

**PERBANDINGAN KEMAMPUAN *NEURAL HAMMERSTEIN*, *NEURAL WIENER*, *HAMMERSTEIN-WIENER MODEL* DALAM PEMODELAN
LANTHANUM MAGNETO-ELECTRO DEPOSITION**

(Skripsi)

Oleh

**FREZA DEVICA GUNADA
NPM. 1857031015**



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

ABSTRACT

COMPARISON OF NEURAL CAPABILITIES NEURAL HAMMERSTEIN, NEURAL WIENER, HAMMERSTEIN- WIENER MODEL IN CURRENT LANTANUM -ELECTRO DEPOSITION LIMITING MODELING

By

Freza Devica Gunada

Lanthanum can be obtained by the electrowinning process. Electrodeposition is a metal depositing process that uses DC current electrolysis. The presence of a magnetic field affects the growth of fractals or the morphology of the resulting deposit. The presence of a magnetic field leads to an increase in limiting current and uniform growth, as well as a more uniform metal deposition surface. Electrodeposition is the main problem, which is the roughness of the resulting layer (non-uniform crystal growth). The MED process will generate a limiting value (i_b) to obtain the limiting value (i_b) required of compounds and tools such as electrode area (A), electron-active concentration (C), kinematic electrolyte viscosity (V), diffusion coefficient (D), magnetic field strength (B), and the number of electrons involved in the MED process (n). Magneto electrodeposition research tends to require expensive compounds, therefore, there is a need for a solution to reduce the cost of expensive compounds from the magneto electrodeposition (MED) process in Lanthanum. One of the solutions offered through mathematical methods is to use Neural Hammerstein Model, Neural Wiener Model and Hammerstein Wiener Model to guess the value of the limiting current (i_b) best by comparing Mean Square Error (MSE), Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE). The results and analysis of this study show that the Hammerstein Wiener Model has the smallest error value and is able to accurately model nonlinear processes and outperform other blocks considered.

Keywords: Lanthanum, Neural Network, Neural Hammerstein, Neural Wiener, Hammerstein Wiener, Machine Learning.

ABSTRAK

PERBANDINGAN KEMAMPUAN *NEURAL HAMMERSTEIN*, *NEURAL WIENER*, *HAMMERSTEIN-WIENER MODEL* DALAM PEMODELAN LANTHANUM *MAGNETO-ELECTRO DEPOSITION*

Oleh

Freza Devica Gunada

Lanthanum bisa didapatkan dengan proses *electrowinning* (elektrodeposisi). Elektrodeposisi merupakan proses pendeposisian logam yang menggunakan arus DC secara elektrolisis. Adanya medan magnet mempengaruhi pertumbuhan fraktal atau morfologi deposit yang dihasilkan. Kehadiran medan magnet menyebabkan peningkatan terhadap limiting current dan pertumbuhan yang seragam, serta permukaan deposisi logam yang lebih seragam. Elektrodeposisi mempunyai masalah utama yaitu kekasaran pada lapisan yang dihasilkan (pertumbuhan kristal yang tidak seragam). Proses MED akan menghasilkan nilai pembatas (i_b) untuk mendapatkan nilai pembatas (i_b) diperlukan senyawa-senyawa dan alat-alat seperti luas area elektroda (A), konsentrasi elektron-aktif (C), kinematik viskositas elektrolit (V), koefisien difusi (D), kuat medan magnet (B), dan jumlah elektron yang terlibat dalam proses MED (n). Penelitian *magneto electrodeposition* ini cenderung membutuhkan senyawa-senyawa yang mahal, Oleh karena itu, perlu adanya solusi untuk menekan biaya senyawa yang mahal dari proses *magneto electrodeposition* (MED) pada lanthanum. Salah satu solusi yang ditawarkan melalui metode matematis adalah dengan menggunakan pemodelan *Neural Hammerstein Model*, *Neural Wiener Model* dan *Hammerstein Wiener Model* untuk menduga nilai dari arus pembatas (i_b) terbaik dengan membandingkan Mean Square Error (MSE), *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE). Hasil dan analisis dari penelitian ini menunjukkan bahwa *Hammerstein Wiener Model* memiliki nilai *error* terkecil dan mampu memodelkan proses nonlinear secara akurat serta mengungguli blok lainnya yang dipertimbangkan.

Kata Kunci: Lanthanum, *Neural Network*, *Neural Hammerstein*, *Neural Wiener*, *Hammerstein Wiener*, *Mechine Learning*.

**PERBANDINGAN KEMAMPUAN *NEURAL HAMMERSTEIN*, *NEURAL WIENER*, *HAMMERSTEIN-WIENER MODEL* DALAM PEMODELAN
LANTHANUM *MAGNETO-ELECTRO DEPOSITION***

Oleh

Freza Devica Gunada

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA**

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

Judul skripsi : **PENERAPAN KEMAMPUAN NEURAL
HAMMERSTEIN, NEURAL WIENER,
HAMMERSTEIN-WIENER MODEL DALAM
PEMODELAN LANTHANUM
MAGNETOELECTRO DEPOSITION**

Nama Mahasiswa : **Freza Devica Gunada**

Nomor Pokok Mahasiswa : **1857031015**

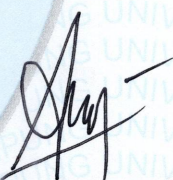
Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



1. Komisi Pembimbing


Prof. Dr. La Zakaria, S.Si., M.Sc.
NIP. 196913021994021001


Dr. Sudibyo, ST., M.Sc., Ph.D.
NIP. 198203272015021002

2. Ketua Jurusan Matematika

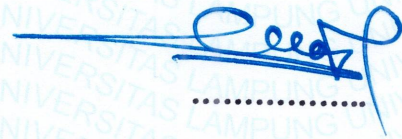


Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

1. Tim Penguji

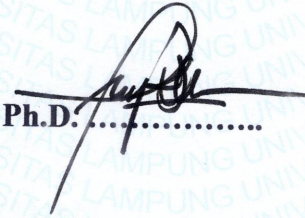
Ketua : **Prof.Dr.La Zakaria, S.Si., M.Sc.**



Sekretaris : **Dr. Sudibyo, ST., M.Sc., Ph.D.**



Penguji
Bukan Pembimbing : **Favorisen R. Lumbanraja, S.Kom., M.Si., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Dr. Eng. Supto Dwi Yuwono, S.Si., M.T.
NIP. 197407052000031001



Tanggal Lulus Ujian Skripsi : **19 Desember 2022**

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : **Freza Devica Gunada**

Nomor Pokok Mahasiswa : **1857031015**

Jurusan : **Matematika**

Judul Skripsi : **PENERAPAN KEMAMPUAN NEURAL
HAMMERSTEIN, NEURAL WIENER,
HAMMERSTEIN-WIENER MODEL DALAM
PEMODELAN LANTHANUM MAGNETO-
ELECTRO DEPOSITION**

Dengan ini menyatakan bahwa penelitian ini adalah hasil pekerjaan saya sendiri dan apabila kemudian hari terbukti bahwa skripsi ini merupakan salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, Desember 2022
Penulis



Freza Devica Gunada

RIWAYAT HIDUP

Penulis bernama Freza Devica Gunada dilahirkan di Kabupaten Tanggamus, Provinsi Lampung pada 10 Maret 2000. Penulis merupakan anak pertama dari dua bersaudara pasangan Bapak Gunadi Bebena dan Ibu Yuni Nur Ida Imawati.

Penulis pertama kali menempuh pendidikannya di SDN 3 Sukaraja pada tahun 2005-2011. Kemudian, penulis melanjutkan jenjang pendidikannya di SMPN 1 Semaka pada tahun 2011-2014. Jenjang pendidikan selanjutnya di MAN 1 Bandar Lampung pada tahun 2014-2017.

Pada tahun 2018 penulis diterima sebagai mahasiswa S1 Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Mandiri Masuk Perguruan Tinggi Negeri (SMMPTN). Selama menjadi mahasiswa penulis juga aktif dalam berorganisasi di HIMATIKA sebagai Anggota Bidang Kaderisasi dan Kepemimpinan. Kemudian pada tahun 2021 penulis melakukan Kuliah Praktik (KP) di Badan Pusat Statistika (BPS) Kabupaten Tanggamus dan melakukan Kuliah Kerja Nyata (KKN) di Desa Sukaraja, Kecamatan Semaka, Kabupaten Tanggamus, Provinsi Lampung, serta penulis mengikuti Program Kampus Merdeka yang bernama Kampus Mengajar di SMPN 33 Bandar Lampung.

KATA INSPIRASI

Sesungguhnya Allah tidak membebani jiwa lebih dari yang dapat ditanggungnya
(Q.A. Al-Baqarah: 286)

Berpikirlah positif, tidak peduli seberapa keras kehidupanmu
(Ali bin Abi Thalib)

Life's battles, don't always go to the stronger or faster man but soon or later the man who wins is the man who thinks he can.
(Napoleon Hill)

Tujuan adalah sebuah mimpi yang datang dari kekuatan pikiran.
(penulis)

PERSEMBAHAN

Dengan mengucapkan puji dan syukur atas kehadiran Allah SWT, atas segala rahmat dan hidayah-Nya skripsi ini dapat terselesaikan dengan baik, serta shalawat serta salam kepada junjungan kita Nabi Muhammad SAW. Dengan penuh ketulusan saya persembahkan karya tulis ini untuk:

Bapak Gunadi dan Ibu Yuni Nur Ida Imawati

Terima kasih kepada kedua orang tua saya yang selalu memberikan dukungan dan saran dalam setiap keputusan, kasih sayang serta doa yang tak pernah putus dalam setiap langkah yang saya tempuh

Banu Mibras Naufal

Terima kasih telah memberikan doa, semangat, serta dukungan selama ini

Dosen Pembimbing dan Pembahas

Terima kasih kepada bapak dosen yang sangat berjasa, membantu, memberikan arahan, serta masukan dan ilmu yang bermanfaat

Teman-teman yang telah membantu, menemani, serta mendukung setiap langkahnya dari awal, hingga saat ini, dan seterusnya;

Almamater Tercinta, Universitas Lampung

SANWACANA

Puji dan syukur penulis panjatkan kehadirat Allah SWT karena berkat segala rahmat dan karunia-Nya penulis dapat menyelesaikan skripsi dengan judul “Perbandingan Kemampuan *Neural Hammerstein*, *Neural Wiener*, *Hammerstein-Wiener Model* dalam Pemodelan *Lanthanum Magneto-Electro Deposition*”.

Dalam menyusun laporan ini penulis banyak mendapatkan bantuan. Oleh karena itu, penulis mengucapkan terimakasih sebesar-besarnya kepada:

1. Bapak Prof. Dr. La Zakaria, S.Si., M.Sc., selaku Dosen Pembimbing I yang telah bersedia membimbing, memberikan saran, bantuan, motivasi, serta arahan, dalam menyelesaikan skripsi ini.
2. Bapak Sudiby, ST., M.Sc., selaku Pembimbing II yang telah bersedia membimbing, memberikan saran serta masukan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Favorisen R. Lumbanraja, S.Kom., M.Si., Ph.D., selaku Dosen Penguji yang telah memberikan bantuan, arahan, serta kritik, dan saran dalam proses penyusunan skripsi ini.
4. Bapak Amanto, S.Si., M.Si., selaku dosen Pembimbing Akademik.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika.
6. Bapak Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh dosen, staff, karyawan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Ibu dan Bapak, Adik, dan keluarga besarku tercinta yang selalu mendoakan dan memberi dukungan.

9. Anisa Dwi Putri, Chinta Chantika, Sulistian Oskavina, Ramona Rahmawati, Nurlela sahabat yang selalu memberikan dukungan selama ini.
10. Kak Ayu, Mila, Riska, Julpiak yang selalu ada dan memberi semangat selama ini.
11. Acil Mutu, Mupeng, Markisut, Kili Kili, Repisang, Ifi, dan Ajeng teman-teman seperjuanganku yang memberikan dukungan selama kuliah.
12. Vindes, The Prediksi, Podkesmas, Trio Kurnia secara tidak langsung memberikan semangat selama menyusun skripsi ini.
13. Semua pihak yang telah membantu dalam menyelesaikan skripsi ini yang tidak bisa penulis sebutkan satu persatu.

Penulis menyadari masih banyak kekurangan dalam skripsi ini. Oleh karena itu, kritik dan saran sangat diharapkan agar dapat menjadi pelajaran dan perbaikan untuk kedepannya. Semoga skripsi ini dapat memberikan manfaat baik bagi penulis maupun bagi pihak yang membutuhkan.

Bandar Lampung, Desember 2022
Penulis,

Freza Devica Gunada

DAFTAR ISI

	Halaman
DAFTAR ISI.....	ii
DATAR TABEL.....	iv
DATAR GAMBAR.....	v
DATAR CODE.....	vi
I. PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA	6
2.1 Model <i>Hammerstein-Wiener</i> dan Pemakaiannya	6
2.2 Lanthanum.....	8
2.3 Elektrodeposisi	9
2.3.1 Elektrodeposisi Konvensional.....	9
2.2.2 Magneto-Elektrodeposisi (MED).....	10
2.4 <i>Black-box Model</i>	11
2.5 Konsep Fungsi Transfer	11
2.6 Persamaan Polinomial	12
2.7 <i>Linear ARX Model</i>	13
2.8 <i>Nonlinear ARX (NARX) Model</i>	14
2.9 <i>Repeat before Forgetting (RbF)</i>	14
2.10 <i>Feedforward Neural Network</i>	15
2.11 <i>State Space</i>	16
2.12 <i>Neural Hammerstein</i>	19

2.13 <i>Neural Wiener</i>	21
2.14 <i>Neural Hammerstein-Wiener</i>	23
2.15 <i>Simulink</i>	25
2.16 Pengukuran Tingkat Keakuratan Peramalan	26
III. METODE PENELITIAN	27
3.1 Waktu dan Tempat Penelitian	27
3.2 Data Penelitian	27
3.3 Metode Penelitian.....	27
IV. HASIL DAN PEMBAHASAN.....	31
4.1 <i>Data Input</i>	31
4.2 <i>Preprocessing</i>	35
4.2.1 <i>Missing Value</i>	36
4.2.2 <i>Scaling Data</i>	37
4.2.3 Pembagian Data <i>Training</i> , <i>Data Validation</i> dan <i>Data Testing</i>	38
4.3 Analisis dan Pembahasan	39
4.3.1 <i>Neural Wiener</i>	39
4.3.2 <i>Neural Hammerstein</i>	45
4.3.3 <i>Neural Hammerstein-Wiener</i>	51
4.4 Evaluasi Model.....	56
4.5 Perancangan Blok <i>Simulink</i>	58
V. KESIMPULAN.....	61
5.1 Kesimpulan.....	61
5.2 Saran.....	62
DAFTAR PUSTAKA	60
LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
1. Berbagai Jenis Model Linear dan Nonlinear yang Digunakan untuk Membuat Model <i>Hammerstein-Wiener</i>	6
2. Data <i>Input</i> Hasil Eksperimen Semi-Empiris.....	31
3. Data Hasil Eksperimen Semi-Empiris Setelah Dilakukan <i>Missing Value</i>	37
4. Hasil Data <i>Scaling</i>	38
5. Pembagian Data <i>Training</i> , Data <i>Validation</i> dan Data <i>Testing</i>	39
6. Perbandingan Nilai Akurasi Model <i>Neural Wiener</i>	45
7. Perbandingan Nilai Akurasi Model <i>Neural Hammerstein</i>	50
8. Perbandingan Nilai Akurasi Model <i>Neural Hammerstein-Wiener</i>	55
9. Perbandingan Nilai Akurasi Model	56
10. Perbandingan Data (ib) Aktual Dengan Hasil <i>Output</i> yang dihasilkan dari Model <i>Neural Wiener</i> , <i>Neural Hammerstein</i> Dan <i>Neural Hammerstein-Wiener</i>	57

DAFTAR GAMBAR

Gambar	Halaman
1. Contoh Skematik Pengolahan Ekstraksi Logam.....	9
2. Konsep Fungsi Transfer	12
3. <i>Feedforward Neural Network</i>	16
4. Diagram Blok Sistem Linear dalam <i>State Space</i>	19
5. Struktur Model <i>Hammerstein</i>	20
6. Struktur Model <i>Wiener</i>	21
7. Struktur Model <i>Hammerstein-Wiener</i>	23
8. <i>Simulink</i> pada Aplikasi Matlab	25
9. Diagram Alir Metode Penelitian Perbandingan Kemampuan <i>Neural Hammerstein, Neural Wiener, Hammerstein-Wiener Model</i> dalam Pemodelan Lanthanum MED	28
10. Pengaruh Konsentrasi $\text{LaCl}_3 \cdot 7\text{H}_2\text{O}$ Terhadap <i>Limiting Current</i>	32
11. Pengaruh Kuat Medan Magnet Terhadap <i>Limiting Current</i>	33
12. Pengaruh Luas Elektroda Kerja Terhadap <i>Limiting Current</i>	34
13. Pengaruh Konsentrasi H_2SO_4 Terhadap <i>Limiting Current</i>	35
14. Grafik <i>Loss Neural Wiener</i> untuk Data <i>Training</i> 40%	40
15. Grafik <i>Loss Neural Wiener</i> untuk Data <i>Training</i> 45%	41
16. Grafik <i>Loss Neural Wiener</i> untuk Data <i>Training</i> 50%	42
17. Simulasi Model <i>Neural Wiener</i> Data <i>Training</i> 40%.....	43
18. Simulasi Model <i>Neural Wiener</i> Data <i>Training</i> 45%.....	43
19. Simulasi Model <i>Neural Wiener</i> Data <i>Training</i> 50%.....	44
20. Grafik <i>Loss Neural Hammerstein</i> untuk Data <i>Training</i> 40%	46
21. Grafik <i>Loss Neural Hammerstein</i> untuk Data <i>Training</i> 45%	46
22. Grafik <i>Loss Neural Hammerstein</i> untuk Data <i>Training</i> 50%	47

23. Simulasi Model <i>Neural Hammerstein</i> Data Training 40%.....	48
24. Simulasi Model <i>Neural Hammerstein</i> Data Training 45%.....	48
25. Simulasi Model <i>Neural Hammerstein</i> Data Training 50%.....	49
26. Grafik <i>Loss Neural Hammerstein-Wiener</i> untuk Data Training 40%	51
27. Grafik <i>Loss Neural Hammerstein-Wiener</i> untuk Data Training 45%	52
28. Grafik <i>Loss Neural Hammerstein-Wiener</i> untuk Data Training 50%	52
29. Simulasi Model <i>Neural Hammerstein-Wiener</i> Data Training 40%.....	53
30. Simulasi Model <i>Neural Hammerstein-Wiener</i> Data Training 45%.....	54
31. Simulasi Model <i>Neural Hammerstein-Wiener</i> Data Training 50%.....	55
32. Grafik Data (ib) Aktual dengan Model Prediksi.....	58
33. Model <i>Neural Wiener</i> dengan <i>Simulink</i>	59
34. Model <i>Neural Hammerstein</i> dengan <i>Simulink</i>	59
35. Model <i>Neural Hammerstein- Wiener</i> dengan <i>Simulink</i>	60

DAFTAR CODE

Code	Halaman
1. Code <i>Missing Value</i>	36

I. PENDAHULUAN

1.1 Latar Belakang Masalah

Semakin majunya peradaban dan teknologi, kebutuhan mineral di dunia akhir-akhir ini meningkat dan beragam. Pengembangan energi dan industri baru yang ramah lingkungan memerlukan beberapa jenis mineral salah satunya adalah logam tanah jarang (LTJ). Penggunaan logam tanah jarang memicu berkembangnya teknologi material baru. Perkembangan material ini banyak diaplikasikan di dalam industri untuk meningkatkan kualitas produk. Posisi tanah jarang pada masa yang akan datang semakin strategis tersebut perlu diupayakan untuk dapat dikembangkan secara berkelanjutan mengingat Indonesia mempunyai sumber daya yang potensial untuk diusahakan. Logam Tanah Jarang (LTJ) merupakan salah satu dari mineral strategis dan termasuk “*critical mineral*” terdiri dari kumpulan unsur-unsur *scandium* (Sc), *lanthanum* (La), *cerium* (Ce), *praseodymium* (Pr), *neodymium* (Nd), *promethium* (Pm), *samarium* (Sm), *europium* (Eu), *gadolinium* (Gd), *terbium* (Tb), *dysprosium* (Dy), *holmium* (Ho), *erbium* (Er), *thulium* (Tm), *ytterbium* (Yb), *lutetium* (Lu) dan *yttrium* (Y). (Kementerian ESDM RI, 2019).

Lanthanum termasuk kelompok tanah jarang yang berupa logam putih kebiruan yang lunak. Logam ini ditemukan pada tahun 1893 dan merupakan salah satu unsur logam transisi golongan III B yang terdapat dalam deret unsur lantanida (Ratmi dkk, 2011). Apabila pengolahan lanthanum dapat optimum dilakukan, Indonesia kedepannya berpotensi menjadi penghasil logam lanthanum berbasis mineral tanah jarang di dunia. Lanthanum dapat diperoleh dengan proses *electrowinning* (elektrodeposisi). Elektrodeposisi yaitu proses pengendapan suatu zat dengan

menggunakan arus listrik searah. Elektrodeposisi memiliki masalah utama yaitu kekasaran pada lapisan yang dihasilkan (pertumbuhan kristal yang tidak seragam) (Uzir, M.H dkk, 2015). Adapun Permasalahan tersebut dapat diselesaikan dengan menerapkan *Magneto elektrodeposition* (MED). Pada proses MED mendapatkan nilai arus pembatas (i_b) sangatlah penting. Untuk mendapatkan nilai pembatas (i_b) diperlukan senyawa-senyawa dan alat-alat seperti luas area elektroda (A), konsentrasi elektron-aktif (C), kinematik viskositas elektrolit (V), koefisien difusi (D), kuat medan magnet (B), dan jumlah elektron yang terlibat dalam proses MED (n). Penelitian *Magneto elektrodeposition* ini cenderung membutuhkan senyawa-senyawa yang mahal (Sudiby, dan Aziz, 2016). Oleh karena itu perlu dilakukan prediksi pembatas (i_b).

Untuk memprediksi arus pembatas (i_b) dapat dilakukan dengan pendekatan *input* dan *output* dari data sebelumnya dengan model matematis. Salah satu metode alternatif yang dapat digunakan adalah model empiris atau *black-box model*, model ini memiliki kinerja yang lebih baik dalam hal waktu dan upaya pengembangan. Jika dipilih dengan bijak, dapat menyederhanakan dan mempercepat pengontrol juga. *black-box model* yang digunakan meliputi: model Volterra, model rata-rata bergerak *autoregressive polinomial* dengan *input* eksogen (ARMAX polinomial), model tipe *Hammerstein* dan *Wiener*, jaringan syaraf tiruan, dan lain-lain (Agachi, 2006). Di antara jenis model ini, model *Hammerstein* dan *Wiener* memiliki keuntungan utama dari model berorientasi blok ini. Pertama, fitur dinamika terlibat pada dasarnya dalam sistem Linear, sedangkan kompleksitas Nonlinear hanya terkandung dalam subsistem statis Nonlinear. Dengan demikian kita dapat menggunakan lebih sedikit waktu komputasi dan memori dalam masalah identifikasi sistem. Kedua, teori Nonlinear Linear atau statis dinamis yang dikembangkan dengan baik dapat diterapkan dalam prosedur pemodelan secara langsung daripada menggunakan teori nonlinear dinamis yang kompleks (Zhu 2002).

Penelitian yang telah dilakukan sebelumnya, penelitian Sudibyo dkk pada (2020), mengenai prediksi arus pembatas (ib) secara sederhana dengan salah satu model yaitu *Artificial Neural Network* (ANN) bermodel *Feed Forward Neural Network* (FFNN) untuk solusi simulasi MED pada *cobalt* dan didapatkan *error* untuk mengetahui kemampuan prediksinya. Penelitian oleh Yi-Chung dan Jeen-Shingn (2009), menyajikan *Hammerstein-Wiener recurrent Neural network* (HWRNN) dengan algoritma identifikasi sistematis untuk mengidentifikasi sistem Nonlinear dinamis yang tidak diketahui. Berdasarkan penelitian ini algoritma identifikasi sistematis, *Hammerstein-Wiener recurrent Neural network* (HWRNN) mampu membangun jaringan yang diusulkan dalam kompak struktur untuk sistem Nonlinear dinamis.

Pada penelitian ini, kemampuan *Neural Hammerstein Model*, *Neural Wiener Model*, dan *Hammerstein-Wiener Model* dibandingkan dalam mensimulasikan nilai dari arus pembatas (ib) terbaik untuk solusi simulasi MED pada lanthanum. Model yang terbaik akan memiliki nilai *error* atau kesalahan yang paling kecil. Sistem *Hammerstein* dan *Wiener* adalah struktur paling populer dalam kelas yang disebut sistem Nonlinear berorientasi blok (Giri dan Bai, 2010). Dari ketiga model tersebut dilakukan proses sebagai berikut. *Neural Hammerstein* memiliki blok Linear dan Nonlinear, dengan *Feedforward Neural Network* sebagai blok Nonlinear di awal dan *state space* digunakan sebagai blok Linear (Murat, dan Aziz, 2013). *Neural Wiener* bekerja dengan mengolah model blok Linear melalui *state space* dan diolah ke bentuk blok Nonlinear melalui *Feedforward Neural Network* (Al-Duwaish et al., 1996). *Hammerstein-Wiener* dapat dilihat sebagai penggabungan dari model *Hammerstein* dan *Wiener*, dimana filter *Linear time-invariant* (LTI) dikelilingi oleh dua blok non-Linear statis (Taringou, 2010).

1.2 Rumusan Masalah

Guna mengatasi masalah kekerasan pada lapisan yang dihasilkan (pertumbuhan kristal yang tidak seragam) pada lanthanum. Ada beberapa model yang dapat

digunakan untuk mendapat solusi dari masalah kekerasan lapisan pada lanthanum, yaitu menggunakan model *Neural Hammerstein*, *Neural Wiener* dan penggabungan antara kedua model yaitu model *Hammerstein-Wiener* dalam mensimulasikan nilai dari arus pembatas (ib) terbaik untuk solusi simulasi MED pada lanthanum yang kemudian diukur menggunakan pengukuran *error*, yaitu MAE, MAPE dan MSE untuk melihat perbandingan keakuratan dari ketiga model.

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah

1. Merancang model prediksi nilai arus pembatas (ib) dari proses *magneto elektrodeposition* (MED) Lanthanum menggunakan model *Neural Hammerstein*, *Neural Wiener*, dan *Hammerstein-Wiener*.
2. Membandingkan kemampuan model *Neural Hammerstein*, *Neural Wiener*, dan *Hammerstein-Wiener*. dalam memodelkan nilai arus pembatas (ib) dari proses *magneto elektrodeposition* (MED) Lanthanum.
3. Merancang model *Neural Hammerstein*, *Neural Wiener*, dan *Hammerstein-Wiener* dengan *simulink* menggunakan *software* Matlab agar mudah dioperasikan.

1.4 Manfaat Penelitian

Manfaat penelitian ini adalah

1. Memberikan informasi tentang model *Neural Hammerstein*, *Neural Wiener*, dan penggabungan dua model yaitu, model *Hammerstein-Wiener*.
2. Sebagai bahan rujukan pengembangan ilmu matematika dalam memprediksi nilai arus pembatas (ib) pada proses *magneto elektrodeposition* (MED) Lanthanum serta menjadi bahan pertimbangan dan memberikan informasi bagi peneliti yang akan melakukan penelitian tentang arus pembatas (ib) pada proses *magneto elektrodeposition* (MED).

3. Mengetahui model prediksi nilai arus pembatas (i_b) dari proses *magneto elektrodeposition* (MED) Lanthanum menggunakan model *Neural Hammerstein*, *Neural Wiener*, dan penggabungan dua model yaitu, model *Hammerstein-Wiener*.

II. TINJAUAN PUSTAKA

2.1 Model *Hammerstein-Wiener* dan Pemakaiannya

Penelitian terdahulu yang menggunakan model *Hammerstein-Wiener* dengan menggunakan berbagai jenis model pada blok model Linear dan blok model Nonlinear seperti ditunjukkan pada Tabel 1. yakni:

Tabel 1. Berbagai Jenis Model Linear dan Nonlinear yang Digunakan untuk Membuat Model *Hammerstein-Wiener*

No	Judul Penelitian	Linear Blok Model	Nonlinear Blok Model	Hasil
1	<i>On the Wiener and Hammerstein Models for Power Amplifier Predistortion</i> (Gilabert, dkk, 2005)	ARX	Polinomial	power amplifier (PA) pada model <i>Hammerstein</i> menyajikan kinerja yang lebih baik dari pada menggunakan model <i>Wiener</i> , karena membutuhkan lebih sedikit parameter untuk identifikasi dan mencapai hasil yang lebih baik ketika melakukan predistorsi PA dengan predistorter berbasis <i>Hammerstein</i> .
2	<i>MPC relevant identification method for Hammerstein and Wiener models</i> (Claudio, 2019)	<i>Transfer Function</i>	NARX	Hasil menunjukkan pada model <i>Hammerstein</i> , algoritma MRI dapat memperoleh model dengan kesalahan yang lebih kecil untuk prediksi multi-langkah ke depan, tetapi algoritmanya dapat menghasilkan perkiraan konsisten yang tidak bias. Untuk model <i>Wiener</i> , meskipun

				estimator yang dihasilkan oleh metode MRI tampak bias, kesalahan prediksi yang diperoleh oleh algoritma MRI untuk multi-langkah prediksi ke depan lebih kecil dari yang diperoleh oleh prediksi 1 langkah ke depan.
3	<i>A Hammerstein-Wiener Recurrent Neural Network with Frequency-Domain Eigensystem Realization Algorithm for Unknown System Identification</i> (Yi-Chung dan Jeen-Shingn 2009)	<i>State-space</i>	FFNN	berdasarkan penelitian ini algoritma identifikasi sistematis, <i>Hammerstein-Wiener recurrent Neural network</i> (HWRNN), mampu membangun jaringan yang diusulkan dalam kompak struktur untuk sistem Nonlinear dinamis.
4	<i>Hierarchical Least Squares Estimation Algorithm for Hammerstein-Wiener Systems</i> (Dong-Qing dan Feng, 2017)	<i>Transfer Function</i>	Polinomial	berdasarkan penelitian ini masalah identifikasi untuk sistem kesalahan keluaran <i>Hammerstein-Wiener</i> dirumuskan dengan menggunakan ide identifikasi model bantu, dan algoritma kuadrat terkecil hierarki diturunkan untuk memperkirakan vektor parameter Linear dari sistem dengan menggunakan prinsip identifikasi hierarkis. Demonstrasi simulasi komputer menunjukkan efektivitas metode yang diusulkan.
5	<i>Double-layered Nonlinear model predictive control based on</i>	<i>State-space</i>	NARX	Hasil simulasi menunjukkan bahwa variabel terkontrol dapat mencapai kontrol bebas offset, metode yang diusulkan, yaitu <i>Hammerstein-</i>

	<p><i>Hammerstein–Wiener model with disturbance rejection</i></p> <p>(Hongbin, dkk, 2018)</p>			<p><i>Wiener</i> dengan menerapkan filter kalman memiliki kinerja penolakan gangguan yang lebih baik, ketahanan yang kuat dan nilai praktis.</p>
--	---	--	--	--

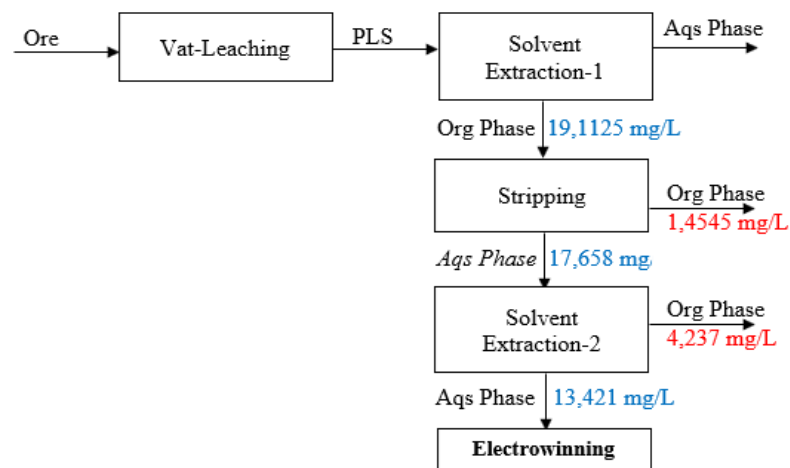
Dalam dekade terakhir, model berorientasi blok (BO), seperti model *Hammerstein*, *Wiener* atau *Hammerstein-Wiener* yang terdiri dari interkoneksi subsistem dinamis Linear dan statis Nonlinear, telah banyak digunakan dalam masalah identifikasi sistem. Berbeda dengan penelitian diatas, penelitian ini menggunakan Linear blok berupa *state space* dan Nonlinear blok berupa SISO FFNN dengan variabel MIMO dalam mensimulasikan nilai dari arus pembatas (ib) terbaik untuk solusi simulasi MED pada lanthanum.

2.2 Lanthanum

Lanthanum termasuk kelompok tanah jarang yang berupa logam putih kebiruan yang lunak. Cadangan logam ini lebih melimpah daripada emas maupun platina, yang mana juga selalu terdapat diantara produk pembelahan uranium; thorium; dan plutonium. Lanthanum disimbolkan dengan La, mempunyai nomor atom 57, tingkat oksidasinya adalah +2 dan +3, dan merupakan salah satu unsur logam transisi golongan III B yang terdapat dalam deret unsur lantanida. Logam lanthanum ini banyak ditemukan di alam pada mineral-mineral seperti *apatite*, *monazite*, *calsit*, dan *fluorspar*. Lanthanum banyak diaplikasikan dan bermanfaat sebagai bahan layar sinar-x, lensa gelas, serta fiber keramik. (Ratmi dkk, 2011).

Proses pengolahan logam lantanum dengan menggunakan teknologi hidrometalurgi adalah proses ekstraksi bijih REE melalui proses leaching dengan menggunakan reagen-reagen tertentu. Leaching merupakan proses pelarutan selektif dengan

hanya melarutkan logam berharga tertentu saja dalam konsentrat tanpa melarutkan pengotornya. Mineral pengotor ini tetap berbentuk solid (Sudiby, 2020). Untuk mengendapkan logam tertentu dari hasil leaching kemudian dilakukan pemerolehan kembali logam dari larutan hasil leaching. Diharapkan agar konsentrasi logam tertentu dapat ditingkatkan hingga level tertentu dan konsentrasi pengotornya dapat diminimalkan sehingga proses pada tahap selanjutnya dapat berlangsung dengan efisien (Prasetyo, 2008). Pregnant leach solution (PLS) merupakan hasil dari proses leaching yang kemudian akan diproses kembali pada tahap *recovery*. Metode *solvent extraction* dipilih sebagai proses *recovery* dari PLS, sementara hasil *solvent extraction* selanjutnya akan diolah menggunakan *electrowinning* (elektrodeposisi). Skematik contoh proses pengolahan logam dapat dilihat pada Gambar 1.



Gambar 1. Contoh Skematik Pengolahan Ekstraksi Logam
(Sumber : Sudiby, 2020)

2.3 Elektrodeposisi

2.3.1 Elektrodeposisi Konvensional

Elektrodeposisi (juga dikenal dengan istilah *electrowinning*) merupakan proses elektro ekstraksi elektrolit dengan terjadinya reduksi katodik yang bertujuan untuk mengambil logam dalam bentuk padat, dari suatu larutan yang mengandung ion

logam. Dalam proses ini arus listrik searah dialirkan ke dalam larutan lewat anoda dan katoda. Arus listrik bergerak dari anoda melewati larutan yang mengandung logam, sehingga logam akan terekstraksi dan tersimpan di katoda. Anoda yang digunakan dalam proses elektrodeposisi harus terbuat dari bahan yang tidak larut (*inert*).

Kelebihan dari metode ini dibandingkan metode *recovery* lain adalah mudah dilakukan karena tidak membutuhkan bahan kimia. Elektrodeposisi juga mampu menghasilkan logam bebas yang diinginkan. Selain pendeposisian dengan *electrowinning*, ada beberapa metode yang dapat dilakukan untuk mengambil kembali kandungan logam, metode *recovery* lain diantaranya seperti presipitasi, membran separasi, dan adsorpsi (Virolainen, 2013).

2.3.2 Magneto-Elektrodeposisi (MED)

Lanthanum memiliki sifat paramagnetik, yaitu memiliki sifat dalam ketertarikan terhadap magnet. Maka dari itu selama proses pendeposisian dengan listrik (elektrodeposisi) memerlukan medan magnet agar prosesnya lebih efektif. Dengan adanya medan magnet yang menghasilkan arah medan magnet yang searah dapat meningkatkan *limiting current* selama proses elektrodeposisi. Elektrodeposisi yaitu proses pengendapan suatu zat dengan menggunakan arus listrik searah. Untuk mendapatkan kualitas deposit yang baik pada proses elektrodeposisi maka, perlu dilakukan optimasi terhadap beberapa faktor yang mempengaruhi antara lain optimasi potensial, rapat arus, waktu, suhu dan pH larutan (Marwati, 2009). Proses elektrodeposisi menggunakan kuat medan magnet atau magneto elektrodeposisi (MED) karena peningkatan *limiting current* dan perubahan elektrodeposit menjadi lebih tersusun.

Magneto elektrodeposisi merupakan proses elektrodeposisi yang dilakukan dibawah pengaruh medan magnet. Pada magneto elektrodeposisi menggunakan dua bahan konduktor elektronik, *counter electrode*, arus pembatas serta medan magnet

(Sudiby, Murat, dan Aziz, 2015). Banyak para peneliti yang mengkaji hal penting pada proses MED yaitu memprediksi arus pembatas (ib). Arus pembatas pembatas (ib) sangat penting baik pada proses elektrodeposisi konvensional.

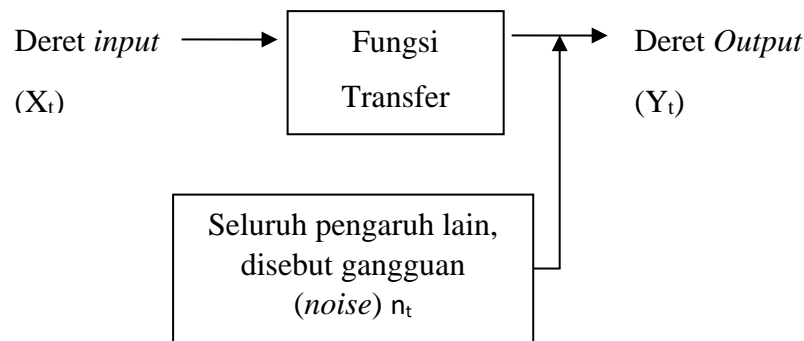
2.4 Black-box Model

Black-box model adalah model hubungan empiris antara *input* dan variabel keluaran. Model ini memiliki struktur yang sederhana dengan akurasi yang lebih rendah dibandingkan dengan model kotak putih dan kotak abu-abu. Namun, model ini membutuhkan waktu komputasi yang rendah untuk menyelesaikannya. Oleh karena itu, ini menjadi lebih penting dalam pengontrol model berbasis model seperti NMPC. Model ini terdiri dari dua kelompok:

1. *Linear black box model* (seperti ARX, *Transfer Function*, *State Space*)
2. *Nonlinear black box model* (seperti *Neural Network*, NARX, model blok berorientasi) (Agachi, 2006).

2.5 Konsep fungsi transfer

Analisis fungsi transfer merupakan salah satu alternatif untuk menyelesaikan permasalahan apabila terdapat lebih dari satu deret berkala, dimana keadaan ini sering disebut *multivariate* deret waktu dalam statistika. Gambar 2 menjelaskan bahwa di dalam fungsi transfer terdapat deret berkala output (Y_t) yang dapat dipengaruhi oleh deret berkala input (X_t) dan input-input lain yang digabungkan dalam satu kelompok yang disebut gangguan (*noise*) n_t (Makridakis, 1995). Seluruh sistem merupakan sistem yang dinamis, dengan kata lain deret input X_t memberikan pengaruhnya kepada deret output melalui fungsi transfer yang mendistribusikan dampak X_t melalui beberapa waktu yang akan datang.



Gambar 2. Konsep Fungsi Transfer

(Sumber : Makridakis dkk, 1995)

Tujuan pemodelan fungsi transfer adalah untuk menetapkan model yang sederhana, yang menghubungkan Y_t dengan X_t dan n_t . Bentuk umum model fungsi transfer tunggal adalah sebagai berikut: (Makridakis dkk, 1995).

$$Y_t = v(B)X_t + n_t \quad (1)$$

Dimana;

Y_t = Deret output

X_t = Deret input

n_t = Pengaruh kombinasi dari seluruh faktor yang mempengaruhi Y_t , dan disebut dengan gangguan (*noise*)

$v(B)$ = Fungsi dari bobot respons impuls.

$v(B) = (v_0 + v_1B + v_1B^2 + \dots + v_kB^k$ dimana k adalah orde fungsi transfer.

v_k = Bobot respons impuls pada lag k .

B = Operator mundur

2.6 Persamaan Polinomial

Persamaan polinomial adalah persamaan suku banyak dalam x orde atau berderajat n , dengan bentuk umum :

$$p(x) = a_nx^n + a_{n-1}x^{n-1} + \dots + a_1x + a_0, a_n \neq 0 \quad (2)$$

Dimana :

n = Derajat atau pangkat tertinggi dari x

a = Koefisien dari x

a_0 = Suku Tetap

Ada beberapa persamaan polinomial yang sering muncul diantaranya adalah persamaan kuadrat, persamaan kubik, dan persamaan kuartik. Persamaan kuadrat mempunyai bentuk umum :

$$\begin{aligned} f(x) &= a_2x^2 + a_1x + a_0 = 0 \\ a_2x^2 + a_1x &= -a_0 \end{aligned} \quad (3)$$

dengan a_2, a_1, a_0 = konstanta x_2, x_1 = variabel

Persamaan kubik merupakan persamaan polinomial orde/berderajat tertinggi tiga.

Bentuk persamaan kubik secara umum adalah :

$$\begin{aligned} f(x) &= a_3x^3 + a_2x^2 + a_1x + a_0 = 0 \\ a_3x^3 + a_2x^2 + a_1x &= -a_0 \end{aligned} \quad (4)$$

dengan a_3, a_2, a_1, a_0 = konstanta x_3, x_2, x_1 = variabel (Liana, 2011).

Berikut adalah contoh polinomial dan orde/derajatnya (Paul, 1995):

$5x^{23}$	orde/berderajatnya : 23
$5x^{12} - 2x^6 + x^5 - 198x + 1$	orde/berderajatnya : 12
$x^4 - x^3 + x^2 - x + 1$	orde/berderajatnya : 4
$5x - 1$	orde/berderajatnya : 1

2.7 Linear ARX Model

Auto-Regressive with Exogenous Input (ARX) merupakan model paling sederhana yang menggabungkan sinyal stimulus. Namun, model ARX menangkap beberapa dinamika stokastik sebagai bagian dari dinamika sistem. Model ARX linier dapat diekspresikan dengan sinyal *single input* dan *single output* (SISO). Secara umum, model linear ARX dapat dituliskan sebagai berikut (Hikmat dkk, 2014):

$$y(k) + a_1y(k-1) + \dots + a_{n_a}y(k-n_a) = b_1u(k-n_k) + \dots + b_{n_b}u(k-n_k-n_b+1) + e(k) \quad (5)$$

Dimana $y(k)$ adalah *output* dari waktu k , $u(k)$ adalah *input* dari waktu k dan $e(k)$ adalah sinyal *error* pada waktu k . n_a adalah jumlah kutub, n_b adalah jumlah nol, dan n_k adalah jumlah tunda waktu murni (waktu mati) dalam sistem.

2.8 Nonlinear ARX (NARX) Model

Nonlinear ARX (NARX) didasarkan pada model ARX linier dan merupakan perluasan nonlinier dari model ARX langsung biasa. Jenis model nonlinear ini umumnya digunakan dalam pemodelan deret waktu dan menawarkan berbagai preferensi termasuk ketepatan dan kekompakan representasi, signifikansi fisik, dan korespondensi langsung antara model dan parameter sistem fisik (Ohata dkk, 2006). Persamaan umum model NARX adalah sebagai berikut (Osman dkk, 2014):

$$y(k) = f(y(k-1), y(k-2), \dots, y(k-n_a), u(k-1), u(k-2), \dots, u(k-n_b)) + e(k) \quad (6)$$

Dimana nilai selanjutnya dari sinyal keluaran dependen, $y(k)$ diregresikan pada nilai sebelumnya dari sinyal keluaran dan sinyal masukan $u(k)$. Sama seperti model linear ARX, n_a adalah jumlah kutub, n_b adalah jumlah nol, dan n_k adalah jumlah tunda waktu murni (waktu mati) dalam sistem.

2.9 Repeat before Forgetting (RbF)

Repeat before Forgetting (RbF) adalah algoritma pengulangan berjarak yang memperhitungkan indikator penarikan yang telah divalidasi sebelumnya untuk melatih jaringan syaraf (Amiri, 2017). *Repeat before Forgetting* (RbF) terinspirasi oleh bukti luas dalam psikologi yang menunjukkan kemampuan manusia untuk menyimpan informasi meningkat dengan paparan berulang dan secara eksponensial meluruh dengan penundaan sejak paparan terakhir. Ini bekerja berdasarkan pengulangan berjarak di mana contoh pelatihan berulang kali disajikan ke jaringan

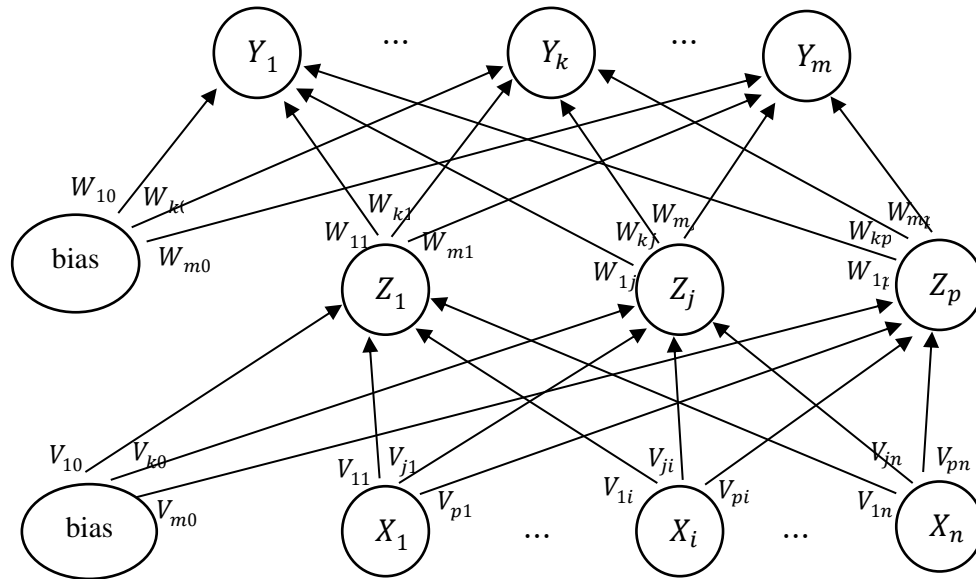
pada jadwal yang ditentukan oleh algoritma pengulangan berjarak. *Repeat before Forgetting* (RbF) mempersingkat atau memperpanjang interval tinjauan untuk instans pelatihan sehubungan dengan hilangnya instans dan kinerja jaringan saat ini pada data validasi.

2.10 Feedforward Neural Network

Feedforward Neural network (FFNN) merupakan salah satu model *Neural network* yang banyak dipakai dalam berbagai bidang. Arsitektur model FFNN terdiri atas Lapisan pertama disebut *input* dan lapisan terakhir disebut *output*. Lapisan di antara *input* dan *output* adalah *Hidden layers* (Zhang, 2003). Heaton (2008) mengatakan bahwa perubahan hasil pelatihan akan tergantung pada banyaknya *hidden layer* yang digunakan. *Output* yang kurang baik dihasilkan apabila menggunakan *neuron* yang terlalu sedikit, tetapi jika menggunakan *neuron* yang terlalu banyak, maka akan memperlambat pelatihan dan menghasilkan jumlah pelatihan yang tak hingga. Beberapa aturan yang sering digunakan dalam menentukan jumlah *hidden layer* sebagai berikut:

1. Jumlah *hidden layer* lebih besar dari jumlah *neuron input* atau jumlah *output*.
2. Jumlah *hidden layer* yaitu $2/3$ besar dari jumlah *neuron input* ditambah jumlah *output*.
3. Jumlah *hidden layer* harus lebih kecil atau sama dengan dua kali jumlah *input layer*.

Dalam model ini, perhitungan respon atau *output* Y dilakukan dengan memproses *input* x mengalir dari satu lapis maju ke lapis berikutnya secara berurutan. *Single layer feedforward* dengan satu *neuron* pada lapisan tersembunyi adalah jaringan saraf yang paling dasar dan umum digunakan dalam ekonomi dan aplikasi keuangan. Kompleksitas dari arsitektur FFNN tergantung pada jumlah lapis tersembunyi dan jumlah *neuron* pada masing-masing lapis.



Gambar 3. *Feedforward Neural Network*

(Sumber : Fajar, 2016)

Gambar 3 adalah *Feedforward Neural Network* dengan n buah masukan (ditambah sebuah bias), sebuah lapisan tersembunyi yang terdiri dari p unit (ditambah sebuah bias), serta m buah unit keluaran. Algoritma *backpropagation* merupakan satu algoritma terkenal dari banyak algoritma yang ada untuk melatih *neural network*. Pada dasarnya pelatihan ini digunakan untuk memperbarui berat sinapsis *neuron* (Sazli, 2006). Hasil penelitian Wayahdi, Zarlis, dan Putra (2019) menunjukkan bahwa algoritma *Backpropagation* mampu mencari bobot *neuron* dengan pelatihan yang cepat dan akurasi yang baik. Selain *backpropagation*, terdapat juga algoritma lainnya. Pada aplikasi MATLAB terdapat algoritma *Levenberg-Marquardt*, *Bayesian Regularization*, dan *Scaled Conjugat Gradient* untuk mencari bobot-bobot *neuron*.

2.11 *State Space*

Space dimensi n yang sumbu koordinat-nya terdiri dari sumbu x_1 , sumbu x_2, \dots , sumbu x_n , dimana x_1, x_2, \dots, x_n adalah variabel *state* disebut *state space*. Dalam analisis *state space* terdapat tiga jenis variabel yang terlibat dalam pemodelan

sistem dinamis yaitu variabel *input*, variabel *output*, dan variabel *state*. Sistem dinamis harus melibatkan memori penyimpanan nilai *input* untuk $t \geq t_1$. $\dot{x}_1(t), \dot{x}_2(t), \dots, \dot{x}_n(t)$ adalah persamaan *state space* dimana setiap $\dot{x}(t)$ merupakan persamaan diferensial orde 1. Banyaknya $\dot{x}(t)$ tergantung pada berapa banyak parameter yang terlibat dalam analisis sistem atau berapa banyak persamaan orde n yang dimiliki oleh system. Persamaan tersebut merupakan penyederhanaan persamaan apabila sistem yang akan dianalisis memiliki persamaan orde 2 atau lebih, hal tersebut merupakan ciri khas dari metode *state space* dalam menganalisis sebuah sistem $\dot{x}(t)$ memiliki persamaan fungsi yang didalamnya terdapat variabel *state* dan *input* yang berubah terhadap waktu $y_1(t), y_2(t), \dots, y_m(t)$ adalah persamaan yang mendeskripsikan keluaran sistem, dimana jumlah persamaan untuk $y(t)$ sama dengan jumlah persamaan dot $\dot{x}(t)$. Asumsikan sistem memiliki *multi-input, multi-output* sistem melibatkan n integrator. Asumsikan juga bahwa r *input* $u_1(t), u_2(t), \dots, u_r(t)$ dan m *output* $y_1(t), y_2(t), \dots, y_m(t)$. Menentukan n integrator *output* sebagai variabel *state* $x_1(t), x_2(t), \dots, x_r(t)$. Jika sistem bersifat Linear dan invarian waktu serta variabel *state* dengan n integrator, variabel *input* dengan r integrator dan variabel *output* dengan m integrator, maka sistem memiliki persamaan *state* sebagai berikut (Ogata, 2010)

$$\begin{aligned}
 \dot{x}_1(t) &= f_1(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\
 \dot{x}_2(t) &= f_2(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\
 &\cdot \\
 &\cdot \\
 &\cdot \\
 \dot{x}_n(t) &= f_n(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t)
 \end{aligned} \tag{7}$$

Output $y_1(t), y_2(t), \dots, y_m(t)$ memiliki bentuk persamaan (1):

$$\begin{aligned}
 y_1(t) &= g_1(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\
 y_2(t) &= g_2(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\
 &\cdot
 \end{aligned} \tag{8}$$

$$y_m(t) = g_n(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t)$$

Jika didefinisikan

$$\mathbf{x}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{bmatrix}, f(x, u, t) = \begin{bmatrix} f_1(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ f_2(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ \vdots \\ f_n(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \end{bmatrix},$$

$$\mathbf{y}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{bmatrix}, g(x, u, t) = \begin{bmatrix} g_1(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ g_2(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \\ \vdots \\ g_n(x_1, x_2, \dots, x_n; u_1, u_2, \dots, u_r; t) \end{bmatrix}, u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

Sehingga

$$\mathbf{x}(t) = f(x, u, t) \quad (9)$$

$$\mathbf{y}(t) = g(x, u, t) \quad (10)$$

Dimana persamaan (9) adalah persamaan *state* dan persamaan (10) adalah persamaan *output*. Jika fungsi vektor f dan atau g melibatkan waktu t secara eksplisit, maka sistem tersebut disebut sistem yang berubah-ubah waktu. Jika persamaan (9) dan (10) dilinearkan tentang operasi *state*, maka kita memiliki persamaan *Linear state* dan persamaan *output* berikut.

$$\mathbf{x}(t) = \mathbf{A}(t)\mathbf{x}(t) + \mathbf{B}(t)\mathbf{u}(t) \quad (11)$$

$$\mathbf{y}(t) = \mathbf{C}(t)\mathbf{x}(t) + \mathbf{D}(t)\mathbf{u}(t) \quad (12)$$


Dimana

$\mathbf{A}(t)$ = matriks *state*,

$\mathbf{B}(t)$ = matriks masukan,

$\mathbf{C}(t)$ = matriks keluaran, dan

$D(t)$ = matriks transmisi langsung.



Gambar 4. Diagram Blok Sistem Linear dalam *State Space*
(Sumber : Ogata, 2010)

Berikut penjelasan mengenai diagram blok representasi persamaan (12) ditunjuk pada Gambar 4. Jika fungsi vektor f dan g tidak melibatkan waktu t secara eksplisit maka sistem tersebut disebut sistem *time-invariant*. Dalam hal ini, Persamaan (11) dan (12) disederhanakan menjadi

$$\dot{x}(t) = Ax(t) + Bu(t) \quad (13)$$


$$y(t) = Cx(t) + Du(t) \quad (14)$$

Persamaan (13) adalah persamaan *Linear state*, sistem *time-invariant* dan Persamaan (14) adalah persamaan *output* untuk sistem yang sama.

2.12 Neural Hammerstein

Neural Hammerstein memiliki blok Linear dan Nonlinear, dengan FFNN sebagai blok Linear awal dan *State space* digunakan sebagai blok Linear (Murat, dan Aziz, 2013). Dalam penelitian Sudiby, Murat dan Aziz (2013) *Neural Hammerstein* mampu melakukan proses kontrol dan memiliki akurasi prediksi *output* yang bagus. Algoritma *Neural Hammerstein* dimulai dengan membangkit data untuk mendapatkan data dinamis dari variabel *input* dan *output*. Lalu blok Nonlinear FFNN mengidentifikasi datanya untuk mendapatkan variabel perantara dan dilanjutkan dengan *State space* dengan *input* variabel perantara. Model

diidentifikasi menggunakan variabel perantara sebagai masukan seperti yang ditunjukkan pada Gambar 5.



Gambar 5. Struktur Model *Hammerstein*

(Sumber : Sudibyo, 2013)

a) Pengembangan Blok *Nonlinear Neural - Hammerstein*

Model *Neural Network* dipilih untuk blok Nonlinear di model *Neural Hammerstein*. Di bagian ini, beberapa *input* - beberapa *output* (MIMO) *Neural Model* jaringan digunakan untuk memodelkan proses. Model ini memiliki *input* yaitu (u). Keluaran dari model *Neural Network* ini menjadi masukan (v) dari blok Nonlinear *Neural Hammerstein* (NH). *Output* $y(k)$ dari jaringan saraf ini dijelaskan dalam Persamaan (15).

$$v_{(k)} = w_0 + \sum_{i=1}^k w_i^2 \varphi \left(w_{i,0}^1 + w_{i,1}^1 u_{(k)} \right) \quad (15)$$

di mana w_0 adalah bias, w_{ij} adalah bobot lapisan, w_i adalah bobot lapisan kedua φ adalah fungsi transfer Nonlinear yakni fungsi transfer sigmoid tangen hiperbolik (tansig), dan k adalah jumlah hidden nodes.

b) Pengembangan Blok *Linear Neural-Hammerstein*


Blok kedua *Neural Hammerstein* menggunakan model *state space*. Menggunakan data *input output* dari pembuatan data, model *state space* dikembangkan menggunakan perintah Matlab *command* (n4sid). Model ini memiliki dua *input* yaitu (v). Keluaran dari model *state space* ini menjadi keluaran (y) dari blok Nonlinear *Neural-Hammerstein*. Oleh karena itu, keluaran model *Neural-Hammerstein* dapat dijelaskan melalui Persamaan (16):

$$y(k) = \mathbf{C} x(k) + \mathbf{D} (w_0 + \sum_{i=1}^k w_i^2) \{w_{i,0}^1 + w_{i,1}^1 u(k)\} \quad (16)$$

Hasil dari model NH secara keseluruhan diplot dan dibandingkan dengan data dari pembangkitan data.

2.13 Neural Wiener

Neural Wiener adalah Linear model yang diikuti dengan model Nonlinear statis (Schoukens dan Ljung, 2019). Algoritma *Wiener* dimulai dengan membangkit data untuk mendapatkan data dinamis dari variabel *input* dan *output*. Lalu blok Linear *State Space* mengidentifikasi datanya untuk mendapatkan variabel perantara dan dilanjutkan dengan FFNN sebagai blok nonlinear dengan *input* variabel perantara. Parameter atau arsitektur model *Neural Wiener* (NW) seperti yang ditunjukkan pada Gambar 6.



Gambar 6. Struktur Model *Neural Wiener*

(Sumber : Sudibyo, dkk, 2015)

a) Pengembangan Blok *Linear Neural Wiener* Model

Seperti yang dinyatakan sebelumnya, blok pertama dari *Neural Wiener* (NW) menggunakan model *state space*. Dengan menggunakan data *input-output* dari pembangkitan data, model *state space* dikembangkan menggunakan perintah Matlab (*n4sid*). Model ini memiliki *input* yaitu (*u*). Keluaran dari model *state*

space ini menjadi masukan (v) dari blok Nonlinear *Neural Wiener* (NW). Oleh karena itu persamaan *state space* dapat dinyatakan sebagai berikut:

$$x(k + 1) = \mathbf{A}x(k) + \mathbf{B}u(k) \quad (17)$$

$$v(k) = \mathbf{C}x(k) + \mathbf{D}u(k) \quad (18)$$

di mana x adalah vektor *state*, u adalah vektor masukan, dan v adalah vektor keluaran. Koefisien matriks \mathbf{A} adalah matriks n -kali- n , n adalah jumlah *state*, Koefisien matriks \mathbf{B} adalah n -kali- n matriks (n adalah jumlah baris dan m adalah jumlah kolom), dan m adalah jumlah *input*. \mathbf{C} adalah matriks r -kali- n , di mana r adalah jumlah *output* dan \mathbf{D} adalah matriks r -kali- m di *Neural Wiener* (NW), akurasi model yang diperoleh dari model *state* ditingkatkan dengan blok Nonlinear dari NW model.

b) Pengembangan Blok *Nonlinear Neural Wiener*

Blok Nonlinear model NW yang digunakan dalam pekerjaan ini adalah model jaringan saraf *feed-forward*. Jaringan saraf *feed-forward* dikembangkan menggunakan perintah Matlab *command* (*newff*). Pada identifikasi model *Neural network*, dua *input* dari model ini adalah *output* dari model *state space* (v), sedangkan dua *output* dari model *Neural network* adalah (y). *Output* $y(k)$ dari jaringan saraf dapat ditulis dalam Persamaan (19):


$$y_{(k)} = w_0 + \sum_{i=1}^k w_i^2 \varphi(w_{i,0}^1 + w_{i,1}^1 v_{(k)}) \quad (19)$$

dimana w_0 adalah bias, w_{ij} adalah berat lapisan pertama, dan w_i adalah berat lapisan kedua, φ adalah fungsi transfer Nonlinear yakni fungsi transfer sigmoid tangen hiperbolik (*tansig*), dan k adalah bilangan tersembunyi node. Keluaran dari Model NW dapat ditunjukkan dalam Persamaan (20):

$$y(k) = w_0 + \sum_{i=1}^k w_i^2 \varphi\{w_{i,0}^1 + w_{i,1}^1 [C x(k) + D u(k) + e(k)]\} \quad (20)$$

2.14 Neural Hammerstein-Wiener

Model *Hammerstein-Wiener* dapat dilihat sebagai penggabungan dari model *Hammerstein* dan *Wiener*, dimana blok *Linear dinamic* dikelilingi oleh dua blok *non Linear steady state*, seperti yang digambarkan pada Gambar. 7 (Taringou, 2010).



Gambar 7. Struktur Model *Hammerstein-Wiener*

a) Pengembangan Blok *Nonlinear Neural Hammerstein-Wiener*

Model *Neural Network* dipilih untuk blok *Nonlinear* di model *Neural Hammerstein-Wiener*. Di bagian ini, beberapa *input* - beberapa *output* (MIMO) *Neural Model* jaringan digunakan untuk memodelkan proses. Model ini memiliki *input* yaitu (u). Keluaran dari model *state space* ini menjadi masukan (v) dari blok *Nonlinear Neural Hammerstein* (NH). *Output* $y(k)$ dari jaringan saraf ini dijelaskan dalam Persamaan (21):

$$v(k) = w_0 + \sum_{i=1}^k w_i^2 \varphi(w_{i,0}^1 + w_{i,1}^1 u(k)) \quad (21)$$

di mana w_0 adalah bias, w_{ij} adalah bobot lapisan, w_i adalah bobot lapisan kedua φ adalah fungsi transfer Nonlinear yakni fungsi transfer sigmoid tangen hiperbolik (tansig), dan k adalah jumlah hidden nodes.

b) Pengembangan Blok Linear *Neural Hammerstein-Wiener*

Blok kedua *Neural Hammerstein* menggunakan model *state space*. Menggunakan data *input output* dari pembuatan data, model *state space* dikembangkan menggunakan perintah Matlab *command* (n4sid). Model ini memiliki dua *input* yaitu (v). Keluaran dari model *state space* ini menjadi keluaran (y) dari blok Nonlinear *Neural-Hammerstein*. Oleh karena itu, keluaran model *Neural-Hammerstein* dapat dijelaskan melalui Persamaan (22).

$$z_{(k)} = \mathbf{C} x_{(k)} + \mathbf{D} (w_0 + \sum_{i=1}^k w_i^2) \{w_{i,0}^1 + w_{i,1}^1 u_{(k)}\} \quad (22)$$

Hasil dari model NH secara keseluruhan diplot dan dibandingkan dengan data dari pembangkitan data.

c) Pengembangan Blok non Linear *Neural Hammerstein-Wiener*

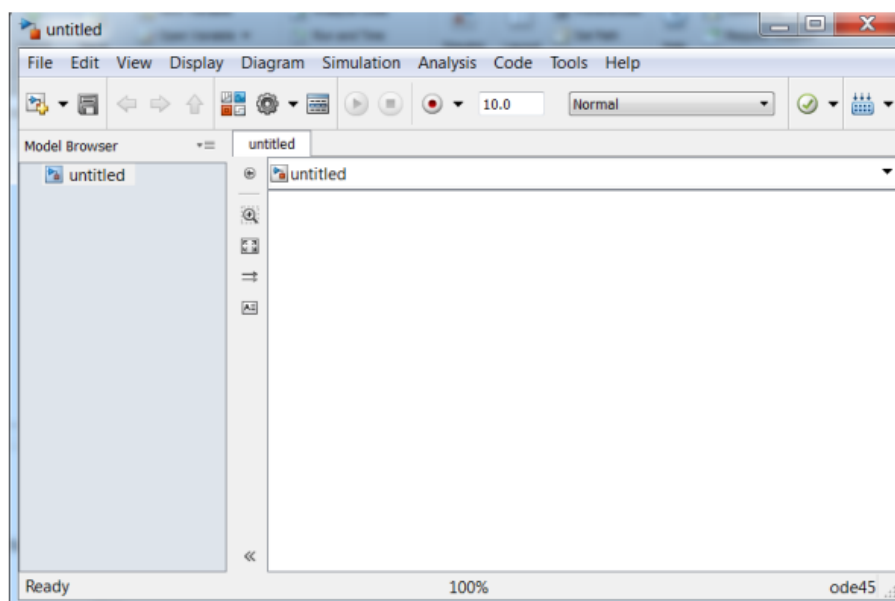
Blok kedua *Neural Hammerstein-Wiener* menggunakan model *state space*. Menggunakan data *input output* dari pembuatan data, model *state space* dikembangkan menggunakan perintah Matlab (n4sid). Model ini memiliki dua *input* yaitu v_1 sebagai *input* dari *Neural Network* dan z_2 sebagai *input* dari *state space*. Keluaran dari model *state space* ini menjadi keluaran (y) dari blok Nonlinear *Hammerstein-Wiener*. Oleh karena itu, keluaran model *Hammerstein-Wiener* dapat dijelaskan melalui Persamaan (23):

$$y_{(k)} = w_0 + \sum_{i=1}^k w_i^2 \varphi \left(w_{i,0}^1 + w_{i,1}^1 [\mathbf{C} x_{(k)} + \mathbf{D} (w_0 + \sum_{i=1}^k w_i^2) \{w_{i,0}^1 + w_{i,1}^1 u_{(k)}\}] \right) \quad (23)$$

Hasil dari model NHW secara keseluruhan diplot dan dibandingkan dengan data dari pembangkitan data.

2.15 *Simulink*

Simulink adalah lingkungan pemrograman grafis berbasis Matlab untuk pemodelan, simulasi dan analisis sistem dinamis multi domain. Antarmuka utamanya adalah alat diagram blok grafis dan satu set pustaka blok yang dapat disesuaikan. Ia menawarkan integrasi yang erat dengan lingkungan Matlab lainnya dan dapat menjalankan Matlab atau membuat skrip darinya. *Simulink* banyak digunakan dalam kontrol otomatis dan pemrosesan sinyal digital untuk simulasi multi domain dan desain berbasis model (Rose, 2004). Cara menggunakan *Simulink* hanya dengan mengetikkan perintah ” *Simulink*” pada *command window* dari Matlab Cara lain adalah cukup dengan menekan tombol *simulink* pada *toolbar* Matlab



Gambar 8. *Simulink* pada Aplikasi Matlab

Gambar 8 adalah tampilan *new file* pada *Simulink*. Dengan menggunakan perangkat lunak ini kita dapat membangun blok-blok model untuk mensimulasi sistem yang kita kehendaki.

2.16 Pengukuran Tingkat Keakuratan Peramalan

Pengukuran tingkat keakuratan peramalan dapat dihitung dengan menggunakan formula MAE, MAPE dan MSE, (Murti,2021). Untuk mengukur ketepatan model peramalan tersebut. Formula yang digunakan untuk mengukur model peramalan sebagai berikut :

1. Mean Square Error (MSE)

$$MSE = \frac{1}{m} \sum_{i=1}^m ((\hat{y}_i - y_i)^2) \quad (24)$$

dengan

\hat{y}_i = data awal (data sebenarnya)

y_i = data akhir (data hasil estimasi)

m = jumlah data

2. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{\sum_i^m APE}{m} \quad (25)$$

dimana

$$APE = \frac{\sum_i^m |\hat{y}_i - y_i|}{y_i} \times 100 \quad (26)$$

dengan

\hat{y}_i = data awal (data sebenarnya)

y_i = data akhir (data hasil estimasi)

m = jumlah data

3. Mean Absolute Error (MAE)

$$MAE = \frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i) \quad (27)$$

dengan

\hat{y}_i = data awal (data sebenarnya)

y_i = data akhir (data hasil estimasi)

m = jumlah data

III. METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2022/2023 bertempat di Balai Penelitian Teknologi Mineral BRIN yang beralamat di Jl. Ir. Sutami Km.15 Tanjung Bintang, Lampung Selatan.

3.2 Data Penelitian

Data dikutip dari hasil penelitian semi-empiris yang sudah ada. Data eksperimen merupakan memiliki 7 *input* dan 1 *output*. Lanthanum (III) Klorida Heptahidrat 98%, elektrolit pembantu (konsentrasi H_2SO_4), luas area elektroda (A), koefisien difusi elektro aktif (D), viskositas kinematik elektrolit (ν), kekuatan medan magnet (B) dan jumlah elektron dalam proses redoks (n) merupakan *input* untuk menghasilkan *output* yaitu arus pembatas (ib). Terdapat 19 sampel dan dilipatgandakan sebanyak 10 kali guna meningkatkan keakuratan data.

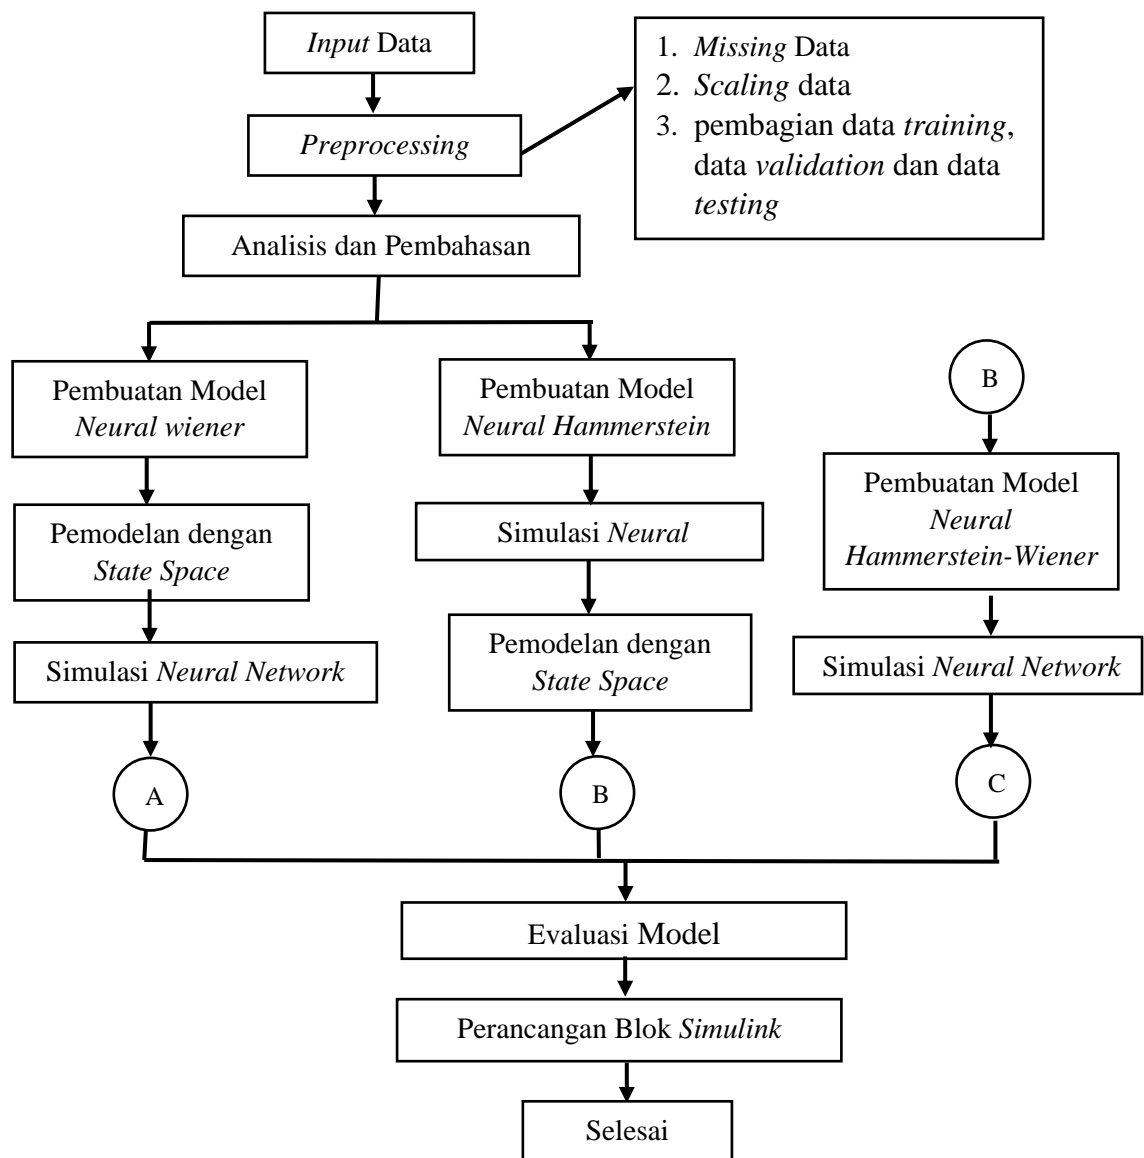
3.3 Metode Penelitian

Penelitian ini menggunakan model *Neural Wiener*, *Neural Hammerstein*, *Neural Hammerstein-Wiener* untuk memprediksi arus pembatas (ib), langkah yang dilakukan pada penelitian ini sebagai berikut:

1. *Input data*

2. *Preprocessing data*
3. Analisis dan pembahasan
4. Evaluasi Model
5. Perancangan blok *simulink*

Model *Neural Wiener*, *Neural Hammerstein*, *Neural Hammerstein-Wiener* untuk memprediksi arus pembatas ib digambarkan dengan diagram alir berikut:



Gambar 9. Diagram Alir Metode Penelitian Perbandingan Kemampuan *Neural Hammerstein*, *Neural Wiener*, *Hammerstein-Wiener Model* dalam Pemodelan Lanthanum MED

Berikut adalah uraian langkah-langkah yang dilakukan:

1. *Input data*

Pada tahap ini dilakukan *input* data menggunakan perintah *xlsread* Matlab dengan mendefinisikan suatu variabel yang dapat diformulasikan yang kemudian disimpan dalam bentuk m-file. Data yang diolah dikutip dari hasil penelitian semi-empiris yang sudah ada tentang nilai arus pembatas pembatas (ib) pada lanthanum dengan 7 *input* dan 1 *output*, kemudian data *input* di bentuk menjadi matriks berukuran 7 x 190, sedangkan *output* menjadi 1 x 190.

2. *Preprocessing*

Preprocessing data merupakan tahapan sebelum proses pengklasifikasian yang diperlukan untuk membersihkan, menghilangkan, mengubah bentuk data. Dalam penelitian ini, *Preprocessing* dilakukan dalam beberapa tahapan, yaitu mengecek data hilang (*missing value*) dilakukan dengan menghapus data yang hilang pada data penelitian atau menggantinya dengan nilai yang lain pada Matlab, dilakukan *Scaling* data menggunakan *z-score* kemudian, Data *input* dilatih menggunakan algoritma *Levenberg-Marquardt* dengan dilakukan uji coba dengan proporsi data *training*, data *validation* dan data *testing* yang digunakan yaitu 50% *training*, 20% *validation*, 30% *testing*, 40% *training*, 30% *validation*, 30% *testing*, serta 45% *training*, 20% *validation*, 35% *testing*.

3. Analisis dan pembahasan

Pada tahap ini, setelah data eksperimen dilatih dengan algoritma *Levenberg-Marquardt* dengan 1 *hidden layer* dilakukan proses pembuatan model dengan bantuan aplikasi Matlab. pembuatan model yang pertama, yaitu Pembuatan *Neural Winner model* dilakukan dengan cara melatih data *input* dan *output* pada blok *state space* terlebih dahulu sehingga menghasilkan variabel sementara, kemudian hasil dari *output State space* dilanjutkan ke dalam *Neural Network* sehingga *Neural* blok menjadi *single input single output (SISO)*. selanjutnya dilakukan pembuatan model yang kedua, yaitu Pembuatan *Neural Hammerstein model* dengan cara melatih data *input* dan *output* pada blok *Neural Network* terlebih dahulu sehingga menghasilkan variabel sementara, hasil dari *output Neural Network* dilanjutkan ke dalam *State space* sebagai *input*. Selanjutnya dilakukan pembuatan model yang terakhir, yaitu Pembuatan *Neural*

Hammerstein-Wiener model dengan cara melatih data *input* dan *output* pada blok *Neural Network* pertama terlebih dahulu sehingga menghasilkan variabel sementara, hasil dari *output Neural Network* dilanjutkan ke dalam *State space* sebagai *input*. Hasil dari *output Neural Hammerstein* kemudian dilanjutkan ke dalam *Neural Network* kedua.

4. Evaluasi Model

Pada tahap ini akan dilakukan proses pengukuran tingkat keakuratan menggunakan MSE, MAPE dan MEA sebagai evaluasi model yang kemudian akan dibandingkan dalam mensimulasikan nilai dari arus pembatas (ib) terbaik untuk solusi simulasi MED pada lanthanum. Kriteria dari hasil pemodelan terbaik akan memiliki nilai *error* atau kesalahan yang paling kecil.

5. Perancangan blok *simulink*

Setelah dilakukan pengukuran tingkat keakuratan model selanjutnya akan dilakukan perancangan model menggunakan blok *Simulink*. Proses *Simulink* dilakukan menggunakan diagram fungsional yang meliputi blok yang terhubung dengan fungsinya masing-masing secara ekuivalen. Proses *Simulink* ini dilakukan untuk melihat kesesuaian dari *output* data (ib) dengan *output* yang dihasilkan dari setiap model akan dilakukan perancangan model menggunakan blok *Simulink*.

V. PENUTUP

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah dijelaskan dalam bab sebelumnya, dapat diambil kesimpulan sebagai berikut:

1. Model *Neural Hammerstein*, *Neural Wiener* dan *Hammerstein Wiener* dapat mensimulasikan nilai dari arus pembatas (ib) untuk solusi simulasi MED pada lanthanum. Sehingga hal ini dapat digunakan untuk mengatasi masalah kekerasan pada lapisan yang dihasilkan pada lanthanum.
2. Menggunakan dataset berupa 7 parameter *input* dan 1 parameter *output*, diketahui bahwa hasil akhir berupa nilai MSE, MAPE, dan MAE dari pemodelan *Hammerstein Wiener* Model lebih kecil dari pemodelan *Neural Hammerstein*, *Neural Wiener* dengan *Hammerstein Wiener* Model memiliki nilai MSE sebesar 0.0019, MAPE 1.4122%, MAE sebesar sebesar 0.0142.

5.2 Saran

Adapun saran yang dianjurkan untuk penelitian selanjutnya yaitu,:

1. Membandingkan dengan menggunakan model *Neural Network* yang lain.
2. Mengimplementasikan model *Neural Hammerstein*, *Neural Wiener* dan *Hammerstein Wiener* dalam aplikasi lain.
3. Penelitian dengan metode penyelesaian yang sama dapat menambahkan proses *hypertuning*,

DAFTAR PUSTAKA

- Al-Duwaish, H., Karim, M.N., Chandrasekar, V. 1996. Use of multilayer feedforward *Neural networks* in identification and control of *Wiener* model. *IEE Proc.-Control Theory Appl*, 255–258.
- Bodemann, C. D., & De Rose, F. (2004). The Successful Development Process with Matlab Simulink in the Framework of ESA's ATV Project. In *55th International Astronautical Congress of the International Astronautical Federation, the International Academy of Astronautics, and the International Institute of Space Law* (pp. U-3).
- Cai, H., Li, P., Su, C., & Cao, J. 2018. Double-layered Nonlinear model predictive control based on *Hammerstein–Wiener* model with disturbance rejection. *Measurement and Control*, **51**(7-8), 260-275.
- Chen, Y. C., & Wang, J. S. 2009. A *Hammerstein-Wiener* Recurrent *Neural Network* with Frequency-Domain Eigensystem Realization Algorithm for Unknown System Identification. *J. Univers. Comput. Sci.*, **15**(13), 2547-2565.
- Cristea, M. V., & Agachi, S. P. (2006). Nonlinear model predictive control of the wastewater treatment plant. In *Computer Aided Chemical Engineering* (Vol. 21, pp. 1365-1370).
- Dawkins, Paul. 2011. *College Algebra*. Texas: Lamar University.
- Fajar, M. (2016). Perbandingan kinerja peramalan pertumbuhan ekonomi Indonesia antara ARMA, FFNN dan hybrid ARMA-FFNN.
- Gilabert, P., Montoro, G., & Bertran, E. 2005. Pada model *Wiener* dan *Hammerstein* untuk predistorsi power amplifier. Pada *2005 Prosiding Konferensi Gelombang Mikro Asia-Pasifik* (Vol. 2, hlm. 4-hal). IEEE.
- Giri, F. and Bai, E. 2010. *Block-oriented Nonlinear System Identification*. Springer-Verlag London, London.
- Hadi Amiri, Timothy Miller, and Guergana Savova. 2017. Repeat before forgetting: Spaced repetition for efficient and effective training of neural

networks. *In Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, pages 2401–2410.

Heaton, J. 2008. *Introduction to Neural Network for Java*. 2nd Ed. Heaton Research Inc. Florida.

Hikmat, O. F., Elnimair, M. O., & Osman, K. (2014). PI adaptive neuro-fuzzy and receding horizon position control for intelligent pneumatic actuator. *Jurnal Teknologi*, 67(3).

Kementerian Energi dan Sumberdaya Mineral RI. 2021. *Laporan Kinerja Kementerian ESDM Tahun 2019*. Jakarta. diakses 17 November 2021. <https://www.esdm.go.id/assets/media/content/content-laporan-kinerja-kementerian-esdm-2019.pdf>

Levich, V. G. 1962. *Physicochemical Hydrodynamics*; Prentice-Hall: Englewood Cliffs, New Jersey: 20-27.

Laina. 2011. Menentukan Akar-Akar dan Diskriminan Pada Persamaan Kuartik. *Jurnal Matematika*.

Lubis, Nur Azizah. 2018. Pengaruh Kekentalan Cairan Terhadap Waktu Jatuh Benda menggunakan Falling Ball Method. *FISITEK: Jurnal Ilmu Fisika dan Teknologi*.

Makridakis, S., Wheelwright, S. C., dan McGee, V. E. 1995. *Metode dan Aplikasi Peramalan*. Diterjemahkan oleh: Ir. Hari Suminto. Jakarta: Binarupa Aksara. Terjemahan dari: *Forecasting 2nd Edition*.

Maraden, Yan. 2004. *Identifikasi Sistem Tiga Tangka Terhubung Dengan Menggunakan Algoritma Fuzzy Clustering Gustafson-Kessel*. Departemen Elektro Fakultas Teknik Universitas Indonesia.

Marwati, S., Padmaningrum, R. T., & Marfuatun, M. 2009. Utilization of Copper Weight Metal Ion (II), Kromium (III), Timbal (II), And Seng (II) In Liquid Waste Industry for Electroplating Iron Coating. *Jurnal Penelitian Sainstek*

Mhiochain Ni, T.R., Hinds, G., Martin, A., Chang, E., Lai, A., Costiner, L., Coey, J.M.D., 2004. *Influence of Magnetic Field and Gravity on the Morphology of Zinc Fractal Electrodeposits*. *Electrochimica Acta*, 49: 4813-4828.

Ogata, Katsuhito. 2010. *Modern Control Engineering 5th Edition*. New Jersey: Pearson Education, Inc.

Ohata, A., Furuta, K., & Nita, H. (2006, October). Identification of nonlinear ARX model with input and output dependent coefficients. In *2006 IEEE Conference on Computer Aided Control System Design, 2006 IEEE*

International Conference on Control Applications, 2006 IEEE International Symposium on Intelligent Control (pp. 2577-2582). IEEE.

- Osman, K., Faudzi, M., Rahmat, M. F., & Suzumori, K. (2014). System identification and embedded controller design for pneumatic actuator with stiffness characteristic. *Mathematical Problems in Engineering*.
- Prasetyo P. 2008. Tinjauan Tertundanya Pengolahan Laterit Dengan Teknologi HPAL Di Indonesia. Seminar Nasional Material dan Metalurgi 2008, p.57-68.
- Quachio, R., & Garcia, C. 2019. *MPC relevant identification method for Hammerstein and Wiener models*. *Journal of Process Control*, 78-88.
- Ratmi Herlani, M. S. 2011. *Mempelajari Pengaruh Logam Tanah Jarang Serium (Ce) Dan Lanthanum (La) Pada Analisis Torium Dengan Metoda Pendar Sinar-X*. Yogyakarta: Pusat Teknologi Akselerator dan Proses Bahan – BATAN, Babarsari Yogyakarta.
- Ridwan, D. I., Setianingsih, C., & Murti, M. A. 2021. Prediksi Penggunaan Energi Listrik Dengan Menggunakan Metode Support Vector Regression. *e-Proceeding of Engineering*.
- Sazli, M. H. 2006. A brief review of *feed-forward* neural networks. *Commun. Fac. Sci. Univ. Ank. Series A2-A3* **50**(1): 11-17
- Schoukens, J., dan Ljung, L. 2019. Nonlinear system identification: A user-oriented road map. *IEEE Control Systems Magazine*
- Sudibyo. 2010, Modeling of Limiting Current and Growth Fractal for Electrodeposition Under Magnetic Field Influence, M.Sc. Universiti Sains Malaysia, Penang.
- Sudibyo dan Aziz, N. 2016. Semi-Empirical Equation of Limiting Current For Cobalt Electrodeposition in The Presence of Magnetic Field and Additive Electrolyte. *AIP Conference Proceedings*.
- Sudibyo, Handoko, A. S., Herlina, U., Aziz, N., dan Sukma, Y. A. 2020. Application of Artificial *Neural Network* model to predict limiting current for cobalt magneto-electrodeposition. *In AIP Conference Proceedings*.
- Sudibyo, S., Murat, M. N., dan Aziz, N. 2015. Simulated annealing-Particle Swarm Optimization (SA-PSO): particle distribution study and application in *Neural Wiener*-based NMPC. *In 2015 10th Asian Control Conference*
- Sudibyo., Murat, M.N., dan Aziz, N. 2013. Development of multi variable *Neural Hammerstein* model for MTBE catalytic distillation. In 2013

International Conference on Robotics, Biomimetics, Intelligent Computational

- Sudibyo., Murat, M.N., dan Aziz, N. 2013. *Neural Hammerstein based MPC (NHMPC) for MTBE reactive distillation*. In 2013 International Conference on Robotics, Biomimetics, Intelligent Computational Systems.
- Sudibyo, Oediyani, Cahyanegoro. 2020. *Optimization of Electro Metal Electrowinning Nickel Metal Processing Resulted by Solvent Extraction Using Versatic 10 And Cyanex 272*. Journal of Materials Science and Applied Energy 9 (1), 491– 497.
- Taringou, F., Hammi, O., Srinivasan, B., Malhame, R., & Ghannouchi, F. M. 2010. Behaviour modelling of wideband RF transmitters using *Hammerstein-Wiener* models. *IET Circuits, Devices and Systems*, 4(4), 282–290. <https://doi.org/10.1049/iet-cds.2009.0258>
- Virolainen, Sami. 2013. *Hydrometallurgical Recovery of Valuable Metals from Secondary Raw Materials*. Lappenranta: Lappenranta University of Technology.
- Wang, D. Q., & Ding, F. 2012. Hierarchical least squares estimation algorithm for *Hammerstein–Wiener* systems. *IEEE Signal Processing Letters*, 19(12), 825-828.
- Wayahdi, M. R., Zarlis, M., dan Putra, P. H. 2019. Initialization of the Nguyen-widrow and Kohonen Algorithm on the Backpropagation Method in the Classifying Process of Temperature Data in Medan. In Journal of Physics: Conference Series.
- Zhang QJ, Gupta KC, 2003. *Neural networks for RF and Microwave Design- From Theory to Practice*, IEEE Transactions on Microwave Theory and Techniques. 51(4): 1339-1350
- Zhu, Y. (2002). Estimasi model N–L–N *Hammerstein–Wiener*. *Automatica* , 38(9), 1607-1614.