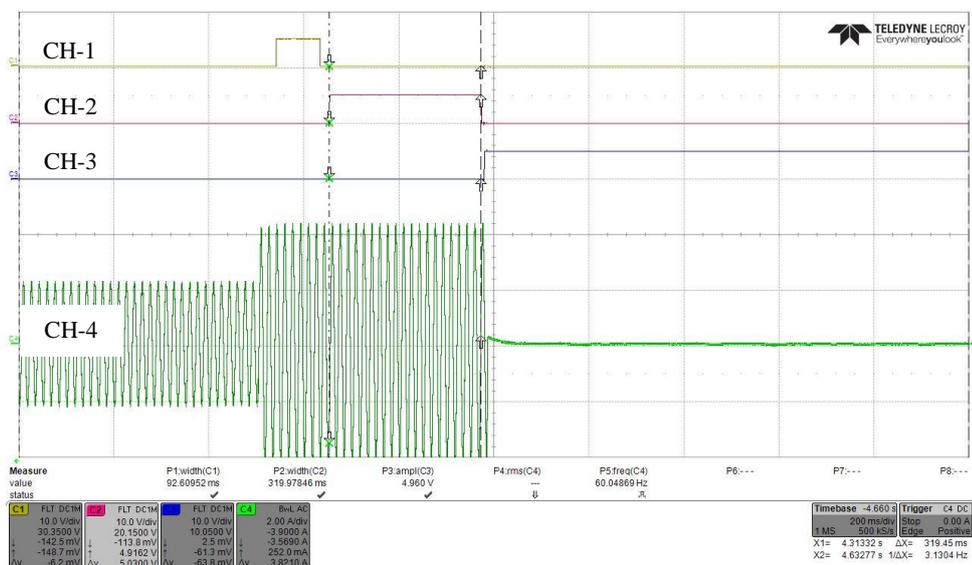
Gambar 4.38 ditunjukkan secara rinci blok diagram untuk melakukan pengukuran secara terintegrasi, besar arus beban ditentukan dengan cara mengatur resistor beban, untuk memasukkan arus beban pada saluran dengan cara menutup switch *fault*, dan switch S1 dan S2 digunakan untuk menentukan arah arus yang lewat DPR.



Gambar 4.38 Blok Diagram Rinci Uji Performansi Terintegrasi

Hasil monitoring dan perekaman pada Gambar 4.38 ditunjukkan pada Gambar 4.39. Program perangkat lunak yang telah dirancang didalam *microcontroller* bertujuan untuk melihat performansi model yang telah tertanam didalamnya dengan urutan sebagai berikut:

- Pada saat switch *fault* ditutup maka arus yang mengalir pada beban akan naik, seperti terekam pada *digital oscilloscope* pada CH-4.
- Kenaikan arus akan terdeteksi dan ditandai dengan *rising-up* pulsa pada CH-1, selanjutnya saat *falling-edge* akan dilakukan perhitungan nilai *trip* menggunakan model yang ada.
- Saat setelah selesai mendapatkan nilai *trip* keluaran dari model, maka akan melakukan *loading* nilai *trip* ke unit *timer* ditandai dengan *rising-up* pulsa pada CH-2.
- Pada saat timer *overflow* dimana diberi tanda dengan *falling-edge* CH-2 maka sinyal *trip* akan dikeluarkan sesuai dengan tanda *rising-up* pulsa CH-3.
- Sinyal *trip* akan memutuskan aliran arus menuju beban dengan dibuktikan hilangnya bentuk sinyal sinus pada CH-4.



Gambar 4.39 Perekaman Sinyal Saat Terjadi Overload

Dengan melakukan beberapa ujicoba dengan beberapa rasio I_L/I_S untuk kurva SI dengan TMS=1, didapatkan hasil seperti ditunjukkan pada Tabel 4.3. dengan hasil yang bisa diterima karena selisih antara saat model ditanam di DPR dengan saat model diuji dengan riel arus beban kurang dari 0,1 detik, dengan asumsi nilai terkecil *trip* adalah 0,1 detik.

Tabel 4.3 Performansi Model saat Terintegrasi

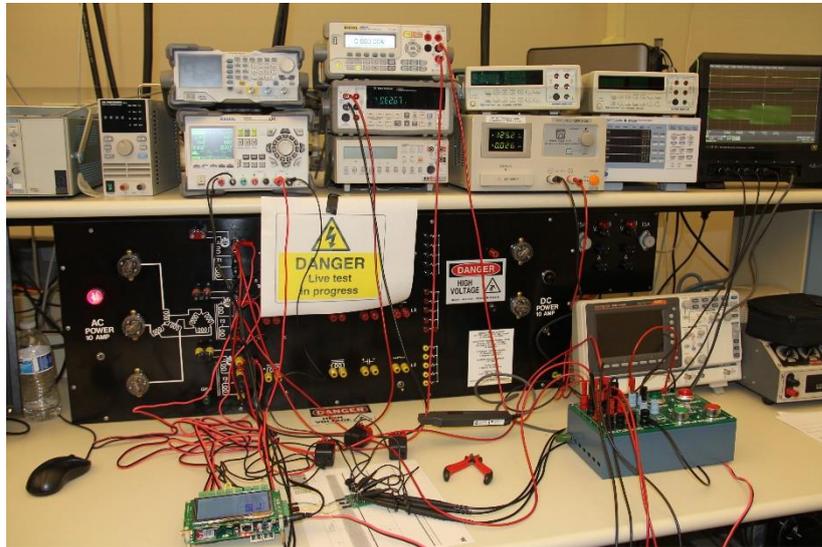
Rasio	Trip (detik)	
	Model di DPR	Model dengan arus riel
19,1	0,24	0,27
17,62	0,25	0,28
15,61	0,27	0,29
11,67	0,32	0,34
10,68	0,33	0,36
8,59	0,38	0,38
6,42	0,46	0,48
4,34	0,62	0,67
2,24	1,45	1,47

Gambar 4.40 diberikan gambar prototipe *digital protection relay* yang selesai dibangun dilengkapi dengan *display touch screen*, lengkap dengan sarana komunikasi baik modem GPRS maupun Ethernet.

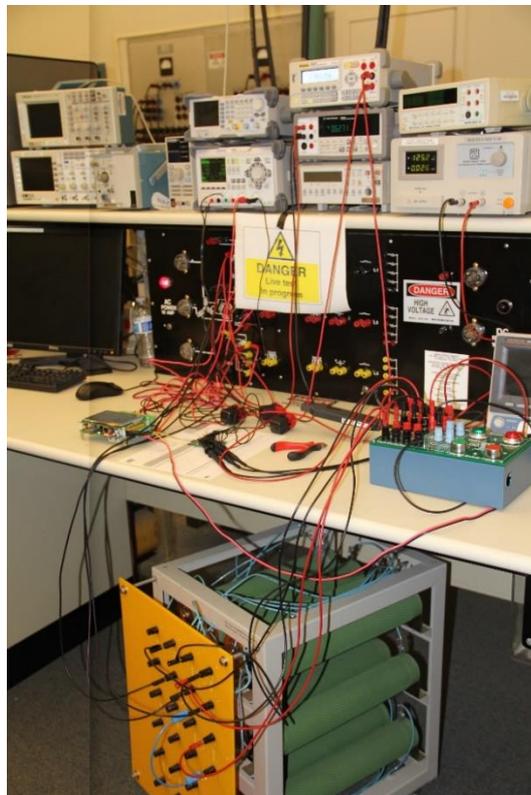


Gambar 4.40 Prototipe *Digital Protection Relay*

Gambar 4.41 dan Gambar 4.42 ditunjukkan situasi saat prototipe diuji di laboratorium dilengkapi dengan peralatan perekam *digital oscilloscope*, sumber AC dan perangkat beban beserta modul *generate fault*.



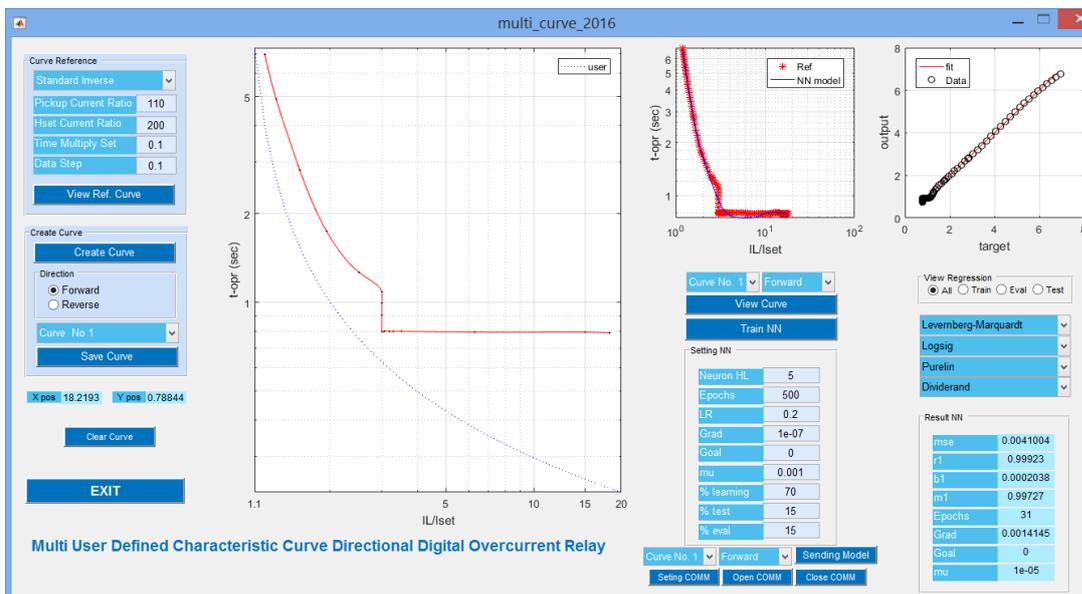
Gambar 4.41 Ujicoba Integrasi di Laboratorium



Gambar 4.42 Terhubung Dengan Beban untuk Ujicoba Saat Overload

4.4. Performansi untuk Pemodelan Kurva Ekstrim

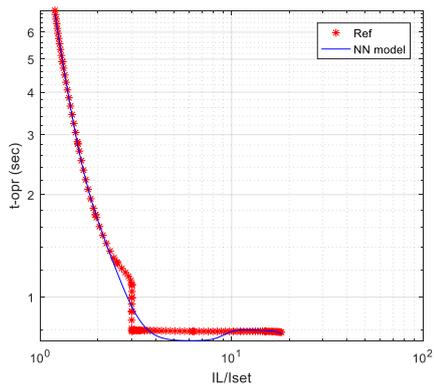
Ujicoba selanjutnya setelah berhasil memodelkan kurva karakteristik dengan basis SI, VI, EI dan LTI adalah dengan kurva dengan bentuk ekstrim, seperti ditunjukkan pada Gambar 4.43, dimana kurva tersebut sebenarnya adalah gabungan kurva *inverse time overcurrent*, *definite time* dan *instaneous relay*. Pengguna membuat kurva dan melakukan pembelajaran ANN dengan menggunakan program aplikasi yang telah dikembangkan.



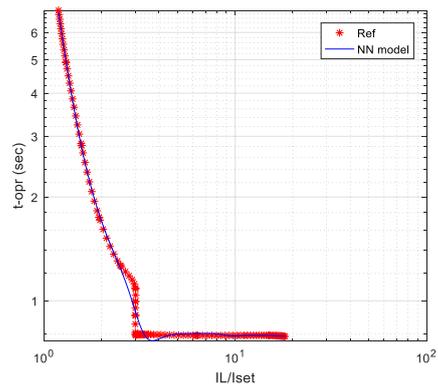
Gambar 4.43 Program Aplikasi untuk Merancang Kurva Karakteristik Rele

Pembelajaran untuk menghasilkan model dilakukan dengan memilih parameter pembelajaran, dengan memilih jumlah neuron pada *hidden layer* akan dihasilkan performansi yang berlainan, Gambar 4.44 ditunjukkan hasil performansi dengan jumlah neuron mulai dari 5 hingga 17, dengan jumlah neuron 5 dan 10 hasil pemodelan kurva belum menunjukkan kesamaan antara target dan model, dan setelah dinaikkan menjadi 15 kurva model mulai menunjukkan hasil yang baik dan setelah dilakukan penambahan neuron menjadi 17 dihasilkan model yang cukup baik.

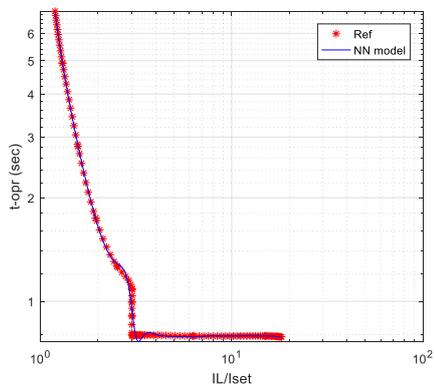
Gambar 4.45 adalah proses saat pembelajaran dengan memonitor perhitungan mse dari tiga parameter akni pelatihan, evaluasi dan testing dengan hasil terbaik mse=0,00177 pada iterasi ke 394 dari 800 iterasi yang dipilih oleh pengguna.



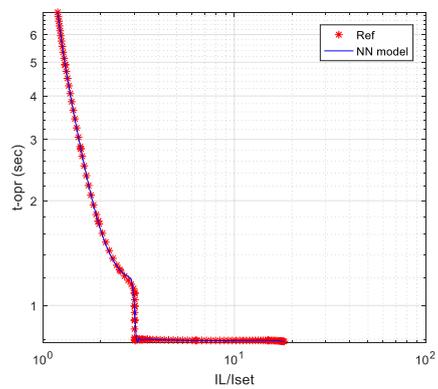
(a) Neuron=5



(b) Neuron=10

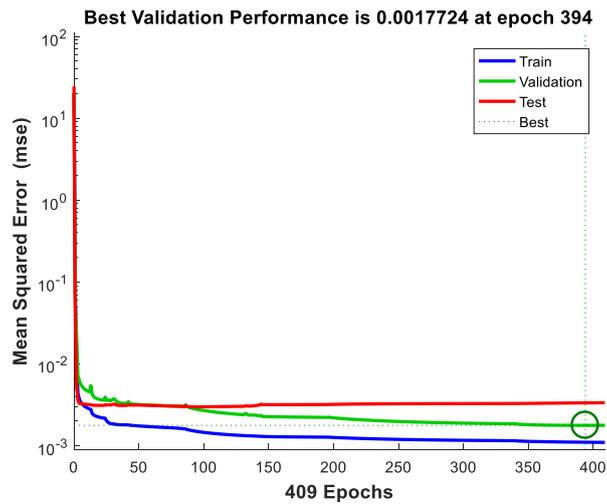


(c) Neuron=15

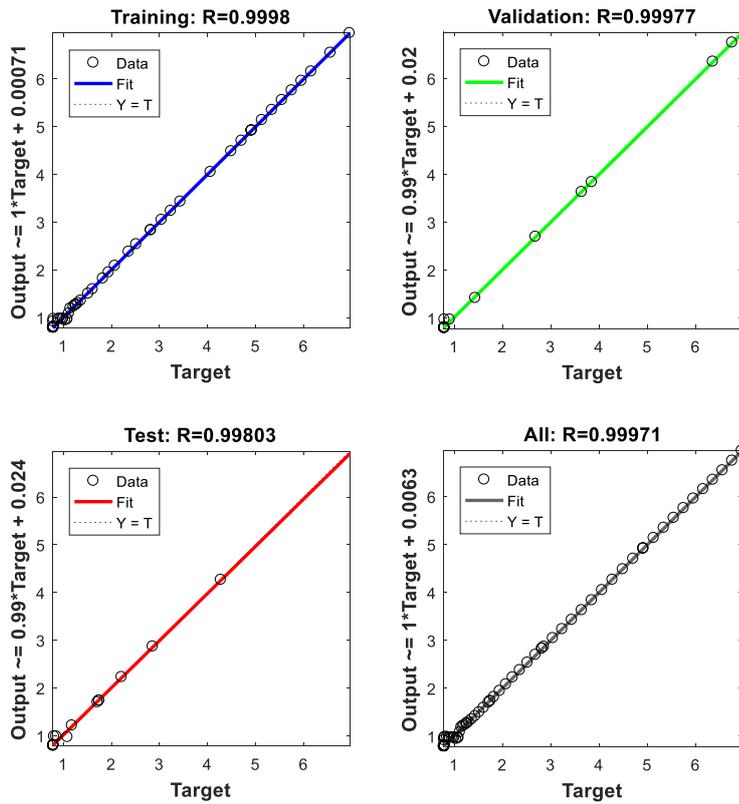


(d) Neuron=17

Gambar 4.44 Performansi Pemodelan dengan Jumlah Neuron Berbeda



Gambar 4.45 Hasil Performansi Parameter Training, Evaluasi dan Testing



Gambar 4.46 Performansi Pemodelan untuk Kurva Ekstrim

Gambar 4.46 adalah performansi hubungan antara kurva hasil pemodelan ANN dengan kurva referensi yang telah dirancang oleh pengguna, dengan konfigurasi seting parameter dan hasil sebagai berikut:

- Jumlah *layer*=2, *learning function*=*levenberg marquardt*.
- *Activation function*=*logsig* untuk *hidden layer* dan fungsi *purelin* untuk *output layer*.
- *Random Devision* [*learning*=70%, *test*=15%, *eval*=15%]
- Dengan jumlah neuron =17
- *Error mse*=0,0015298
- Nilai parameter regresi $r_0=0,99971$, $b_0=0,0063306$, $m_0=0,99801$
- Iterasi berhenti pada *epochs* =394

Hal ini membuktikan bahwa hasil pemodelan kurva *user-defined* mampu dikembangkan lebih lanjut dengan perbaikan pada algoritma dan user interface yang lebih baik.

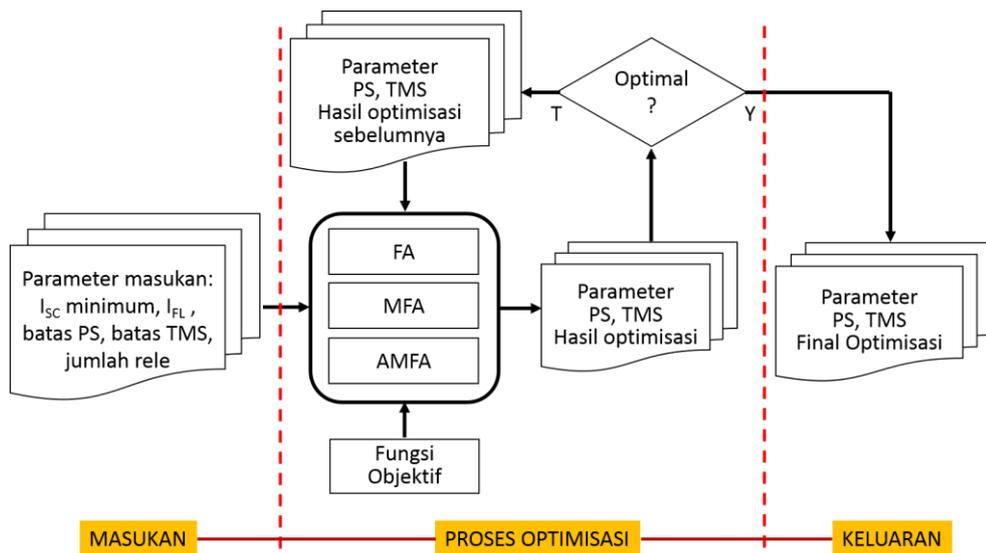
BAB V

OPTIMISASI PARAMETER SETING DOCR

5.1. Metode Optimisasi Parameter Seting *Digital Overcurrent Relay (DOCR)*

Setelah mendapatkan model kurva yang tertanam didalam rele dan secara mandiri pengguna mampu merancang kurva karakteristik yang dibutuhkan, penelitian selanjutnya adalah bagaimana melakukan optimisasi dari parameter-parameter seting yang dibutuhkan dalam suatu rele saat berkoordinasi dengan banyak rele dalam suatu jaringan distribusi.

Ide inovasi ini akan menghasilkan kontribusi pengurangan *stressing time* saat peralatan industri ter-aliri arus yang sangat besar yang terjadi saat ada gangguan dalam jaringan distribusi, hal ini terjadi karena nilai arus *plug setting (PS)* serta nilai *time multiplier seting (TMS)* yang digunakan sesuai hasil perhitungan manual belum dilakukan optimisasi. Gambar 5.1 adalah metode melakukan optimisasi dua parameter PS dan TMS menggunakan algoritma *firefly* dan modifikasinya yakni *modified firefly algorithm (MFA)* serta *adaptive modified firefly algorithm (AMFA)*.



Gambar 5.1. Metode Optimisasi Parameter Seting DOCR

Sebelum menjalankan program optimisasi dengan menggunakan algoritma MFA dan AMFA pengguna telah merencanakan sistem jaringan yang akan digunakan serta telah melakukan perhitungan sebagai bahan perhitungan data masukan pada program optimisasi meliputi data trafo, data kabel, unit pembangkit, beban, data trafo arus serta rele ang digunakan. Dari data-data tersebut selanjutnya digunakan untuk menghitung arus beban penuh (I_{FL}), arus hubung singkat I_{sc} minimal, batas waktu operasi *trip* rele, batas PS serta batas TMS yang akan menjadi data masukan program optimisasi, dengan nilai fungsi objektif ang telah ditetntukan pula.

Ide atau inovasi optimisasi dilakukan dengan cara melakukan modifikasi algoritma *firefly* standar dengan cara mengurangi nilai α dengan konstanta tertentu pada setiap iterasi yang terjadi yang selanjutnya disebut dengan MFA, serta dengan merubah secara adaptif nilai dari α pada setiap iterasi dengan menggunakan persamaan tertentu yang selanjutnya disebut dengan AMFA.

5.2. Optimisasi Parameter Seting DOCR menggunakan *Modified Firefly Algorithm* (MFA)

DOCR mempunyai parameter atau variabel penting untuk tujuan optimasi koordinasi yakni PS sebagai penentu operasi rele dan TMS untuk menentukan waktu operasi rele, oleh karenanya harus didapatkan nilai minimal untuk mendapatkan nilai koordinasi yang optimal dengan *Objective Function* sebagai berikut :

$$\text{minimize } (OF) = \sum_{j=1}^n W_j \cdot t_{j,k} \quad (5.1)$$

dengan:

n = jumlah rele

$t_{j,k}$ = waktu operasi kerja rele X_j saat ada gangguan di k .

W_j = nilai bobot yang menunjukkan probabilitas gangguan pada saluran

Karena probabilitas gangguan sama pada setiap saluran maka $W=1$, sedangkan waktu total pengoperasian rele diminimalkan dengan batasan-batasan tertentu, persamaan berikut memberikan batasan koordinasi:

$$t_{j,k} - t_{i,k} \geq \Delta t \quad (5.2)$$

dengan $t_{j,k}$ adalah waktu operasi rele cadangan untuk arus gangguan pada k, $t_{i,k}$ adalah waktu operasi rele utama untuk arus pada k, dan Δt adalah *clearing time interval* (CTI) dengan nilai dari 0,2 sampai 0,5s [24].

Waktu operasi rele juga memiliki kendala karena persyaratannya dalam waktu operasi minimum atau maksimum:

$$t_{j,min} \leq t_{j,k} \leq t_{j,max} \quad (5.3)$$

dengan $t_{j,min}$ adalah waktu operasi terkecil untuk rele j, sedangkan $t_{j,max}$ adalah waktu operasi maksimum untuk rele j.

Waktu operasi rele langsung dipengaruhi oleh TMS, oleh karena itu, kendala dapat ditunjukkan sebagai:

$$TMS_{j,min} \leq TMS_j \leq TMS_{j,max} \quad (5.4)$$

dengan $TMS_{j,min}$ adalah nilai optimum dalam TMS untuk rele j, dan $TMS_{j,max}$ adalah nilai optimum dalam TMS untuk rele j.

Persamaan berikut menunjukkan batas-batas PS pada setiap rele:

$$PS_{j,min} \leq PS_j \leq PS_{j,max} \quad (5.5)$$

dengan $PS_{j,min}$ adalah nilai terkecil untuk rele PS_j , dan $PS_{j,max}$ adalah nilai optimum untuk PS pada rele j.

Setiap rele memiliki karakteristik yang sama yaitu:

$$T_{j,m} = \frac{0,14}{\left(\frac{I_{j,m}}{PS}\right)^{0,02} - 1} \times TMS_j \quad (5.6)$$

dengan $I_{j,m}$ adalah arus yang melewati rele.

5.2.1. Modified Firely Algorithm (MFA)

Xin She Yang adalah pengusul *firely algorithm* (FA) di universitas Cambridge, yang terinspirasi oleh perilaku kunang-kunang. FA dapat digambarkan dengan tiga karakteristik:

- Dua kunang-kunang tertarik satu sama lain terlepas dari jenis kelamin mereka karena semua kunang-kunang adalah unisex.
- Daya tarik sebanding dengan kecerahannya, dimana kunang-kunang terang akan menarik kunang-kunang dengan lebih redup.
- Fungsi objektifnya adalah kecerahan kunang-kunang.

Dalam masalah minimisasi, *brightness firefly* memiliki fungsi obyektif yang lebih rendah. Secara matematis, daya tarik dapat ditunjukkan pada persamaan (5.7):

$$\beta(r) = \beta_0 e^{(-\gamma r^m)} \quad m \geq 1 \quad (5.7)$$

Dengan jarak antara dua kunang-kunang i dan j dihitung dengan jarak Cartesian adalah r , yang ditunjukkan pada persamaan (5.8) sebagai berikut:

$$r_{ij} = \|X_j - X_i\| = \sqrt{\sum_{m=1}^k (x_{j,m} - x_{i,m})^2}$$

$$X_j = [x_{j,1}, x_{j,2}, x_{j,3}, \dots, x_{j,k}]$$

$$X_i = [x_{i,1}, x_{i,2}, x_{i,3}, \dots, x_{i,k}] \quad (5.8)$$

Gerakan kunang-kunang dengan kecerahan yang lebih rendah (X_i) tertarik kepada kunang-kunang lain yang lebih terang (X_j) ditentukan oleh:

$$X_i = X_i + \beta_0 e^{(-\gamma r^m)} (X_j - X_i) + \alpha \varepsilon_i \quad (5.9)$$

dengan ε_i adalah nilai acak distribusi Gaussian. Dalam persamaan (5.9), menunjukkan bahwa pergerakan kunang-kunang terdiri dari tiga hal. Yang pertama, menggambarkan posisi sekarang dari kunang-kunang itu. Yang kedua, gerakan kunang-kunang dengan kecerahan rendah tertarik kepada kunang-kunang dengan kecerahan lebih tinggi. Yang ketiga, menggambarkan pergerakan acak kunang-kunang dengan nilai dari interval $[0,1]$.

Algoritma MFA ini diusulkan untuk menghilangkan kelemahan FA dengan meningkatkan keacakan kunang-kunang karena mempengaruhi kunang-kunang dalam eksplorasi solusi optimal. MFA mengurangi keacakan kunang-kunang dengan menggunakan parameter pengacakan α . Dalam proses FA, mutasi sederhana dari parameter pengacakan α sesuai dengan perubahan iterasi. Dalam setiap iterasi, parameter pengacakan α berkurang sebesar 0,001. MFA akan membantu dalam mendapatkan konvergensi dengan cepat. *Pseudo code* MFA ditunjukkan pada Gambar 5.2.

```

Fungsi obyektif  $f(x)$ ,  $x = (x_1, \dots, x_d)^T$ 
Buat populasi awal kunang-kunang  $x_i$  ( $i = 1, 2, \dots, n$ )
Intensitas cahaya  $I_i$  pada  $x_i$  ditentukan oleh  $f(x_i)$ 
Tetapkan koefisien penyerapan cahaya  $\gamma$ 
while ( $t <$  iterasi maksimum)
  for  $i = 1$ :  $n$  semua  $n$  kunang-kunang
    for  $j = 1$ :  $n$  semua  $n$  kunang-kunang
      if ( $I_j > I_i$ ), kunang-kunang  $i$  untuk  $j$  dalam  $d$  dimensi; end if
      Variasi banding ke jarak  $r$  melalui  $\exp[-\gamma r]$ 
      Perbaharui Nilai alfa melalui pengurangan dengan  $U$  tiap iterasi
      Evaluasi solusi baru dan intensitas cahaya yang diperbarui
    end j
  end i
  Atur kunang-kunang dan temukan yang terbaik saat ini
end while
Tampilkan hasilnya dari proses keseluruhan

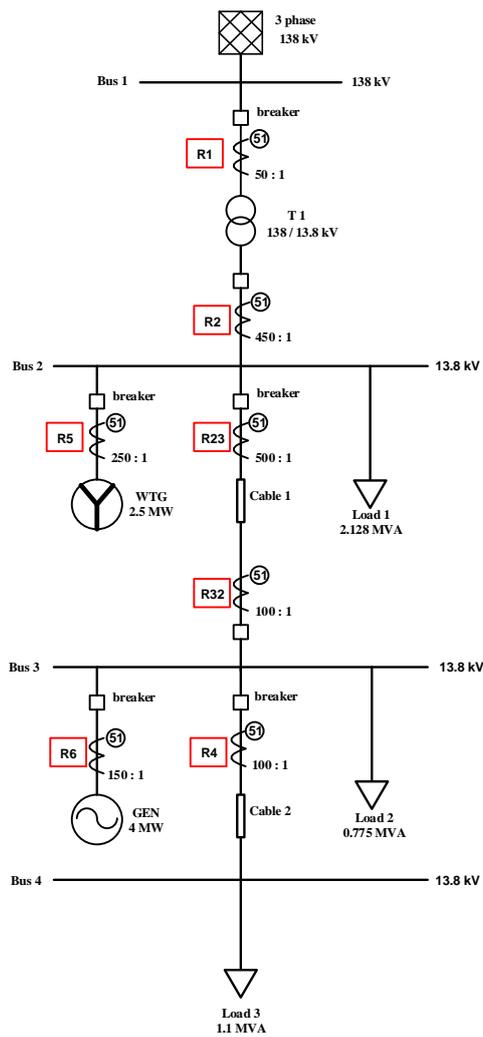
```

Gambar 5.2. Pseudo Code MFA

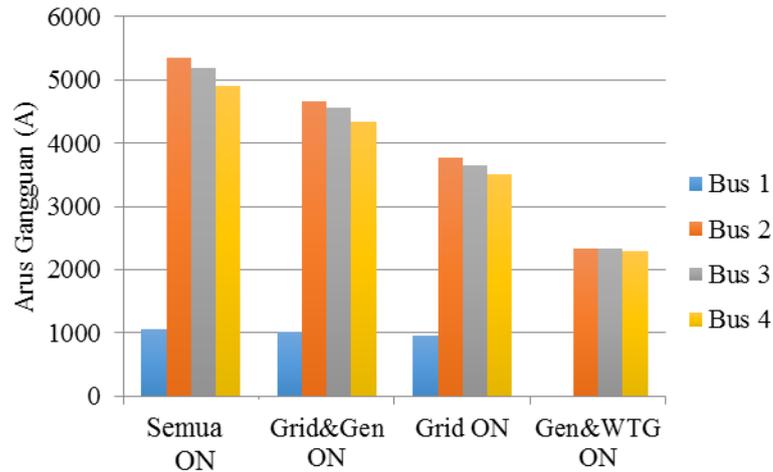
Algoritma yang diusulkan disimulasikan dalam jaringan radial, yang terdiri dari *grid*, *wind turbine generator* (WTG), generator, transformator 138 / 13,8 kV, 4 sistem bus dan 6 OCR seperti ditunjukkan pada Gambar 5.3. Daya masuk dari *grid* adalah 3 fasa 138 kV, dengan transformator menjadi 13,8 kV. Generator berkapasitas 4 MW dipasang di bus 3. Turbin angin dengan kapasitas 2,5 MW terpasang di bus 2. Sistem ini dilengkapi dengan 3 beban. Di dalam bus 2, beban 1 dipasang dengan kapasitas 2,218 MVA. Beban 2 dipasang dengan kapasitas 0,775 MVA di dalam bus 3. Beban 3 dipasang dengan kapasitas 1,1 MVA di bus 4. Algoritma yang diusulkan diimplementasikan pada empat kasus uji yang berbeda seperti pada Tabel 5.1, dimana perubahan sistem dengan adanya DG mempengaruhi pengaturan koordinasi proteksi dalam setiap kasus, hasil algoritma yang diusulkan dibandingkan dengan metode FA dan konvensional. Pada Gambar 5.4, ditunjukkan *fault current* dalam empat kondisi sistem yang berbeda untuk kesalahan tiga fasa pada setiap bus.

Tabel 5.1 Rincian Status Sumber pada Setiap Kasus

Kasus	Status		
	Grid	Generator	WTG
1	ON	ON	ON
2	ON	ON	OFF
3	ON	OFF	OFF
4	OFF	ON	ON



Gambar 5.3 Jaringan Radial untuk Uji Simulasi



Gambar 5.4 Arus *Fault* pada Setiap Bus

5.3. Performansi Optimisasi Menggunakan MFA

5.3.1. Kasus 1

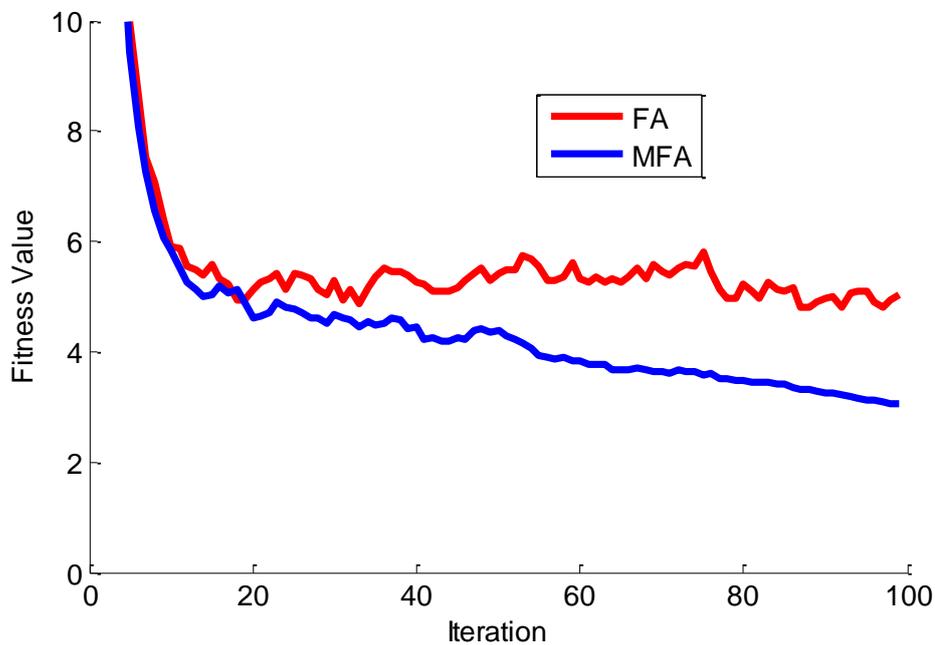
Uji performansi dilakukan dengan menggunakan jaringan radial pada Gambar 5.3, ujicoba pada kasus 1 adalah semua sumber ON dengan diberikan arus gangguan pada setiap bus seperti ditunjukkan pada grafik Gambar 5.4. Untuk gangguan pada bus 4, OCR R4 mewakili rele utama dan rele lainnya sebagai rele cadangan.

Pada Tabel 5.2 hasil ujicoba menunjukkan bahwa koordinasi optimal dengan menggunakan algoritma MFA memiliki *error* yang lebih kecil daripada algoritma FA, mengacu pada nilai *Objective Function* MFA 3.0528 detik dan FA 5.1253 detik. Secara total terjadi pengurangan sebesar 40,44% untuk semua rele jika dibandingkan antara MFA dengan FA. Ini menunjukkan bahwa perlindungan koordinasi dengan menggunakan MFA dalam kasus 1 lebih optimal daripada FA, MFA mengurangi waktu operasi FA secara signifikan. Pada Gambar 5.5 MFA memiliki konvergensi yang lebih cepat daripada FA. Nilai α akan mempengaruhi keakuratan optimasi karena pergerakan kunang-kunang acak yang lebar menghasilkan pergerakan yang tidak mengarah ke titik yang diinginkan atau tidak optimal. Dengan mengurangi nilai α akan meminimalkan pergerakan kunang-kunang, dan mempengaruhi kenaikan kecepatan konvergensi dan akurasi nilai optimal.

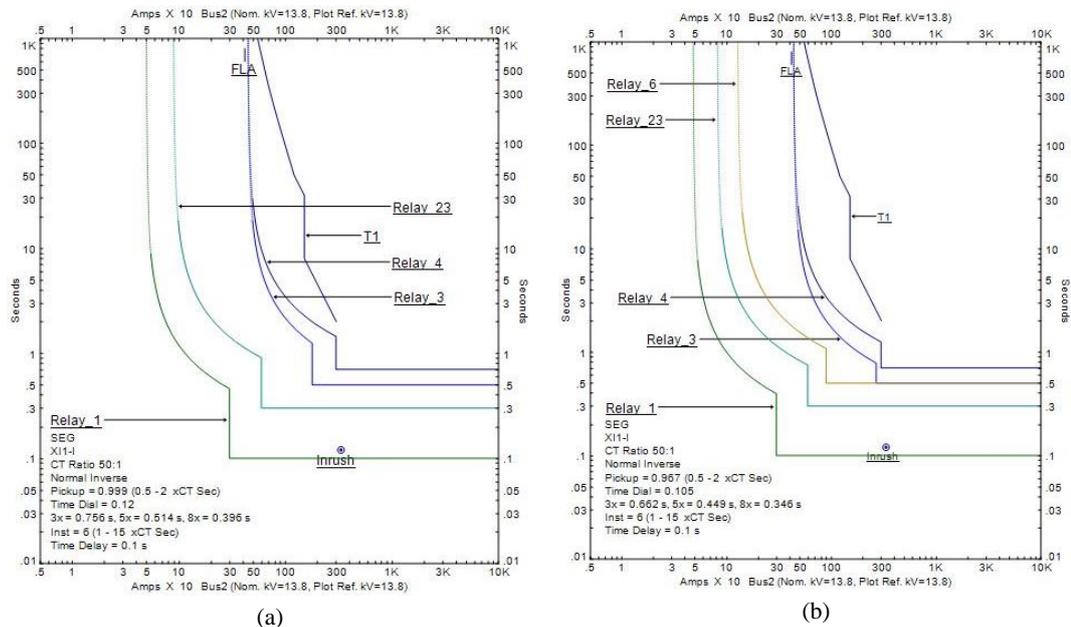
Pada Gambar 5.6 menunjukkan bahwa rele beroperasi pada urutan operasi relay primer dan cadangan untuk setiap lokasi kesalahan sehingga arus kesalahan dapat diisolasi dengan menggunakan waktu operasi rele yang optimum. Hasil ini menunjukkan bahwa algoritma MFA dapat menjamin keandalan dan kecepatan pengoperasian rele.

Tabel 5.2 Performansi dengan FA dan MFA pada Kasus 1

Rele	FA		MFA	
	PS	TMS	PS	TMS
R4	0,968	0,196	0,967	0,105
R32	0,825	0,328	0,824	0,216
R2	0,977	0,420	0,976	0,206
R1	0,882	0,494	0,879	0,350
R5	0,862	0,444	0,861	0,305
<i>Objective Function</i>	5,1253 detik		3,0528 detik	



Gambar 5.5 Kurva Konvergensi Kasus 1 antara FA dan MFA



Gambar 5.6 Hasil Koordinasi Kasus 1 (a) Konvensional (b) MFA

5.3.2. Kasus 2

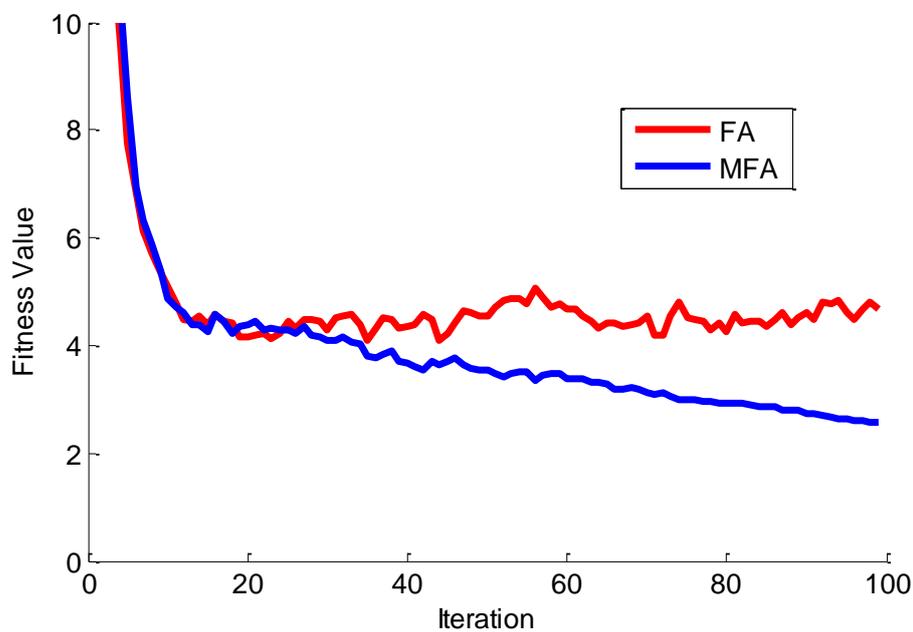
Dalam kasus 2, MFA diimplementasikan dalam sistem tanpa mengoperasikan WTG. Sistem ini memiliki arus gangguan yang lebih rendah daripada arus gangguan pada kasus 1. Untuk *fault* pada bus 4, OCR R4 mewakili rele primer dan rele lainnya sebagai rele cadangan. Pada Tabel 5.3 menunjukkan bahwa *error* pada koordinasi optimal dengan menggunakan MFA lebih rendah daripada FA. Nilai kesalahan mengacu pada nilai *Objective Function* MFA 2,5623 detik dan FA 4,0496 detik.

Pengurangan keseluruhan dari MFA untuk semua rele adalah 36,73% bila dibandingkan dengan FA. Ini menunjukkan bahwa perlindungan koordinasi dengan menggunakan MFA dalam kasus 2 lebih optimal daripada FA, dan MFA secara signifikan mengurangi masa operasi FA. Pada Gambar 5.7 algoritma MFA dengan memperbarui α memiliki konvergensi yang lebih cepat daripada FA. Nilai α mempengaruhi keakuratan pengoptimalan, karena pergerakan kunang-kunang acak yang besar menghasilkan gerakan yang tidak mengarah ke titik yang diinginkan atau tidak optimal. Dengan mengurangi nilai α akan meminimalkan pergerakan kunang-kunang, sehingga meningkatkan kecepatan konvergensi dan akurasi nilai

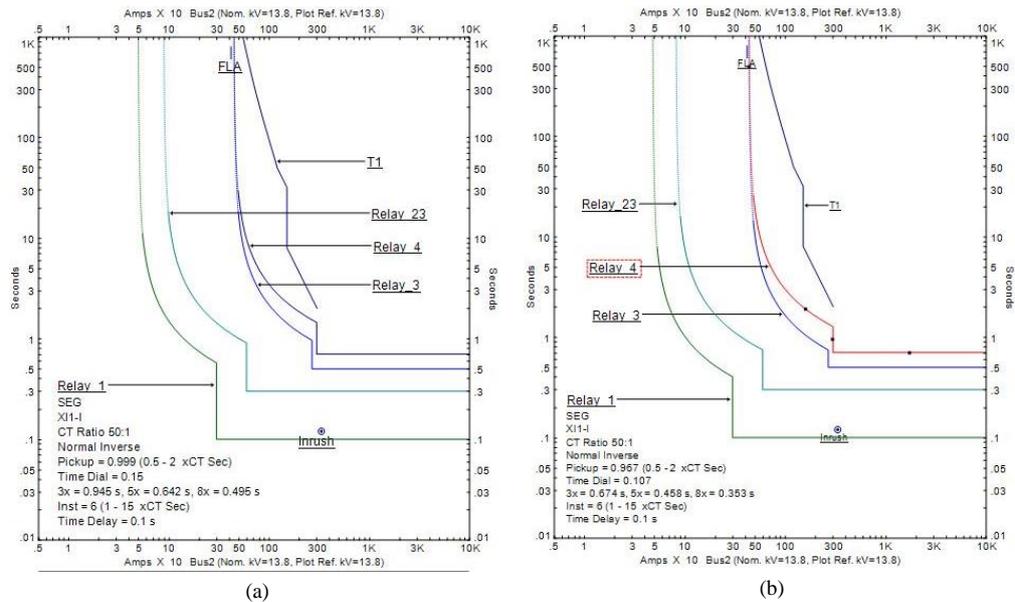
optimal. Pada Gambar 5.8 menunjukkan bahwa rele beroperasi dalam urutan operasi rele primer dan cadangan untuk setiap lokasi kesalahan sehingga arus *fault* dapat diisolasi menggunakan waktu operasi rele yang optimum. Hal ini menunjukkan bahwa algoritma MFA dapat menjamin keandalan dan kecepatan pengoperasian rele.

Tabel 5.3 Performansi FA dan MFA pada Kasus 2

Rele	FA		MFA	
	PS	TMS	PS	TMS
R4	0,970	0,276	0,967	0,107
R32	0,826	0,406	0,824	0,216
R2	0,977	0,383	0,976	0,196
R1	0,882	0,522	0,879	0,356
Objective Function	4,0496 detik		2,5623 detik	



Gambar 5.7 Kurva Konvergensi Kasus 2 antara FA dan MFA



Gambar 5.8 Hasil Koordinasi Kasus 2 (a) Konvensional (b) MFA

5.3.3. Kasus 3

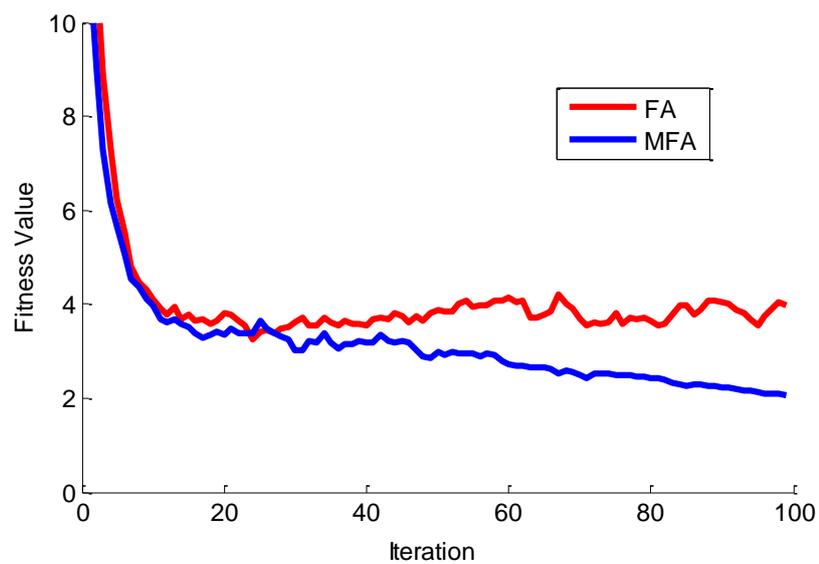
Dalam kasus 3, algoritma MFA diimplementasikan pada sistem dengan *grid* sedangkan generator dan WTG tidak dioperasikan. Untuk *fault* pada bus 4, OCR R4 mewakili rele utama dan rele lainnya sebagai rele cadangan. Pada Tabel 5.4, hasil menunjukkan bahwa koordinasi optimal dengan menggunakan MFA memiliki kesalahan yang lebih rendah daripada FA, dimana masing-masing nilai mengacu pada nilai *Objective Function* MFA 2,0805 detik dan FA 3,2166 detik.

Keseluruhan pengurangan algoritma MFA untuk semua rele adalah 35,31% dibandingkan dengan FA. Ini menunjukkan bahwa perlindungan koordinasi dengan menggunakan MFA dalam kasus 3 lebih optimal daripada penggunaan FA dan mengurangi secara signifikan waktu operasi FA. Pada Gambar 5.9, algoritma MFA dengan pembaharuan α memiliki konvergensi yang lebih cepat daripada waktu di FA. Nilai α mempengaruhi keakuratan optimasi karena pergerakan acak yang besar dari kunang-kunang menghasilkan pergerakan tidak mengarah ke titik yang diinginkan atau tidak optimal. Dengan mengurangi nilai α akan meminimalkan pergerakan kunang-kunang, dan mempengaruhi kenaikan kecepatan konvergensi dan akurasi nilai optimal. Pada Gambar 5.10, menunjukkan bahwa rele beroperasi dalam urutan operasi rele primer dan cadangan untuk setiap lokasi gangguan

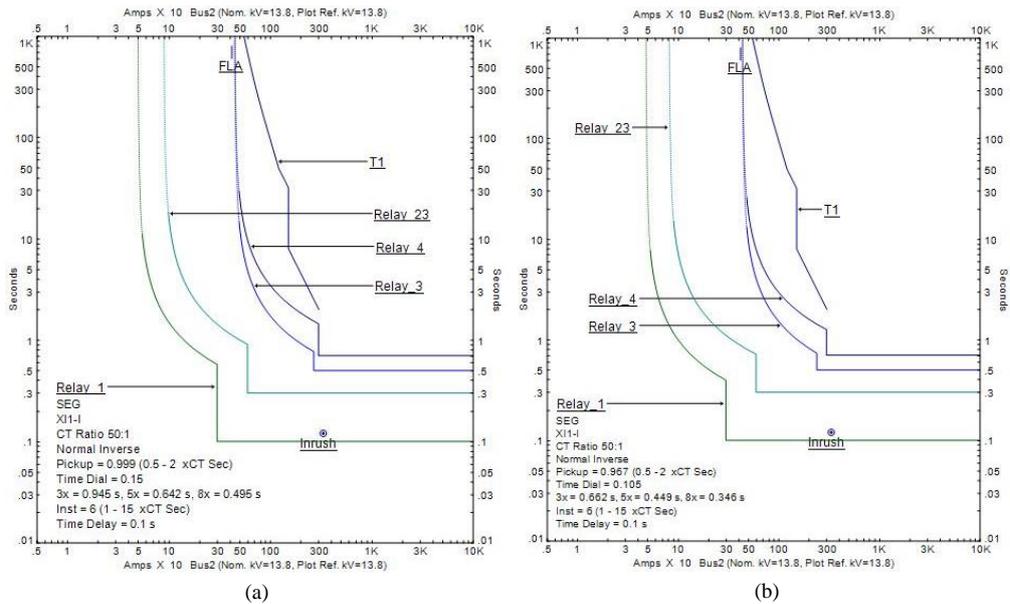
sehingga arus *fault* dapat diisolasi menggunakan waktu operasi rele yang optimum. Hasil penelitian menunjukkan bahwa algoritma MFA dapat menjamin keandalan dan kecepatan pengoperasian rele.

Tabel 5.4 Performansi dengan FA dan MFA pada Kasus 3

Rele	FA		MFA	
	PS	TMS	PS	TMS
R4	0,968	0,277	0,967	0,105
R32	0,825	0,385	0,824	0,201
R2	0,977	0,391	0,976	0,181
R1	0,882	0,554	0,879	0,352
Objective Function	3,2166 detik		2,0805 detik	



Gambar 5.9 Kurva Konvergensi Kasus 3 antara FA dan MFA



Gambar 5.10 Hasil Koordinasi kasus 3 (a) Konvensional (b) MFA

5.3.4. Kasus 4

Pada kasus 4, algoritma MFA diimplementasikan pada sistem tanpa *grid*. Sistem ini memiliki gangguan yang terkecil dari kasus lainnya. Untuk kesalahan pada bus 4, OCR R4 mewakili rele utama dan rele lainnya sebagai rele cadangan. Pada Tabel 5.5 menunjukkan bahwa *error* dalam koordinasi optimal dengan menggunakan algoritma MFA lebih rendah daripada kesalahan pada FA, yang masing-masing mengacu pada nilai *Objective Function* MFA 2,1091 detik dan FA 3,5764 detik. Secara keseluruhan dari algoritma MFA untuk semua rele adalah 41,03% dibandingkan dengan FA. Ini menunjukkan bahwa perlindungan koordinasi dengan menggunakan MFA dalam kasus 4 lebih optimal daripada penggunaan FA, dan MFA mengurangi secara signifikan waktu operasi FA.

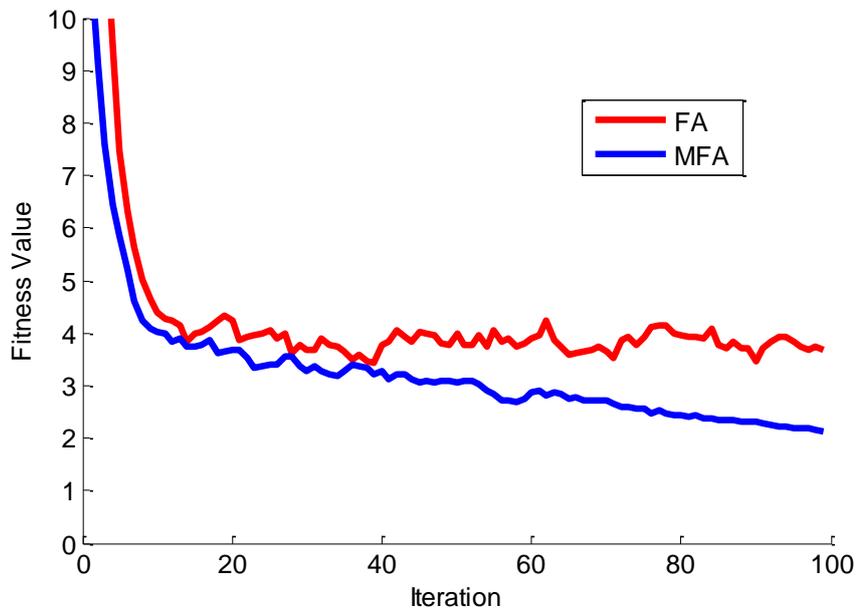
Pada Gambar 5.11 algoritma MFA dengan memperbarui α memiliki konvergensi yang lebih cepat daripada waktu dengan FA. Nilai α mempengaruhi keakuratan optimasi karena pergerakan kunang-kunang acak yang besar menghasilkan gerakan kunang-kunang tidak menuju titik yang diinginkan atau tidak optimal. Nilai α mempengaruhi keakuratan pengoptimalan, karena pergerakan kunang-kunang acak besar menghasilkan gerakan yang tidak mengarah ke titik yang diinginkan atau tidak optimal. Dengan mengurangi nilai α akan

meminimalkan pergerakan kunang-kunang, sehingga meningkatkan kecepatan konvergensi dan akurasi nilai optimal.

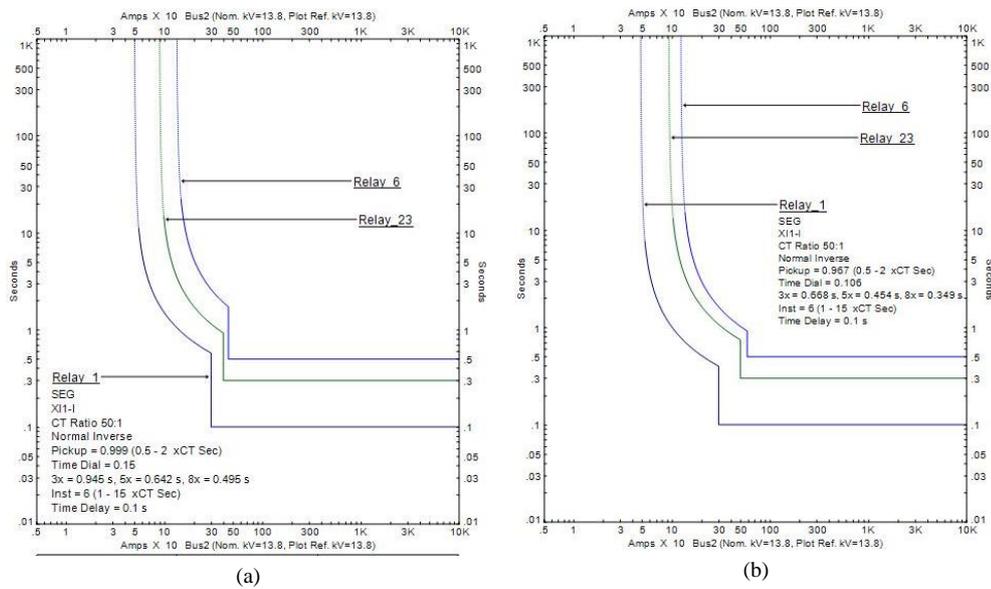
Pada Gambar 5.12 menunjukkan bahwa rele beroperasi pada urutan operasi rele primer dan cadangan untuk setiap lokasi kesalahan sehingga arus kesalahan dapat diisolasi menggunakan waktu operasi rele yang optimum. Hasil ini menunjukkan bahwa algoritma yang diusulkan dapat menjamin keandalan dan kecepatan pengoperasian rele.

Tabel 5.5 Performansi dengan FA dan MFA pada Kasus 4

Rele	FA		MFA	
	PS	TMS	PS	TMS
R4	0,970	0,293	0,967	0,106
R23	0,936	0,317	0,935	0,181
R6	0,828	0,364	0,827	0,207
Objective Function	3,5764 detik		2,1091 detik	



Gambar 5.11 Kurva Konvergensi Kasus 4 antara FA dan MFA



Gambar 5.12 Hasil Koordinasi Kasus 4 (a) Konvensional (b) MFA

Pada Tabel 5.6 dibandingkan antara algoritma MFA dengan metode konvensional untuk memastikan keandalan dan kecepatan operasi rele untuk mengisolasi area yang *fault* dan mengevaluasi kinerja algoritma MFA, hasilnya menunjukkan bahwa semua rele dalam algoritma MFA memiliki pengurangan waktu operasi rele untuk semua rele pada metode konvensional.

Oleh karena itu, MFA untuk koordinasi proteksi dapat mengurangi secara signifikan jumlah keseluruhan waktu operasi rele dibandingkan dengan metode konvensional pada sistem radial dengan DG, yang dapat mengurangi tegangan mekanik atau listrik pada peralatan listrik utama. Hasil optimisasi dalam setiap kasus diimplementasikan dalam jaringan secara riil dengan menyusun basis data dan mengoperasikan metode pencarian tabel. Kondisi sumber sebagai tabel pencarian input digunakan untuk mengetahui nilai TMS dan PS masing-masing rele.

Setelah berhasil mendapatkan nilai optimal setiap rele, perlu dilakukan penelitian lebih lanjut untuk menjalin koordinasi dengan banyak rele dengan menggunakan hasil optimisasi yang telah diperoleh, dan didukung oleh algoritma dan protokol komunikasi untuk membangun koordinasi terpusat atau otonom.

Tabel 5.6 Resume Performansi Optimisasi TMS dengan FA dan MFA

Kasus	Rele	Arus Gangguan (A)	Konvensioanl (s)	FA (s)	MFA (s)
Kasus 1	R1	300	0,460	0,738	0,395
	R32	600	0,905	1,134	0,746
	R3	2700	0,959	1,452	0,779
	R4	300	1,448	1,454	1,251
	R6	900	1,267	1,57	1,078
Kasus 2	R1	300	0,576	0,738	0,403
	R32	600	0,905	1,405	0,746
	R3	2700	0,959	1,450	0,742
	R4	300	1,448	1,869	1,272
Kasus 3	R1	300	0,576	1,043	0,395
	R32	600	0,905	1,328	0,715
	R3	1800	0,996	1,914	0,885
	R4	300	1,448	1,984	1,258
Kasus 4	R1	300	0,576	1,105	0,399
	R32	592	0,729	1,181	0,674
	R6	596,5	1,392	1,590	0,908

5.4. Optimisasi Parameter Seting DOCR menggunakan *Adaptive Modified Firefly Algorithm* (AMFA)

Berbagai metode telah diupayakan untuk memperbaiki kinerja FA. Dua parameter yang sering diatur adalah faktor pergerakan acak (α) dan koefisien penyerapan (γ). Namun, jika nilai ini dipilih secara tidak tepat maka terjadi kelambatan mencapai konvergensi, dan hasilnya tidak optimal dan mungkin terjebak dalam optima lokal.

Parameter α seperti yang telah disebutkan sebelumnya, memainkan peran penting dalam mengendalikan gerakan acak untuk mendapatkan solusi, dan umumnya mengambil nilai antara 0 dan 1. Nilai α yang tinggi akan memiliki tingkat akurasi yang rendah untuk mencari nilai optimal. Karena perpindahan acak kunang-kunang menjadi terlalu lebar sehingga gerakan kunang-kunang tidak mengarah ke titik yang diinginkan. Sebuah α kecil di sisi lain akan menghasilkan tingkat konvergensi yang baik untuk perpindahan kunang-kunang menuju ke titik yang diinginkan. Namun, jika nilai awal α diatur ke nilai kecil, maka α akan berkurang

menjadi nilai yang hampir sama dengan menghilangkan perpindahan acak dari kunang-kunang. Hal ini tidak diinginkan karena perpindahan acak membantu menemukan koordinasi yang lebih baik. Selain itu, mengurangi nilai α akan menghambat kemampuan untuk mendapatkan konvergensi maksimum karena nilai iterasi maksimum yang dikurangi, sehingga sulit untuk menemukan konvergensi.

Oleh karena itu, memodifikasi nilai α secara adaptif akan memecahkan masalah ini. Meskipun kunang-kunang memiliki nilai α acak, namun tetap bisa bergerak menuju titik optimal karena nilai α akan berubah sesuai jarak. Seiring jarak mendekati optimal, α akan menjadi lebih kecil untuk meminimalkan nilai acak.

Algoritma yang diusulkan bertujuan untuk secara dinamis menyesuaikan nilai α dalam iterasi dan menghilangkan kelemahan FA dengan mengelola α yang mempengaruhi kunang-kunang untuk mengeksplorasi koordinasi OCR yang optimal. Memiliki sifat adaptif seperti itu, algoritma yang diusulkan disebut *adaptive modified firely algorithm* (AMFA).

AMFA menjamin konvergensi yang lebih cepat untuk menemukan solusi optimum global. AMFA menurunkan pergerakan acak kunang-kunang dengan menerapkan faktor pergerakan acak α yang dikontrol secara adaptif sesuai dengan perubahan iterasi. Faktor pergerakan acak α diatur secara dinamis pada setiap iterasi dengan persamaan:

$$\alpha^{k+1} = \alpha^k \times \left(\frac{1}{2 \times k_{max}} \right)^{\frac{1}{k_{max+1}}} \quad (5.10)$$

k adalah urutan iterasi dan k_{max} adalah iterasi maksimum. Gambar 5.13 menunjukkan diagram alir AMFA.

Untuk melakukan implementasi ide inovasi AMFA seperti layaknya membangun program optimisasi pada umumnya yakni menentukan *Objective Function* yang menjadi sasaran akhir dari program optimisasi yang dikembangkan. Langkah berikutnya adalah melakukan inisialisasi kunang-kunang beserta definisi parameternya serta formulasi intensitas cahaya dan koefisien penyerapan cahaya.

Setelah beberapa parameter siap, langkah selanjutnya adalah melakukan inisialisasi lokasi kunang-kunang sebagai posisi awal dari kunang-kunang yang ada sebelum menjalankan iterasi berulang untuk mendapatkan nilai optimum.

Looping dimulai dengan pengaturan parameter *attractive* serta perpindahan posisi kunang-kunang dari i ke posisi j dengan variasi masing-masing kunang-kunang dengan jarak r , selanjutnya melakukan pengaturan secara adaptif parameter α pada setiap iterasi, setelah itu dilakukan perbaikan intensitas cahaya, demikian seterusnya hingga menemukan nilai optimal dengan batasan nilai iterasi sudah tercapai.

Dengan empat buah kasus diasumsikan bahwa sumber energi listrik akan berhenti beroperasi untuk beberapa saat, dengan konfigurasi yang berubah-ubah tersebut menuntut seting rele akan berubah pula dan setiap kasus dilakukan optimisasi nilai parameternya untuk semua rele yang beroperasi, dengan demikian kita telah siap dengan seting rele yang terkait dengan perubahan sumber secara otomatis.

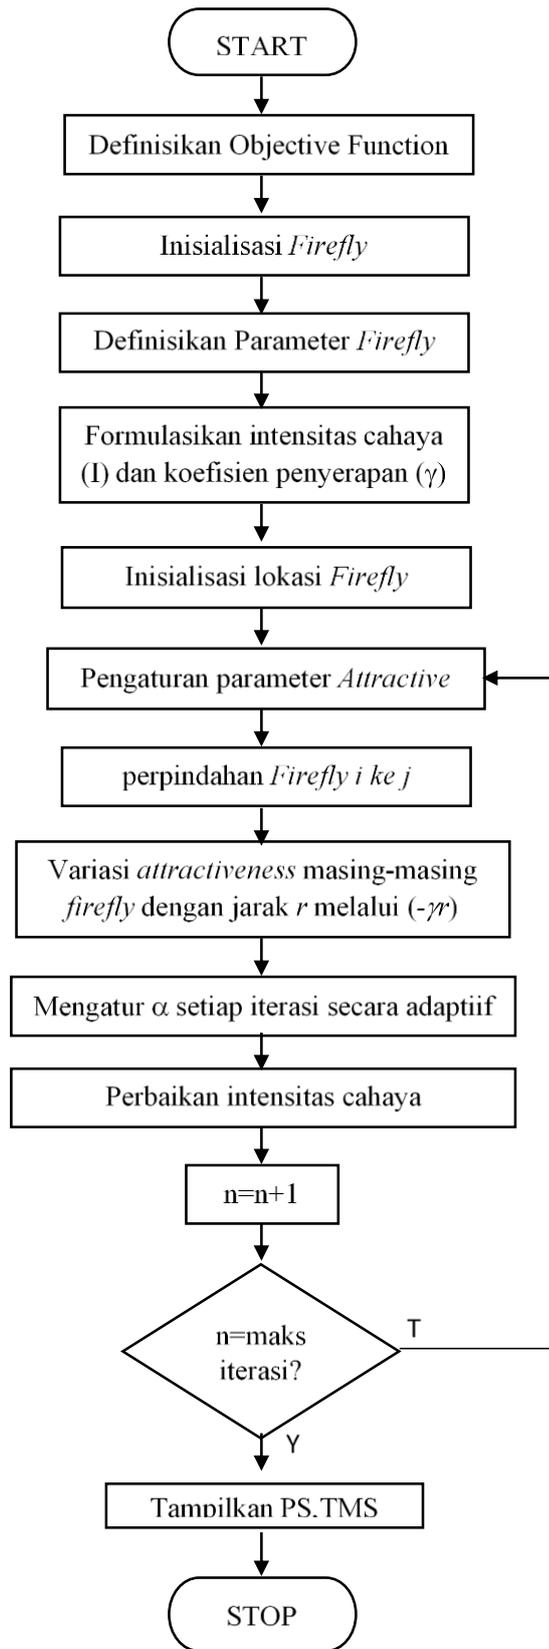
Dengan algoritma monitoring status sumber saat itu maka kendali terpusat akan melakukan instruksi kepada masing-masing rele untuk mempergunakan seting parameter yang sesuai dengan kondisi saat itu. Dengan demikian telah terbangun sistem rele yang bersifat adaptif terhadap perubahan kondisi sumber.

5.5. Performansi Optimisasi Menggunakan *Adaptive Modified Firefly Algorithm* (AMFA)

Ujicoba optimisasi dengan menggunakan algoritma AMFA dilakukan persis sama dengan saat melakukan ujicoba dengan MFA, baik dari topologi jaringan distribusi radial seperti ditunjukkan pada Gambar 5.3, kondisi sumber energi listrik menggunakan empat kasus seperti Tabel 5.1 serta arus gangguan yang diberika pada setiap kasus pada setiap bus seperti ditunjukkan pada Gambar 5.4.

Hasil ujicoba akan ditampilkan dengan membandingkan hasil optimisasi dengan menggunakan algortima FA, MFA serta AMFA untuk empat kasus yang berbeda.

Langkah-langkah yang ditempuh sama dengan saat ujicoba dengan menggunakan MFA, mulai dari ujicoba performansi, kurva konvergensi serta kurva hasil optimisasi secara keseluruhan dengan rele yang lain, sehingga dapat diketahui performansi dari ketiga jenis algoritma secara menyeluruh.



Gambar 5.13. Flowchart AMFA

5.5.1. Kasus 1

Pada kasus 1, algoritma AMFA diimplementasikan dengan kondisi *grid*, generator dan WTG ON. Kondisi tersebut menghasilkan kesalahan arus terbesar di antara kondisi lainnya. Tabel 5.7 menunjukkan hasil yang optimal dengan AMFA. Ada 5 OCR untuk koordinasi rele dengan R23 sebagai directional OCRs untuk mem-backup R1. Pada saat bus 4 diberi *fault*, hasilnya menunjukkan bahwa fungsi objektif untuk semua rele dengan AMFA lebih rendah dari FA dan MFA pada uji kasus 1 dengan nilai masing-masing 2,9915 detik, 5,1253 detik dan 3,0528 detik.

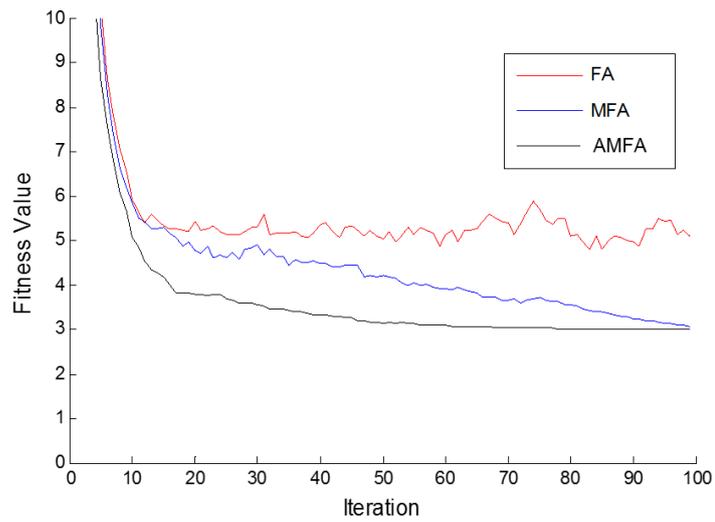
Pengurangan fungsi objektif untuk rele menggunakan metode AMFA adalah 41,63% lebih rendah dari pada FA. Ini menunjukkan bahwa AMFA untuk manajemen perlindungan dalam kasus uji 1 lebih optimal dan secara signifikan dapat mengurangi keseluruhan waktu operasi rele dibandingkan dengan FA pada jaringan DG radial.

Pada Gambar 5.14, tingkat konvergensi untuk algoritma yang diusulkan adalah konvergensi yang lebih cepat dibandingkan FA dan MFA. Koordinasi optimal OCR dengan AMFA ditunjukkan pada Gambar 5.15.

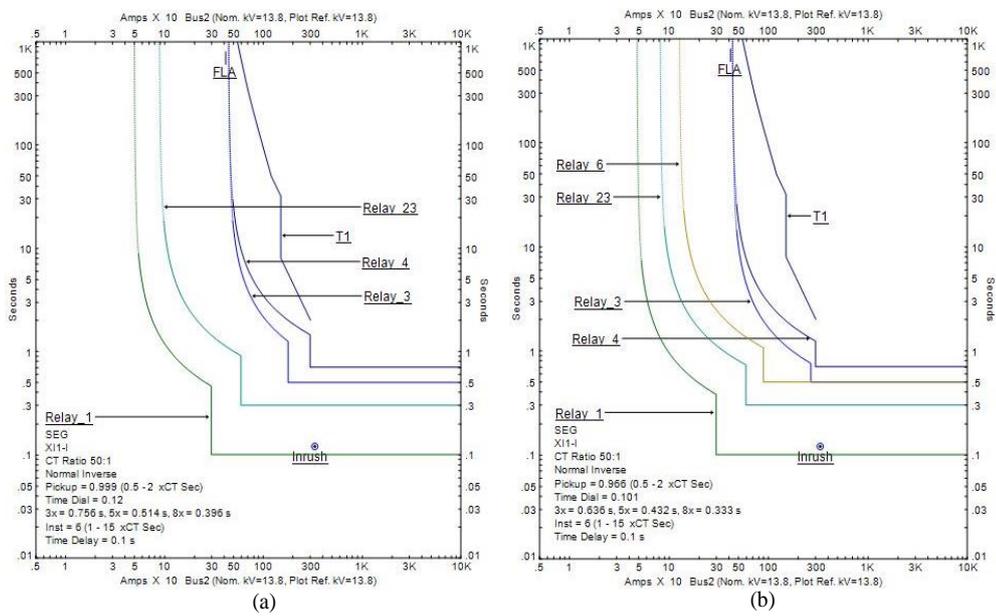
Skema proteksi koordinasi AMFA dapat membuat operasi rele dapat diandalkan dan selektif untuk mengisolasi arus gangguan yang dianggap baik dalam melindungi peralatan listrik.

Tabel 5.7 Performansi Perbandingan hasil FA, MFA dan AMFA pada Kasus 1

Rele	FA		MFA		AMFA	
	PS	TMS	PS	TMS	PS	TMS
R1	0,968	0,196	0,967	0,105	0,879	0,101
R23	0,825	0,328	0,824	0,216	0,824	0,211
R3	0,977	0,42	0,976	0,206	0,976	0,199
R4	0,882	0,494	0,879	0,350	0,879	0,346
R6	0,862	0,444	0,861	0,305	0,861	0,301
Objective Function	5,1253 detik		3,0528 detik		2,9915 detik	



Gambar 5.14 Kurva Konvergensi Kasus 1 dengan FA, MFA dan AMFA



Gambar 5.15 Hasil Koordinasi Kasus 1 (a) Konvensional (b) AMFA

5.5.2. Kasus 2

Pada kasus 2, AMFA diimplementasikan dengan kondisi WTG yang tidak beroperasi. Kondisi ini memberikan kesalahan arus lebih rendah daripada kesalahan pada kasus 1. Tabel 5.9 menunjukkan hasil yang optimal dengan AMFA. Ada 4 OCR untuk koordinasi rele dengan R23 sebagai directional OCRs untuk mem-backup R1. *Fault* pada bus 4, hasilnya menunjukkan bahwa fungsi objektif untuk semua rele metode yang diusulkan lebih rendah dari FA dan MFA dengan nilai masing-masing 2,5052 detik, 4,0496 detik dan 2,5623 detik.

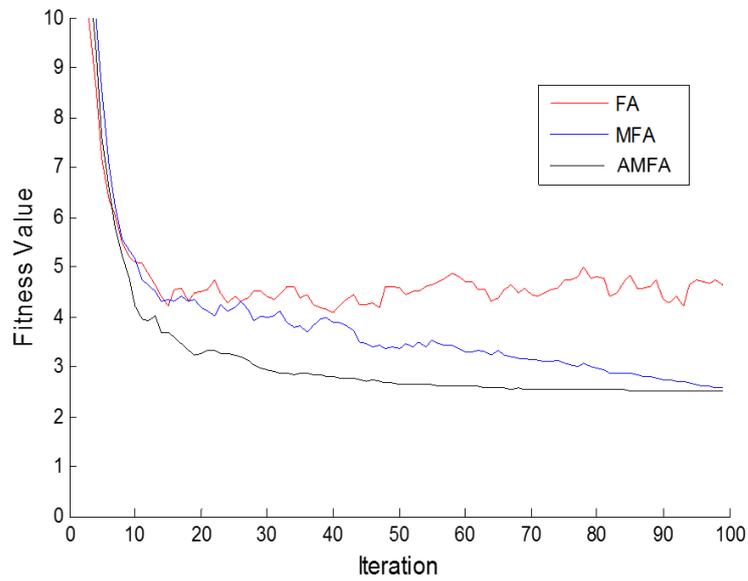
Pengurangan fungsi objektif untuk semua rele menggunakan AMFA mencapai 38,14% lebih rendah dari pada FA. Ini berarti bahwa AMFA untuk manajemen perlindungan dalam kasus 2 lebih optimal karena dapat mengurangi secara signifikan keseluruhan waktu operasi rele dibandingkan dengan FA di jaringan radial DG.

Pada Gambar 5.16, tingkat konvergensi dari metode yang diusulkan sangat cepat, sedangkan metode yang diusulkan memiliki konvergensi yang lebih cepat dibandingkan FA dan MFA. Koordinasi optimal OCR dengan metode yang diusulkan ditunjukkan pada Gambar 5.17.

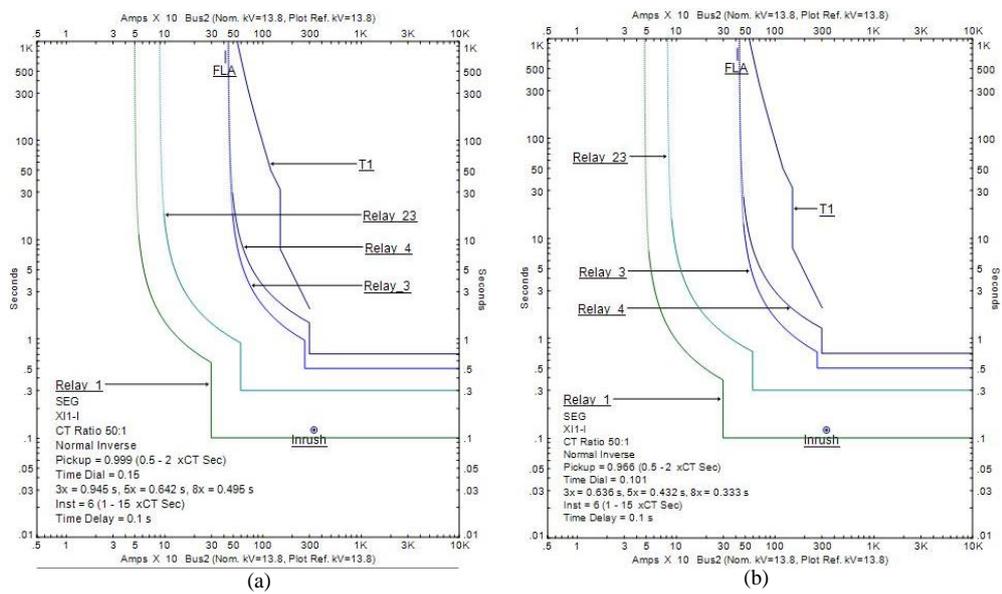
Skema proteksi koordinasi dengan AMFA mampu membuat operasi rele dapat diandalkan dan selektif untuk mengisolasi arus gangguan.

Tabel 5.9 Performansi Kasus 2 dengan FA, MFA dan AMFA

Rele	FA		MFA		AMFA	
	PS	TMS	PS	TMS	PS	TMS
R1	0,970	0,276	0,967	0,107	0,966	0,101
R23	0,826	0,406	0,824	0,216	0,824	0,211
R3	0,977	0,383	0,976	0,196	0,976	0,191
R4	0,882	0,522	0,879	0,356	0,879	0,351
Objective Function	4,0496 detik		2,5623 detik		2,5052 detik	



Gambar 5.16 Kurva Konvergensi Kasus 2 antara FA, MFA dan AMFA



Gambar 5.17 Hasil Koordinasi Kasus 2 (a) Konvensional (b) AMFA

5.5.3. Kasus 3

Pada kasus 3, AMFA diuji dalam kondisi pasokan yang hanya dari *grid* sedangkan generator dan WTG tidak dioperasikan. Kondisi ini untuk perlindungan koordinasi lebih sederhana daripada kasus uji lainnya.

Tabel 5.10 menunjukkan hasil koordinasi yang optimal dengan AMFA. Ada 4 OCR untuk koordinasi rele sedangkan R23 adalah directional OCRs untuk mem-backup R1. Pada kasus 3, rele 32 tidak aktif karena daya mengalir hanya dari satu arah. Pada *fault* bus 4, hasilnya menunjukkan bahwa fungsi objektif untuk semua rele dengan AMFA kurang dari FA dan MFA yang nilainya masing-masing 2,0237 detik, 3,2166 detik dan 2,0805 detik.

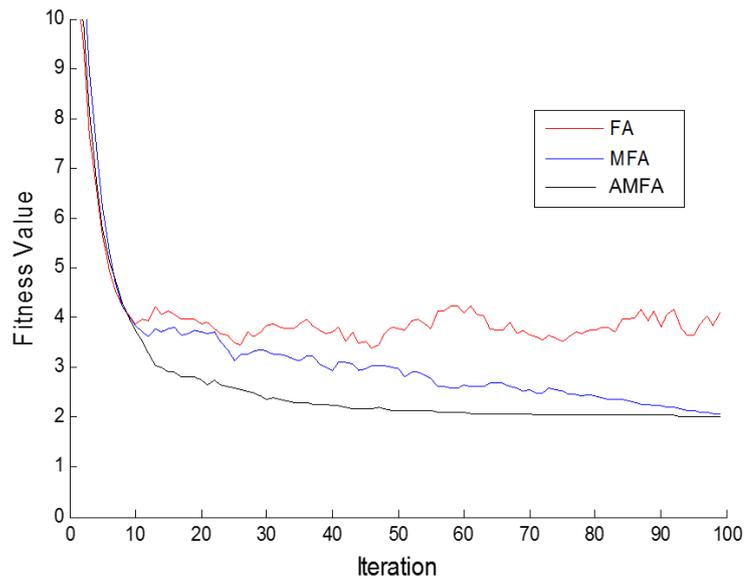
Pengurangan fungsi objektif untuk semua rele menggunakan AMFA mencapai 37,09% lebih rendah dari penggunaan FA. Ini menunjukkan bahwa AMFA untuk perlindungan dalam kasus 3 lebih optimal dan jumlah waktu operasi rele tanpa DG signifikan dibanding dengan FA pada jaringan radial.

Pada Gambar 5.18 tingkat konvergensi algoritma AMFA memiliki konvergensi yang lebih cepat dibandingkan FA dan MFA. Pengelolaan OCR yang optimal dengan AMFA ditunjukkan pada Gambar 5.19.

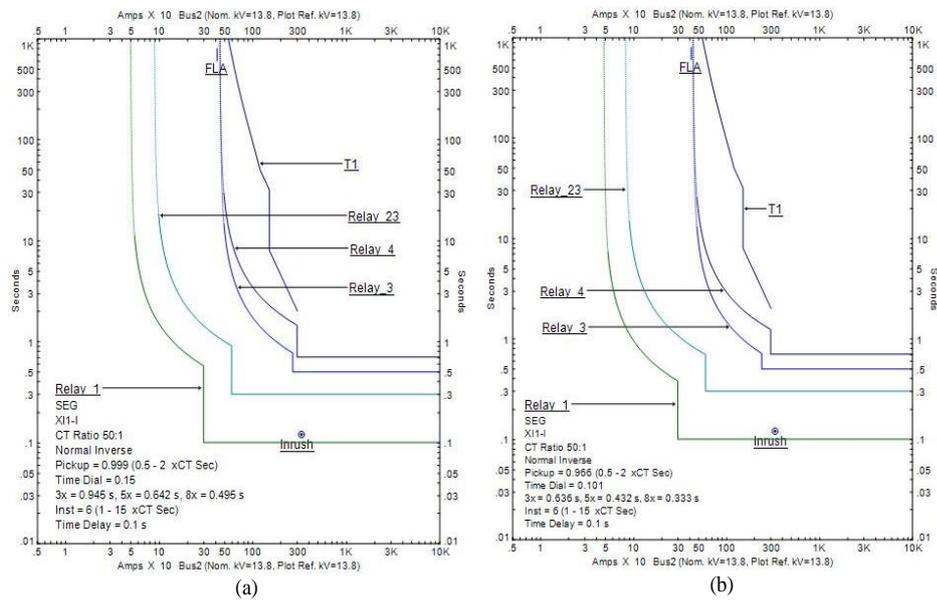
Skema proteksi koordinasi AMFA dapat memastikan keandalan dan operasi rele yang selektif untuk mengisolasi arus gangguan.

Tabel 5.10 Performansi Kasus 3 dengan FA, MFA dan AMFA

Rele	FA		MFA		AMFA	
	PS	TMS	PS	TMS	PS	TMS
R1	0,968	0,277	0,967	0,105	0,966	0,101
R23	0,825	0,385	0,824	0,207	0,824	0,201
R3	0,977	0,391	0,976	0,181	0,976	0,176
R4	0,882	0,554	0,879	0,352	0,879	0,346
<i>Objective Function</i>	3,2166 detik		2,0805 detik		2,0237 detik	



Gambar 5.18 Kurva Konvergensi Kasus 3 dengan FA, MFA dan AMFA



Gambar 5.19 Hasil Koordinasi Kasus 3 (a) Konvensional (b) AMFA

5.5.4. Kasus 4

Kasus 4 menunjukkan percobaan AMFA tanpa *grid*. Arus *fault* kurang dari kasus uji lainnya. Kondisi ini bergantung pada dua generator yang menjamin kelangsungan pasokan listrik. Tabel 5.11 menunjukkan hasil yang optimal dengan AMFA. Ada 3 OCR untuk koordinasi rele, R23 adalah *directional* OCRs untuk mem-backup R1. Pada saat *fault* di bus 4, hasilnya menunjukkan bahwa fungsi objektif untuk semua rele dengan AMFA kurang dari FA dan MFA yang masing-masing 2,0663 detik, 3.5764 detik dan 2.1091 detik.

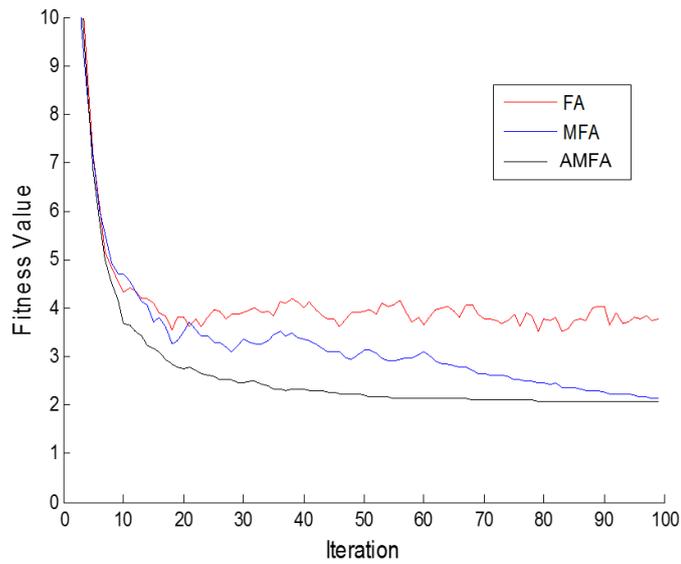
Pengurangan fungsi objektif untuk semua rele menggunakan AMFA 42,22% dibandingkan dengan FA. Hal ini menunjukkan bahwa AMFA untuk koordinasi proteksi pada kasus uji 4 lebih optimal dan dapat membuat semua operasi waktu rele lebih signifikan daripada FA di jaringan DG radial.

Pada Gambar 5.20 tingkat konvergen dari AMFA lebih cepat daripada waktu konvergensi dengan FA dan MFA. Pengelolaan OCR yang optimal dengan metode AMFA ditunjukkan pada Gambar 5.21.

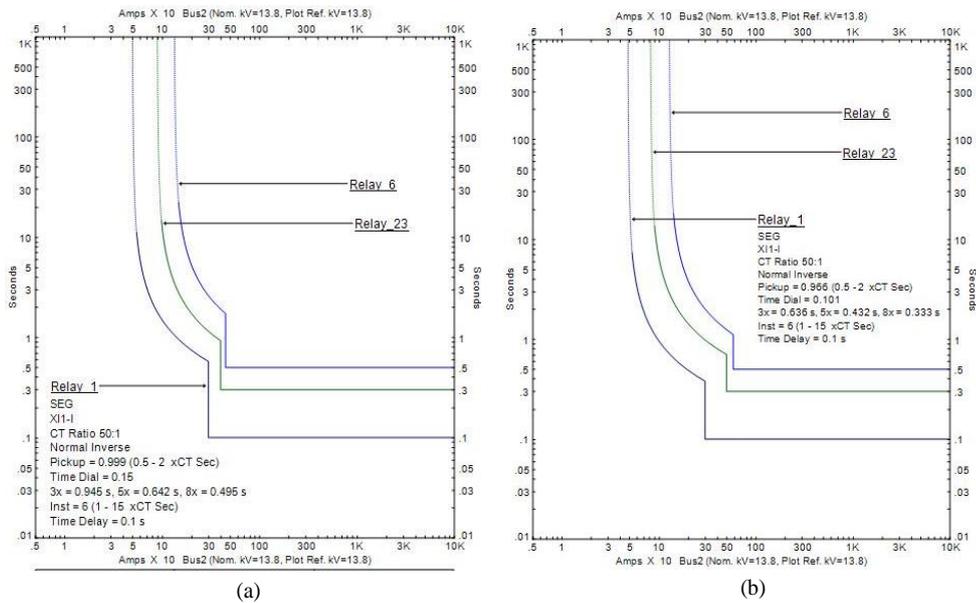
Skema proteksi koordinasi AMFA dapat memastikan operasi rele dapat diandalkan dan selektif untuk mengisolasi arus gangguan yang merupakan koordinasi proteksi yang baik.

Tabel 5.11 Performansi Kasus 4 antara FA, MFA dan AMFA

Rele	FA		MFA		AMFA	
	PS	TMS	PS	TMS	PS	TMS
R1	0,970	0,293	0,967	0,106	0,966	0,101
R23	0,936	0,317	0,935	0,181	0,935	0,176
R6	0,828	0,364	0,827	0,207	0,827	0,204
Objective Function	3,5764 detik		2,1091 detik		2,0663 detik	



Gambar 5.20 Kurva Konvergensi Kasus 4 algoritma FA, MFA dan AMFA



Gambar 5.21 Hasil Koordinasi Kasus 4 (a) Konvensional (b) AMFA

Tabel 5.12 ditunjukkan hasil simulasi dari semua rele yang menggambarkan pengurangan waktu operasi saat digunakan algoritma AMFA dibanding dengan metode konvensional. Ini menunjukkan bahwa metode yang diusulkan ketika digunakan untuk mengoptimalkan pengelolaan OCR dapat menurunkan secara

signifikan seluruh waktu operasi semua rele dibandingkan dengan skema konvensional pada jaringan DG radial.

Tabel 5.12 Performansi Total Menggunakan AMFA

Kasus	Rele	Arus Gangguan (A)	Konvensional (s)	Algorithm AMFA(s)
Kasus 1	R1	300	0,460	0,388
	R23	600	0,905	0,775
	R3	2700	0,959	0,767
	R4	300	1,448	1,253
	R6	900	1,267	1,093
Kasus 2	R1	300	0,576	0,388
	R23	600	0,905	0,757
	R3	2700	0,959	0,729
	R4	300	1,448	1,264
Kasus 3	R1	300	0,576	0,388
	R23	600	0,905	0,731
	R3	1800	0,996	0,718
	R4	300	1,448	1,253
Kasus 4	R1	300	0,576	0,388
	R23	592	0,729	0,678
	R6	596,5	1,392	1,155

BAB VI

KESIMPULAN DAN PENELITIAN SELANJUTNYA

6.1. Kesimpulan

1. Uji coba dengan menggunakan tiga jenis algoritma pemodelan kurva karakteristik rele telah berhasil di-*deploy* pada unit *microcontroller* sehingga menjadi prototipe *digital protection relay* dengan kurva berupa model yang ditanam pada unit *microcontroller*.
2. Pemodelan kurva menggunakan algoritma interpolasi Lagrange menghasilkan MSE minimum 0,000012 untuk kurva *Standard Inverse* dengan TMS=0,1 dan MSE maksimum 0,19175 untuk kurva *Long Time Inverse* dengan TMS=1,0, namun mempunyai kekurangan dalam hal penbenaman model di *microcontroller* dikarenakan harus menyertakan semua data kurva yang dibutuhkan saat eksekusi model.
3. Performansi pemodelan kurva menggunakan ANFIS mencapai MSE minimum 0,0000119 untuk kurva *Standard Inverse* dengan TMS=0,1 dan MSE maksimum 0,374 kurva *Long Time Inverse* dengan TMS=1,0 dengan epochs 1000 dan jumlah *membership function* MF=8, namun mempunyai kekurangan dalam ujicoba ini dikarenakan ANFIS bersifat *multi input single output* sehingga akan menambah memori saat model di-*deploy* di unit *microcontroller*.
4. Performansi pemodelan kurva menggunakan ANN dengan 30 *neuron* mencapai MSE minimum 0,000232 untuk kurva karakteristik *Standard Inverse* dengan TMS=0,1, karena bersifat *multi input* dan *multi output* sehingga hanya memerlukan sedikit memori untuk menyimpan model.
5. Dari hasil evaluasi secara keseluruhan terkait dengan penbenaman model di *microcontroller*, ANN lebih mempunyai peluang untuk dikembangkan karena *source code* memerlukan memori yang lebih kecil dan akan berdampak pada kecepatan akses dari model yang dihasilkan.
6. Dengan pertimbangan ANN lebih mempunyai peluang untuk dipilih sebagai algoritma pemodelan maka pada riset ini dikembangkan *direction digital protection relay* dengan fitur *user-defined characteristic curve*, dan telah menghasilkan performansi MSE=0,00010 untuk basis kurva *Very Inverse*.
7. *User-defined characteristic curve direction digital protection relay* merupakan suatu prototipe rele digital yang berhasil dibuat pada disertasi ini dengan kemampuan memodelkan kurva karakteristik

standar hingga pemodelan kurva gabungan *inverse* dan *definite time* dengan menggunakan neuron sejumlah 7 buah menghasilkan $mse=0,0015298$. Kurva-kurva yang telah dimodelkan disimpan didalam rele dan dapat dipilih sesuai kebutuhan saat itu dengan memanfaatkan perangkat komunikasi yang ada didalam rele sehingga mampu melakukan koordinasi baik dengan sesama rele maupun dengan *master control* sehingga menjadi rele digital yang bersifat adaptif.

8. Untuk kepentingan koordinasi dalam satu jaringan distribusi, parameter seting pada kurva-kurva rele yang terpasang dalam jaringan dsitribusi perlu dicari nilai yang optimum, kenaikan performansi dengan algortima AMFA dibanding algoritma FA mampu meningkatkan performansi hingga 42,22%.

6.2. Penelitian Selanjutnya

1. Riset lanjutan untuk topik *adaptive protection relay* adalah melakukan optimisasi parameter seting pada masing-masing rele yang ada didalam jaringan distribusi yang telah dimodelkan.
2. Riset lain yang juga akan dikembangkan adalah pemodelan koordinasi dari rele-rele yang terdapat dalam satu jaringan distribusi aktif, mengingat sumber energi dalam satu jaringan distribusi bersifat *intermitten* sehingga dibutuhkan perubahan seting parameter rele yang dinamis.

DAFTAR PUSTAKA

- [1] F. V. Edwards, G. J. Dudgeon, J. R. McDonald, and W. E. Leithead, "Dynamics of distribution networks with distributed generation," in Proc. IEEE PES Summer Meeting, 2000, pp. 1032–1037.
- [2] H. L. Willis and W. G. Scott, "Distributed Power Generation Planning and Evaluation", New York: Marcel Dekker, 2000.
- [3] N. Hadjsaid, J. Canard, and F. Dumas, "Dispersed generation impact on distribution networks," IEEE Computer Appl. Power, Vol. 12, pp. 22–28, April 1999.
- [4] Alexandre Oudalov and team members, "Novel protection systems for microgrids", WORK PACKAGE C: Alternative Designs for Microgrids, November 2009.
- [5] Razavi, F., Abyaneh, H.A., Al-Dabbagh, M., et al.: "A new comprehensive genetic algorithm method for optimal overcurrent relays coordination", Electr. Power Syst. Res., 2008, pp. 713–720
- [6] J. L. Blackburn and T. J. Domin, "Protective Relaying: Principles and Applications", Fourth Edition. CRC Press, 2015.
- [7] J. C. Tan, P. G. McLaren, R. P. Jayasinghe, and P. L. Wilson, "Software model for inverse time overcurrent relays incorporating IEC and IEEE standard curves," in Canadian Conference on Electrical and Computer Engineering, 2002. IEEE CCECE 2002, 2002, vol. 1, pp. 37–41 vol.1.
- [8] J. M. Gers and E. J. Holmes, "Protection of Electricity Distribution Networks", 3rd ed. The Institution of Engineering and Technology, 2011.
- [9] Y. G. Paithankar and S. R. Bhide, "Fundamentals of power system protection", PHI Learning Pvt. Ltd., 2010.
- [10] A. Tjahjono et al., "Modeling Characteristic Curves of Digital Overcurrent Relay (DOCR) for User-Defined Characteristic Curve Using Artificial Neural Network," in 2016 International Conference on Computational Science and Computational Intelligence (CSCI), 2016, pp. 478–483.
- [11] A. Tjahjono, A. Priyadi, M.H. Purnomo, M. Pujiantara, "Overcurrent Relay Curve Modeling Using Adaptive Neuro Fuzzy Inference System", IEEE Makassar International Conference on Electrical Engineering and Informatics, 2014
- [12] A. Tjahjono, D. O. Anggriawan, A. Priyadi, M. Pujiantara, and M. H. Purnomo, "Digital overcurrent relay with conventional curve modeling

- using Levenberg-Marquardt backpropagation," in 2015 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2015, pp. 171–176.
- [13] A. Tjahjono, D. O. Anggriawan, A. Priyadi, M. Pujiantara, and M. H. Purnomo, "Overcurrent relay curve modeling and its application in the real industrial power systems using adaptive neuro fuzzy inference system," in 2015 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA), 2015, pp. 1–6.
- [14] A. Tjahjono, D.O. Anggriawan, A. Priyadi, M. Pujiantara, M.H. Purnomo, "Digital Overcurrent Relay with Conventional Curve Modeling Using Levenberg Marquardt Backpropagation", IEEE International Seminar on Intelligent and Its Applications, 2015
- [15] A. Tjahjono, D.O. Anggriawan, A. Priyadi, M.H. Purnomo, M. Pujiantara, "Overcurrent Relay Curve Modeling and Its Application in the Industrial Power Systems Using Adaptive Neuro Fuzzy Inference System", IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications, 2015
- [16] A. Tjahjono, I. Sudiharto, Suryono, and D. O. Anggriawan, "Modelling non-standard over current relay characteristic curves using combined lagrange polynomial interpolation and curve fitting," in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 589–594.
- [17] P. J. Werbos, "Backpropagation through time: what it does and how to do it," *Proc. IEEE*, vol. 78, no. 10, pp. 1550–1560, 1990.
- [18] J. M. Zurada, "Introduction to artificial neural systems", vol. 8. West St. Paul, 1992.
- [19] M.-Y. Chow, "Methodologies of Using Neural Network and Fuzzy Logic Technologies for Motor Incipient Fault Detection". World Scientific, 1997.
- [20] M.-Y. Chow, R. N. Sharpe, and J. C. Hung, "On the application and design of artificial neural networks for motor fault detection. I," *IEEE Trans. Ind. Electron.*, vol. 40, no. 2, pp. 181–188, Apr. 1993.
- [21] Mo-yuen Chow, G. L. Bilbro, and Sui Oi Yee, "Application of learning theory to a single phase induction motor incipient fault detector artificial neural network," 1991, pp. 97–101.
- [22] D. E. Rumelhart, "Parallel Distributed Processing: Explorations in the Microstructure of Cognition", MIT Press, 1986.
- [23] M. A. Arbib, "The Handbook of Brain Theory and Neural Networks": Second Edition, 2nd ed. The MIT Press, 2002.

- [24] C. R. Alavala, "Fuzzy Logic and Neural Networks: Basic Concepts and Applications". New Age Publications (Academic), 2008.
- [25] L.-X. Wang, "Adaptive Fuzzy Systems and Control: Design and Stability Analysis", Englewood Cliffs, N.J: Prentice Hall, 1994.
- [26] A. M.A. (ed.), "Handbook of brain theory and neural networks", 2ed. MIT, 2003.
- [27] Bedekar, P.P., Bhide, S.R.: "Optimum coordination of directional overcurrent relays using the hybrid GA-NLP approach", IEEE Trans. Power Deliv., 2011, (1)
- [28] D. N. Vishwakarma and Z. Moravej, "ANN based directional overcurrent relay," in Transmission and Distribution Conference and Exposition, 2001 IEEE/PES, 2001, vol. 1, pp. 59–64 vol.1.
- [29] G. Cybenko, "Approximation by superpositions of a sigmoidal function," Math. Control Signals Syst. MCSS, vol. 2, no. 4, pp. 303–314, 1989.
- [30] J.-S. R. Jang, C.-T. Sun, and E. Mizutani, "Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence", Prentice Hall, 2014.
- [31] Abyaneh, H.A., Keyhani, R.: "Optimal coordination of overcurrent relays in power system by dual simplex method", Proc. AUPEC Conf., Perth, Australia, 1995, vol. 3, pp. 440–445
- [32] A.S. Noghabi, H.R. Mashhadi, J. Sadeh., "Optimal Coordination of Directional OCRs Considering Different Network Topologies Using Interval Linear Programming", IEEE Trans. Power Del. Jul. 2010
- [33] Bedekar, P.P., Bhide, S.R., Kale, V.S.: "Optimum time coordination of overcurrent relays in distribution system using big-M method", WSEAS Trans. Power Syst., 2009, (4)
- [34] Bedekar, P.P., Bhide, S.R., Vijay, S.K.: "Optimum coordination of overcurrent relay timing using simplex method", Electr. Power Compon. Syst., 2010, (10), pp. 1175–1193
- [35] Z. Moravej, F. Adelnia, F. Abbasi, "Optimal Coordination of Directional OCRs Using NSGA-II", Electric Power Systems Research 2015; 119:228-236
- [36] Zeineldin, H.H., Sharaf, H.M., Ibrahim, D.K., et al.: "Optimal protection coordination for meshed distribution systems with DG using dual setting directional over-current relays", IEEE Trans. Smart Grid, 2015, (1)
- [37] Thangaraj, R., Pant, M., Deep, K.: "Optimal coordination of overcurrent relays using modified differential evolution algorithms", Eng. Appl. Artif. Intell., 2010, pp. 820–829
- [38] Singh, M., Panigrahi, B.K., Abhyankar, A.R.: "Optimal coordination of directional overcurrent relays using teaching learning-based

- optimization (TLBO) algorithm", *Electr. Power Energy Syst.*, 2013, pp. 33–41
- [39] M. Pujiantara et al., "Optimization technique based adaptive overcurrent protection in radial system with DG using genetic algorithm," in *2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2016, pp. 83–88.
- [40] C.R. Chen, C.H. Lee, C.J. Chang, "Optimal Overcurrent Relay Coordination in Power Distribution System Using a New Approach", *Electrical Power and Energy Systems* 2013; 24:217-222
- [41] P.P. Bedekar, S.R. Bhide, "Optimum Coordination of Directional OCRs Using the Hybrid GA-NLP Approach", *IEEE Trans. Power Del.*, vol. 26, no. 1, Jan. 2011
- [42] P.P. Bedekar, S.R. Bhide, "Optimum Coordination of Overcurrent Relay Timing Using Continuous Genetic Algorithm", *Expert Systems with Applications* 2011; 38:11286-11292
- [43] P.P. Bedekar, S.R. Bhide, V.S. Kale, "Optimum Time Coordination of OCRs in Distribution System Using Big-M Method", *WSEAS Trans. Power Sys.* Iss. 4 Vol. 4, Nov. 2009
- [44] R. Mohammadi, H. A. Abyaneh, F. Razavi, M. Al-Dabbagh, S.H.H. Sadeghi, "Optimal Relays Coordination Efficient Method in Interconnected Power Systems", *Journal of Electrical Engineering*, Vol. 61, No. 2, pp. 75-83, 2010
- [45] R. Thangaraj, M. Pant, K. Deep, "Optimal Coordination of OCRs Using Modified Differential Evolution Algorithms", *Engineering Applications of Artificial Intelligence* 2010; 23:820-829
- [46] F. Razavi, H. A. Abyaneh, M. Al-Dabbagh, R. Mohammadi, H. Torkaman, "A New Comprehensive Genetic Algorithm Method for Optimal Overcurrent Relays Coordination", *Electric Power Systems Research* 2008; 78:713-720
- [47] A.K. Fard, T. Niknam, "Optimal Stochastic Capacitor Placement Problem from the reliability and cost Views Using FA", *IET Sci. Meas. Technol.*, 2014, vol. 8, Iss. 5, pp. 260-269
- [48] Zellagui, M., Benabid, R., Boudour, M., et al.: "Application of FA for optimal coordination of directional overcurrent protection relays in presence of series compensation", *J. Autom. Syst. Eng.*, 2014, 8, (2), pp. 92–107
- [49] Yang, X.S.: "FA, levy flights and global optimization", "Research and development in intelligent systems XXVI", Springer, London, UK, 2010, pp.209–218
- [50] X.S. Yang, "FA, Levy Flights and Global Optimization", in *Research and Development in Intelligent Systems XXVI*, pp. 209-218, Springer, London, UK, 2010

- [51] S.S. Gokhale, V.S. Kale, "Application of the FA to Optimal Overcurrent Relay Coordination", IEEE International Conference on Optimization of Electrical and Electronic Equipment, 2014
- [52] Gokhale, S.S., Kale, V.S.: "Application of the FA to optimal overcurrent relay coordination". IEEE Int. Conf. on Optimization of Electrical and Electronic Equipment, 2014
- [53] S. Goel, V.K. Panchal, "Performance Evaluation of a New MFA", IEEE International Conference on Reliability, Infocom Technologies and Optimization, 2014
- [54] M.H. Sulaiman, H. Daniyal, M.W. Mustafa, "MFA in Solving Economic Dispatch Problems with Practical Constraints", IEEE International Conference on Power and Energy, 2012
- [55] A. Tjahjono, D. O. Anggriawan, A. K. Faizin, A. Priyadi, M. Pujiantara, and M. H. Purnomo, "Optimal Coordination of Overcurrent Relays in Radial System with Distributed Generation Using Modified Firefly Algorithm," *Int. J. Electr. Eng. Inform.*, vol. 7, no. 4, p. 691, 2015.
- [56] N. A. Windarko, A. Tjahjono, D. O. Anggriawan, and M. H. Purnomo, "Maximum power point tracking of photovoltaic system using adaptive modified firefly algorithm," in 2015 International Electronics Symposium (IES), 2015, pp. 31–35.
- [57] S. D. Nugraha, E. Wahjono, E. Sunarno, D. O. Anggriawan, E. Prasetyono, and A. Tjahjono, "Maximum power point tracking of photovoltaic module for battery charging based on modified firefly algorithm," in 2016 International Electronics Symposium (IES), 2016, pp. 238–243.
- [58] A. Tjahjono, M. Pujiantara, J. Taufik, M. H. Purnomo, and others, "Adaptive Modified Firefly Algorithm for Optimal Coordination of Overcurrent Relays," *IET Gener. Transm. Distrib.* vol. 11, Issue no. 7, DOI: 10.1049/iet-gtd.2016.1563 2017.
- [59] H. A. Darwish, A. I. Taalab, and H. Assal, "A novel overcurrent relay with universal characteristics," in Transmission and Distribution Conference and Exposition, 2001 IEEE/PES, 2001, vol. 1, pp. 53–58 vol.1.
- [60] IEEE Standard Inverse-Time Characteristic Equations for OCRs, IEEE Std. C37.112-1996
- [61] G. Benmouyal, "Design of a digital multi-curve time-overcurrent relay," *IEEE Trans. Power Deliv.*, vol. 5, no. 4, pp. 1725–1731, Oct. 1990.
- [62] G. V. Kshirsagar, G. N. Mulay, and S. Yeolekar, "TMS320F28335 based single phase overcurrent protection Implementation using Numerical Relay," in 2014 6th IEEE Power India International Conference (PIICON), 2014, pp. 1–5.

- [63] H. A. Darwish, M. A. Rahman, A. I. Taalab, and H. Shaaban, "Digital model of overcurrent relay characteristics," in , Conference Record of the 1995 IEEE Industry Applications Conference, 1995. Thirtieth IAS Annual Meeting, IAS '95, 1995, vol. 2, pp. 1187–1192 vol.2.
- [64] K. Balasubramanian, "EPROM-based overcurrent relays," in ,Proceedings of the Thirty-Eighth IEEE Holm Conference on Electrical Contacts, 1992, 1992, pp. 203–207.
- [65] K. Shehata, A. Bahaa, K. Morad, and A. Sharaf, "Design and implementation of FPGA based and microcontroller based current relay," in The 16th International Conference on Microelectronics, 2004. ICM 2004 Proceedings, 2004, pp. 783–786.
- [66] Y. L. Goh, A. K. Ramasamy, A. A. Z. Abidin, and F. H. Nagi, "Modelling of overcurrent relay using digital signal processor," in 2010 IEEE Symposium on Industrial Electronics Applications (ISIEA), 2010, pp.367–370.
- [67] H. A. Abyaneh, H. K. Karegar, and M. Al-Dabbagh, "Interpolation of measured data based on neural network to model overcurrent relays in power systems," in Control Conference, 2004. 5th Asian, 2004, vol. 3, p. 1393–1397 Vol.3.
- [68] S.A. Gopalan, V. Sreeram, H.H.C. Lu, "A Review of Coordination Strategies and Protection Schemes for Microgrids", *Renewable and Sustainable Energy Reviews* 2014; 32: 222-228
- [69] A.-M. Borbely and J. F. Kreider, "Distributed generation: the power paradigm for the new millennium", CRC press, 2001.
- [70] A. R. Bergen and V. Vittal, "Power Systems Analysis [OCR]", 2nd ed. 1999.
- [71] C. R. Mason, "The Art and Science of Protective Relaying". Wiley, 1967.
- [72] L. L. Grigsby, "Electric Power Generation, Transmission, and Distribution", Third Edition, 3rd ed. CRC Press, 2012.
- [73] Lazar Irwin, "Electrical Systems Analysis and Design for Industrial Plants", McGraw-Hill Book Company, 1980

BIOGRAFI PENULIS



IDENTITAS DIRI

Nama : Anang Tjahjono
NIP : 196411191988031001
NIDN : 0019116404
Tempat dan Tanggal Lahir : Ponorogo/19 Nopember 1964
Golongan / Pangkat : IVc/Pembina Utama Muda
Jabatan Fungsional Akademik : Lektor Kepala
Pekerjaa : Dosen Politeknik Elektronika Negeri Surabaya
URL : <http://www.pens.ac.id>
Alamat : Jl. Raya ITS Keputih Sukolilo Surabaya 60111
Telp./Faks. : 031-5947280 / 031-5946114
Alamat Rumah : Delta Sari Indah AD-61 Waru Sidoarjo
Telp./Faks. : 0811370853
Alamat e-mail : anang.tj@pens.ac.id
Nama Istri : Nurudducha
Nama Anak : Fawaati Tsabita
Naufal Rasyiq

RIWAYAT PENDIDIKAN PERGURUAN TINGGI

Tahun Lulus	Jenjang	Perguruan Tinggi	Jurusan/ Bidang Studi
1986	Diploma III	Institut Teknologi Sepuluh Nopember Surabaya	Teknik Elektro/ Layanan Industri
1990	Strata 1 (S1)	Institut Teknologi Sepuluh Nopember Surabaya	Teknik Elektro/ Elektronika
1999	Strata 2 (S2)	Institut Teknologi Sepuluh Nopember Surabaya	Teknik Elektro/ T. Sistem Pengaturan

PENGALAMAN JABATAN

Jabatan	Institusi	Tahun ... s.d. ...
Kepala Spare Part Center	Politeknik Elektronika Negeri Surabaya	1992-1993
Kaprodi Elektronika	Politeknik Elektronika Negeri Surabaya	1993-1996
Pembantu Direktur IV	Politeknik Elektronika Negeri Surabaya	2000-2001
Pembantu Direktur IV	Politeknik Elektronika Negeri Surabaya	2001-2005
Pembantu Direktur II	Politeknik Elektronika Negeri Surabaya	2005-2009
Direktur PSMK	Kementerian Pendidikan & Kebudayaan RI	2012-2013

PENGALAMAN PENELITIAN

Tahun	Judul Penelitian	Jabatan	Sumber Dana
1995	Pengaturan Kecepatan Pada DC Brushless Motor Dengan Metode	Ketua	SPP PENS

	PWM Berbasis Mikrokontroler		
1996	Pengembangan Computer Based Development Tool untuk Kontroler Logika Fuzzy Standar Industri.	Peneliti	Direktorat P2M DIKTI (Hibah Bersaing V-1)
1997	Optimasi Pengaturan Proses Kristalisasi Minyak Kelapa Sawit Berbasis Lengkung Kurva Kristalisasi Standar	Ketua	Proyek Pengembangan Pendidikan Politeknik
1998	Pengembangan Computer Based Development Tool untuk Kontroler Logika Fuzzy Standar Industri.	Peneliti	Direktorat P2M DIKTI (Hibah Bersaing V-2)
1999	Rancang Bangun Modul Praktikum Elektronika Terapan Untuk Peningkatan Kemampuan Perancangan Sistem Kendali Industri Nyata Berbasis Mikrokontroler MCS- 51	Ketua	ADB Loan No. 1432-Ino
1999	Rancang Bangun Kontrol Logika Fuzzy dengan Perubahan Fungsi Keanggotaan Untuk Pengaturan Suhu Pada Kolom Pemanas.	Ketua	PENS
2010	Rancang Bangun Sistem Monitoring Dan Kendali Kualitas Air di Sungai Secara Online dengan Wireless Sensor Network (WSN) Untuk Industri Pengolahan Air Minum di PDAM	Ketua	MenRistek
2015	Prototipe Digital Protection Relay Sebagai Intelligent Electronic Device pada Sistem Distribusi Microgrid	Peneliti	Kemenristek Dikti (PUPT)
2016	Prototipe Digital Protection Relay Sebagai Intelligent Electronic Device pada Sistem Distribusi Microgrid	Peneliti	Kemenristek Dikti (PUPT)
2016	Disain Prototipe Monitoring dan Deteksi Dini Kerusakan Trafo Daya Secara Online pada Jaring Penyaluran Daya Listrik PLN dan Industri Berbasis Kecerdasan Komputasional	Peneliti	Kemenristek Dikti (STRANAS)
2016	Pemodelan Kurva Unconventional Overcurrent Digital Protection Relay Menggunakan Kombinasi Lagrange Dan Anfis	Ketua	Kemenristek Dikti (Hibah Bersaing)
2017	Pemodelan Kurva Unconventional Overcurrent Digital Protection Relay Menggunakan Kombinasi Lagrange Dan Anfis	Peneliti	Kemenristek Dikti (Penelitian Produk Terapan)

KARYA TULIS ILMIAH (Jurnal)

Tahun	Judul	Penerbit/Jurnal
2011	Anang Tjahjono, Joke Pratilastiarso, Syechu DN, Doni P, Rancang Bangun Building Automation System Dengan Menerapkan Kontrol Logika Fuzzy untuk mendapatkan Efisiensi Daya Dari beban Kipas Angin, Lampu dan Air Conditioner Journal of Emitter Vol: 02/02 Tahun Terbit Desember 2011 Penerbit EEPIS	PENS
2011	Anang Tjahjono, Entin Martiana, Taufan Harsilo A, Penerapan Adaptive Neuro Fuzzy Inference System (ANFIS) untuk Sistem Pengambilan Keputusan Distribusi Obat pada Sistem Informasi Terintegrasi Puskesmas dan Dinas Kesehatan. Journal of Emitter Vol:02/02 Tahun Terbit Desember 2011 Penerbit EEPIS	PENS
2015	E. Prasetyono, W. Ashary, A. Tjahjono, and N. A. Windarko, "Studi Komparasi Fungsi Keanggotaan Fuzzy sebagai Kontroler Bidirectional DC-DC Converter pada Sistem Penyimpan Energi," J. Nas. Tek. ELEKTRO, vol. 4, no. 2, 2015.	Jurusan T.Elektro, Fakultas Teknik, Universitas Andalas, Padang
2015	A. Tjahjono, D. O. Anggriawan, A. K. Faizin, A. Priyadi, M. Pujiantara, and M. H. Purnomo, "Optimal Coordination of Overcurrent Relays in Radial System with Distributed Generation Using Modified Firefly Algorithm," Int. J. Electr. Eng. Inform., vol. 7, no. 4, p. 691, 2015.	School of Electrical Engineering and Informatics, ITB, Indonesia.
2016	M. Pujiantara, D. O. Anggriawan, A. Tjahjono, D. Permadi, A. Priyadi, and M. H. Purnomo, "A Real-Time Current Harmonic Monitoring System Based on Stockwell Transform Method," Int. Rev. Electr. Eng. IREE, vol. 11, no. 2, pp. 193–199, 2016.	IREE
2017	I. Sudiharto, D. O. Anggriawan, and A. Tjahjono, "Harmonic Load Identification Based On Fast Fourier Transform And Levenberg Marquardt Backpropagation," J. Theor. Appl. Inf. Technol., vol. 95, no. 5, p. 1080, 2017.	JATIT
2017	A. Tjahjono, M. Pujiantara, J. Taufik, M. H. Purnomo, and others, "Adaptive Modified Firefly Algorithm for Optimal Coordination of Overcurrent Relays," IET Generation, Transmission & Distribution Journal, vol. 11, issue no. 10, p. 2575, 2017.	IET
2017	Wahjono, E., Anggriawan, D.O., Sunarno, E., Nugraha, S.D., Tjahjono, A., "Maximum power point tracking of photovoltaic module for battery charging based on modified particle swarm optimization ", International Review on Modelling and Simulations, Vol. 10, No.1, pp.71-84, 2017.	Praise Worthy Prize

KARYA TULIS ILMIAH (Makalah/Prosiding)

Tahun	Judul	Penyelenggara
2010	Rancang Bangun Supervisory Control and Data Acquisition (SCADA) Pada Proses Water Intake dan Water Forwarding di PDAM Karang Pilang I Surabaya Andryanto, Anang Tjahjono, Era Purwanto Prosiding IES 2010, ISBN 978-979-8689-13-0 Tahun 2010 Penerbit Politeknik Elektronika Negeri Surabaya	PENS
2010	Rancang Bangun Supervisory Control and Data Acquisition (SCADA) Pada Proses Pembubuhan Tawas di PDAM Karangpilang I Surabaya Andi Muh Ardian, Anang Tjahjono, Era Purwanto Prosiding IES 2010 ISBN 978-979-8689-13-0 Tahun 2010 Penerbit Politeknik Elektronika Negeri Surabaya	PENS
2010	Rancang Bangun Sistem Monitoring dan Kendali Kualitas Air Sungai Secara Online dengan Wireless Sensor Network (WSN) Untuk Industri Pengolahan Air Minum di PDAM Anang Tjahjono, Eru Puspita, Edi Satriyanto Prosiding IES 2010 ISBN 978-979-8689-13-0 Tahun 2010 Penerbit Politeknik Elektronika Negeri Surabaya	PENS
2010	Penerapan Logika Fuzzy pada Proses Pencucian Filter Air dengan Menggunakan PLC di PDAM Karang Pilang I Surabaya Anang Tjahjono, Era Purwanto, Yanuar Rizky Prosiding IES 2010 ISBN 978-979-8689-13-0 Tahun 2010, PENS	PENS
2010	Pengaturan Kecepatan Motor AC Tiga Fasa untuk Mengatur Kecepatan Aliran Air Ada Implementasi Wireless Sensor Network (WSN) sebagai Pendeteksi Sumber Polutan yang Potensial Nur Saádah, Anang Tjahjono Prosiding IES 2010 ISBN 978-979-8689-13-0 Tahun 2010 Penerbit Politeknik Elektronika Negeri Surabaya	PENS
2011	Penerapan Adaptive Neuro Fuzzy Inference System (ANFIS) untuk Sistem Pengambilan Keputusan Distribusi Obat pada Sistem Informasi Terintegrasi Puskesmas dan Dinas Kesehatan. Anang Tjahjono, Entin Martiana, Taufan Harsilo A, Prosiding IES 2011, ISBN 978-979-8689-14-7 Tahun 2011 Politeknik Elektronika Negeri Surabaya	PENS

2011	Building Automation System Dengan Menerapkan Kontrol Logika Fuzzy Untuk Mendapatkan Efisiensi Daya Dari Beban Kipas Angin, Lampu Dan Air Conditioner	PENS
2011	Penerapan Adaptive Neuro Fuzzy Inference System (ANFIS) untuk Sistem Pengambilan Keputusan Distribusi Obat pada Sistem Informasi Terintegrasi Puskesmas dan Dinas Kesehatan. Anang Tjahjono, Entin Martiana, Taufan Harsilo A, Prosiding IES 2011, ISBN 978-979-8689-14-7 Tahun 2011 Politeknik Elektronika Negeri Surabaya	PENS
2014	Overcurrent Relay Characteristic Curve Modeling Using Adaptif Neuro Fuzzy Inference System. Anang Tjahjono, Ardyono Priyadi, Mauridhi Hery Purnomo, Margo Pujiantoro. Proceeding MICEEI (Makasar International Conference on Electrical Engineering and Informatics) 2014 supported by IEEE Indonesia Section, ISBN: 978-1-4799-6725-4	Universitas Hasanudin, faculty of Information Science and Technology and the Institute of Visual Informatics Universiti Kebangsaan Malaysia, Malaysia, IEEE Indonesia Section
2014	Photovoltaic Module and Maximum Power Point Tracking Modelling Using Adaptive Neuro Fuzzy Inference System. Anang Tjahjono, Ony Asraul Qudsi, Novie Ayub Windarko, Dimas Okky A, Ardyono Priyadi, Mauridhi Hery Purnomo Proceeding MICEEI (Makasar International Conference on Electrical Engineering and Informatics) 2014 supported by IEEE Indonesia Section, ISBN: 978-1-4799-6725-4	Universitas Hasanudin, faculty of Information Science and Technology and the Institute of Visual Informatics Universiti Kebangsaan Malaysia, Malaysia, IEEE Indonesia Section
2014	Optimized PI Constant for Current Controller of Grid Connected Inverter with LCL Filter Using Genetic Algorithm. Novie Ayub Windarko, Ony Asraul Qudsi Anang Tjahjono, Dimas Okky A, Mauridhi Hery Purnomo Proceeding MICEEI (Makasar International Conference on Electrical Engineering and Informatics) 2014 supported by IEEE Indonesia Section, ISBN: 978-1-4799-6725-4	Universitas Hasanudin, faculty of Information Science and Technology and the Institute of Visual Informatics Universiti Kebangsaan Malaysia, Malaysia, IEEE Indonesia Section
2015	Digital Overcurrent Relay with Conventional Curve Modeling Using Levenberg-Marquardt Backpropagation. Anang Tjahjono, Dimas Okky A., Ardyono Priyadi, Mauridhi Hery Purnomo, Margo Pujiantoro. Proceeding ISITIA IEEE 2015	International Seminar on Intelligent Technology and Its Applications (ISITIA) IEEE 2015, Surabaya-Indonesia, 20 May 2015.

2015	Overcurrent Relay Curve Modeling and Its Application in the Real Industrial Power Systems Using Adaptive Neuro Fuzzy Inference System. Anang Tjahjono, Dimas Okky A., Ardyono Priyadi, Mauridhi Hery Purnomo, Margo Pujiantoro. Proceeding CIVEMSA 2015	2015 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA 2015), Shenzhen-China, 12-14 June 2015
2015	N. A. Windarko, A. Tjahjono, D. O. Anggriawan, and M. H. Purnomo, "Maximum power point tracking of photovoltaic system using adaptive modified firefly algorithm," in 2015 International Electronics Symposium (IES), 2015, pp. 31–35.	2015 International Electronics Symposium (IES)
2016	D. Irawan, A. Tjahjono, M. Pujiantara, and P. M. Hery, "Adaptive overcurrent relays coordination based on multiple sequence alignment algorithm (MSA)," in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 101–106.	2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)
2016	S. D. Nugraha, E. Wahjono, E. Sunarno, D. O. Anggriawan, E. Prasetyono, and A. Tjahjono, "Maximum power point tracking of photovoltaic module for battery charging based on modified firefly algorithm," in 2016 International Electronics Symposium (IES), 2016, pp. 238–243.	2016 International Electronics Symposium (IES)
2016	A. Tjahjono, I. Sudiharto, Suryono, and D. O. Anggriawan, "Modelling non-standard over current relay characteristic curves using combined lagrange polynomial interpolation and curve fitting," in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 589–594.	2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)
2016	M. Pujiantara et al., "Optimization technique based adaptive overcurrent protection in radial system with DG using genetic algorithm," in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 83–88.	2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)
2016	A. E. M. Pujiantara, A. Priyadi, M. Pujiantara, O. Penangsang, D. O. Anggriawan, and A. Tjahjono, "Improvement of power quality monitoring based on modified S-transform," in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 539–544.	2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)
2016	A. Tjahjono et al., "Modeling Characteristic Curves of Digital Overcurrent Relay (DOCR) for User-Defined Characteristic Curve Using Artificial Neural Network," in 2016 International Conference	2016 International Conference on Computational Science and Computational

	on Computational Science and Computational Intelligence (CSCI), 2016, pp. 478–483.	Intelligence (CSCI)
--	--	---------------------

PESERTA KONFERENSI/SEMINAR/LOKAKARYA/SIMPOSIUM

Tahun	Judul Kegiatan	Penyelenggara
2010	Industrial Electronic Symposium 2010	PENS
2011	Workshop on WebAccess, Malaysia	Advantech
2011	Nara Sumber Seminar Kurikulum Berbasis Kompetensi	Politeknik Negeri Padang
2011	International Electronics Symposium (IES) 2011	PENS
2012	Seminar and Advanced Training New Tendencies in TVET in Germany	GIZ
2012	UNESCO-APEID Meeting on Entrepreneurship Education	UNESCO Bangkok, Zhejiang University China
2012	Keynote speaker Seminar Nasional Pendidikan “Meningkatkan Daya Saing Bangsa: Implementasi KKNI dalam Pendidikan Ekonomi”	Universitas Negeri Padang
2012	Narasumber Seminar Pendidikan “Peran Industri Terhadap Mutu Pendidikan dan Pengakuan Lulusan SMK”	SMK Mikael Surakarta
2012	Narasumber Lokakarya Pendidikan Menengah Universal “SMK Model Berkeunggulan dan Kearifan Jawa Barat Berbasis Industri”	Dewan Pendidikan Provinsi Jawa Barat
2014	Makasar International Conference on Electrical Engineering and Informatics 2014	UNHAS
2015	International Seminar on Intelligent Technology and Its Applications (ISITIA) IEEE 2015	ITS
2015	Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA 2015)	IEEE
2015	2015 International Electronics Symposium (IES)	PENS
2016	IEEE Conference Management Workshop and Educational Meeting	IEEE Indonesia Section dan T.Elektro ITS
2016	2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)	IEEE Indonesia Section dan T.Elektro ITS
2016	2016 International Electronics Symposium (IES)	PENS dan IEEE Indonesia Section
2016	2016 International Conference on Computational Science and Computational Intelligence (CSCI)	IEEE

KEGIATAN PROFESIONAL/PENGABDIAN KEPADA MASYARAKAT

Tahun	Kegiatan
2009	Sebagai JICA Expert di Tumba College of Technology Rwanda, Afrika
2010	Sebagai JICA Expert di Tumba College of Technology Rwanda, Afrika
2012	Sebagai JICA Expert di Tumba College of Technology Rwanda, Afrika

PENGHARGAAN/PIAGAM

Tahun	Bentuk Penghargaan	Pemberi
2010	Dosen Berprestasi Peringkat I di PENS	PENS
2010	Sebagai JICA Expert di Tumba College of Technology, Rwanda, Afrika	JICA
2010	Peserta Energy Efficiency University Challenge 2010	Schneider Electric
2010	Pembimbing PLC & SCADA Competition 2010 Tingkat Nasional	Schneider Electric
2013	Pembicara pada Stadium General Sidang Terbuka Senat PENS dalam rangka Penerimaan Mahasiswa Baru 2013	PENS
2014	Dosen JOS Mata Kuliah Teori Semester Gasal 2013/2014	PENS
2014	Dosen JOS Mata Kuliah Praktikum Semester Gasal 2013/2014	PENS
2014	Satyalancana Karya Satya XX Tahun	Presiden RI
2016	Doctoral Student Award	T. Elektro ITS

ORGANISASI PROFESI/ILMIAH

Tahun	Organisasi	Jabatan
2014- sekarang	IEEE ID member 93242607	Anggota

Surabaya, 8 Agustus 2017



(Ir. Anang Tjahjono, MT)