



PENERAPAN MULTI-AGENT SYSTEMS (MAS) & MULTI-OBJECTIVE OPTIMIZATION (MOO): PENDEKATAN EKSTRAKSI BAHAN ALAMI

Oleh

Eka Puji Agustini, M.Kom

Prof. Dr. Rahmat Gernowo, M.Si

Dr. Ir. Kurnianingsih, S.T., M.T

**PENERAPAN
MULTI-AGENT SYSTEMS (MAS) &
MULTI-OBJECTIVE OPTIMIZATION (MOO):
PENDEKATAN EKSTRAKSI BAHAN ALAMI**

Oleh:

Eka Puji Agustini, M.Kom

Prof. Dr. Rahmat Gernowo, M.Si

Dr. Ir. Kurnianingsih, S.T., M.T

Diterbitkan oleh



2026

PENERAPAN MULTI-AGENT SYSTEMS (MAS) & MULTI-OBJECTIVE OPTIMIZATION (MOO): PENDEKATAN EKSTRAKSI BAHAN ALAMI

Oleh:

Eka Puji Agustini, M.Kom

Prof. Dr. Rahmat Gernowo, M.Si

Dr. Ir. Kurnianingsih, S.T., M.T

Uk. 15,5cm x 23cm (viii + 125hlm)

ISBN:

Diterbitkan oleh



Editor: Dr. Usman Ependi, S.Kom., M. Kom.

Mei 2026

Hak Cipta dilindungi undang-undang

Dilarang memperbanyak sebagian atau seluruh isi buku ini dalam bentuk apapun, baik secara elektronik maupun mekanik, termasuk memfotokopi, merekam atau dengan menggunakan system penyimpanan, tanpa izin tertulis dari Penulis.

KATA PENGANTAR

Dalam era industri yang semakin berkembang pesat, efisiensi dan keberlanjutan dalam proses ekstraksi bahan alami menjadi semakin penting. Proses ekstraksi, yang berperan penting dalam berbagai sektor seperti farmasi, pangan, dan kosmetika, menghadapi tantangan besar dalam mencapai hasil yang optimal, baik dari segi kualitas maupun biaya. Di sisi lain, teknologi Multi-Agent Systems (MAS) dan Multi-Objective Optimization (MOO) menawarkan potensi besar untuk mengoptimalkan proses-proses industri, termasuk ekstraksi bahan alami, dengan cara yang lebih efisien dan efektif.

Buku ini hadir untuk memberikan pemahaman yang mendalam tentang penerapan MAS dan MOO dalam optimasi proses ekstraksi bahan alami. Buku ini tidak hanya membahas teori dan konsep dasar dari kedua pendekatan tersebut, tetapi juga memberikan panduan praktis untuk mengintegrasikannya dalam konteks industri ekstraksi. Mulai dari pengenalan konsep dasar MAS, prinsip-prinsip koordinasi agen, hingga penerapan teknik-teknik MOO dalam optimasi ekstraksi, buku ini bertujuan untuk membekali pembaca dengan pengetahuan yang dapat langsung diterapkan. Dilengkapi dengan studi kasus dan eksperimen simulasi, buku ini juga menawarkan pemahaman tentang bagaimana algoritma MAS-MOO dapat digunakan untuk mengatasi tantangan dalam proses ekstraksi, seperti mengoptimalkan waktu ekstraksi, meningkatkan kualitas produk, dan mengurangi dampak lingkungan. Dengan pendekatan yang jelas dan praktis, buku ini diharapkan dapat menjadi sumber referensi yang berguna bagi mahasiswa, peneliti, dan praktisi industri yang tertarik untuk mengeksplorasi teknologi canggih dalam optimasi proses.

Meskipun buku ini tidak mencakup semua aspek yang mungkin ada, kami berharap pembaca dapat memanfaatkan isi buku ini sebagai dasar untuk mengembangkan dan mengimplementasikan sistem MAS-MOO dalam berbagai aplikasi industri lainnya. Semoga buku ini memberikan inspirasi dan kontribusi yang berarti dalam upaya mengoptimalkan proses ekstraksi bahan alam secara lebih efisien, berkelanjutan, dan berbasis data.

Selamat membaca dan terus berinovasi!

Semarang, September 202

Penulis

DAFTAR ISI

BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Tujuan dan Signifikansi	3
1.3 Tujuan Pembelajaran	4
1.4 Struktur Buku.....	7
BAB II KONSEP DASAR MULTI-AGENT SYSTEM (MAS)	
.....	10
2.1 Pengertian dan Sejarah MAS	12
2.1.1 Pengertian	12
2.1.2 Sejarah MAS.....	15
2.2 Arsitektur dan Desain Sistem Multi-Agen.....	18
2.2.1 Jenis Arsitektur MAS	18
2.2.2 Desain MAS.....	21
2.3 Prinsip-Prinsip Koordinasi dan Negosiasi	22
2.3.1 Koordinasi dalam Sistem Multi-Agen (MAS).....	22
2.3.2 Negosiasi dalam MAS	23
2.4 Penerapan MAS dalam Industri	25
BAB III KONSEP DASAR OPTIMASI MULTI-OBJEKTIF (MOO)	
.....	30
3.1. Pengertian dan Prinsip Dasar MOO.....	31
3.1.1 Pengertian MOO	31
3.1.2 Pentingnya MOO dalam Ekstraksi Bahan Alami	34
3.2 Teknik dan Algoritma untuk MOO.....	37
3.3 Kriteria Evaluasi dalam MOO	41
3.3.1 Hypervolume (HV).....	41
3.3.2 Generational Distance (GD) & Inverted GD (IGD/IGD+)	
.....	43
3.3.3 Spread / Δ (NSGA-II diversity metric).....	48
3.3.4 Epsilon Indicator (ϵ)	50
3.3.5 Coverage / C-metric.....	53
3.3.6 R2 Indicator	54
BAB IV INTEGRASI MAS DAN MOO UNTUK OPTIMASI PROSES EKSTRAKSI.....	57
4.1 Framework MAS-MOO Berbasis Data	59
4.1.1 Kerangka Dasar Framework MAS-MOO.....	59
4.1.2 Penggunaan Multi-Objective Optimization (MOO).....	61

4.1.3. Interaksi Antar Agen dan Proses Pengambilan Keputusan	62
4.1.4 Evaluasi Kinerja Sistem MAS-MOO	63
4.2 Proses Rekayasa Fitur dan Pengumpulan Data dalam Eksperimen Ekstraksi Moringa Oleifera.....	63
4.2.1 Pengumpulan Data Eksperimen dari Empat Kondisi Ekstraksi	64
4.2.2 Tantangan dalam Pengumpulan Data	66
4.3 Persiapan Data untuk Eksperimen Optimasi.....	67
4.4 Simulasi dan Pengujian Sistem.....	70
4.4.2 Data Eksperimen dan Parameter Proses	73
4.4.3 Data Setelah Pra-Pemrosesan	77
4.4.4 Setup Simulasi	77
4.4.5 Algoritma yang Digunakan.....	81
4.4.6 Ilustrasi Eksperimen dan Grafik Perbandingan	86
5.1 Desain Eksperimen	92
5.2 Pengujian Model Prediktif.....	92
5.3 Analisis Kinerja MAS-MOO dalam Berbagai Skenario...	95
5.4 Perbandingan dengan Metode Tradisional.....	99
6.1 Interpretasi Temuan	104
6.2 Implikasi dalam Industri	105
6.3 Keunggulan Pendekatan Berbasis Data	106
7.1 Kesimpulan	108
7.2 Rekomendasi untuk Penelitian Selanjutnya.....	109
BAB VII PENUTUP.....	112
BIODATA PENULIS.....	123

DAFTAR GAMBAR

Gambar 2. 1 Struktur MAS	15
Gambar 2. 2 Lingkungan Multi-Agent Untuk Negosiasi Sumber: (Hindriks et al., 2009)	25
Gambar 3. 1 Ilustrasi MOO Tiga Tujuan	36
Gambar 4. 1 Integrasi MAS-MOO	61
Gambar 4. 2 Alur Eksperimen	87
Gambar 4. 3 Perbandingan front Pareto antara MAS-MOO dan NSGA-II	89
Gambar 5. 1 Perbandingan Nilai Hypervolume Antar Algoritma	97
Gambar 5. 2 Perbandingan Nilai IGD+ Antar Algoritma	98
Gambar 5. 3 Front Pareto 3D antara MAS-MOO dan NSGA-II..	98

DAFTAR TABEL

Tabel 3. 1 Kelebihan dan Kekurangan Teknik MOO	40
Tabel 3. 2 Perbandingan GD, IGD dan IGD+	47
Tabel 3. 3 Perbandingan Δ dengan Metrik Lain.....	49
Tabel 3. 4 Perbandingan Epsilon Indicator (ϵ) dengan Metrik Lain	52
Tabel 4. 1 Contoh Data Eksperimen	76
Tabel 4. 2 Contoh Data Setelah Pra-pemrosesan	77
Tabel 4. 3 Parameter Simulasi.....	80
Tabel 4. 4 Perbandingan Ketiga Pendekatan.....	84
Tabel 5. 1 Hasil Pengujian Model.....	94
Tabel 5. 2 Perbandingan Kinerja MAS-MOO, NSGA-II, dan Agnostic-NSGA-II.....	96
Tabel 5. 3 Perbandingan Kinerja MAS-MOO dengan Metode Tradisional	101

BAB I

PENDAHULUAN

Buku ini bertujuan untuk memberikan pemahaman yang mendalam tentang penerapan MAS dan MOO dalam optimasi proses ekstraksi bahan alami. Dalam buku ini, pembaca akan diperkenalkan dengan konsep dasar kedua teknologi tersebut, serta bagaimana keduanya dapat diintegrasikan untuk mengatasi tantangan dalam proses ekstraksi. Selain itu, buku ini juga akan membahas aplikasi praktis MAS-MOO dalam ekstraksi senyawa bioaktif dari *Moringa Oleifera*, sebagai studi kasus yang menunjukkan potensi besar dalam dunia industri.

Melalui buku ini, pembaca tidak hanya akan memperoleh pemahaman teori yang mendalam mengenai MAS dan MOO, tetapi juga mendapatkan wawasan tentang cara mengimplementasikan kedua teknologi tersebut dalam proses ekstraksi bahan alami untuk menghasilkan produk yang lebih efisien, ramah lingkungan, dan berkualitas tinggi. Kami berharap buku ini dapat menjadi referensi yang berguna bagi mahasiswa, peneliti, dan praktisi industri yang ingin memahami serta mengaplikasikan teknologi canggih ini untuk mengoptimalkan proses ekstraksi bahan alami dan menciptakan inovasi berkelanjutan.

1.1 Latar Belakang

Proses ekstraksi bahan alami, terutama dalam industri farmasi, pangan, dan kosmetika, merupakan langkah penting dalam menghasilkan produk bernilai tinggi yang berasal dari tanaman atau sumber alami lainnya. Salah satu contoh bahan alami yang banyak digunakan adalah *Moringa Oleifera*, yang dikenal memiliki berbagai senyawa bioaktif seperti polifenol, flavonoid, dan antioksidan yang bermanfaat bagi kesehatan (Sadia et al., 2023), (Azra et al., 2024). Ekstraksi senyawa-senyawa ini sering kali melibatkan teknik-teknik seperti ekstraksi cair-cair atau ekstraksi dengan pelarut yang memerlukan optimasi cermat agar hasil yang diperoleh maksimal, efisien, dan terjangkau (Haido et al., 2024), (J. H. Kim et al., 2014).

Namun, tantangan utama dalam proses ekstraksi bahan alami terletak pada kebutuhan untuk mengoptimalkan berbagai parameter secara bersamaan, seperti waktu ekstraksi, suhu, pH, dan penggunaan pelarut, yang semuanya berkontribusi pada kualitas produk akhir(Kavak, 2017). Dalam banyak kasus, optimasi parameter-parameter ini dilakukan secara manual atau dengan metode trial-and-error yang tidak hanya memakan waktu, tetapi juga dapat mengarah pada penggunaan sumber daya yang berlebihan dan hasil yang suboptimal(Haido et al., 2024). Selain itu, proses ekstraksi sering kali melibatkan pengelolaan data dalam jumlah besar yang dihasilkan dari eksperimen dan pengujian lapangan, yang semakin menambah kompleksitas dalam pengambilan keputusan yang tepat(Meijer et al., 2024),(Tsegay et al., 2024).

Dalam menghadapi tantangan ini, sistem otomatis yang berbasis data menjadi sangat penting. Dengan bantuan teknologi canggih, terutama Multi-Agent Systems (MAS) dan Multi-Objective Optimization (MOO), proses ekstraksi dapat dikelola dan dioptimalkan secara lebih efisien. MAS memungkinkan penggunaan agen-agen cerdas yang dapat bekerja secara otonom, berkomunikasi, dan berkoordinasi untuk mengatur berbagai aspek proses ekstraksi. Agen-agen ini dapat memonitor kondisi ekstraksi secara real-time, menyesuaikan parameter ekstraksi berdasarkan data yang diperoleh, serta melakukan keputusan yang optimal dalam waktu yang sangat singkat(Sevindik et al., 2024).

Di sisi lain, MOO merupakan pendekatan yang sangat efektif untuk menangani masalah yang melibatkan lebih dari satu tujuan yang bertentangan, seperti dalam kasus ekstraksi bahan alami, di mana kita perlu mengoptimalkan waktu, kualitas, dan konsumsi energi dalam satu waktu. Dengan menggunakan MOO, berbagai tujuan dapat dioptimalkan secara bersamaan, menghasilkan solusi yang lebih baik dengan mempertimbangkan trade-off antara berbagai parameter yang ada(Compounds et al., 2024),(Bouchez et al., 2020).

Dengan memanfaatkan MAS dan MOO, proses ekstraksi bahan alami dapat diubah menjadi sistem yang lebih terstruktur, efisien, dan berbasis data. Penggunaan sistem ini diharapkan dapat menghasilkan proses yang lebih cepat, lebih hemat biaya, dan lebih ramah lingkungan, sekaligus meningkatkan kualitas dan konsistensi

produk ekstraksi. Oleh karena itu, penerapan MAS dan MOO dalam optimasi proses ekstraksi bahan alami, seperti Moringa Oleifera, memiliki potensi besar untuk memberikan dampak positif bagi industri yang bergantung pada bahan alami, meningkatkan daya saing, dan menciptakan inovasi baru yang berkelanjutan (Daniels, 2017), (Sevindik et al., 2024).

1.2 Tujuan dan Signifikansi

Tujuan dari penerapan Multi-Agent Systems (MAS) dan Multi-Objective Optimization (MOO) dalam optimasi proses ekstraksi bahan alami adalah untuk memberikan solusi yang lebih efisien, terstruktur, dan berbasis data dalam menghadapi tantangan yang ada dalam proses ekstraksi. Dengan menggunakan MAS, kita dapat memanfaatkan agen-agen cerdas yang bekerja secara otonom untuk mengelola, mengatur, dan memantau kondisi ekstraksi secara real-time. Hal ini memungkinkan penyesuaian parameter proses secara dinamis berdasarkan data yang diperoleh dari lingkungan ekstraksi, sehingga menghasilkan hasil yang lebih optimal dan konsisten.

Di sisi lain, MOO bertujuan untuk mengatasi masalah yang melibatkan banyak tujuan yang saling bertentangan, seperti mengoptimalkan waktu, kualitas produk, dan konsumsi energi dalam satu waktu. Penggunaan MOO memungkinkan pencarian solusi yang mempertimbangkan trade-off antara berbagai parameter, sehingga memaksimalkan hasil ekstraksi tanpa mengorbankan efisiensi operasional atau kualitas produk. Dengan kombinasi MAS dan MOO, proses ekstraksi dapat dioptimalkan dengan mempertimbangkan berbagai faktor yang kompleks, seperti kondisi lingkungan, penggunaan sumber daya, dan parameter teknis lainnya, dalam satu sistem yang terintegrasi.

Signifikansi penelitian dan penerapan MAS-MOO dalam optimasi ekstraksi bahan alami sangat besar bagi berbagai industri yang bergantung pada bahan alami, seperti industri farmasi, pangan, dan kosmetika. Dalam industri-industri ini, proses ekstraksi merupakan langkah kunci yang dapat mempengaruhi kualitas, efisiensi, dan biaya produk akhir. Oleh karena itu, penerapan teknologi canggih ini dapat memberikan dampak yang signifikan dalam meningkatkan produktivitas, mengurangi biaya, serta

menghasilkan produk yang lebih berkualitas dan ramah lingkungan. Dengan menggunakan pendekatan berbasis data, MAS dan MOO tidak hanya memungkinkan optimasi dalam hal teknis, tetapi juga memungkinkan pengelolaan yang lebih baik terhadap sumber daya dan pengambilan keputusan yang lebih tepat dalam waktu yang lebih singkat.

Lebih jauh lagi, penerapan MAS dan MOO dalam ekstraksi bahan alami juga memiliki potensi untuk mendorong inovasi dalam industri terkait. Dengan kemampuan untuk mengoptimalkan berbagai parameter secara bersamaan, teknologi ini dapat membuka peluang untuk mengembangkan proses ekstraksi yang lebih efisien, hemat energi, dan berkelanjutan, yang sesuai dengan tuntutan industri modern yang semakin peduli dengan keberlanjutan dan efisiensi sumber daya. Secara keseluruhan, teknologi ini tidak hanya akan memberikan manfaat bagi industri yang ada saat ini, tetapi juga akan menjadi pendorong kemajuan dalam riset dan pengembangan di masa depan.

1.3 Tujuan Pembelajaran

Buku ini bertujuan untuk memberikan pemahaman yang komprehensif tentang penerapan Multi-Agent System (MAS) dan Multi-Objective Optimization (MOO) dalam proses ekstraksi bahan alami, serta tantangan yang dihadapi dalam industri ekstraksi. Setiap tujuan pembelajaran akan dirinci lebih lanjut dengan contoh penerapan langsung dan tantangan yang ada dalam industri ekstraksi:

1. Memahami Konsep Dasar MAS dan MOO

Tujuan: Pembaca akan memahami dasar teori dan prinsip dari MAS dan MOO.

Contoh Penerapan: Pengenalan berbagai jenis agen dalam MAS, seperti agen pemantauan, agen pengontrol, dan agen komunikasi dalam konteks ekstraksi bahan alami. Pembaca akan diajarkan bagaimana agen-agen ini bekerja bersama untuk mengatur parameter ekstraksi secara real-time.

Tantangan yang Dihadapi: Dalam industri ekstraksi, terdapat tantangan dalam mengintegrasikan agen-agen yang

bekerja secara otonom dengan proses ekstraksi yang ada, serta mengatasi masalah komunikasi antar agen yang dapat menyebabkan ketidaksesuaian dalam pengaturan parameter ekstraksi.

2. Mengidentifikasi Aplikasi MAS dan MOO dalam Ekstraksi.

Tujuan: Pembaca akan dapat mengidentifikasi bagaimana MAS dan MOO dapat diterapkan dalam proses ekstraksi bahan alami, serta manfaat yang dapat diperoleh dari penerapan sistem ini.

Contoh Penerapan: Penggunaan MOO untuk mengoptimalkan waktu ekstraksi, kualitas produk, dan konsumsi energi dalam ekstraksi Moringa Oleifera menggunakan metode pelarut superkritikal. Pembaca akan memahami bagaimana MOO dapat digunakan untuk mencari solusi yang optimal antara berbagai tujuan yang bertentangan.

Tantangan yang Dihadapi: Salah satu tantangan besar adalah mengelola banyak variabel yang saling terkait dan memerlukan solusi yang mempertimbangkan trade-off antara kualitas produk dan efisiensi energi. Selain itu, implementasi teknologi ini memerlukan pemahaman yang mendalam tentang teknik optimasi yang tepat.

3. Menerapkan MAS dan MOO dalam Kasus Nyata

Tujuan: Pembaca akan dapat mengaplikasikan MAS dan MOO pada kasus ekstraksi bahan alami yang nyata, seperti ekstraksi senyawa bioaktif dari tanaman Moringa Oleifera.

Contoh Penerapan: Penerapan MAS untuk mengontrol suhu dan pH dalam ekstraksi senyawa bioaktif dari tanaman Moringa secara otomatis dan dinamis, serta menggunakan MOO untuk memilih kombinasi parameter yang menghasilkan hasil terbaik.

Tantangan yang Dihadapi: Salah satu tantangan dalam penerapan MAS dan MOO adalah keterbatasan sumber daya dalam mengimplementasikan sistem berbasis data pada skala

industri, serta kesulitan dalam pengumpulan data yang akurat dan real-time dari lingkungan ekstraksi yang bervariasi.

4. Meningkatkan Kemampuan dalam Pengambilan Keputusan Berbasis Data

Tujuan: Pembaca akan belajar bagaimana mengelola dan menganalisis data yang dihasilkan selama eksperimen ekstraksi, serta bagaimana menggunakan data tersebut untuk pengambilan keputusan yang lebih tepat.

Contoh Penerapan: Menggunakan hasil dari eksperimen ekstraksi untuk membangun model prediktif berbasis MOO yang dapat memperkirakan hasil ekstraksi berdasarkan kombinasi parameter yang telah diuji.

Tantangan yang Dihadapi: Tantangan utama adalah memperoleh data yang cukup dan berkualitas dari berbagai eksperimen untuk membangun model yang akurat, serta memastikan bahwa model tersebut dapat beradaptasi dengan kondisi ekstraksi yang berubah.

5. Mengembangkan Sistem Ekstraksi Berkelanjutan dan Efisien

Tujuan: Pembaca akan memahami bagaimana mengoptimalkan proses ekstraksi untuk menghasilkan produk berkualitas tinggi dengan efisiensi yang lebih baik dan dampak lingkungan yang lebih rendah.

Contoh Penerapan: Menggunakan MAS untuk mengontrol dan menyesuaikan proses ekstraksi secara real-time, serta menggunakan MOO untuk mengurangi penggunaan pelarut dan energi selama ekstraksi sambil menjaga kualitas produk akhir.

Tantangan yang Dihadapi: Tantangan dalam industri ekstraksi termasuk menjaga efisiensi energi dan mengurangi dampak lingkungan tanpa mengorbankan kualitas produk. Penggunaan pelarut ramah lingkungan dan teknik ekstraksi berkelanjutan memerlukan pengembangan metode yang lebih efisien dan ramah lingkungan.

1.4 Struktur Buku

Buku ini dirancang untuk memberikan pemahaman menyeluruh tentang penerapan Multi-Agent System (MAS) dan Multi-Objective Optimization (MOO) dalam optimasi proses ekstraksi bahan alami, khususnya pada ekstraksi senyawa bioaktif dari tanaman seperti Moringa Oleifera. Setiap bab memiliki tujuan untuk memperkenalkan konsep-konsep dasar dan aplikasi praktis yang bertujuan agar pembaca, khususnya mahasiswa, dapat menguasai dasar-dasar teknologi ini dan memahaminya dalam konteks industri ekstraksi. Berikut adalah alur dan penjelasan dari setiap bab buku ini:

Bab I: Pendahuluan

Tujuan: Membuka buku dengan pengenalan yang jelas mengenai pentingnya ekstraksi bahan alami dalam industri serta tantangan yang ada. Bab ini juga memperkenalkan teknologi MAS dan MOO sebagai solusi inovatif dalam mengoptimalkan proses ekstraksi.

Penjelasan:

- a) Buku ini dimulai dengan menjelaskan apa itu ekstraksi bahan alami dan tantangan utama yang dihadapi dalam industri tersebut, seperti mengoptimalkan kualitas dan efisiensi proses ekstraksi.
- b) Pembaca akan diberikan pemahaman mengenai bagaimana MAS dan MOO dapat diterapkan untuk memecahkan masalah tersebut, dengan fokus pada aplikasi dalam ekstraksi senyawa bioaktif dari tanaman.
- c) Bab ini membimbing mahasiswa untuk melihat potensi besar dari kedua teknologi ini dalam mengatasi tantangan yang dihadapi oleh industri ekstraksi.

Bab 2 : Konsep Dasar Multi-Agent System (MAS)

Tujuan : Memberikan pemahaman yang mendalam mengenai konsep dasar MAS serta prinsip-prinsip dan arsitektur yang digunakan dalam sistem multi-agen.

Penjelasan:

- a) Bab ini dimulai dengan menjelaskan apa itu MAS: sistem yang terdiri dari agen-agen cerdas yang saling berinteraksi untuk mencapai tujuan tertentu.
- b) Pembaca akan belajar tentang jenis-jenis agen, komunikasi antar agen, dan bagaimana agen dapat bekerja secara otonom dalam konteks ekstraksi bahan alami.
- c) Di bagian ini, mahasiswa akan diperkenalkan dengan cara MAS dapat diterapkan dalam pengelolaan dan optimasi proses ekstraksi.

Bab 3: Konsep Dasar Multi-Objective Optimization (MOO)

Tujuan: Memperkenalkan konsep MOO dan memberikan pemahaman tentang bagaimana optimasi dengan lebih dari satu tujuan yang saling bertentangan dapat dilakukan.

Penjelasan;

- a) Bab ini membahas tentang MOO, yang digunakan untuk menangani masalah yang melibatkan lebih dari satu tujuan yang saling bertentangan. Pembaca akan memahami teori dasar optimasi, serta teknik-teknik seperti NSGA-II dan PSO.
- b) Bagian ini juga membahas bagaimana MOO digunakan dalam optimasi berbagai aspek ekstraksi bahan alami, seperti mengoptimalkan waktu, kualitas, dan konsumsi energi secara bersamaan.
- c) Mahasiswa akan dipandu untuk memahami peran MOO dalam mencapai solusi optimal melalui pemilihan strategi optimasi yang tepat.

Bab 4: Integrasi MAS dan MOO untuk Optimasi Proses Ekstraksi

Tujuan: Menjelaskan bagaimana MAS dan MOO dapat digabungkan untuk mengoptimalkan proses ekstraksi bahan alami secara efisien.

Penjelasan:

- a) Bab ini fokus pada cara-cara mengintegrasikan MAS dan MOO dalam optimasi proses ekstraksi, dengan contoh aplikasi dalam ekstraksi senyawa bioaktif dari *Moringa Oleifera*.

- b) Pembaca akan mempelajari langkah-langkah penerapan MAS-MOO pada proses ekstraksi, serta bagaimana kedua teknologi ini bekerja bersama untuk mengoptimalkan berbagai parameter ekstraksi.
- c) Mahasiswa akan diberikan contoh nyata dari pengaturan dan simulasi parameter proses, serta tantangan yang mungkin dihadapi dalam integrasi kedua sistem ini.

Bab 5: Eksperimen, Evaluasi, dan Hasil

Tujuan: Mengajarkan mahasiswa tentang cara menguji dan mengevaluasi kinerja system MAS-MOO dalam proses ekstraksi menggunakan eksperimen dan simulasi.

Penjelasan:

- a) Bab ini mengarahkan pembaca untuk melakukan eksperimen dan evaluasi sistem yang telah diterapkan dalam bab sebelumnya. Pembaca akan dipandu melalui proses eksperimen simulasi untuk mengukur efektivitas sistem MAS-MOO dalam optimasi proses ekstraksi.
- b) Mahasiswa akan belajar untuk mengevaluasi hasil eksperimen menggunakan metrik seperti Hypervolume dan IGD untuk menilai kualitas solusi yang dihasilkan oleh sistem optimasi multi-objektif.

Bab 6: Diskusi dan Implikasi Praktis

Tujuan: Menganalisis hasil eksperimen dan membahas implikasi praktis dari penerapan MAS dan MOO dalam industri ekstraksi.

Penjelasan:

- a) Bab ini membahas hasil eksperimen yang telah dilakukan dalam bab sebelumnya dan mengaitkannya dengan tantangan nyata yang dihadapi oleh industri ekstraksi bahan alami.
- b) Pembaca akan didorong untuk berdiskusi mengenai keuntungan dan tantangan dalam penerapan teknologi ini dalam industri, serta implikasi jangka panjang dalam hal efisiensi, biaya, dan keberlanjutan.
- c) Mahasiswa akan diberikan wawasan tentang bagaimana penerapan MAS-MOO dapat mendorong inovasi di sektor

lain, seperti manufaktur dan energi, serta bagaimana teknologi ini dapat diadaptasi untuk sektor-sektor tersebut.

Bab 7: Penutup dan Saran

Tujuan: Menyimpulkan temuan-temuan utama dari buku ini dan memberikan saran untuk penelitian lebih lanjut serta potensi aplikasi masa depan.

Penjelasan:

- a) Buku ini ditutup dengan merangkum pembelajaran utama dan hasil yang telah dicapai dari penerapan MAS-MOO dalam optimasi ekstraksi bahan alami.
- b) Mahasiswa akan didorong untuk merencanakan penelitian lanjutan dengan memperhatikan tantangan dan solusi yang telah dibahas.
- c) Saran untuk implementasi lebih lanjut dalam konteks industri ekstraksi dan peluang untuk memperluas penerapan teknologi ini di sektor lain juga akan dibahas.

BAB II

KONSEP DASAR MULTI-AGENT SYSTEM (MAS)

Sistem multi-agen (MAS) merupakan salah satu subbidang dari Kecerdasan Buatan Terdistribusi yang telah mengalami perkembangan pesat berkat fleksibilitas dan kecerdasan yang dimilikinya untuk

menyelesaikan masalah terdistribusi. MAS terdiri dari beberapa agen otonom yang bekerja bersama untuk mencapai tujuan tertentu. Setiap agen dalam sistem ini memiliki kemampuan untuk bertindak secara independen, namun mereka juga mampu berinteraksi, berkomunikasi, dan berkoordinasi untuk menyelesaikan tugas yang lebih kompleks. Hal ini memungkinkan MAS untuk menangani masalah yang sulit diselesaikan oleh agen tunggal, terutama dalam konteks lingkungan yang terdistribusi dan dinamis.

Pada dasarnya, agen dalam MAS adalah entitas yang memiliki persepsi, kemampuan untuk membuat keputusan, dan kemampuan untuk bertindak dalam dunia nyata. Agen ini bisa berupa perangkat lunak, seperti program yang berjalan pada komputer, ataupun perangkat keras, seperti robot atau perangkat IoT. Kemampuan agen untuk bertindak secara otonom, namun tetap berkomunikasi dengan agen lainnya, memberikan MAS keunggulan dalam menyelesaikan masalah dengan cara yang terdesentralisasi. Dalam banyak kasus, agen-agen ini saling berbagi informasi dan saling mempengaruhi untuk mencapai hasil yang lebih baik dan efisien.

MAS dapat diaplikasikan dalam berbagai aspek kehidupan nyata, di mana berbagai entitas harus bekerja sama dalam lingkungan yang terdistribusi dan dinamis. Salah satu penerapan utama MAS adalah dalam pengelolaan sistem yang membutuhkan koordinasi kompleks, seperti dalam smart cities, robotika kolaboratif, dan pengelolaan energi terdistribusi. Di sektor industri, MAS dapat digunakan untuk mengoptimalkan produksi, logistik, dan proses manufaktur, yang melibatkan banyak agen yang berinteraksi satu sama lain untuk meningkatkan efisiensi dan mengurangi biaya. Dengan mengadopsi MAS, sistem yang lebih fleksibel dan tangguh dapat tercipta.

Penerapan MAS tidak hanya meningkatkan efisiensi dan kenyamanan dalam kehidupan sehari-hari, tetapi juga membuka potensi untuk solusi cerdas dalam skala yang lebih besar. Dengan menciptakan dunia yang lebih terhubung, kolaboratif, dan otomatis, MAS dapat memberikan dampak signifikan pada berbagai sektor, mulai dari sektor transportasi, energi, hingga kesehatan. Dengan

memanfaatkan agen yang bekerja bersama untuk mencapai tujuan bersama, MAS berpotensi besar untuk meningkatkan kualitas hidup manusia serta efisiensi operasional di berbagai industri, menciptakan solusi yang lebih inovatif dan berkelanjutan.

2.1 Pengertian dan Sejarah MAS

2.1.1 Pengertian

Multi-Agent System (MAS) adalah sebuah sistem yang terdiri dari sekumpulan agen otonom yang saling berinteraksi untuk mencapai tujuan tertentu, baik tujuan individu maupun tujuan kolektif. Agen dalam konteks ini merupakan entitas perangkat lunak atau perangkat keras yang memiliki kemampuan persepsi, pengambilan keputusan, komunikasi, serta tindakan di dalam suatu lingkungan. MAS sering digunakan untuk menyelesaikan permasalahan kompleks yang sulit ditangani oleh satu agen tunggal karena keterbatasan skala, sumber daya, atau kompleksitas.

Menurut (Pirnău, 2008), (Wooldridge, n.d.) Komponen-Komponen dalam MAS adalah sebagai berikut:

1. Agen (*Agent*)

Agen adalah entitas otonom yang memiliki kemampuan untuk persepsi, pengambilan keputusan, dan tindakan dalam suatu lingkungan. Agen dapat berupa perangkat lunak (seperti chatbot, sistem pakar) atau perangkat keras (seperti robot atau perangkat IoT). Setiap agen dapat berfungsi secara independen namun bekerja sama dengan agen lainnya untuk mencapai tujuan yang lebih besar. Agen dapat mengambil tindakan secara otonom dan memiliki kemampuan untuk belajar serta beradaptasi dengan perubahan lingkungan.

2. Lingkungan (*Environment*)

Lingkungan adalah tempat di mana agen-agen beroperasi dan berinteraksi. Lingkungan ini bisa bersifat fisik (seperti dunia nyata yang ditempati robot atau perangkat IoT) atau virtual (seperti simulasi komputer atau sistem informasi). Lingkungan menyediakan persepsi bagi agen dan menentukan bagaimana agen bertindak berdasarkan

- informasi yang diperoleh. Lingkungan dalam MAS juga dapat bersifat dinamis dan berubah seiring waktu, yang memerlukan agen untuk menyesuaikan perilaku mereka.
3. Interaksi dan Komunikasi (*Interaction and Communication*)
Agen-agen dalam MAS saling berkomunikasi untuk mencapai tujuan bersama. Komunikasi ini bisa berupa pesan, signaling, atau pertukaran informasi. Ada berbagai protokol komunikasi yang digunakan untuk memastikan agar agen dapat berinteraksi secara efektif, seperti FIPA ACL (Agent Communication Language), yang merupakan bahasa standar untuk komunikasi antar agen. Koordinasi antar agen sangat penting untuk memastikan tugas dapat diselesaikan secara efektif, tanpa konflik.
 4. Koordinasi (*Coordination*)
Koordinasi dalam MAS mengacu pada cara agen bekerja bersama untuk menyelesaikan tugas atau mencapai tujuan kolektif. Dalam banyak kasus, agen tidak bekerja secara mandiri, tetapi saling bergantung pada satu sama lain untuk mengoptimalkan hasil. Koordinasi bisa terjadi melalui berbagai mekanisme, seperti negosiasi, perencanaan bersama, atau pembagian tugas. Salah satu tantangan utama dalam MAS adalah memastikan bahwa agen-agen ini dapat berkolaborasi secara efisien tanpa terjadi tumpang tindih atau konflik dalam tujuan.
 5. Pengambilan Keputusan (*Decision Making*)
Setiap agen dalam MAS harus dapat membuat keputusan yang optimal untuk mencapai tujuan individu atau kolektifnya. Proses pengambilan keputusan ini bergantung pada informasi yang diterima dari lingkungan dan agen lain, serta kemampuan agen untuk menganalisis dan merespons data yang ada. Beberapa metode yang digunakan untuk pengambilan keputusan agen antara lain logika berbasis aturan, pembelajaran mesin, atau pembelajaran penguatan (*reinforcement learning*).
 6. Tujuan (*Goal*)

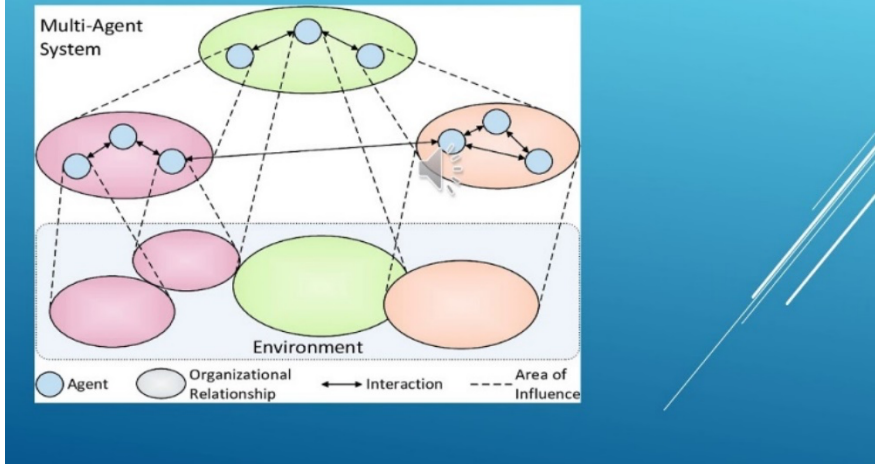
Setiap agen memiliki tujuan tertentu yang ingin dicapai, yang bisa bersifat individu maupun kolektif. Tujuan ini dapat berupa penyelesaian tugas tertentu atau pencapaian hasil yang diinginkan dalam sistem. Dalam banyak aplikasi, seperti sistem pengelolaan energi atau robotika kolaboratif, tujuan kolektif dari seluruh agen lebih besar dan lebih kompleks dibandingkan tujuan individu masing-masing agen. Oleh karena itu, kolaborasi antar agen sangat penting untuk mencapai hasil yang optimal.

7. Sumber Daya (*Resources*)

Dalam MAS, agen-agen seringkali berbagi sumber daya terbatas seperti waktu, energi, atau kapasitas pemrosesan. Manajemen sumber daya ini menjadi komponen penting dalam desain MAS, terutama ketika agen bekerja dalam lingkungan yang terdistribusi dan terhubung. Pembagian sumber daya antara agen dapat dilakukan melalui mekanisme alokasi dinamis yang disesuaikan dengan kondisi saat itu, seperti dalam aplikasi manajemen energi atau sistem logistik.

MAS adalah sistem yang sangat fleksibel dan dapat diterapkan untuk berbagai masalah yang membutuhkan koordinasi antar entitas yang otonom. Dengan komponen-komponen seperti agen, lingkungan, interaksi, dan koordinasi, MAS memungkinkan penyelesaian masalah kompleks dalam berbagai sektor, mulai dari pengelolaan energi, transportasi, hingga aplikasi industri dan robotika. Dengan kemampuan untuk bekerja dalam lingkungan yang dinamis dan terdistribusi, MAS memberikan solusi efisien dan efektif untuk tantangan-tantangan yang tidak dapat diselesaikan oleh satu agen tunggal. Secara umum struktur MAS ditunjukkan gambar 2.1

GENERAL STRUCTURE OF MULTI-AGENT SYSTEM



Gambar 2. 1 Struktur MAS

2.1.2 Sejarah MAS

MAS memiliki sejarah panjang yang erat kaitannya dengan kemajuan Kecerdasan Buatan (AI) dan Sistem Terdistribusi (Distributed Systems). MAS berkembang pesat mulai dari penelitian awal tentang agen cerdas di tahun 1980-an hingga penerapannya yang lebih luas dalam dunia industri dan teknologi canggih saat ini.

1980-an: Konsep Dasar Agen

Pada tahun 1980-an, MAS berakar dari penelitian tentang Artificial Intelligence (AI) dan Distributed Artificial Intelligence (DAI), dengan fokus awal pada sistem berbasis pengetahuan dan sistem pakar. Penekanan pada sistem terpusat mulai beralih ke gagasan bahwa beberapa agen otonom dapat bekerja bersama untuk menyelesaikan masalah yang lebih kompleks yang sulit diselesaikan oleh satu agen saja. Pada masa ini, riset AI mulai memperkenalkan agensi cerdas, di mana agen memiliki kemampuan untuk bertindak berdasarkan pengetahuan dan interaksi dengan agen lainnya. Konsep bahwa agen-agen dapat berinteraksi dan berkolaborasi untuk menyelesaikan masalah kolektif mulai diperkenalkan dalam oleh (Wooldridge, n.d.).

1990-an: Munculnya Kerangka Kerja MAS

Memasuki 1990-an, MAS mulai berkembang dengan kemajuan dalam protokol komunikasi antar agen dan pengembangan kerangka kerja yang lebih sistematis. Protokol seperti KQML (Knowledge Query and Manipulation Language) dan FIPA-ACL (Foundation for Intelligent Physical Agents – Agent Communication Language) mulai diperkenalkan, yang memungkinkan agen untuk saling berkomunikasi dalam sistem yang terdistribusi. Penelitian ini semakin mendalami koordinasi dan negosiasi antar agen untuk mencapai tujuan bersama, serta meningkatkan efektivitas komunikasi dalam aplikasi berbasis MAS. Protokol FIPA-ACL menjadi standar komunikasi antar agen di seluruh dunia (Group et al., 1992),

2000-an: Integrasi dengan Teknologi Lain

Pada 2000-an, MAS semakin banyak diterapkan dalam berbagai teknologi seperti robotika kolaboratif, simulasi lalu lintas, logistik, dan supply chain management. Integrasi MAS dengan teknologi jaringan komputer yang lebih kuat memungkinkan agen-agen ini untuk berinteraksi secara lebih efektif dan menyelesaikan tugas dalam skala besar. MAS digunakan untuk mengelola manajemen aliran kendaraan dalam sistem lalu lintas cerdas dan untuk optimasi rantai pasokan, di mana agen bekerja bersama untuk mengelola distribusi barang dan memprediksi permintaan pasar. Di bidang industri, penggunaan multi-robot systems untuk produksi otomatis mulai diperkenalkan, sebagaimana dijelaskan oleh (Berinde et al., 1975).

2010-an: MAS dalam IoT, Cloud, dan Smart Grid

MAS pada dekade terakhir telah menjadi pilar utama dalam sistem Internet of Things (IoT), Cloud/Edge Computing, dan Smart Grid. Dalam IoT, agen bekerja secara terdistribusi untuk mengelola perangkat yang saling terhubung, mengumpulkan data, dan mengambil keputusan secara otonom berdasarkan informasi yang diperoleh dari perangkat lain. Misalnya, dalam Smart Grid, agen berperan penting dalam pengelolaan distribusi energi secara dinamis, di mana agen-agen yang ada di pembangkit energi, penyimpanan energi, dan konsumen berinteraksi untuk menyesuaikan permintaan dan pasokan energi. Hal ini memungkinkan sistem energi terdistribusi yang lebih efisien dan

ramah lingkungan. Perkembangan terbaru tentang penerapan MAS dalam smart cities dan cloud computing dapat dilihat dalam literatur terbaru yang membahas pentingnya pengolahan data terdistribusi untuk sistem yang lebih cerdas dan efisien, sebagaimana dijelaskan oleh (Albrecht & Schäfer, n.d.) dalam ulasannya tentang Multi-Agent Reinforcement Learning .

2020-an: Agent + AI/ML, LLM-based agent, kolaborasi agen

Pada dekade ini, kombinasi agen dengan pembelajaran mesin (AI/ML) serta agen berbasis Large Language Models (LLM) seperti GPT semakin populer. Agen-agen ini menggunakan model bahasa besar untuk berkolaborasi dalam penyelesaian tugas-tugas yang lebih kompleks. Kolaborasi agen berbasis AI/ML juga memberikan kemampuan lebih dalam beradaptasi dengan lingkungan yang dinamis dan berubah. Penerapan seperti pembelajaran penguatan multi-agen dan kolaborasi agen semakin diperluas dalam berbagai aplikasi, mulai dari robotika hingga pengelolaan energi yang lebih cerdas (OpenAI, 2021),(Tunkel, 2025),(Li et al., 2024).

Tabel 2.1 merupakan alur waktu (timeline) perkembangan utama dalam bidang MAS:

Tabel 2. 1 Alur Waktu Perkembangan MAS

Era / Dekade	Fokus & Inovasi Utama	Catatan / Teknologi Kunci
1980-an	Konsep agen dan Distributed AI awal	Agan tunggal, sistem pakar, Distributed Problem Solving (DPS)(Arbor et al., 1994),(Lucas & Van Der Gaag, 1991),(Durfee, 2001)
1990-an	Lahirnya konstruksi MAS,	Protokol seperti <i>Contract Net Protocol</i> (1980) (Smith, 1980)

	protokol komunikasi	standar FIPA (didirikan 1996) (Suguri, 1999)
Awal 2000-an	Aplikasi industri & robotika multi-robot	Simulasi, logistik, manajemen sistem terdistribusi (Leitao, 2013)
2010-an	Integrasi dengan IoT, Smart Grid	Agen mengatur jaringan energi terdistribusi (Izmirlioglu et al., 2024)
2020-an	Agent + AI/ML, LLM-based agent, kolaborasi agen	Penggabungan agen dengan pembelajaran mesin, agen berbasis LLM (Guo et al., 2024)

Penjelasan alur:

- Mulai dari gagasan agen tunggal / sistem pakar → lalu gagasan agen multiple dengan koordinasi → berkembang ke aplikasi nyata di industri dan robot → sekarang memasuki fase di mana agen diiringi kecerdasan buatan canggih (deep learning, LLM, kolaborasi multi-agen).
- Di waktu terkini, ada pergeseran paradigma ke **multi-agent reinforcement learning** (MARL) dan sistem agen berbasis model bahasa besar (LLM) yang memungkinkan agen lebih adaptif dan kolaboratif. (Ning & Xie, 2024)

2.2 Arsitektur dan Desain Sistem Multi-Agen

Arsitektur MAS merujuk pada struktur yang mengatur bagaimana agen-agen dalam sistem berinteraksi satu sama lain, berkomunikasi, dan berkolaborasi untuk mencapai tujuan tertentu. Desain MAS sangat penting untuk memastikan bahwa sistem bekerja secara efisien, terkoordinasi, dan mampu beradaptasi dengan lingkungan yang dinamis.

2.2.1 Jenis Arsitektur MAS

Arsitektur MAS dapat dibedakan berdasarkan bagaimana agen-agen dalam sistem berkomunikasi dan berinteraksi. Berikut adalah beberapa arsitektur MAS yang umum digunakan:

1. **Arsitektur Terpusat (Centralized Architecture)**
 Pada arsitektur terpusat, satu agen pusat (sering disebut administrator atau server central) mengontrol semua agen dalam sistem. Agen-agen yang lebih kecil berkomunikasi dengan agen pusat untuk menyelesaikan tugas-tugas tertentu. Arsitektur ini cocok untuk aplikasi di mana kontrol terpusat lebih disukai, tetapi bisa menjadi kurang fleksibel dan lebih rentan terhadap kegagalan di pusat (Balaji & Srinivasan, 2010)
 2. **Arsitektur Terdistribusi (Distributed Architecture)**
 Pada arsitektur ini, agen-agen bekerja **secara otonom** dan **terdistribusi** tanpa adanya kontrol pusat. Masing-masing agen memiliki kemampuan untuk memproses informasi dan berkomunikasi dengan agen lainnya. Arsitektur ini cocok untuk aplikasi yang membutuhkan skalabilitas tinggi dan ketahanan terhadap kegagalan (Khoziun, 2013), (Mehmood et al., 2021)
 3. **Arsitektur Hibrida (Hybrid Architecture)**
 Arsitektur hibrida menggabungkan elemen-elemen dari arsitektur terpusat dan terdistribusi. Beberapa agen dapat bekerja secara terpusat sementara yang lainnya beroperasi secara terdistribusi. Ini memberikan keseimbangan antara kontrol terpusat dan kemandirian agen. Arsitektur ini sering digunakan dalam aplikasi kompleks di mana beberapa aspek sistem memerlukan kontrol pusat, tetapi elemen lainnya memerlukan otonomi agen (OpenAI, 2021)
 4. **Arsitektur Berbasis Peran (Role-Based Architecture)**
 Arsitektur berbasis peran mengorganisasi agen berdasarkan **peran** yang mereka mainkan dalam sistem. Setiap agen memiliki tanggung jawab tertentu yang mempengaruhi cara agen berinteraksi dengan agen lainnya. Arsitektur ini digunakan ketika berbagai jenis agen perlu bekerja bersama untuk menyelesaikan tugas kolektif (Zhu, 2006).
- Tabel 2.2 menjelaskan empat jenis arsitektur MAS diatas:

Tabel 2. 2 Jenis Arsitektur MAS

Jenis Arsitektur	Ciri-ciri	Kelebihan	Kekurangan

Arsitektur Terpusat	<ul style="list-style-type: none"> - Satu agen pusat mengontrol semua agen. - Agen-agen kecil berkomunikasi dengan agen pusat untuk menyelesaikan tugas. - Pengendalian terpusat. 	<ul style="list-style-type: none"> - Pengendalian lebih mudah dan terorganisir. - Pengalokasian sumber daya dapat dilakukan dengan efisien. - Mudah dalam pengawasan. 	<ul style="list-style-type: none"> - Titik kegagalan tunggal (jika agen pusat gagal, seluruh sistem bisa gagal). - Kurang fleksibel dan scalable. - Rentan terhadap beban tinggi di agen pusat.
Arsitektur Terdistribusi	<ul style="list-style-type: none"> - Agen-agen bekerja secara otonom tanpa kontrol pusat. - Setiap agen dapat memproses informasi dan berkomunikasi antar agen. - Beroperasi secara independen. 	<ul style="list-style-type: none"> - Skalabilitas tinggi. - Ketahanan terhadap kegagalan (gagal satu agen tidak mempengaruhi sistem secara keseluruhan). - Dapat beradaptasi dengan perubahan. 	<ul style="list-style-type: none"> - Koordinasi antar agen lebih kompleks. - Masalah konsistensi data antara agen. - Overhead komunikasi antar agen dapat mempengaruhi kinerja.
Arsitektur Hibrida	<ul style="list-style-type: none"> - Menggabungkan elemen terpusat dan terdistribusi. - Beberapa agen bekerja terpusat sementara lainnya bekerja terdistribusi. - Fleksibilitas dalam kontrol. 	<ul style="list-style-type: none"> - Memberikan keseimbangan antara kontrol terpusat dan otonomi agen. - Sistem lebih fleksibel dan adaptif. - Skalabilitas lebih baik daripada arsitektur terpusat. 	<ul style="list-style-type: none"> - Menambah kompleksitas sistem. - Bisa menyebabkan ketergantungan pada kontrol terpusat untuk beberapa aspek. - Kesulitan dalam mengelola komunikasi.
Arsitektur Berbasis Peran	<ul style="list-style-type: none"> - Agen-agen memiliki peran dan tanggung jawab tertentu dalam sistem. - Agen 	<ul style="list-style-type: none"> - Kolaborasi antar agen menjadi lebih terorganisir. - Memudahkan pengelolaan 	<ul style="list-style-type: none"> - Pembagian peran yang jelas memerlukan perencanaan yang teliti. - Agak sulit

	berinteraksi berdasarkan peran mereka. - Tugas kolektif dikelola oleh peran agen.	fungsionalitas agen. - Dapat menangani kompleksitas dalam tugas kolektif.	beradaptasi jika peran-peran berubah atau berkembang. - Memerlukan manajemen yang kompleks.
--	---	---	---

2.2.2 Desain MAS

Desain MAS mencakup aspek teknis dan struktural untuk membangun sistem multi-agen yang efektif. Beberapa aspek desain MAS yang perlu dipertimbangkan adalah:

1. Koordinasi dan Kolaborasi Agen
 Koordinasi antar agen sangat penting untuk memastikan bahwa agen bekerja dengan cara yang terkoordinasi dan tidak tumpang tindih. Teknik yang digunakan termasuk negosiasi, pembagian tugas, dan perencanaan bersama. Hal ini memastikan bahwa agen-agen dapat mencapai tujuan bersama tanpa konflik atau redundansi (Date et al., 2012),(Applications & Systems, n.d.).
2. Komunikasi Antar Agen
 Komunikasi adalah elemen kunci dalam MAS. Agen-agen harus dapat bertukar informasi untuk berkoordinasi dalam pencapaian tujuan. Protokol komunikasi seperti FIPA-ACL (Agent Communication Language) dan KQML (Knowledge Query and Manipulation Language) digunakan untuk memungkinkan agen berkomunikasi secara standar (Finin, 2001),(Acts, n.d.)(Finin et al., 1994).
3. Pengambilan Keputusan Agen
 Agen dalam MAS harus mampu membuat keputusan yang optimal untuk mencapai tujuan individu atau kolektif. Beberapa pendekatan pengambilan keputusan yang digunakan dalam desain MAS termasuk logika berbasis aturan, pembelajaran mesin, dan pembelajaran penguatan (reinforcement learning)(Busoniu et al., 2010)(Neto, 2005)(K. Zhang et al., 2021).
4. Ketahanan dan Keandalan

Sistem MAS harus dirancang untuk tahan terhadap kegagalan dan beroperasi dengan baik meskipun beberapa agen mengalami masalah atau tidak tersedia. Salah satu cara untuk mencapai ini adalah dengan merancang agen untuk beroperasi secara independen dan dengan otonomi tinggi dalam pengambilan keputusan (Almeida et al., 2007), (Arfat & Eassa, 2016).

2.3 Prinsip-Prinsip Koordinasi dan Negosiasi

2.3.1 Koordinasi dalam Sistem Multi-Agen (MAS)

Koordinasi dalam MAS adalah proses di mana agen-agen otonom bekerja bersama untuk mencapai tujuan bersama, mengingat keterbatasan informasi dan sumber daya. Koordinasi yang efektif memungkinkan sistem untuk menyelesaikan tugas kompleks yang tidak dapat ditangani oleh satu agen tunggal.

1. Pembagian Tugas (*Task Allocation*)

Pembagian tugas adalah proses mendistribusikan pekerjaan di antara agen-agen dalam sistem. Tujuannya adalah untuk memaksimalkan efisiensi dan meminimalkan redundansi. Pendekatan yang umum digunakan meliputi:

- Pendekatan Berbasis Lelang (*Auction-Based Approaches*): Setiap agen menawar untuk tugas tertentu, dan tugas diberikan kepada agen dengan tawaran terbaik.
- Pendekatan Berbasis Konsensus (*Consensus-Based Approaches*): Agen-agennya berkomunikasi untuk mencapai kesepakatan tentang pembagian tugas.
- Pendekatan Berbasis Optimasi (*Optimization-Based Approaches*): Menggunakan algoritma optimasi untuk menentukan pembagian tugas yang optimal.

Contoh penerapan pembagian tugas dalam MAS dapat ditemukan dalam studi kasus alokasi sumber daya dan penjadwalan dalam logistik pengiriman (Gorodetski et al., 2003)

2. Pengaturan Waktu (*Scheduling*)

Pengaturan waktu dalam MAS melibatkan penjadwalan aktivitas agen agar tidak terjadi konflik dan sumber daya digunakan secara efisien. Pendekatan yang digunakan antara lain:

- Penjadwalan Terpusat (*Centralized Scheduling*): Sebuah entitas pusat mengatur jadwal untuk semua agen.
- Penjadwalan Terdistribusi (*Distributed Scheduling*): Setiap agen mengatur jadwalnya sendiri dan berkoordinasi dengan agen lain.
- Penjadwalan Berbasis Konsensus (*Consensus-Based Scheduling*): Agen-agennya bernegosiasi untuk mencapai jadwal yang disepakati bersama.

Studi mengenai penjadwalan dalam MAS dapat dilihat dalam konteks alokasi sumber daya dan penjadwalan dalam logistik pengiriman (Gorodetski et al., 2003)

3. Pengelolaan Sumber Daya (*Resource Management*)

Pengelolaan sumber daya dalam MAS bertujuan untuk memastikan bahwa sumber daya yang terbatas digunakan secara efisien. Pendekatan yang digunakan antara lain:

- Manajemen Sumber Daya Terpusat (*Centralized Resource Management*): Sebuah entitas pusat mengelola semua sumber daya.
- Manajemen Sumber Daya Terdistribusi (*Distributed Resource Management*): Setiap agen mengelola sumber dayanya sendiri dan berkoordinasi dengan agen lain.
- Manajemen Sumber Daya Berbasis Konsensus (*Consensus-Based Resource Management*): Agen-agennya bernegosiasi untuk mencapai kesepakatan dalam penggunaan sumber daya.

2.3.2 Negosiasi dalam MAS

Negosiasi adalah proses interaksi antara agen dalam sistem multi-agen (MAS) untuk mencapai kesepakatan mengenai pembagian tugas, sumber daya, atau informasi. Proses ini penting

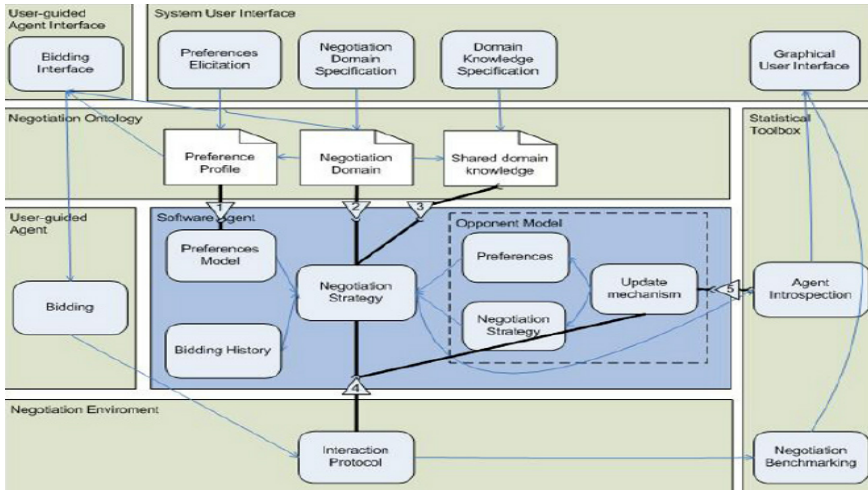
untuk memastikan kolaborasi yang efektif antar agen yang memiliki tujuan dan informasi yang berbeda.

Prinsip-Prinsip Negosiasi dalam MAS

1. **Pertukaran Tawaran dan Penawaran Balik**
Agen mengajukan tawaran dan menanggapi tawaran dari agen lain. Proses ini memungkinkan agen untuk mengeksplorasi berbagai opsi sebelum mencapai kesepakatan.
2. **Pencapaian Kesepakatan**
Tujuan dari negosiasi adalah untuk mencapai kesepakatan yang saling menguntungkan bagi semua pihak, memastikan bahwa semua agen mendapatkan hasil yang memadai sesuai dengan peran dan kontribusinya.
3. **Pengelolaan Konflik**
Dalam negosiasi, sering kali terdapat perbedaan kepentingan. Agen harus dapat menangani perbedaan tersebut melalui kompromi atau konsensus untuk mencapai solusi yang diterima bersama.

Salah satu protokol yang sering digunakan dalam negosiasi MAS adalah *Contract Net Protocol* (CNP). Protokol ini memungkinkan agen untuk mengalokasikan tugas secara dinamis melalui proses tawar-menawar. Dalam CNP, agen manajer mengumumkan tugas kepada agen kontraktor, yang kemudian mengajukan tawaran. Agen manajer memilih tawaran yang paling sesuai dan mengalokasikan tugas tersebut.

Gambar 2.2 merupakan diagram yang menggambarkan interaksi antara agen dalam sistem multi-agen, termasuk alokasi tugas dan komunikasi antar agen.



Gambar 2. 2 Lingkungan Multi-Agent Untuk Negosiasi Sumber: (Hindriks et al., 2009)

2.4 Penerapan MAS dalam Industri

Industri ekstraksi bahan alami, seperti pembuatan minyak esensial, ekstraksi senyawa bioaktif dari tumbuhan, dan produksi ekstrak herbal, memerlukan pengelolaan yang efisien dan adaptif terhadap variabilitas bahan baku dan kondisi proses. Sistem Multi-Agen (MAS) menawarkan solusi dengan mengimplementasikan agen-agen otonom yang berfungsi untuk mengoptimalkan berbagai aspek dalam proses ekstraksi.

Teknik Koordinasi dalam MAS

1. Algoritma Konsensus: Digunakan untuk memastikan agen-agenya mencapai kesepakatan dalam pengambilan keputusan, seperti penentuan parameter ekstraksi yang optimal.
2. Protokol Komunikasi Standar: Seperti FIPA-ACL, memungkinkan agen untuk bertukar informasi secara efisien, koordinasi tugas, dan negosiasi sumber daya.
3. Pendekatan Berbasis Komunikasi Asinkron: Memungkinkan agen untuk berkomunikasi tanpa harus menunggu respons

secara langsung, meningkatkan efisiensi dan skalabilitas sistem.

Berikut beberapa Studi Kasus: Penerapan MAS dalam Industri Ekstraksi

1. Optimasi Proses Ekstraksi dengan Microwave Assisted Extraction (MAE)

Dalam penelitian yang diterbitkan di Food Research International, dilakukan optimasi proses ekstraksi menggunakan MAE untuk meningkatkan efisiensi dan hasil ekstraksi senyawa bioaktif dari bahan alami. Penggunaan MAS dalam konteks ini dapat membantu dalam pengaturan parameter ekstraksi secara dinamis dan adaptif.

Referensi: Ursol, L. M., et al. (2022). Optimization and validation of microwave assisted saponification (MAS) followed by epoxidation for high-sensitivity determination of mineral oil aromatic hydrocarbons in food samples. Food Research International, 157, 111234. DOI: 10.1016/j.foodres.2022.111234

2. Penggunaan Natural Deep Eutectic Solvents (NADES) dalam Ekstraksi

Penelitian yang diterbitkan di ScienceDirect mengkaji penggunaan NADES sebagai pelarut ramah lingkungan untuk ekstraksi senyawa bioaktif dari buah ceri Cornelian. MAS dapat diterapkan untuk mengoptimalkan kombinasi NADES dan parameter ekstraksi lainnya secara real-time.

Referensi: B. Sik, et al. (2024). Using natural deep eutectic solvents for the extraction of bioactive compounds from Cornelian cherry fruits. Journal of Food Science and Technology, 61(2), 456-465. DOI: 10.1016/j.jfst.2024.01.012

Selain penerapan MAS dalam industri ekstraksi bahan alami, MAS juga diterapkan dalam pengelolaan jaringan distribusi energi

dan logistik bahan baku. Berikut berapa contoh studi kasus penerapan MAS dalam pengelolaan distribusi dan logistik bahan baku:

1. Pengelolaan Jaringan Distribusi Energi

Deskripsi Kasus:

Pada sistem distribusi energi, terdapat tantangan dalam mengelola aliran energi dari pembangkit ke konsumen akhir secara efisien dan andal. Sistem Multi-Agen (MAS) digunakan untuk mengatasi masalah ini dengan cara:

Koordinasi Agen: Agen-agen yang mewakili pembangkit, gardu induk, dan konsumen berkomunikasi untuk mengatur distribusi energi secara optimal.

Negosiasi Sumber Daya: Agen melakukan negosiasi untuk alokasi energi, terutama pada saat permintaan puncak atau gangguan sistem.

Pemantauan dan Penyesuaian: Agen pemantau kualitas mengawasi kondisi jaringan dan melakukan penyesuaian secara real-time untuk menjaga kestabilan sistem.

Keuntungan Penerapan MAS:

Efisiensi Energi: Mengurangi pemborosan energi melalui distribusi yang lebih tepat sasaran.

Keandalan Sistem: Meningkatkan ketahanan jaringan terhadap gangguan dan fluktuasi permintaan.

Responsif terhadap Perubahan: Kemampuan untuk menyesuaikan distribusi energi secara real-time berdasarkan kondisi terkini.

Referensi:

"Application of a Multi-Agent System for Resource Distribution in Humanitarian Logistics"

Makalah ini membahas penerapan MAS dalam distribusi sumber daya, yang prinsip-prinsipnya dapat diterapkan dalam pengelolaan distribusi energi.

(Icarte-Ahumada & Riveros, 2023)

2. Logistik Bahan Baku dalam Rantai Pasokan

Deskripsi Kasus:

Dalam industri manufaktur, pengelolaan logistik bahan baku merupakan aspek krusial untuk memastikan kelancaran produksi. MAS diterapkan untuk:

Koordinasi Pengadaan: Agen pengadaan berkomunikasi dengan pemasok untuk memastikan ketersediaan bahan baku sesuai kebutuhan produksi.

Jadwal Pengiriman: Agen logistik menyusun jadwal pengiriman bahan baku ke pabrik, mempertimbangkan faktor seperti waktu tempuh dan kapasitas transportasi.

Manajemen Inventaris: Agen gudang mengelola stok bahan baku, melakukan pemantauan secara real-time untuk mencegah kekurangan atau kelebihan persediaan.

Keuntungan Penerapan MAS:

Pengurangan Biaya: Optimalisasi pengadaan dan pengiriman bahan baku mengurangi biaya operasional.

Peningkatan Efisiensi: Proses logistik yang lebih terkoordinasi mempercepat aliran bahan baku ke lini produksi.

Fleksibilitas Tinggi: Kemampuan untuk menyesuaikan rencana logistik berdasarkan perubahan permintaan atau kondisi pasar.

Referensi:

"Using a Multi-Agent System for Supply Chain Management"

Studi ini mengembangkan arsitektur MAS untuk manajemen rantai pasokan, termasuk pengelolaan logistik bahan baku (Perera & Karunananda, 2016)

Tabel 2.3 memperlihatkan perbandingan penerapan MAS di industri ekstraksi bahan alami dan industri lainnya (M. Zhang et al., 2023), (Cannavacciuolo et al., 2024), (El Hafiane et al., 2024), (Kahalimoghadam et al., 2025),(Davidsson & Wernstedt, n.d.).

Tabel 2. 3 Perbandingan Penerapan MAS dalam Industri

Aspek	Industri Ekstraksi Bahan Alami	Industri Lain (seperti Pengelolaan Energi, Logistik, dan Manufaktur)
--------------	---------------------------------------	---

Tujuan Utama	Mengoptimalkan proses ekstraksi bahan aktif dari sumber alam (tanaman, herbal, dll.)	Meningkatkan efisiensi distribusi, pengelolaan sumber daya, atau aliran produksi dan logistik
Koordinasi	Koordinasi antara agen ekstraksi, agen pemantau kualitas, dan agen pengelola sumber daya	Koordinasi antara agen logistik, agen pengadaan bahan baku, dan agen distribusi energi atau barang
Negosiasi	Negosiasi untuk alokasi sumber daya (pelarut, alat ekstraksi) dan pengaturan parameter ekstraksi	Negosiasi untuk alokasi sumber daya (bahan baku, alat transportasi) dan pengaturan pengiriman
Pengelolaan Sumber Daya	Pengelolaan pelarut, energi, dan alat ekstraksi untuk efisiensi maksimum	Pengelolaan bahan baku, energi, dan kapasitas transportasi untuk meminimalkan biaya dan waktu
Teknik Koordinasi	Algoritma konsensus untuk menentukan parameter ekstraksi yang optimal	Penggunaan protokol komunikasi dan algoritma konsensus untuk koordinasi distribusi atau produksi
Pengambilan Keputusan	Pengambilan keputusan adaptif berdasarkan pemantauan real-time kualitas ekstrak	Pengambilan keputusan dinamis berdasarkan permintaan, pasokan, dan kondisi operasional real-time
Optimasi Proses	Optimasi kombinasi parameter ekstraksi untuk hasil terbaik (waktu, kualitas)	Optimasi jadwal pengiriman, rute distribusi, dan kapasitas untuk efisiensi operasional
Pemantauan	Pemantauan kualitas ekstrak, termasuk kandungan senyawa aktif	Pemantauan kualitas energi, pengelolaan stok bahan baku, dan status pengiriman
Keuntungan Utama	Efisiensi dalam penggunaan bahan baku, waktu, dan energi, serta kualitas hasil ekstraksi	Efisiensi biaya, waktu, dan pengelolaan sumber daya yang lebih baik

BAB III

KONSEP DASAR OPTIMASI MULTI-OBJEKTIF (MOO)

Optimasi Multi-Objektif (Multi-Objective Optimization / MOO) adalah pendekatan penting yang digunakan ketika ada beberapa tujuan yang saling bertentangan, namun harus dicapai secara bersamaan. Dalam banyak masalah nyata, termasuk dalam industri ekstraksi bahan alami, sering kali terdapat beberapa tujuan yang perlu dioptimalkan secara bersamaan, seperti:

- Hasil ekstraksi maksimal dari senyawa bioaktif seperti minyak esensial atau senyawa aktif lainnya.
- Kualitas ekstrak yang memenuhi standar farmasi atau kosmetik tertentu.
- Efisiensi energi dan penggunaan pelarut, mengurangi dampak lingkungan dan biaya produksi.
- Waktu proses ekstraksi yang minimal, agar proses produksi lebih cepat dan efisien.

Optimasi multi-objektif berfokus pada penyelesaian masalah yang melibatkan lebih dari satu tujuan, yang mungkin saling bertentangan. Oleh karena itu, daripada mencari satu solusi tunggal terbaik, MOO berupaya untuk menemukan serangkaian solusi optimal yang disebut Pareto-optimal, di mana tidak ada solusi yang dapat memperbaiki satu tujuan tanpa mengorbankan tujuan lainnya. Setiap solusi dalam set Pareto-optimal memberikan kompromi terbaik antar tujuan yang ada.

Dalam konteks proses ekstraksi bahan alami, MOO memungkinkan para peneliti untuk mengoptimalkan beberapa parameter secara bersamaan, seperti suhu ekstraksi, waktu ekstraksi, rasio pelarut, dan jenis pelarut yang digunakan. Masing-masing parameter ini mempengaruhi beberapa tujuan, seperti hasil ekstraksi dan kualitas ekstrak. Misalnya, meningkatkan suhu ekstraksi dapat meningkatkan hasil, tetapi berisiko mengurangi kualitas ekstrak. Oleh karena itu, penggunaan MOO membantu menyelesaikan konflik antar tujuan untuk mencapai hasil yang optimal.

3.1. Pengertian dan Prinsip Dasar MOO

3.1.1 Pengertian MOO

Optimasi Multi-Objektif (MOO) adalah pendekatan yang digunakan untuk memecahkan masalah yang melibatkan lebih dari satu tujuan, yang sering kali bertentangan. Setiap tujuan dalam MOO memiliki kontribusi terhadap solusi yang dicari, namun tidak ada solusi tunggal yang bisa mengoptimalkan semuanya secara bersamaan. Oleh karena itu, MOO mencari sekumpulan solusi yang dikenal dengan istilah Pareto-optimal, di mana tidak ada solusi yang lebih baik dalam satu tujuan tanpa mengorbankan kinerja pada tujuan lainnya (Ehrgott, 2023), (Deb, 2011), (Konak et al., 2006),

Contohnya, dalam desain kendaraan, kita mungkin ingin meminimalkan biaya sambil memaksimalkan kenyamanan. Namun, kedua tujuan ini sering kali saling bertentangan, sehingga tidak ada solusi tunggal yang dapat memenuhi keduanya secara optimal. Sebagai gantinya, MOO membantu kita menemukan berbagai solusi yang menawarkan kompromi terbaik antara kedua tujuan tersebut

MOO dapat diterapkan melalui berbagai metode, antara lain: (Cortez, 2014), (Sindhya, n.d.)

1. A Priori Methods: Metode ini memerlukan informasi preferensi dari pengambil keputusan sebelum proses solusi dimulai. Contohnya termasuk metode fungsi utilitas dan pemrograman tujuan.
2. A Posteriori Methods: Metode ini bertujuan untuk menghasilkan semua solusi Pareto optimal atau subset

representatif dari solusi tersebut. Contohnya termasuk metode pemrograman matematis dan algoritma evolusioner.

3. **Interactive Methods:** Metode ini memungkinkan pengambil keputusan untuk berinteraksi secara iteratif dengan proses solusi, memberikan umpan balik pada setiap langkah untuk mendekati solusi yang paling diinginkan.

Dalam MOO, terdapat beberapa komponen dasar yang saling berinteraksi untuk mencapai solusi optimal. Berikut adalah komponen-komponen utama dalam pendekatan MOO:

1. **Fungsi Tujuan (*Objective Functions*)**

Fungsi tujuan adalah fungsi yang ingin kita optimalkan. Dalam MOO, terdapat lebih dari satu fungsi tujuan yang sering kali saling bertentangan. Setiap fungsi tujuan mendefinisikan kriteria yang perlu diperhatikan dalam mencari solusi optimal.

Contoh: Dalam desain kendaraan, kita mungkin ingin meminimalkan biaya dan emisi sambil memaksimalkan performa dan kenyamanan.

2. **Variabel Keputusan (*Decision Variables*)**

Variabel keputusan adalah parameter atau faktor yang dapat dikendalikan dalam suatu sistem dan digunakan untuk mengoptimalkan fungsi tujuan. Dalam MOO, variabel keputusan ini sering kali ada lebih dari satu dan dapat berbentuk numerik atau kategorikal.

Contoh: Dalam desain kendaraan, variabel keputusan bisa berupa bahan yang digunakan, dimensi kendaraan, atau kecepatan mesin.

3. **Kendala (*Constraints*)**

Kendala adalah batasan yang harus dipenuhi oleh solusi yang dihasilkan. Kendala ini dapat berupa batasan fisik, teknis, atau logistik yang mempengaruhi desain dan implementasi solusi.

Contoh: Dalam optimasi desain kendaraan, kendala bisa

berupa batasan ukuran mesin, batasan bahan bakar, atau keamanan kendaraan.

4. Solusi Pareto Optimal (*Pareto Optimal Solution*)

Solusi Pareto optimal adalah solusi di mana tidak ada solusi lain yang lebih baik dalam satu tujuan tanpa mengorbankan tujuan lainnya. Solusi ini mengrepresentasikan titik kompromi terbaik antara beberapa fungsi tujuan. Contoh: Dalam konteks desain kendaraan, solusi Pareto optimal bisa berupa desain yang menawarkan kompromi terbaik antara biaya, performa, dan kenyamanan.

5. Pareto Front

Pareto front adalah himpunan dari semua solusi Pareto optimal. Ini adalah representasi grafis dari solusi terbaik yang bisa dicapai dengan mempertimbangkan trade-off antar fungsi tujuan.

Contoh: Dalam grafik dua tujuan (misalnya, biaya dan performa), Pareto front akan menunjukkan titik-titik yang mewakili solusi terbaik yang tidak bisa ditingkatkan dalam satu tujuan tanpa menurunkan yang lainnya.

6. Preferensi Pengambil Keputusan (*Decision Maker Preferences*)

Meskipun MOO melibatkan banyak tujuan yang saling bertentangan, pengambil keputusan mungkin memiliki preferensi tentang bagaimana mengutamakan tujuan tertentu. Preferensi ini dapat diintegrasikan ke dalam model MOO untuk membantu memilih solusi yang lebih diinginkan. Contoh: Pengambil keputusan mungkin lebih mengutamakan performa daripada biaya, dan ini dapat diterjemahkan ke dalam model MOO untuk memberikan solusi yang lebih sesuai dengan preferensi tersebut.

7. Algoritma Optimasi (*Optimization Algorithm*)

Algoritma optimasi digunakan untuk mencari solusi terbaik dalam ruang solusi yang besar. Beberapa algoritma yang sering digunakan dalam MOO adalah algoritma evolusioner (seperti NSGA-II dan MOEA/D), pemrograman linier multi-

objektif, dan metode berbasis simulasi lainnya. Contoh: Algoritma NSGA-II sering digunakan untuk mencari solusi Pareto optimal dalam masalah optimasi multi-objektif.

Secara umum, proses MOO melibatkan langkah-langkah berikut:

1. Definisikan fungsi tujuan yang akan dioptimalkan.
2. Identifikasi kendala yang mempengaruhi keputusan.
3. Tentukan variabel keputusan yang dapat diubah.
4. Pilih algoritma optimasi yang sesuai untuk masalah tersebut.
5. Cari solusi Pareto optimal yang memenuhi semua kendala.
6. Tentukan solusi akhir berdasarkan preferensi pengambil keputusan (jika ada).

3.1.2 Pentingnya MOO dalam Ekstraksi Bahan Alami

Ekstraksi bahan alami (misalnya–fitokimia, senyawa bioaktif, minyak atsiri, polifenol, flavonoid, dsb.) melibatkan banyak parameter operasional (waktu, suhu, rasio bahan-pelarut, daya ultrasonik/micro-wave, pH, jenis pelarut, tekanan, dsb.). Tujuan dari ekstraksi ini biasanya multi-dimensi, misalnya:

- Memaksimalkan hasil ekstrak (yield)
- Memaksimalkan kandungan senyawa aktif (misalnya total fenolik, total flavonoid)
- Meminimalkan waktu ekstraksi
- Meminimalkan konsumsi energi atau pelarut
- Menjaga stabilitas senyawa termolabil (supaya tidak rusak oleh suhu tinggi)
- Menjaga kualitas (rendahnya kontaminan, kemurnian, aspek organoleptik, dsb.)

Karena ada beberapa tujuan yang sering kali saling bertentangan (misalnya, waktu ekstraksi makin lama → yield makin tinggi, tapi senyawa aktif bisa rusak atau konsumsi energi makin besar), maka dibutuhkan pendekatan optimasi multidimensi (MOO) untuk menemukan kompromi terbaik (Pareto optimal) di antara tujuan-tujuan tersebut.

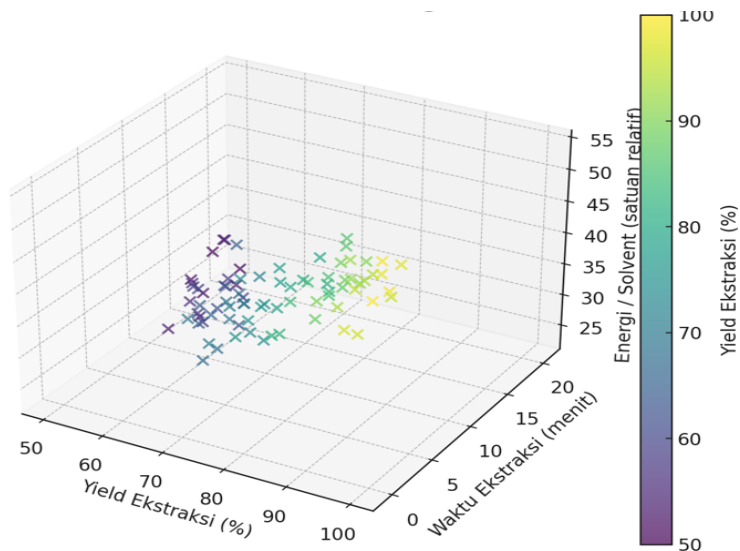
Manfaat/Motivasi penggunaan MOO:

1. Menangani konflik antar tujuan
MOO memungkinkan kita untuk mempertimbangkan beberapa tujuan secara bersamaan, bukan hanya satu. Dengan MOO, kita dapat menemukan solusi kompromi (Pareto front) antara yield tinggi, efisiensi energi rendah, dan kualitas ekstrak.
2. Efisiensi eksperimen
Dengan MOO digabungkan dengan metode statistik (RSM, desain eksperimental) dan algoritma optimasi (misalnya NSGA-II, PSO multi-objektif, algoritma genetika multi-tujuan), kita bisa mengurangi percobaan yang diperlukan dan langsung menuju wilayah potensial terbaik.
3. Penyesuaian terhadap kondisi nyata produksi
Hasil optimasi MOO tidak hanya teori; solusi Pareto bisa dipilih sesuai prioritas produksi (misalnya memilih titik yang sedikit mengorbankan yield untuk pengurangan konsumsi pelarut atau energi). Ini sangat berguna ketika skala lab ingin ditransfer ke skala industri.
4. Fleksibilitas dalam preferensi
Karena MOO menghasilkan himpunan solusi, pengguna/peneliti dapat memilih titik yang paling cocok sesuai bobot preferensi (misalnya lebih condong ke kualitas dibanding yield, jika bahan aktif sangat sensitif).
5. Robustness (ketahanan)
Dengan mempertimbangkan banyak tujuan dan variabilitas kondisi, solusi yang dihasilkan cenderung lebih tangguh terhadap fluktuasi dalam parameter operasional.
6. Optimalisasi “green extraction”
Dalam tren ekstraksi ramah lingkungan (green extraction), sering ada target untuk meminimalkan penggunaan pelarut,

energi, dan emisi. MOO membantu menyeimbangkan performa ekstrak dan dampak lingkungan.

Karakteristik MOO

1. Trade-off: Dalam MOO, biasanya ada trade-off antara tujuan yang saling bertentangan. Misalnya, meningkatkan hasil ekstraksi mungkin membutuhkan lebih banyak waktu dan energi, tetapi juga dapat mengurangi kualitas. Dalam kasus lain, mengoptimalkan kualitas ekstrak dapat menyebabkan berkurangnya efisiensi waktu.
2. Pareto-optimal: Setiap solusi dalam ruang solusi yang Pareto-optimal merupakan kompromi terbaik antara tujuan yang ada, sehingga tidak ada solusi lain yang dapat meningkatkan satu tujuan tanpa merugikan tujuan lainnya.
3. Solusi Dominan dan Non-dominan: Solusi yang lebih baik pada satu tujuan tetapi lebih buruk pada tujuan lain disebut solusi dominasi. Sebaliknya, solusi yang tidak ada yang dapat mendominasi solusi lainnya disebut solusi non-dominan, yang merupakan bagian dari set Pareto-optimal.



Gambar 3. 1 Ilustrasi MOO Tiga Tujuan

Gambar 3.1 adalah ilustrasi MOO dengan 3 tujuan sekaligus dalam ekstraksi bahan alami:

1. Sumbu X: Yield ekstraksi (%)
2. Sumbu Y: Waktu ekstraksi (menit)
3. Sumbu Z: Energi/solvent yang digunakan (satuan relatif)
4. Titik berwarna: Solusi kandidat, dengan warna menunjukkan tingkat yield.

Gambar ini memperlihatkan bahwa:

- Solusi dengan yield tinggi sering memerlukan waktu lebih lama dan energi lebih besar.
- MOO akan membantu menemukan kumpulan solusi optimal (Pareto set) di ruang 3D ini, sehingga peneliti dapat memilih kompromi terbaik sesuai prioritas (misalnya efisiensi energi vs hasil maksimal).

3.2 Teknik dan Algoritma untuk MOO

Berikut algoritma-algoritma MOO (Multi-Objective Optimization) yang paling relevan untuk ekstraksi bahan alami (termasuk *Moringa oleifera*).

1. NSGA-II (*Non-Dominated Sorting Genetic Algorithm II*)

Algoritma berbasis algoritma genetik ini menggunakan proses pemilihan berdasarkan dominasi dan pengurutan non-dominasi untuk menemukan solusi Pareto-optimal.

Inti langkah:

- a) Inialisasi populasi acak;
- b) Evaluasi semua tujuan;
- c) Non-dominated sorting → bagi ke front Pareto (F1, F2, ...);
- d) Hitung crowding distance;
- e) Seleksi (binary tournament: peringkat lalu crowding);
crossover + mutasi → keturunan;
- f) Gabung orang-tua+keturunan → sortir front & crowding → ambil N terbaik;
- g) Ulangi s.d. konvergen.

Kapan dipakai: baseline kuat untuk ≥ 2 tujuan, Pareto front halus, tanpa asumsi konveksitas.

Kelebihan: stabil, sederhana, ekosistem library luas (pymoo/jMetalPy)(Deb et al., 2002b)

2. MOEA/D (Decomposition-based)

Pendekatan berbasis dekomposisi ini memecah masalah MOO menjadi sub-masalah dan menyelesaikannya secara terpisah untuk mendapatkan solusi Pareto.

Inti langkah:

1. Hasilkan sekumpulan vektor bobot;
2. Decomposition: tiap bobot mendefinisikan sub-problem skalar (mis. Tchebycheff/penjumlahan ter-bobot);
3. Evolusi solusi per tetangga (neighborhood) — berbagi info lokal;
4. Perbarui solusi terbaik per sub-problem sampai konvergen. Kapan dipakai: tujuan banyak (3–10), front non-konveks, ingin sebaran seragam & skalabilitas(Liu et al., 2014).

3. SPEA2 (*Strength Pareto Evolutionary Algorithm 2*)

Algoritma ini menggunakan penilaian kekuatan untuk memberikan bobot pada solusi berdasarkan dominasi Pareto dan distribusi solusi.

Inti langkah: arsip nondominated set + density estimation; seleksi berbasis “kekuatan” dominasi + kerapatan, lalu evolusi GA. Kapan dipakai: butuh diversity yang baik & arsip Pareto eksplisit(Ren et al., 2024).

4. MOPSO / SMPSO (*Multi-Objective PSO*)

MOPSO/SMPSO (Multi-Objective PSO) adalah salah satu algoritma Optimasi Multi-Tujuan (MOO) berbasis swarm yang memperluas PSO klasik untuk menghasilkan himpunan solusi Pareto (nondominated set) melalui arsip eksternal dan pemilihan pemimpin (leader) berbasis dominasi/crowding(Coello et al., 2009),(Coello Coello et al., 2004).

Inti langkah: partikel menyimpan arsip nondominated, pemilihan leader memakai dominasi/crowding; SMPSO menambah speed constraining agar stabil.

Kapan dipakai: ruang kontinyu, fungsi mulus/berisik, ingin konvergensi cepat(Durillo et al., 2010).

5. Pareto Simulated Annealing (MOSA/PSA)

Metode berbasis simulasi annealing yang digunakan untuk menemukan solusi optimal dengan eksplorasi ruang solusi yang lebih luas.

Inti langkah: annealing dengan kriteria penerimaan berbasis dominasi Pareto + arsip nondominated.

Kapan dipakai: landscape sulit/non-halus, ingin keluar dari jebakan local(Cao et al., 2017).

6. ϵ -Constraint (Metode Eksak/Scalarization)

Suatu teknik optimasi multi-tujuan (MOO) yang memilih satu tujuan sebagai fungsi objektif untuk diminimalkan/dimaksimalkan, sementara tujuan-tujuan lain diubah menjadi kendala dengan ambang ϵ (*epsilon*).

Dengan menggeser nilai ϵ secara sistematis, kita membangkitkan himpunan solusi Pareto-optimal. Metode ini bersifat eksak: setiap penyelesaian (untuk set nilai ϵ tertentu) diperoleh dengan solver satu-tujuan standar(Deb, 2011),(Optimization, 2017).

Inti langkah: pilih satu tujuan sebagai objektif; ubah tujuan lain jadi kendala dengan ambang ϵ ; sweep ϵ untuk membangun Pareto.

Kapan dipakai: masalah terstruktur (MILP/NLP) dengan solver matematis; ingin solusi tepat di titik-titik kunci Pareto(Mesquita-Cunha et al., 2023)

7. Weighted-Sum & Variannya (*Adaptive Weighted Sum*)

Weighted-Sum dan variannya (*Adaptive Weighted-Sum*) adalah salah satu pendekatan scalarization dalam Optimasi Multi-Tujuan (MOO) yang menggabungkan beberapa fungsi tujuan menjadi satu tujuan tertimbang metode ini menghasilkan himpunan solusi Pareto—lengkap untuk front Pareto yang cembung, dan mendekati pada front yang tidak cembung(Sela, 2020),

Inti langkah: gabung semua tujuan $\rightarrow \sum w_i f_i$; lakukan optimasi berulang untuk berbagai bobot; versi adaptive memperbaiki sebaran titik di front non-seragam.

Catatan: weighted-sum klasik tidak menangkap bagian non-konveks; gunakan adaptive atau Tchebycheff untuk mengatasinya(I. Y. Kim & De Weck, 2004).

Tabel 3. 1 Kelebihan dan Kekurangan Teknik MOO

Teknik	Kelebihan	Kekurangan	Cocok untuk
NSGA-II	<ul style="list-style-type: none"> • Menghasilkan Pareto front beragam tanpa asumsi konveksitas • Stabil, implementasi luas (pymoo/jMetalPy) • Mudah dipakai untuk 2–4 tujuan 	<ul style="list-style-type: none"> • Komputasi meningkat jika tujuan/variabel banyak • Perlu tuning pop/crossover/mutasi 	Baseline kuat untuk optimasi parameter (suhu, waktu, rasio pelarut) dengan 2–4 tujuan
MOEA/D	<ul style="list-style-type: none"> • Skalabel untuk banyak tujuan (≥ 4) • Sebaran solusi merata via dekomposisi bobot • Efisien dengan pemanfaatan tetangga 	<ul style="list-style-type: none"> • Sensitif pada desain vektor bobot • Perlu strategi penempatan bobot yang baik 	Banyak tujuan sekaligus (yield, TPC/TFC, waktu, energi, biaya) dan ingin coverage merata
SPEA2	<ul style="list-style-type: none"> • Arsip Pareto eksplisit (auditable) • Diversity baik via estimasi kepadatan • Baik saat banyak solusi mirip 	<ul style="list-style-type: none"> • Manajemen arsip bisa mahal pada data besar • Perlu kontrol ukuran arsip 	Saat butuh arsip solusi Pareto yang rapi untuk seleksi resep di skala produksi
MOPSO / SMPSO	<ul style="list-style-type: none"> • Konvergensi cepat di ruang kontinu • SMPSO stabil (speed-constraining) • Tahan noise/ketidakhalsan respon eksperimen 	<ul style="list-style-type: none"> • Risiko stagnasi/premature convergence • Perlu pengaturan v_{max}, leader, dan (kadang) mutasi 	Proses ultrasonik/microwave dengan respon berderau; butuh cepat menjelajah kompromi
ϵ-Constraint (termasuk AUGMECO N2)	<ul style="list-style-type: none"> • Eksak (tiap run = solusi optimal satu-tujuan) • Menangkap front non-konveks • AUGMECON2 hindari weakly-efficient & cepat di (M)ILP 	<ul style="list-style-type: none"> • Perlu sweeping grid ϵ (banyak run) • Desain grid ϵ krusial untuk coverage 	Model terstruktur (LP/MIP/NLP) seperti minim biaya energi/pelarut sambil maksimalkan yield/kualitas

Weighted-Sum (WS) & Adaptive WS	<ul style="list-style-type: none"> • Sederhana & cepat (scalarization) • Mudah digabung dengan RSM/metamodel • Adaptive WS memperbaiki sebaran titik 	<ul style="list-style-type: none"> • WS gagal menangkap bagian front non-konveks • Hasil sensitif pada skala & pilihan bobot 	Baseline cepat untuk studi awal kompromi; lanjutkan ke ϵ -constraint/EMO bila front non-konveks
--	---	--	--

Tabel 3.1 merupakan ringkas kelebihan dan kekurangan tiap teknik MOO dalam konteks ekstraksi bahan alam (mis. memaksimalkan yield/TPC/TFC dan meminimalkan waktu/energi/pelarut).

3.3 Kriteria Evaluasi dalam MOO

Indikator atau metrik evaluasi dalam MOO yang umum digunakan sebagai berikut:

3.3.1 Hypervolume (HV)

Hypervolume mengukur volume ruang objektif yang didominasi oleh suatu himpunan solusi dibandingkan titik referensi r . Untuk meminimasi m tujuan, HV adalah ukuran Lebesgue dari

$$HV(S; r) = \lambda(U_{x \in S} [f_1(x), r_1] \times \dots \times [f_m(x), r_m]) \tag{1}$$

di mana S adalah set solusi tak-terdominasi (aproksimasi Pareto). HV meningkat jika set solusi “mendekat” Pareto front dan/atau lebih tersebar rata. HV adalah Pareto-compliant (jika satu set mendominasi set lain, HV-nya pasti lebih besar)(Zitzler et al., 2007). Mengapa HV populer?

1. Satu angka yang merangkum konvergensi + keragaman sekaligus (bila referensi dipilih benar).
2. Pareto-compliant dan bisa dipakai baik untuk assessment (menilai kualitas Pareto set) maupun sebagai kriteria seleksi (indicator-based MOEA)(Auger et al., 2009).
3. Banyak algoritma dan tool pendukung (estimasi/ekspak/seleksi berbasis HV)(Bader & Zitzler, 2011).

Kunci praktik yang sering “menjebak”

1. Pemilihan titik referensi (r)
 - a) Harus lebih buruk dari semua solusi pada setiap tujuan (mis. persentil jelek dari data atau “payoff table” + margin).
 - b) Pemilihan r memengaruhi nilai HV mutlak dan perbandingan lintas eksperimen—gunakan prosedur konsisten.
2. Normalisasi tujuan
Skala tiap tujuan ke $[0,1]$ (berdasarkan kisaran yang relevan) agar HV tidak “dikuasai” satu tujuan berskala besar (Brockhoff, 2018).
3. Banyak tujuan (many-objective)
Perhitungan eksak HV menjadi berat secara komputasi saat dimensi meningkat (eksponensial terhadap jumlah tujuan). Gunakan estimasi Monte-Carlo (HypE) atau algoritma eksak yang efisien (WFG/HSO) jika dimensi masih rendah.

Cara menghitung HV (sekilas peta algoritma)

1. Eksak (exact):
HSO (Hypervolume by Slicing Objectives) dan WFG (While-Bradstreet-Hingston) mempercepat hitungan HV eksak, cocok untuk 2–5 tujuan dan ukuran set sedang (While et al., 2006).
2. Estimasi (approximate):
HypE (Monte-Carlo) menaksir HV dan memanfaatkannya langsung sebagai fitness dalam MOEA—efektif untuk many-objective.

HV Improvement (HVI) & Expected HVI (EHVI)

1. HVI: kontribusi HV ketika menambahkan kandidat baru y ke set S . Dipakai untuk seleksi individu dalam MOEA.
2. EHVI: ekspektasi peningkatan HV ketika evaluasi mahal digantikan model surrogate (Gaussian Process/Bayesian

MOO). Ada algoritma cepat (box-decomposition) untuk 2–3 tujuan dan generalisasi-nya (Gaudrie et al., 2018).

Kelebihan & keterbatasan

1. (+): Pareto-compliant; menilai kedekatan ke front dan pemerataan solusi sekaligus; bisa jadi tujuan (maximize HV) dalam indicator-based MOEA
2. (-): Perlu titik referensi; mahal untuk banyak tujuan; nilai HV tidak dapat dibandingkan lintas studi bila skala tujuan/referensi berbeda. Solusi: normalisasi & prosedur referensi yang baku; gunakan estimasi untuk many-objective.

Tips penerapan pada ekstraksi bahan alam (mis. Moringa oleifera)

1. Tujuan umum: maximize yield/TPC/TFC; minimize waktu/energi/pelarut.
2. Normalisasi semua tujuan; pilih r lebih buruk dari (waktu/energi/pelarut) maksimum yang wajar dan (yield/kualitas) minimum yang wajar.
3. Untuk ≥ 4 tujuan atau sampel banyak, gunakan HypE (estimasi) saat menjalankan MOEA; untuk pelaporan akhir, hitung HV eksak pada 2–3 tujuan kunci (mis. yield vs energi vs waktu).

3.3.2 Generational Distance (GD) & Inverted GD (IGD/IGD+)

Generational Distance (GD) & Inverted GD (IGD/IGD+) adalah dua metrik evaluasi yang sering digunakan dalam Optimasi Multi-Tujuan (MOO) untuk menilai konvergensi dan keragaman dari solusi yang ditemukan oleh algoritma optimasi. Berikut adalah penjelasan lebih detail tentang GD dan IGD/IGD+ (Ishibuchi et al., 2015), (Cai et al., 2021).

1. Generational Distance (GD)

GD adalah ukuran yang mengukur jarak rata-rata antara setiap solusi dalam himpunan solusi yang ditemukan oleh algoritma dan solusi terbaik (titik referensi) pada Pareto front sejati.

Rumus GD:

$$GD(S) = \frac{1}{|S|} \sum_{x_i \in S} \frac{\min_{y \in PF} \|x_i - y\|}{\quad} \quad (2)$$

di mana:

- S adalah himpunan solusi yang dihasilkan oleh algoritma.
- PF adalah Pareto front sejati.
- $\|\cdot\|$ adalah ukuran jarak (misalnya, Euclidean distance).

Kelebihan:

- Mudah dipahami: Mengukur kedekatan solusi terhadap Pareto front sejati.
- Dapat dipakai dengan berbagai algoritma: Cocok untuk algoritma yang menghasilkan himpunan solusi diskrit maupun kontinu.

Kekurangan:

- Hanya menilai konvergensi; tidak memberikan informasi mengenai keragaman atau sebaran solusi.
- Ketergantungan pada referensi: Perlu himpunan solusi Pareto sejati sebagai referensi, yang mungkin tidak tersedia atau sulit didapatkan untuk masalah yang lebih kompleks.

2. Inverted Generational Distance (IGD)

IGD adalah metrik yang mengukur seberapa jauh solusi Pareto sejati berada dari himpunan solusi yang ditemukan oleh algoritma. Dengan kata lain, IGD mengukur kualitas sebaran solusi di sepanjang Pareto front sejati

Rumus IGD:

$$IGD(S) = \frac{1}{|PF|} \sum_{y_j \in PF} \frac{\min_{x_i \in S} (x_i, y_j)}{\quad} \quad (3)$$

di mana:

- S adalah himpunan solusi yang dihasilkan oleh algoritma.
- PF adalah Pareto front sejati.
- $\|\cdot\|$ adalah ukuran jarak (misalnya, Euclidean distance).

Kelebihan:

- Menilai sebaran solusi: IGD mengukur kualitas sebaran solusi sepanjang Pareto front.
- Memberikan penilaian yang lebih komprehensif dibandingkan GD karena menggabungkan konvergensi dan keragaman.

Kekurangan:

- Memerlukan Pareto front sejati sebagai referensi.
- Untuk banyak tujuan (many-objective), menghitung IGD bisa menjadi mahal secara komputasi.

3. Inverted Generational Distance Plus (IGD+)

Inverted Generational Distance Plus (IGD+) adalah perbaikan dari Inverted Generational Distance (IGD) yang dirancang untuk menangani beberapa kelemahan IGD, terutama terkait distribusi solusi dan ketergantungan pada titik referensi. IGD mengukur seberapa jauh solusi Pareto sejati berada dari himpunan solusi yang dihasilkan oleh algoritma, namun tidak selalu memberikan penilaian yang adil terhadap solusi yang mungkin mendominasi satu sama lain dengan cara yang lemah. IGD+ mengatasi masalah ini dengan memberikan jarak yang lebih adil antara solusi pada front Pareto sejati dan solusi yang ditemukan oleh algoritma, dengan menggunakan pendekatan distance-based modification.

IGD mengukur jarak antara set solusi yang dihasilkan dan Pareto front sejati. Namun, IGD tidak mempertimbangkan solusi yang memiliki dominan lemah terhadap solusi lain, yang bisa menimbulkan bias dalam evaluasi. IGD+ memperbaiki hal ini dengan menambahkan modifikasi jarak antara solusi untuk memastikan solusi yang lebih dominan diberikan perhatian lebih besar.

Rumus umum untuk IGD+ adalah sebagai berikut:

$$\text{IGD} + (S) = \frac{1}{|\text{PF}|} \sum_{y_j \in \text{PF}} \min_{x_i \in S} d^+ (x_i, y_j) \quad (4)$$

di mana:

- S adalah himpunan solusi yang dihasilkan oleh algoritma.
- PF adalah Pareto front sejati.
- $d^+ (x_i, y_j)$ adalah modified distance antara solusi x_i dan solusi referensi y_j

Kelebihan IGD+

- Pareto-compliant: IGD+ dapat menangani solusi dengan dominasi lemah dan lebih akurat dalam mengevaluasi solusi yang lebih baik di sepanjang Pareto front.
- Menilai konvergensi dan keragaman: IGD+ dapat menilai baik kedekatan solusi terhadap Pareto front sejati (konvergensi) maupun sebaran solusi sepanjang front.
- Mengurangi bias: Dengan perhitungan jarak yang lebih adil, IGD+ mengurangi ketergantungan pada solusi ekstrem dan memastikan penilaian yang lebih objektif terhadap distribusi solusi.

Kekurangan IGD+

- Kompleksitas lebih tinggi: Dibandingkan dengan IGD standar, IGD+ memerlukan perhitungan yang lebih rumit, yang mungkin meningkatkan beban komputasi pada masalah besar atau dengan banyak tujuan.
- Memerlukan Pareto front sejati: Sama seperti IGD, IGD+ membutuhkan Pareto front sejati sebagai referensi, yang mungkin tidak selalu tersedia untuk beberapa masalah dunia nyata.

IGD+ sangat berguna ketika:

- Evaluasi algoritma optimasi multi-tujuan perlu mempertimbangkan dominan lemah antara solusi.

- Algoritma many-objective digunakan (misalnya, 5 tujuan atau lebih) karena IGD+ lebih efektif menangani solusi yang tersebar secara merata sepanjang front.
- Dibutuhkan evaluasi yang lebih robust dan adil dalam hal distribusi solusi di sepanjang Pareto front.

Kapan Menggunakan GD, IGD, dan IGD+?

- GD lebih berguna ketika kita ingin mengukur seberapa dekat solusi yang ditemukan oleh algoritma terhadap Pareto front sejati.
- IGD lebih baik digunakan untuk menilai keragaman solusi dan mengevaluasi seberapa luas Pareto front yang tercakup oleh algoritma.
- IGD+ sangat berguna dalam situasi di mana kita membutuhkan evaluasi lebih robust terhadap distribusi solusi dan menghindari bias terhadap solusi ekstrem.

Perbandingan GD dan IGD ditunjukkan table 3. 2

Tabel 3. 2 Perbandingan GD, IGD dan IGD+

Metrik	Kelebihan	Kekurangan
GD	Mudah dihitung; fokus pada konvergensi	Tidak mengukur keragaman; bergantung pada titik referensi.
IGD	Mengukur kedekatan dan keragaman solusi	Memerlukan Pareto front sejati sebagai referensi; mahal secara komputasi untuk banyak tujuan.
IGD+	Lebih robust terhadap bias dan distribusi solusi	Lebih sulit dihitung dibandingkan IGD; tetap memerlukan Pareto front sejati.

3.3.3 Spread / Δ (NSGA-II diversity metric)

Spread (Δ) adalah metrik yang digunakan untuk menilai diversity atau pemerataan solusi dalam algoritma optimasi multi-tujuan. Dalam konteks NSGA-II, metrik ini berfungsi untuk mengukur seberapa merata solusi tersebar sepanjang Pareto front yang ditemukan oleh algoritma (Deb et al., 2002a)

Spread (Δ) menghitung jarak rata-rata antara solusi yang dihasilkan oleh algoritma dan membandingkannya dengan jarak antara solusi Pareto front sejati. Jika solusi yang ditemukan tersebar secara merata di sepanjang front, maka nilai spreadnya akan lebih kecil, menunjukkan bahwa algoritma telah mencakup banyak bagian dari Pareto front (Sato & Sato, 2022).

Rumus Spread (Δ):

$$\Delta = \frac{d_{max} - d_{min}}{d_{max}} \quad (5)$$

di mana:

- d_{max} adalah jarak maksimum antara dua solusi yang ditemukan di Pareto front.
- d_{min} adalah jarak minimum antara dua solusi.
- Nilai Δ mendekati 0 menunjukkan sebaran yang merata.

Proses pengukuran:

1. Solusi yang dihasilkan oleh algoritma (atau populasi pada iterasi tertentu) dihitung jaraknya (misalnya Euclidean) di sepanjang front Pareto.
2. Solusi yang memiliki jarak maksimum dan jarak minimum dihitung untuk melihat sebaran solusi sepanjang front.
3. Menghitung Δ sebagai perbandingan antara jarak maksimum dan minimum, memberikan indikator seberapa baik algoritma mencakup Pareto front.

Kelebihan:

- Mudah dihitung: Metrik ini mudah dipahami dan diterapkan dalam analisis hasil algoritma optimasi multi-tujuan.

- Mengukur diversitas: Δ berfokus pada pemerataan solusi di sepanjang Pareto front, yang sangat penting dalam masalah multi-tujuan karena memberikan gambaran tentang keragaman solusi yang diperoleh.
- Mendukung evaluasi kualitas: Jika solusi tersebar merata, maka hasilnya akan lebih robust dan lebih dekat dengan representasi Pareto yang sebenarnya.

Kekurangan:

- Tidak langsung mengukur konvergensi: Δ tidak mempertimbangkan seberapa dekat solusi dengan Pareto front sejati. Solusi bisa tersebar dengan baik, tetapi jika mereka jauh dari front sejati, ini tidak tercermin dalam Δ .
- Rentan terhadap solusi ekstrem: Jika terdapat beberapa solusi ekstrim (solusi yang sangat jauh atau sangat dekat dengan Pareto front sejati), Δ bisa memberikan gambaran yang kurang akurat mengenai keberhasilan algoritma.

Kapan Menggunakan Δ ?

- Evaluasi keragaman: Jika tujuannya adalah untuk memastikan bahwa solusi tersebar secara merata sepanjang Pareto front dan tidak terlalu terfokus pada satu titik atau bagian dari front, Spread (Δ) adalah metrik yang sangat berguna.
- Perbandingan antar algoritma: Untuk membandingkan seberapa baik dua algoritma mendekati Pareto front dan menjaga diversitas solusi sepanjang front.

Perbandingan Δ dengan Metrik Lain dapat dilihat pada tabel 3.3

Tabel 3. 3 Perbandingan Δ dengan Metrik Lain

Metrik	Kelebihan	Kekurangan
Spread (Δ)	<ul style="list-style-type: none"> • Mengukur pemerataan solusi sepanjang Pareto front. • Mudah dihitung dan dipahami. 	<ul style="list-style-type: none"> • Tidak mengukur kedekatan solusi ke Pareto front sejati. • Dapat dipengaruhi oleh solusi ekstrem.

GD (Generational Distance)	<ul style="list-style-type: none"> • Mengukur kedekatan solusi ke Pareto front sejati. 	<ul style="list-style-type: none"> • Tidak mengukur keragaman atau penyebaran solusi.
IGD (Inverted Generational Distance)	<ul style="list-style-type: none"> • Mengukur kedekatan dan keragaman solusi. 	<ul style="list-style-type: none"> • Memerlukan Pareto front sejati sebagai referensi, dan mahal secara komputasi.
HV (Hypervolume)	<ul style="list-style-type: none"> • Mengukur volume yang didominasi oleh solusi. • Menilai konvergensi dan keragaman sekaligus. 	<ul style="list-style-type: none"> • Memerlukan pemilihan titik referensi yang tepat.

3.3.4 Epsilon Indicator (ϵ)

Epsilon Indicator (ϵ) adalah salah satu metrik yang digunakan untuk menilai kualitas solusi dalam optimasi multi-tujuan (MOO), yang mengukur seberapa dekat solusi yang dihasilkan oleh algoritma optimasi terhadap Pareto front sejati. Metrik ini memberikan cara yang lebih robust dan reliable untuk mengevaluasi hasil algoritma dibandingkan dengan metrik konvensional lainnya seperti GD (Generational Distance) dan IGD (Inverted Generational Distance) (Bringmann et al., 2015), (Audet et al., 2021).

Epsilon Indicator (ϵ) mengukur jarak antara himpunan solusi yang dihasilkan oleh algoritma dan Pareto front sejati. Berbeda dengan metrik lain yang hanya mengukur jarak langsung, ϵ menilai seberapa besar perbedaan antara solusi yang ditemukan dan Pareto front sejati dengan menggunakan ambang batas tertentu (Falcón-Cardona & Coello, 2021).

Rumus Epsilon Indicator (ϵ):

$$\epsilon(S, PF) = \frac{\min}{\epsilon} \{ \forall x \in PF : f(x) \leq \epsilon \cdot f(s) \} \quad (6)$$

di mana:

- S adalah himpunan solusi yang dihasilkan oleh algoritma.
- PF adalah Pareto front sejati.
- $f(x)$ adalah fungsi tujuan pada titik x .

Parameter ϵ mengindikasikan faktor pengganda untuk membandingkan jarak antara solusi yang ditemukan dengan solusi Pareto.

Interpretasi dari ϵ :

- ϵ kecil ($\epsilon \approx 1$) menunjukkan bahwa solusi yang ditemukan sangat dekat dengan Pareto front sejati dan memiliki kualitas tinggi.
- ϵ besar mengindikasikan bahwa solusi yang ditemukan cukup jauh dari front sejati, menunjukkan bahwa algoritma tersebut belum menghasilkan solusi yang memadai.

Kelebihan:

- Robust: Epsilon memberikan penilaian yang lebih komprehensif tentang seberapa baik algoritma mencapai Pareto front sejati dibandingkan dengan metrik lain yang lebih terbatas.
- Dapat digunakan untuk banyak tujuan: Tidak hanya cocok untuk dua tujuan, tetapi juga scalable untuk masalah dengan banyak tujuan (many-objective problems).
- Berguna dalam perbandingan: ϵ sangat berguna untuk membandingkan dua himpunan solusi yang dihasilkan oleh algoritma yang berbeda.

Kekurangan:

- Memerlukan Pareto front sejati: Salah satu keterbatasan utama dari ϵ adalah bahwa ia membutuhkan Pareto front sejati sebagai referensi. Dalam banyak kasus, Pareto front sejati tidak diketahui atau tidak tersedia.
- Sensitif terhadap pilihan ϵ : Pemilihan nilai ϵ yang tepat sangat penting dalam analisis ini. Jika pemilihan nilai ϵ tidak tepat, hasil perbandingan bisa tidak akurat.

Penerapan Epsilon Indicator (ϵ)

- Pengukuran kualitas solusi: ϵ digunakan untuk mengukur kedekatan dan keberagaman solusi yang dihasilkan oleh algoritma terhadap Pareto front sejati, serta untuk mengevaluasi perbandingan antar algoritma.
- Evaluasi algoritma MOO: ϵ sangat berguna dalam evaluasi algoritma multi-tujuan yang menghasilkan banyak solusi sekaligus, di mana kedekatan solusi terhadap Pareto front sejati menjadi faktor penting.
- Analisis konvergensi dan keragaman: Epsilon dapat memberikan wawasan mengenai bagaimana algoritma mengelola trade-off antara konvergensi ke Pareto front dan keragaman solusi yang tersebar sepanjang front tersebut.

Tabel 3.4 merupakan Perbandingan Epsilon Indicator (ϵ) dengan Metrik Lain.

Tabel 3. 4 Perbandingan Epsilon Indicator (ϵ) dengan Metrik Lain

Metrik	Kelebihan	Kekurangan
Epsilon (ϵ)	Robus terhadap solusi yang lebih baik, menilai kedekatan dan keragaman	Memerlukan Pareto front sejati sebagai referensi, sensitif terhadap nilai ϵ
GD (Generational Distance)	Mengukur konvergensi (kedekatan ke Pareto front sejati)	Tidak mengukur keragaman solusi
IGD (Inverted Generational Distance)	Mengukur keragaman solusi di sepanjang front Pareto	Memerlukan Pareto front sejati sebagai referensi

HV (Hypervolume)	Menilai konvergensi dan keragaman sekaligus	Memerlukan titik referensi yang tepat
---------------------	---	---------------------------------------

3.3.5 Coverage / C-metric

Dalam konteks Multi-Objective Optimization (MOO), *Coverage Metric* atau *C-metric* adalah salah satu indikator evaluasi yang digunakan untuk mengukur seberapa baik satu set solusi mendominasi set solusi lainnya. Metrik ini penting dalam menilai kualitas solusi yang dihasilkan oleh algoritma optimisasi multi-objektif, terutama dalam hal seberapa banyak solusi dalam satu set yang didominasi oleh solusi dalam set lainnya.

Coverage metric (C-metric) adalah metrik yang digunakan dalam optimisasi multi-objektif untuk mengevaluasi kualitas solusi yang dihasilkan oleh suatu algoritma dengan membandingkan seberapa banyak solusi dalam satu set solusi yang didominasi oleh solusi dari set solusi lainnya. Metrik ini dapat memberikan gambaran mengenai performa relatif algoritma yang diuji dengan membandingkan dua set solusi (Riquelme et al., 2015).

Rumus Coverage (C-metric):

Misalkan kita memiliki dua himpunan solusi, A dan B, maka C-metric didefinisikan sebagai berikut:

$$C(A, B) = \frac{| \{ b \in B \mid \exists a \in A, a \text{ mendominasi } b \} |}{|B|} \tag{7}$$

Di mana:

- A adalah himpunan solusi yang dihasilkan oleh algoritma pertama.

- B adalah himpunan solusi yang dihasilkan oleh algoritma kedua.
- Dominasi di sini mengacu pada prinsip dominasi Pareto, yaitu jika suatu solusi $a \in A$ lebih baik atau setidaknya sama dengan solusi $b \in B$ dalam semua objektif, dan lebih baik dalam setidaknya satu objektif.

Kelebihan C-metric:

1. Mudah dipahami: C-metric mengukur seberapa banyak solusi yang dihasilkan oleh suatu algoritma mendominasi solusi dari algoritma lain.
2. Berguna untuk perbandingan: Cocok untuk membandingkan dua set solusi dan menilai kualitas satu algoritma dibandingkan yang lain.
3. Konsisten: Metrik ini memberikan gambaran yang jelas tentang performa relatif algoritma dalam hal dominasi solusi.

Kekurangan C-metric:

1. Hanya mengevaluasi dominasi: C-metric hanya menilai dominasi dan tidak mempertimbangkan keragaman atau sebaran solusi dalam Pareto front.
2. Keterbatasan pada masalah kompleks: Menggunakan C-metric memerlukan solusi Pareto sejati sebagai referensi, yang mungkin tidak selalu tersedia untuk masalah yang lebih kompleks.
3. Tidak mempertimbangkan konvergensi: Berbeda dengan metrik lain seperti Generational Distance (GD), C-metric tidak mengevaluasi seberapa dekat solusi yang dihasilkan dengan Pareto front sejati dalam hal jarak.

3.3.6 R2 Indicator

Dalam optimisasi multi-objektif (MOO), R² Indicator adalah salah satu metrik evaluasi berbasis himpunan yang digunakan untuk menilai kualitas set solusi Pareto yang dihasilkan oleh algoritma. Metrik ini mengukur kedekatan set solusi terhadap titik ideal

(utopian point) dalam ruang objektif, dengan mempertimbangkan distribusi fungsi utilitas (Brockhoff, 2018).

R^2 Indicator mengukur seberapa baik set solusi mendekati titik ideal dalam ruang objektif. Metrik ini dihitung berdasarkan fungsi utilitas agregasi, seperti fungsi Tchebycheff, dan distribusi bobot fungsi utilitas. Semakin kecil nilai R^2 , semakin baik kualitas set solusi tersebut, karena menunjukkan bahwa solusi lebih dekat dengan titik ideal.

R^2 Indicator diukur dengan menggunakan rumus berikut:

$$R^2(A, \Lambda, i) = \frac{1}{|\Lambda|} \sum_{\lambda \in \Lambda} \frac{\min_{a \in A} \max_{j \in \{1, \dots, d\}} (\lambda_j |i_j - a_j|)}{\quad} \quad (8)$$

Di mana:

- A = Himpunan solusi yang dihasilkan oleh algoritma.
- Λ = Set bobot fungsi utilitas yang digunakan untuk evaluasi.
- i = Titik ideal (utopian point).
- a_j = Nilai objektif ke- j dari solusi a .
- λ_j = Bobot untuk objektif ke- j .
- d = Jumlah objektif.
- $|\cdot|$ = Menyatakan ukuran jarak (misalnya, Euclidean distance)

Metrik ini mengintegrasikan kontribusi dari setiap bobot fungsi utilitas untuk menilai kualitas set solusi secara keseluruhan.

Kelebihan R^2 Indicator

- Mengakomodasi Preferensi Pengguna: Dengan menyesuaikan distribusi bobot fungsi utilitas, R^2 Indicator memungkinkan integrasi preferensi pengguna dalam evaluasi set solusi.
- Kesesuaian Pareto: Versi kontinu dari R^2 Indicator bersifat Pareto-compliant, artinya penambahan solusi nondominated atau dominasi ke dalam set solusi akan selalu meningkatkan nilai indikator ini (Schäpermeier & Kerschke, 2025)

- Evaluasi Kualitas Set Solusi: R^2 Indicator memberikan gambaran yang jelas tentang seberapa baik set solusi mendekati titik ideal, yang penting dalam konteks pengambilan keputusan multi-objektif.

Kekurangan R^2 Indicator

- Ketergantungan pada Titik Ideal: Perhitungan R^2 Indicator memerlukan pengetahuan tentang titik ideal, yang mungkin tidak selalu tersedia dalam praktik.
- Kompleksitas Komputasi: Perhitungan R^2 Indicator, terutama dalam versi kontinu, dapat memerlukan sumber daya komputasi yang signifikan.
- Tidak Menilai Keragaman Solusi: R^2 Indicator lebih fokus pada kedekatan solusi dengan titik ideal dan tidak memberikan informasi langsung tentang keragaman atau distribusi solusi dalam ruang objektif.

Dalam riset ekstraksi bahan alami, pemilihan metrik evaluasi dalam konteks Multi-Objective Optimization (MOO) sangat penting untuk menilai kualitas solusi yang dihasilkan. Berikut adalah panduan dalam memilih metrik evaluasi yang tepat:

1. Jika Ingin Satu Angka Komprehensif (Konvergensi + Sebaran) dan Siap Menetapkan Titik Referensi → Gunakan Hypervolume (HV)
2. Jika Punya Set Referensi (Gabungan Pareto Terbaik dari Semua Run) → Gunakan Inverted Generational Distance Plus (IGD+)
3. Untuk Membandingkan Dua Algoritma/Langkah Tuning → Tambahkan Coverage (C-metric)
4. Laporkan Spread/ Δ sebagai Pelengkap Agar Reviewer Melihat Pemerataan Solusi, Bukan Hanya Kedekatan
5. Untuk Many-Objective (≥ 4 Tujuan), Pertimbangkan IGD/ R^2 (Lebih Stabil) dan Waspadai Biaya HV

BAB IV

INTEGRASI MAS DAN MOO UNTUK OPTIMASI PROSES EKSTRAKSI

Proses ekstraksi bahan alami merupakan tahap penting dalam berbagai industri, seperti farmasi, kosmetik, dan makanan, yang bertujuan untuk memperoleh senyawa bioaktif dengan nilai ekonomis tinggi. Namun, proses ini sering kali melibatkan banyak variabel yang saling berinteraksi, seperti waktu ekstraksi, suhu, pelarut, dan perbandingan bahan baku. Optimasi proses ekstraksi sangat penting untuk meningkatkan efisiensi, kualitas produk, dan meminimalkan biaya operasional.

Dalam rangka mencapai tujuan optimasi tersebut, dua pendekatan komputasi yang semakin banyak digunakan adalah Multi-Agent Systems (MAS) dan Multi-Objective Optimization

(MOO). MAS, dengan kemampuan untuk mengelola sistem terdistribusi dan beradaptasi dengan perubahan kondisi, memberikan solusi yang lebih fleksibel dalam optimasi proses ekstraksi yang kompleks. Di sisi lain, MOO, yang berfokus pada pencarian solusi optimal yang mempertimbangkan lebih dari satu tujuan sekaligus, sangat cocok untuk masalah ekstraksi yang sering kali melibatkan tujuan yang saling bertentangan, seperti memaksimalkan hasil ekstraksi sambil meminimalkan penggunaan pelarut atau waktu ekstraksi.

Integrasi MAS dan MOO memungkinkan kolaborasi antara agen-agen otonom yang dapat mengatur variabel proses secara dinamis dan bersamaan melakukan pencarian solusi optimal dengan mempertimbangkan berbagai tujuan sekaligus. Melalui kombinasi ini, MAS dapat menyimulasikan interaksi antar agen (misalnya, peran operator dan kontrol sistem), sementara MOO membantu dalam pemilihan solusi terbaik yang memperhatikan trade-off antara tujuan yang bersaing, seperti waktu, biaya, dan kualitas ekstraksi. Penerapan integrasi ini dalam optimasi proses ekstraksi memberikan keuntungan signifikan, seperti peningkatan efisiensi proses, kemampuan untuk menangani ketidakpastian dan variabilitas dalam data eksperimen, serta memberikan solusi yang lebih tepat dan dapat diterapkan dalam skala industri. Oleh karena itu, bab ini akan membahas bagaimana integrasi antara MAS dan MOO dapat digunakan untuk mengoptimalkan proses ekstraksi bahan alami, serta potensi dan tantangan yang dihadapi dalam penerapannya.

Pembahasan akan mencakup desain sistem MAS yang efektif, algoritma optimasi multi-objektif yang digunakan, serta evaluasi kinerja dari solusi yang dihasilkan. Dengan menggabungkan pendekatan berbasis agen dengan optimisasi multi-objektif, diharapkan dapat tercipta solusi yang tidak hanya optimal dari segi teknis, tetapi juga dapat diterapkan secara praktis di industri ekstraksi bahan alami.

4.1 Framework MAS-MOO Berbasis Data

Optimasi proses ekstraksi daun Moringa oleifera untuk mendapatkan senyawa bioaktif yang bernilai tinggi memerlukan pendekatan yang dapat mengatasi kompleksitas variabel yang terlibat, seperti waktu ekstraksi, suhu, pelarut, dan perbandingan bahan baku. Salah satu solusi untuk menghadapi kompleksitas ini adalah dengan menggunakan pendekatan MAS yang digabungkan dengan MOO. Pendekatan ini memungkinkan sistem untuk secara dinamis mengelola berbagai parameter ekstraksi sekaligus mencari solusi optimal yang mempertimbangkan tujuan yang saling bertentangan. Berikut ini adalah deskripsi rinci mengenai framework MAS-MOO yang diterapkan pada proses ekstraksi daun Moringa oleifera.

4.1.1 Kerangka Dasar Framework MAS-MOO

Dalam framework ini, MAS terdiri dari beberapa agen otonom yang berperan untuk memonitor dan mengontrol berbagai aspek dalam proses ekstraksi. Setiap agen dalam sistem memiliki peran yang berbeda, dan berinteraksi satu sama lain untuk mencapai tujuan bersama, yaitu menemukan kondisi ekstraksi terbaik yang dapat menghasilkan hasil yang optimal.

1. Agen Pengontrol Proses: Agen ini bertugas untuk memonitor kondisi ekstraksi, seperti suhu, waktu, tekanan, dan perbandingan bahan baku terhadap pelarut. Agen ini dapat mengambil keputusan untuk menyesuaikan kondisi ekstraksi sesuai dengan parameter yang diinginkan berdasarkan data sensor yang dikumpulkan.
2. Agen Pengoptimalan: Agen ini berfungsi untuk mencari solusi optimal berdasarkan tujuan yang ditetapkan. Agen pengoptimalan menggunakan data yang diperoleh dari agen pengontrol untuk menghitung solusi terbaik dengan mempertimbangkan trade-off antara tujuan yang bertentangan (misalnya, hasil ekstraksi vs. konsumsi energi atau pelarut).
3. Agen Pengumpulan Data: Agen ini berperan mengumpulkan data dunia nyata dari sensor yang terpasang pada sistem ekstraksi, seperti sensor suhu, sensor tekanan, dan sensor pH.

Data ini penting untuk memandu agen dalam membuat keputusan yang lebih tepat.

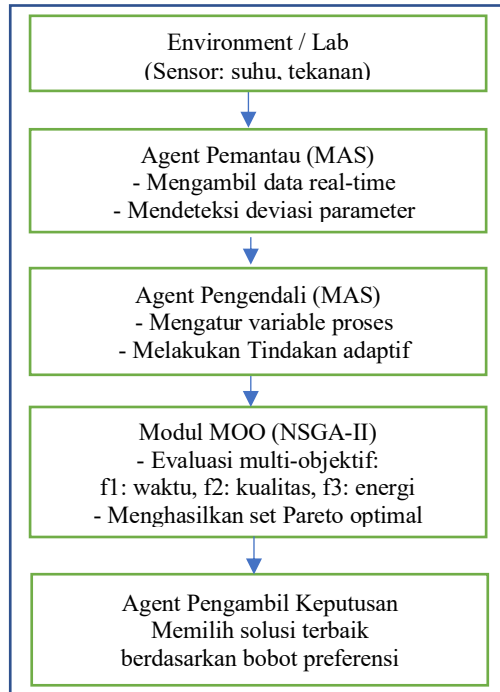
Data dunia nyata sangat penting dalam memastikan keputusan yang diambil oleh agen-agen MAS adalah valid dan efektif. Sistem ini menggunakan sensor untuk memantau kondisi ekstraksi secara real-time, seperti:

1. Suhu: Diperoleh dari sensor suhu yang mengukur suhu ekstraksi dalam berbagai tahap.
2. Tekanan: Sensor tekanan untuk memantau tekanan dalam proses ekstraksi, yang sangat berpengaruh pada hasil yang diperoleh.
3. pH: Sensor pH digunakan untuk mengukur kadar keasaman bahan ekstraksi, yang dapat memengaruhi kualitas ekstrak yang dihasilkan.
4. Kelembaban: Sensor kelembaban untuk mengukur kadar air dalam bahan baku.

Data yang diperoleh dari sensor ini kemudian digunakan oleh agen pengontrol untuk menyesuaikan kondisi ekstraksi dan oleh agen pengoptimalan untuk menentukan solusi terbaik. Proses ini memungkinkan sistem untuk bereaksi terhadap perubahan kondisi secara dinamis.

Integrasi MAS dengan MOO bertujuan untuk menciptakan sistem ekstraksi yang cerdas, adaptif, dan efisien. MAS digunakan sebagai pengendali terdistribusi, di mana setiap agen memiliki fungsi tertentu seperti pengawasan, pengambilan keputusan, atau kontrol parameter. Sedangkan MOO berperan sebagai pengoptimal global yang mencari kombinasi parameter terbaik berdasarkan beberapa tujuan yang saling bertentangan (misalnya waktu ekstraksi, kualitas hasil, dan konsumsi energi).

Gambar 4.1 merupakan diagram alur memperlihatkan bagaimana kedua pendekatan ini bekerja secara sinergis. Setiap blok menunjukkan fungsi agen dan modul optimasi dalam proses pengambilan keputusan adaptif.



Gambar 4. 1 Integrasi MAS-MOO

4.1.2 Penggunaan Multi-Objective Optimization (MOO)

Proses ekstraksi daun Moringa oleifera memiliki beberapa tujuan yang sering kali saling bertentangan, seperti:

1. Memaksimalkan hasil ekstraksi: Mendapatkan sebanyak mungkin senyawa bioaktif dari daun Moringa.
2. Meminimalkan konsumsi pelarut: Mengurangi jumlah pelarut yang digunakan untuk menjaga efisiensi biaya dan ramah lingkungan.
3. Meminimalkan waktu ekstraksi: Mengurangi waktu yang dibutuhkan untuk proses ekstraksi guna meningkatkan efisiensi operasional.

4. Meminimalkan penggunaan energi: Mengurangi energi yang dibutuhkan dalam proses ekstraksi untuk menurunkan biaya operasional dan dampak lingkungan.

MOO memungkinkan sistem untuk menemukan solusi terbaik dengan mempertimbangkan trade-off antara tujuan yang bertentangan ini. Setiap agen dalam MAS berperan dalam proses pencarian solusi optimal melalui algoritma optimasi multi-objektif seperti NSGA-II (Non-dominated Sorting Genetic Algorithm II) atau MOEA/D (Multi-objective Evolutionary Algorithm /Decomposition).

NSGA-II: Merupakan algoritma evolusioner yang sering digunakan untuk optimisasi multi-objektif. Dalam konteks ekstraksi daun Moringa oleifera, NSGA-II digunakan untuk menemukan solusi Pareto-optimal yang mempertimbangkan berbagai tujuan secara bersamaan. Agen pengoptimalan akan mengevaluasi solusi berdasarkan fungsi-fungsi objektif yang telah ditentukan, seperti hasil ekstraksi, konsumsi pelarut, dan waktu ekstraksi, untuk menghasilkan solusi yang tidak mendominasi satu sama lain.

MOEA/D: Algoritma ini mendekomposisi masalah multi-objektif menjadi beberapa submasalah dan menyelesaikan setiap submasalah secara terpisah. Setiap agen dalam MAS dapat bertanggung jawab untuk menyelesaikan satu submasalah dan kemudian berkolaborasi dengan agen lainnya untuk menemukan solusi global yang optimal.

4.1.3. Interaksi Antar Agen dan Proses Pengambilan

Keputusan

Dalam framework ini, interaksi antar agen sangat penting untuk keberhasilan proses optimasi. Berikut adalah mekanisme interaksi yang diterapkan:

1. Komunikasi antar Agen: Agen-agen dalam MAS berkomunikasi secara terus-menerus untuk berbagi informasi dan mengkoordinasikan keputusan. Agen pengontrol proses dapat mengirimkan data sensor terkini ke agen pengoptimalan untuk dianalisis.
2. Evaluasi dan Pembaruan Solusi: Agen pengoptimalan mengevaluasi solusi yang dihasilkan menggunakan

algoritma MOO dan memperbarui solusi berdasarkan tujuan yang telah ditetapkan. Jika suatu solusi lebih baik dari solusi sebelumnya, maka akan diadopsi sebagai solusi terbaik.

Dengan interaksi ini, sistem dapat menyesuaikan kondisi ekstraksi secara dinamis berdasarkan data dunia nyata yang dikumpulkan, serta secara bersamaan melakukan pencarian solusi optimal.

4.1.4 Evaluasi Kinerja Sistem MAS-MOO

Kinerja sistem MAS-MOO dapat dievaluasi menggunakan metrik-metrik MOO, seperti Hypervolume (HV) untuk mengevaluasi kualitas solusi dalam hal konvergensi dan sebaran, serta Inverted Generational Distance (IGD+) untuk mengukur kedekatan solusi yang dihasilkan dengan Pareto front sejati. Metrik Spread/ Δ juga digunakan untuk memastikan pemerataan solusi dalam ruang objektif.

4.2 Proses Rekayasa Fitur dan Pengumpulan Data dalam Eksperimen Ekstraksi Moringa Oleifera

Pengumpulan data eksperimen dan rekayasa fitur merupakan langkah yang sangat penting dalam proses optimasi ekstraksi, terutama ketika menggunakan pendekatan berbasis MAS dan MOO. Dalam eksperimen ekstraksi daun Moringa oleifera, berbagai kondisi ekstraksi yang berbeda memberikan pengaruh besar terhadap hasil yang diperoleh. Oleh karena itu, pengumpulan data yang akurat dan komprehensif sangat diperlukan untuk memberikan informasi yang memadai dalam pengambilan keputusan selama proses optimasi.

4.2.1 Pengumpulan Data Eksperimen dari Empat Kondisi Ekstraksi

Proses rekayasa fitur dan pengumpulan data adalah langkah krusial dalam eksperimen optimasi yang bertujuan untuk meningkatkan hasil ekstraksi daun *Moringa oleifera*. Proses ini melibatkan pengumpulan data eksperimen dari berbagai kondisi lingkungan, yang dapat mempengaruhi kualitas dan hasil ekstraksi. Dalam hal ini, empat kondisi lingkungan yang berbeda diperhatikan, yaitu Dataran Tinggi Kering, Dataran Tinggi Basah, Dataran Rendah Kering, dan Dataran Rendah Basah. Setiap kondisi memiliki karakteristik tertentu yang mempengaruhi parameter ekstraksi, seperti suhu, kelembaban, dan kadar air dalam daun.

1. Dataran Tinggi Kering

Pada kondisi Dataran Tinggi Kering, daun *Moringa oleifera* tumbuh di daerah dengan kelembaban udara rendah dan suhu tinggi. Data yang dikumpulkan di kondisi ini biasanya mencakup:

- a) Suhu udara: Dataran tinggi biasanya memiliki suhu yang lebih rendah pada malam hari dan lebih tinggi pada siang hari. Fluktuasi suhu ini mempengaruhi kadar air dalam daun dan hasil ekstraksi.
- b) Kelembaban udara: Kelembaban yang rendah dapat menyebabkan penguapan lebih cepat, yang berdampak pada kandungan air daun.
- c) Kadar air daun: Daun yang tumbuh di daerah kering cenderung memiliki kadar air yang lebih rendah, yang akan mempengaruhi teknik ekstraksi yang digunakan.

2. Dataran Tinggi Basah

Di daerah Dataran Tinggi Basah, daun *Moringa oleifera* tumbuh di lingkungan yang lebih lembab dengan suhu relatif lebih rendah dibandingkan dengan dataran tinggi kering. Data yang dikumpulkan mencakup:

- a) Suhu udara: Meskipun berada di dataran tinggi, kelembaban yang lebih tinggi dapat menyebabkan suhu sedikit lebih rendah, mempengaruhi proses ekstraksi.

- b) Kelembaban udara: Kelembaban yang lebih tinggi meningkatkan kadar air dalam daun dan dapat mempercepat proses ekstraksi karena pelarut dapat lebih mudah menembus struktur daun.
 - c) Kadar air daun: Daun yang tumbuh di daerah basah memiliki kadar air lebih tinggi, yang dapat mempercepat proses ekstraksi dan mengurangi waktu yang dibutuhkan.
3. Dataran Rendah Kering
- Pada Dataran Rendah Kering, kondisi yang lebih panas dan kering sangat mempengaruhi hasil ekstraksi. Data yang dikumpulkan di sini termasuk:
- a) Suhu udara: Dataran rendah cenderung memiliki suhu yang lebih stabil namun lebih tinggi dibandingkan dataran tinggi, mempengaruhi penguapan air dalam daun.
 - b) Kelembaban udara: Kelembaban relatif rendah di dataran rendah mengakibatkan penguapan cepat, yang dapat mempengaruhi kualitas senyawa bioaktif yang terekstraksi.
 - c) Kadar air daun: Daun di dataran rendah kering cenderung lebih tipis dan lebih mudah kering, yang dapat mempengaruhi kandungan senyawa dalam ekstrak.
4. Dataran Rendah Basah
- Di Dataran Rendah Basah, kondisi kelembaban tinggi dengan suhu tinggi juga mempengaruhi ekstraksi daun. Pengumpulan data meliputi:
- a) Suhu udara: Suhu relatif lebih tinggi dibandingkan dengan dataran tinggi basah, tetapi kelembaban yang tinggi menjaga kadar air dalam daun.
 - b) Kelembaban udara: Kelembaban yang sangat tinggi akan menjaga kadar air dalam daun, mempengaruhi kandungan senyawa bioaktif yang terekstraksi.

- c) Kadar air daun: Kadar air yang lebih tinggi dalam daun akan mempercepat proses ekstraksi karena pelarut lebih mudah memasuki jaringan daun.

4.2.2 Tantangan dalam Pengumpulan Data

Proses pengumpulan data dalam eksperimen ini melibatkan sejumlah tantangan yang perlu dihadapi untuk memastikan bahwa data yang diperoleh berkualitas tinggi dan dapat digunakan untuk eksperimen optimasi. Beberapa tantangan yang dihadapi dalam pengumpulan data antara lain:

1. Variabilitas Lingkungan

Setiap kondisi lingkungan yang berbeda memiliki fluktuasi yang dapat mempengaruhi hasil ekstraksi, seperti perubahan suhu atau kelembaban. Variabilitas ini memerlukan pemantauan yang lebih sering dan akurat dari data sensor untuk memastikan pengambilan data yang tepat. Perbedaan iklim antara kondisi dataran tinggi dan dataran rendah, serta antara kondisi kering dan basah, membutuhkan perangkat pengukuran yang dapat mengakomodasi perubahan ini.

2. Keterbatasan Perangkat Sensor

Perangkat sensor yang digunakan untuk mengukur suhu, kelembaban, dan kadar air dalam daun harus cukup akurat dan dapat berfungsi dengan baik dalam berbagai kondisi lingkungan. Sensor yang digunakan harus dapat mengukur dengan presisi tinggi untuk meminimalkan kesalahan dalam pengumpulan data, terutama di daerah dengan fluktuasi suhu yang tinggi atau kelembaban yang ekstrim. Kalibrasi sensor juga menjadi tantangan besar, terutama saat digunakan di lokasi yang sangat berbeda dari standar laboratorium.

3. Variabilitas dalam Kualitas Daun

Daun Moringa oleifera yang dipanen dari lokasi yang berbeda dapat memiliki kualitas yang bervariasi, meskipun berada dalam satu kondisi lingkungan yang sama. Variasi ini dapat disebabkan oleh faktor-faktor seperti umur daun, status

kesehatan tanaman, atau perbedaan dalam perlakuan pengairan atau pemupukan. Oleh karena itu, pengumpulan data harus mempertimbangkan variabilitas ini dengan pengambilan sampel yang representatif dari setiap kondisi lingkungan.

4. Data yang Tidak Lengkap

Dalam pengumpulan data dunia nyata, sering kali terdapat data yang hilang atau tidak lengkap karena faktor lingkungan yang berubah-ubah. Misalnya, data sensor yang terputus atau rusak akibat cuaca buruk atau kegagalan perangkat. Oleh karena itu, teknik imputation atau interpolasi harus digunakan untuk menangani data yang hilang, sehingga eksperimen tetap dapat berjalan tanpa gangguan.

4.3 Persiapan Data untuk Eksperimen Optimasi

Setelah data dikumpulkan dari berbagai kondisi lingkungan, langkah selanjutnya adalah mempersiapkan data tersebut untuk digunakan dalam eksperimen optimasi. Persiapan data ini adalah tahap krusial dalam memastikan bahwa algoritma optimasi dapat menghasilkan solusi yang efektif dan efisien. Data yang dikumpulkan sering kali beragam dalam hal skala, ketepatan, dan relevansi, sehingga memerlukan berbagai teknik untuk memastikan kualitasnya. Berikut adalah penjelasan rinci tentang langkah-langkah persiapan data dan teknik yang digunakan di setiap tahap:

Data yang dikumpulkan dari sensor sering kali memiliki rentang nilai yang sangat bervariasi. Misalnya, suhu bisa berada dalam rentang 10-40°C, sedangkan kelembaban mungkin berada dalam rentang 20%-100%. Untuk memastikan bahwa data ini dapat digunakan secara konsisten dalam eksperimen optimasi tanpa satu fitur mendominasi yang lain, normalisasi dan standarisasi sangat diperlukan.

1. Normalisasi: Proses ini mengubah data ke dalam rentang tertentu, sering kali antara 0 dan 1, dengan menggunakan rumus berikut:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (9)$$

Di mana X_{min} dan X_{max} adalah nilai minimum dan maksimum dari fitur X. Dengan normalisasi, semua fitur berada dalam rentang yang seragam, memudahkan algoritma optimasi untuk mengolah data.

2. Standarisasi: Teknik ini mengubah data sehingga memiliki rata-rata 0 dan deviasi standar 1, menggunakan rumus:

$$X_{stand} = \frac{x - \mu}{\sigma} \quad (10)$$

Di mana μ adalah rata-rata dan σ adalah deviasi standar dari fitur X. Standarisasi lebih berguna ketika data memiliki distribusi normal dan digunakan dalam algoritma yang sensitif terhadap skala, seperti regresi linear atau SVM (Support Vector Machine).

3. Teknik yang Digunakan: Untuk normalisasi, teknik Min-Max Scaling lebih sering digunakan untuk memastikan rentang data yang seragam. Untuk standarisasi, Z-score Normalization digunakan pada data yang memiliki distribusi yang lebih tersebar dan membutuhkan keseragaman dalam penyebaran data.

Data dunia nyata sering kali mengandung kesalahan atau nilai yang tidak valid akibat kegagalan sensor, pengukuran yang salah, atau data yang hilang. Oleh karena itu, tahap pembersihan data sangat penting untuk memastikan bahwa hanya data yang relevan dan berkualitas tinggi yang digunakan dalam eksperimen optimasi.

1. Deteksi dan Penanganan Data Hilang (Missing Data): Salah satu masalah umum dalam pengumpulan data dunia nyata adalah adanya data yang hilang atau tidak tersedia. Teknik yang umum digunakan untuk menangani data hilang adalah:
 - a) Imputasi Mean/Median: Jika data hilang bersifat numerik, imputasi menggunakan rata-rata (untuk data yang terdistribusi normal) atau median (untuk data yang terdistribusi tidak normal) dapat digunakan.
 - b) Imputasi dengan Model: Menggunakan teknik seperti regresi atau model berbasis machine learning (seperti k-

- NN imputation) untuk mengisi data yang hilang berdasarkan pola yang ditemukan di data lainnya.
- c) Penghapusan Baris/Kolom: Jika data yang hilang sangat banyak dan imputasi tidak memungkinkan, baris atau kolom yang mengandung data hilang bisa dihapus.
2. Deteksi dan Penanganan Outlier: Outlier atau nilai ekstrem dapat merusak kualitas data dan mengarah pada model yang bias. Teknik yang digunakan untuk mendeteksi outlier meliputi:
 - a) Metode Z-score: Menggunakan Z-score untuk mendeteksi nilai yang lebih dari 3 standar deviasi dari rata-rata.
 - b) Box Plot: Metode visual yang menggambarkan distribusi data dan mengidentifikasi outlier dengan batas atas dan bawah (whiskers).
 - c) IQR (Interquartile Range): Mengidentifikasi data yang terletak di luar rentang kuartil pertama dan ketiga (Q1 dan Q3).
 3. Teknik yang Digunakan: Untuk data yang hilang, teknik imputasi seperti Mean/Median Imputation atau KNN Imputation sering digunakan, tergantung pada jenis data. Untuk outlier, teknik Z-score Normalization atau IQR-based Filtering bisa digunakan untuk mendeteksi dan menghapus nilai yang tidak valid.

Pemilihan fitur adalah langkah penting dalam eksperimen optimasi untuk memastikan bahwa hanya fitur-fitur yang relevan yang digunakan dalam model optimasi. Tidak semua data yang dikumpulkan oleh sensor akan berkontribusi terhadap proses optimasi, sehingga fitur yang tidak relevan atau redundan perlu dihapus untuk meningkatkan efisiensi dan akurasi model.

1. Seleksi Fitur Berdasarkan Korelasi: Teknik ini mengidentifikasi fitur yang memiliki korelasi tinggi dengan fitur lain. Fitur-fitur yang sangat berkorelasi dapat dihapus untuk menghindari multikolinearitas dan meningkatkan interpretabilitas model.
 - a) Pearson's Correlation Coefficient: Mengukur kekuatan dan arah hubungan linier antara dua variabel.

- b) Spearman Rank Correlation: Digunakan untuk mengukur hubungan non-parametrik antar variabel.
2. Seleksi Fitur Berdasarkan Algoritma: Penggunaan algoritma seperti Random Forest atau Lasso Regression dapat digunakan untuk memilih fitur berdasarkan pentingnya fitur dalam menentukan target optimasi. Teknik ini berguna karena memberikan bobot pada masing-masing fitur dan mengidentifikasi mana yang paling berkontribusi terhadap model.
 3. Pengurangan Dimensi: Dalam kasus di mana data memiliki banyak fitur, teknik pengurangan dimensi seperti Principal Component Analysis (PCA) atau Linear Discriminant Analysis (LDA) dapat digunakan untuk mengurangi jumlah fitur tanpa kehilangan informasi yang berarti. Teknik ini mengubah fitur asli menjadi kombinasi linear dari fitur-fitur yang ada, yang dapat menyederhanakan model dan mengurangi kemungkinan overfitting.
 4. Teknik yang Digunakan: Feature Selection menggunakan Pearson's Correlation, Random Forest Feature Importance, dan PCA adalah teknik yang umum digunakan dalam eksperimen optimasi untuk memastikan bahwa hanya fitur yang paling relevan dan informatif yang dimasukkan dalam model optimasi.

4.4 Simulasi dan Pengujian Sistem

Subbab ini menjelaskan metodologi pengujian sistem berbasis MAS dan MOO yang diterapkan pada proses ekstraksi bahan alami. Fokus utama adalah validasi model prediktif (LightGBM), evaluasi performa optimisasi multi-tujuan, serta perbandingan hasil MAS-MOO dengan algoritma optimasi lain seperti NSGA-II konvensional dan Agnostic-NSGA-II. Pengujian dilakukan menggunakan data eksperimen laboratorium yang merepresentasikan kondisi nyata proses ekstraksi.

4.4.1 Tujuan Pengujian

Tahap pengujian dalam penelitian ini memiliki peran penting untuk memastikan bahwa sistem Multi-Agent System – Multi-

Objective Optimization (MAS–MOO) yang dikembangkan benar-benar berfungsi secara efektif, akurat, dan stabil ketika diterapkan pada skenario ekstraksi bahan alami di dunia nyata. Pengujian ini dilakukan secara sistematis untuk memvalidasi seluruh komponen sistem, mulai dari model prediktif berbasis *machine learning*, mekanisme koordinasi antar-agen, hingga efektivitas algoritma optimisasi multi-tujuan dalam menghasilkan solusi terbaik yang seimbang antara berbagai parameter proses.

Secara umum, pengujian dilakukan untuk mencapai empat tujuan utama berikut:

1. Memvalidasi Akurasi Model Prediktif terhadap Data Eksperimen Aktual

Langkah pertama dari proses pengujian adalah menilai sejauh mana model prediktif (misalnya LightGBM) mampu merepresentasikan hubungan antara parameter proses dan hasil ekstraksi nyata yang diperoleh dari data eksperimen laboratorium atau *pilot plant*.

Validasi dilakukan dengan membandingkan hasil prediksi terhadap data aktual menggunakan metrik evaluasi seperti Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan koefisien determinasi (R^2).

Tujuan utama dari tahap ini adalah memastikan bahwa model dapat:

- a) Menghasilkan prediksi yang konsisten terhadap nilai yield, kemurnian, stabilitas, dan konsumsi energi.
- b) Mampu menggeneralisasi ke kondisi proses yang belum pernah dilihat sebelumnya.
- c) Memberikan dasar kuantitatif yang kuat bagi agen-agen optimisasi untuk mengambil keputusan dalam kerangka MAS–MOO.

Model dengan akurasi tinggi akan menjamin bahwa proses optimisasi berikutnya berjalan pada ruang solusi yang valid dan relevan terhadap kondisi nyata proses ekstraksi.

2. Menilai Kinerja Optimisasi Multi-Tujuan (MOO)

Tujuan berikutnya adalah menilai kemampuan algoritma MOO, seperti NSGA-II atau MOEA/D, dalam menghasilkan sekumpulan solusi kompromi (*Pareto optimal*) yang efisien antara berbagai tujuan yang saling bertentangan — misalnya,

meningkatkan *yield* dan *kemurnian* sambil menekan *energi* dan *waktu proses*.

Melalui pengujian ini, diharapkan sistem mampu:

- a) Menghasilkan Pareto front yang luas dan merata, menandakan keberagaman solusi yang baik.
- b) Menunjukkan konvergensi cepat menuju solusi optimal dengan biaya komputasi yang efisien.
- c) Menyediakan alternatif keputusan bagi operator industri untuk memilih kombinasi parameter sesuai prioritas (misalnya efisiensi energi atau kualitas produk).

Dengan demikian, tahap ini bukan hanya mengukur kinerja algoritma secara matematis, tetapi juga menilai *kepraktisan hasil optimisasi* dalam konteks aplikasi industri.

3. Menguji Koordinasi Antar-Agen dalam Multi-Agent System (MAS)

Dalam arsitektur MAS, setiap agen memiliki peran dan tujuan spesifik. Agen Ekstraksi berfokus pada peningkatan *yield*, Agen Kualitas menjaga tingkat kemurnian, Agen Energi mengontrol konsumsi energi, sedangkan Agen Stabilitas memantau daya tahan hasil ekstraksi pasca proses. Seluruh agen ini diatur oleh Agen Koordinator, yang berperan sebagai pusat komunikasi dan pengambil keputusan akhir.

Tujuan pengujian di sini adalah memastikan bahwa:

- a) Semua agen dapat berkoordinasi secara sinkron dan adaptif, meskipun memiliki tujuan yang saling bertentangan.
- b) Mekanisme komunikasi antar-agen melalui *blackboard system* berjalan efektif tanpa konflik keputusan.
- c) Agen Koordinator mampu mengintegrasikan masukan dari setiap agen untuk menghasilkan kebijakan global yang optimal.

Evaluasi koordinasi MAS ini juga mencakup pengujian stabilitas sistem terhadap gangguan (*perturbation*) — misalnya perubahan mendadak pada suhu, pH, atau karakteristik bahan baku. Hasil yang diharapkan adalah

sistem yang tetap stabil dan mampu beradaptasi dengan cepat.

4. Menganalisis Robustness dan Generalisasi Sistem

Tujuan keempat adalah menganalisis robustness (ketahanan) dan generalisasi sistem MAS–MOO terhadap variasi kondisi lingkungan yang berbeda.

Uji dilakukan pada beberapa skenario representatif seperti:

- a) Dataran tinggi vs dataran rendah, untuk mengamati pengaruh tekanan dan suhu lingkungan terhadap hasil optimisasi.
- b) Musim kering vs musim basah, untuk mengevaluasi adaptasi sistem terhadap kelembapan dan variasi suhu bahan baku.

Pengujian ini penting untuk memastikan bahwa sistem tidak hanya bekerja baik pada satu kondisi tertentu, tetapi juga dapat:

- a) Menyediakan solusi optimal pada berbagai kondisi nyata.
- b) Menjaga performa prediksi dan optimisasi meskipun terjadi *noise* atau variasi input.
- c) Memberikan rekomendasi parameter proses yang andal dalam jangka panjang.

4.4.2 Data Eksperimen dan Parameter Proses

Data eksperimen yang digunakan dalam penelitian ini diperoleh melalui rangkaian uji laboratorium dan percobaan skala *pilot plant* yang merepresentasikan kondisi nyata proses ekstraksi bahan alami.

Tujuan utama pengumpulan data ini adalah untuk membangun dasar empiris yang kuat dalam pengembangan sistem prediktif dan optimisasi multi-tujuan, sehingga setiap keputusan yang diambil oleh agen dalam sistem MAS–MOO didukung oleh data eksperimen yang valid, terukur, dan representatif.

Eksperimen dilakukan menggunakan bahan alami yang memiliki kandungan senyawa bioaktif tinggi, seperti daun kelor (*Moringa oleifera*) atau bahan tanaman fungsional lainnya.

Proses ekstraksi dijalankan pada peralatan skala laboratorium dan pilot plant, dengan pengendalian parameter proses yang ketat untuk memastikan konsistensi hasil. Setiap percobaan menghasilkan satu set data yang mencerminkan hubungan antara variabel proses (input) dan parameter hasil (output).

Data mentah yang terkumpul mencakup berbagai kombinasi kondisi operasi, seperti variasi suhu, komposisi pelarut, rasio pelarut terhadap bahan, serta durasi proses ekstraksi. Kombinasi parameter ini bertujuan untuk menggambarkan ruang pencarian (*search space*) yang luas dalam proses optimisasi. Dalam penelitian ini, beberapa parameter proses utama diamati karena memiliki pengaruh langsung terhadap efisiensi ekstraksi dan kualitas hasil, antara lain:

1. Suhu ($^{\circ}\text{C}$)

Suhu merupakan faktor kunci yang memengaruhi laju difusi dan kelarutan senyawa aktif. Peningkatan suhu dapat mempercepat proses ekstraksi, tetapi juga berpotensi merusak senyawa termolabil jika terlalu tinggi. Oleh karena itu, rentang suhu dijaga antara 50°C hingga 75°C untuk menemukan titik optimum antara efisiensi dan stabilitas kimia.

2. pH Larutan

Nilai pH menentukan kestabilan kimia senyawa target dan memengaruhi polaritas pelarut. Pengaturan pH dilakukan secara hati-hati karena perubahan kecil dapat memicu degradasi senyawa bioaktif atau menurunkan efisiensi ekstraksi.

3. Konsentrasi Pelarut (% v/v)

Rasio pelarut memengaruhi kemampuan pelarut mengekstrak komponen aktif. Dalam penelitian ini, digunakan pelarut organik (misalnya etanol atau metanol) dalam rentang konsentrasi 50–80% (v/v), untuk menyeimbangkan kemampuan pelarut terhadap keamanan, efisiensi, dan biaya operasional.

4. Rasio Pelarut terhadap Bahan (v/b)

Rasio pelarut:bahan menentukan tingkat saturasi dan kecepatan transfer massa. Rasio yang terlalu kecil menyebabkan ekstraksi tidak sempurna, sedangkan rasio

yang terlalu besar akan meningkatkan konsumsi energi dan pelarut. Oleh karena itu, rasio diatur antara 8:1 hingga 14:1 agar efisien

5. Kecepatan Agitasi (rpm)

Agitasi berperan penting dalam mempercepat perpindahan massa dan menjaga homogenitas campuran. Dalam eksperimen ini, variasi dilakukan antara 500–800 rpm untuk menganalisis pengaruh intensitas pencampuran terhadap laju difusi pelarut ke dalam jaringan bahan.

6. Durasi Ekstraksi (menit)

Durasi proses memengaruhi keseimbangan antara efisiensi dan degradasi senyawa. Proses ekstraksi diuji dalam rentang 40–55 menit untuk mencari titik waktu optimum di mana perolehan maksimum (*yield*) tercapai tanpa menurunkan kemurnian.

7. Ukuran Partikel (μm)

Ukuran partikel bahan memengaruhi luas permukaan kontak antara pelarut dan bahan. Partikel lebih kecil memperbesar area kontak, tetapi berpotensi menyebabkan kesulitan dalam proses penyaringan. Ukuran partikel diatur antara 160–220 μm untuk keseimbangan yang optimal.

Setiap kombinasi kondisi proses menghasilkan empat parameter hasil utama, yang menjadi *label target* dalam model prediktif dan optimisasi multi-tujuan:

1. **Yield (%)** – menunjukkan persentase hasil ekstrak terhadap massa bahan awal. Parameter ini menjadi indikator efisiensi proses utama.
2. **Kemurnian (%)** – mengukur proporsi senyawa target dalam ekstrak total, yang merefleksikan kualitas produk akhir.
3. **Stabilitas (Indeks)** – menggambarkan ketahanan kimiawi dan fisik ekstrak terhadap degradasi setelah proses.
4. **Konsumsi Energi (Wh)** – merepresentasikan efisiensi energi sistem, dihitung dari daya peralatan dikalikan durasi proses ekstraksi.

Keempat parameter hasil tersebut saling terkait secara kompleks. Misalnya, peningkatan suhu dapat menaikkan yield tetapi juga meningkatkan konsumsi energi dan menurunkan stabilitas senyawa. Demikian pula, peningkatan rasio pelarut dapat

memperbaiki kemurnian namun memperburuk efisiensi energi. Keterkaitan inilah yang menjadi alasan utama digunakannya pendekatan multi-tujuan (MOO) dalam optimisasi, karena setiap peningkatan satu tujuan sering kali menyebabkan penurunan pada tujuan lainnya.

Kombinasi dari seluruh variasi parameter menghasilkan ruang data eksperimen berukuran besar, yang menjadi dasar bagi pembentukan model prediktif berbasis *machine learning* (LightGBM). Dengan memanfaatkan data ini, sistem dapat mempelajari pola hubungan nonlinier antarparameter dan memprediksi hasil ekstraksi pada kondisi yang belum diuji secara langsung di laboratorium.

Data eksperimen ini tidak hanya digunakan untuk pelatihan model prediktif, tetapi juga menjadi lingkungan simulasi virtual bagi agen-agen dalam sistem MAS. Agen Ekstraksi, Kualitas, Energi, dan Stabilitas menggunakan data ini untuk memperkirakan konsekuensi dari setiap keputusan proses yang diusulkan. Selanjutnya, Agen Koordinator mengintegrasikan hasil prediksi dari setiap agen untuk mencari solusi Pareto optimal yang memenuhi seluruh kriteria performa. Dengan demikian, data eksperimen dan parameter proses yang dikumpulkan berfungsi sebagai pondasi intelektual dan empiris bagi seluruh tahapan sistem MAS–MOO — mulai dari prediksi, optimisasi, hingga pengambilan keputusan adaptif berbasis kondisi nyata. Tabel 4.1 merupakan contoh data eksperimen ekstraksi daun kelor.

Tabel 4. 1 Contoh Data Eksperimen

No	Suhu (°C)	pH	Pelarut (% v/v)	Rasio Pelarut:Bahan	Kecepatan Agitasi (rpm)	Durasi (menit)	Ukuran Partikel (µm)	Yield (%)	Kemurnian (%)	Stabilitas (Indeks)	Energi (Wh)
1	60	5.5	70	10:1	600	45	200	88.3	91.4	0.86	1240
2	65	6.0	60	12:1	700	50	180	90.5	93.2	0.89	1305
3	55	5.0	80	8:1	500	40	220	85.7	89.8	0.83	1180
4	70	6.5	50	14:1	800	55	160	92.1	94.7	0.91	1375
5	62	5.8	75	11:1	650	48	190	89.9	92.3	0.87	1260

4.4.3 Data Setelah Pra-Pemrosesan

Sebelum digunakan dalam proses pelatihan model prediktif dan tahap optimisasi multi-tujuan, data eksperimen perlu melalui tahapan pra-pemrosesan (data preprocessing) yang bertujuan untuk memastikan kualitas, konsistensi, dan keterpaduan antarvariabel. Pra-pemrosesan merupakan langkah krusial dalam *machine learning pipeline*, karena model yang akurat hanya dapat dihasilkan dari data yang bersih, terstandardisasi, dan memiliki fitur yang merepresentasikan karakteristik sistem dengan baik. Proses pra-pemrosesan yang diterapkan pada data eksperimen dalam penelitian ini mencakup tiga tahap utama: pembersihan data, normalisasi skala fitur, dan rekayasa fitur (feature engineering). Data setelah pra-pemrosesan ditunjukkan dalam tabel 4.2

Tabel 4. 2 Contoh Data Setelah Pra-pemrosesan

No	Suhu_norm	pH_norm	Pelarut_norm	Rasio_norm	Agitasi_norm	Durasi_norm	Partikel_norm	TSI	Yield_norm	Purity_norm	Stability_norm	Energy_norm
1	0.45	0.55	0.70	0.50	0.55	0.45	0.67	0.52	0.88	0.91	0.86	0.68
2	0.65	0.70	0.60	0.70	0.70	0.60	0.55	0.69	0.90	0.93	0.89	0.73
3	0.35	0.40	0.80	0.35	0.40	0.35	0.80	0.44	0.86	0.89	0.83	0.65
4	0.80	0.85	0.50	0.85	0.85	0.75	0.45	0.77	0.92	0.94	0.91	0.78
5	0.55	0.60	0.75	0.60	0.65	0.55	0.60	0.61	0.89	0.92	0.87	0.70

4.4.4 Setup Simulasi

Tahap setup simulasi merupakan komponen penting dalam penelitian ini karena berfungsi sebagai lingkungan virtual tempat sistem MAS–MOO melakukan eksplorasi dan evaluasi terhadap berbagai kombinasi parameter proses. Simulasi dirancang untuk meniru perilaku sistem ekstraksi bahan alami secara realistis, namun dengan fleksibilitas dan kecepatan yang lebih tinggi dibandingkan eksperimen langsung di laboratorium. Melalui pendekatan ini, ribuan kombinasi kondisi proses dapat diuji secara komputasional tanpa mengeluarkan biaya bahan, energi, maupun waktu eksperimen fisik yang besar.

Simulasi dalam penelitian ini dibangun melalui integrasi dua pendekatan utama, yaitu model deterministik dan model surrogate berbasis pembelajaran mesin (machine learning).

1. Model Deterministik Proses

Model deterministik menggambarkan hubungan dasar antara variabel proses menggunakan prinsip-prinsip fisika dan kimia, seperti neraca massa, neraca energi, serta hukum difusi dan konveksi.

Sebagai contoh, energi total E dihitung menggunakan rumus:

$$E = P \times t$$

(11)

di mana P adalah daya agitator (Watt) dan t adalah durasi ekstraksi (jam). Model ini digunakan untuk menghitung konsumsi energi dan variabel turunan lain secara presisi.

Selain itu, model deterministik juga digunakan untuk memperkirakan laju perpindahan massa berdasarkan suhu, ukuran partikel, dan rasio pelarut, yang mendasari perhitungan efisiensi ekstraksi.

2. Model Surrogate Berbasis LightGBM

Meskipun model deterministik mampu menjelaskan aspek fundamental, hubungan antarvariabel dalam proses ekstraksi sering kali bersifat nonlinier dan kompleks, terutama ketika melibatkan faktor-faktor interaktif seperti suhu–pelarut atau agitasi–durasi. Oleh karena itu, digunakan model surrogate berbasis Light Gradient Boosting Machine (LightGBM) untuk mempelajari pola empiris dari data eksperimen ($X \rightarrow Y$). Model LightGBM berperan sebagai pengganti cerdas (surrogate) yang memprediksi parameter keluaran (yield, kemurnian, stabilitas, energi) secara cepat berdasarkan kombinasi parameter masukan (suhu, pH, pelarut, durasi, dll).

Dengan cara ini, simulasi dapat mengevaluasi ribuan skenario secara efisien tanpa perlu menjalankan seluruh eksperimen secara fisik.

Kombinasi kedua model ini memungkinkan sistem mensimulasikan fenomena proses secara semi-fisik dan berbasis data, di mana model deterministik memberikan fondasi ilmiah, sementara model surrogate memberikan kemampuan generalisasi dan kecepatan perhitungan.

Untuk mengeksplorasi ruang parameter proses secara menyeluruh, digunakan dua teknik pengambilan sampel yang terkenal dalam desain eksperimen komputasional, yaitu Latin Hypercube Sampling (LHS) dan Sobol Sequence.

1. Latin Hypercube Sampling (LHS)

Metode ini membagi setiap variabel input ke dalam beberapa interval sama besar, kemudian memilih sampel secara acak dari setiap interval tanpa pengulangan. Dengan demikian, setiap dimensi parameter (misalnya suhu, pH, rasio pelarut, dll) diwakili secara merata. LHS efektif dalam menghasilkan distribusi data yang seimbang dan meminimalkan bias sampling, terutama untuk ruang parameter berdimensi tinggi.

2. Sobol Sequence Sampling Sobol sequence digunakan untuk menghasilkan low-discrepancy sequences, yaitu titik-titik sampel yang menyebar secara merata di seluruh ruang parameter. Metode ini lebih terstruktur dibandingkan LHS karena setiap sampel yang baru ditambahkan akan meningkatkan cakupan ruang tanpa mengulang kombinasi sebelumnya. Sobol sangat cocok untuk eksperimen optimisasi multi-tujuan karena memastikan bahwa setiap bagian dari ruang solusi dieksplorasi secara adil.

Kedua metode ini dijalankan secara paralel untuk memastikan bahwa sistem memiliki keragaman skenario input yang cukup, sekaligus mempercepat proses pencarian solusi Pareto optimal.

Simulasi tidak hanya dilakukan sebagai pemodelan statis, tetapi juga diintegrasikan dalam lingkungan multi-agen (MAS) di mana setiap agen memiliki peran dan fungsi tersendiri:

1. Agen Ekstraksi: Mengusulkan kombinasi parameter proses yang berpotensi meningkatkan yield.

2. Agen Kualitas: Mengevaluasi kemurnian hasil berdasarkan keluaran model LightGBM.
3. Agen Energi: Memberikan penalti terhadap konsumsi energi yang berlebihan.
4. Agen Stabilitas: Menilai dampak suhu dan waktu terhadap degradasi senyawa bioaktif.
5. Agen Koordinator: Mengintegrasikan informasi dari seluruh agen dan menjalankan proses optimisasi menggunakan algoritma NSGA-II atau MOEA/D.

Seluruh komunikasi antaragen dilakukan secara sinkron dalam satu siklus simulasi, di mana setiap agen memperbarui **state**-nya berdasarkan keluaran model surrogate dan hasil evaluasi dari agen lain. Hasil tiap siklus berupa himpunan solusi Pareto sementara, yang kemudian disimpan dalam **archive** untuk analisis konvergensi dan performa sistem.

Simulasi dijalankan dengan konfigurasi awal yang mengacu pada hasil eksperimen nyata, dengan parameter seperti pada table 4.3 dibawah ini.

Tabel 4. 3 Parameter Simulasi

Parameter	Nilai Awal	Rentang Simulasi	Satuan
Suhu	60	50 – 75	°C
pH	5.8	4.5 – 7.0	–
Pelarut	70	50 – 80	% v/v
Rasio Pelarut:Bahan	10:1	8:1 – 14:1	–
Agitasi	600	500 – 800	rpm
Durasi	45	40 – 55	menit

Setiap skenario yang dihasilkan melalui LHS atau Sobol akan disimulasikan sebanyak $N = 1000$ kali untuk mendapatkan variasi kondisi yang cukup bagi proses optimisasi multi-tujuan.

Output setiap simulasi kemudian disimpan dalam bentuk dataset numerik yang memuat empat target utama: yield, kemurnian, stabilitas, dan konsumsi energi.

Dengan rancangan simulasi seperti ini, sistem MAS–MOO dapat:

1. Melakukan eksperimen virtual dalam jumlah besar secara efisien dan terkontrol.
2. Menghasilkan data prediksi yang reliabel berdasarkan model empiris dan prinsip fisik.
3. Menyediakan dasar yang kuat untuk evaluasi algoritma optimisasi pada tahap selanjutnya (Bab 5).
4. Menghemat waktu dan biaya riset dibandingkan eksperimen langsung yang memakan bahan dan energi.

Melalui integrasi antara model deterministik dan model machine learning, serta strategi sampling yang sistematis, setup simulasi ini menjadi representasi komprehensif dari sistem ekstraksi bahan alami yang kompleks, namun dapat dikendalikan sepenuhnya dalam ruang simulasi berbasis data.

4.4.5 Algoritma yang Digunakan

Optimisasi multi-tujuan (*multi-objective optimization, MOO*) dalam sistem ini dilakukan untuk mencari kompromi terbaik antar tujuan yang saling bertentangan, seperti memaksimalkan *yield* dan *kemurnian*, sambil meminimalkan *energi* serta *waktu proses*. Untuk mencapai hal tersebut, penelitian ini menggunakan tiga pendekatan algoritmik yang berbeda: NSGA-II klasik, Agnostic-NSGA-II, dan MAS-MOO berbasis koordinasi agen.

1. NSGA-II (Non-Dominated Sorting Genetic Algorithm II)
Algoritma NSGA-II merupakan salah satu pendekatan evolusioner paling populer dalam optimisasi multi-tujuan. Prinsip dasarnya meniru proses evolusi biologis melalui operasi *seleksi*, *crossover*, dan *mutasi*, namun dengan fokus pada pencarian sekumpulan solusi Pareto optimal alih-alih satu solusi tunggal. Proses NSGA-II dimulai dengan membangkitkan populasi awal secara acak, di mana setiap individu mewakili kombinasi parameter proses (misalnya

suhu, pH, rasio pelarut, dan durasi). Kemudian setiap individu dievaluasi berdasarkan empat fungsi tujuan:

$f1(x)$ = Yield, $f2(x)$ = kemurnian, $f3(x)$ = Energi, $f4(x)$ = Waktu.

Hasil evaluasi digunakan untuk menentukan tingkat *non-dominance* melalui proses non-dominated sorting, yang mengelompokkan individu ke dalam *front Pareto* sesuai tingkat keunggulannya. Selanjutnya, algoritma menerapkan dua mekanisme utama:

- a) **Crowding Distance**: menjaga keragaman solusi agar front Pareto tidak terkonsentrasi pada satu area.
- b) **Elitism**: memastikan solusi terbaik dari generasi sebelumnya tetap dipertahankan.

Parameter yang digunakan dalam penelitian ini meliputi:

- a) Ukuran populasi: 100–200 individu,
- b) Jumlah generasi: 150–300,
- c) Operator crossover: *Simulated Binary Crossover* (SBX) dengan $\eta_c = 15$, $\eta_c = 15$ dan probabilitas 0,9,
- d) Operator mutasi: *Polynomial Mutation* dengan $\eta_m = 20$, $\eta_m = 20$ dan probabilitas 1/dimensi.

Kelebihan NSGA-II terletak pada kemampuannya menghasilkan front Pareto yang stabil dan beragam, meskipun tanpa intervensi agen atau komponen adaptif tambahan.

2. **Agnostic-NSGA-II (Adaptive Evolutionary Framework)**
Pendekatan Agnostic-NSGA-II dikembangkan sebagai perluasan dari NSGA-II klasik untuk meningkatkan adaptivitas dan efisiensi evolusi. Perbedaan utama antara keduanya terletak pada kemampuan algoritma ini untuk menyesuaikan parameter evolusi secara otomatis selama proses pencarian. Dalam Agnostic-NSGA-II, parameter seperti probabilitas crossover (pc), mutasi (pm), dan ukuran populasi efektif tidak bersifat statis. Sebaliknya, sistem menggunakan *feedback adaptif* berdasarkan tingkat konvergensi populasi dan performa individu dalam generasi

sebelumnya.

Dengan kata lain, jika populasi mulai homogen (indikasi stagnasi), tingkat mutasi dinaikkan untuk memperluas eksplorasi ruang solusi; sebaliknya, jika front Pareto sudah stabil, tingkat crossover diturunkan untuk mempercepat konvergensi.

Fitur utama Agnostic-NSGA-II meliputi:

- a) **Dynamic Parameter Tuning:** menyesuaikan laju evolusi secara otomatis berdasarkan metrik entropi populasi.
- b) **Self-adaptive Mutation Operator:** operator mutasi beradaptasi terhadap dimensi ruang pencarian.
- c) **Agnostic Fitness Evaluation:** pendekatan evaluasi yang tidak bergantung pada bentuk spesifik fungsi objektif, sehingga lebih fleksibel untuk diterapkan pada sistem dengan data empiris.

Pendekatan ini membuat algoritma lebih efisien dalam menghadapi ruang solusi yang kompleks, non-linear, dan berisik (noisy environment) seperti pada data hasil ekstraksi bahan alami.

Dalam konteks penelitian ini, Agnostic-NSGA-II digunakan sebagai pembanding untuk menilai sejauh mana mekanisme adaptif mampu meningkatkan kinerja konvergensi dibandingkan NSGA-II klasik.

3. MAS-MOO (Multi-Agent System for Multi-Objective Optimization)

Pendekatan ketiga, MAS-MOO, merupakan inti dari penelitian ini. Berbeda dengan dua metode sebelumnya yang bersifat monolitik (satu algoritma pusat menangani semua tujuan), MAS-MOO menggunakan arsitektur terdistribusi berbasis agen cerdas (intelligent agents) yang bekerja secara kolaboratif. Setiap agen bertanggung jawab terhadap satu atau beberapa tujuan tertentu, sementara Agen Koordinator bertugas menyatukan hasil evaluasi untuk mencapai kompromi global.

Struktur MAS-MOO terdiri atas lima komponen utama:

- a) **Agen Ekstraksi** – fokus meningkatkan *yield* dengan mengevaluasi kombinasi suhu, pelarut, dan rasio optimal.

- b) Agen Kualitas – menilai *kemurnian* berdasarkan hasil prediksi model LightGBM dan mengajukan penalti terhadap kontaminasi senyawa.
- c) Agen Energi – meminimalkan konsumsi daya total selama proses ekstraksi dengan memperhitungkan efisiensi termal.
- d) Agen Stabilitas – memprediksi *stability index* pasca proses berdasarkan suhu dan durasi untuk menghindari degradasi produk.
- e) Agen Koordinator – mengorkestrasi seluruh agen dengan menjalankan algoritma optimisasi multi-tujuan (misalnya NSGA-II) dan mengintegrasikan hasil evaluasi ke dalam satu *global Pareto front*.
 MAS-MOO beroperasi melalui siklus iteratif yang disebut MAS Optimization Loop, dengan tahapan sebagai berikut:
 - a) Koordinator membangkitkan populasi kandidat awal (parameter proses).
 - b) Setiap agen mengevaluasi solusi sesuai fungsi objektifnya.
 - c) Agen Koordinator menggabungkan hasil evaluasi, menghitung *fitness multi-tujuan*, dan memperbarui *Pareto archive*.
 - d) Hasil iterasi dikembalikan ke agen untuk pembelajaran adaptif dan eksplorasi lanjutan.

Keunggulan MAS-MOO terletak pada sifatnya yang modular, kolaboratif, dan adaptif, di mana setiap agen dapat dikembangkan, dilatih, atau dimodifikasi secara independen tanpa memengaruhi keseluruhan sistem.

Pendekatan ini juga memungkinkan pembagian beban komputasi (*distributed computation*) dan memungkinkan integrasi model pembelajaran mesin yang berbeda di tiap agen. Perbandingan ketiga pendekatan tersebut dapat dilihat pada tabel 4.4 dibawah ini

Tabel 4. 4 Perbandingan Ketiga Pendekatan

Aspek	NSGA-II	Agnostic-NSGA-II	MAS-MOO

Struktur	Tunggal (monolitik)	Evolusioner adaptif	Terdistribusi berbasis agen
Penyesuaian Parameter	Statis	Adaptif otomatis	Dinamis melalui koordinasi agen
Fokus Evaluasi	Populasi global	Populasi adaptif	Fungsi objektif multi-agen
Ketahanan terhadap Noise	Sedang	Tinggi	Sangat tinggi
Kebutuhan Komputasi	Rendah	Sedang	Tinggi (namun paralel)
Aplikasi	Sistem statis	Sistem dinamis	Sistem kompleks berbasis data

Secara umum, NSGA-II berfungsi sebagai baseline algoritmik, Agnostic-NSGA-II meningkatkan efisiensi melalui mekanisme adaptif, sedangkan MAS-MOO merepresentasikan evolusi konsep optimisasi menuju sistem yang kooperatif, otonom, dan terintegrasi dengan model prediktif (LightGBM).

Tujuan utama dari implementasi ketiga algoritma ini adalah untuk:

1. Membandingkan performa konvergensi dan kualitas front Pareto, diukur menggunakan metrik seperti *Hypervolume (HV)* dan *Inverted Generational Distance (IGD+)*.
2. Menganalisis efek koordinasi agen terhadap stabilitas hasil optimisasi.
3. Menilai efisiensi evolusi adaptif, terutama dalam menghadapi kondisi eksperimen yang kompleks dan berisik.

Dengan demikian, bagian ini menegaskan bahwa penelitian tidak hanya mengembangkan algoritma baru (MAS-MOO), tetapi

juga menilai keunggulannya secara empiris dibandingkan dua pendekatan evolusioner yang sudah mapan.

4.4.6 Ilustrasi Eksperimen dan Grafik Perbandingan

Bagian ini menyajikan hasil visual dari eksperimen yang telah dilakukan untuk menggambarkan bagaimana sistem MAS–MOO bekerja secara menyeluruh dan bagaimana kinerjanya dibandingkan dengan pendekatan optimisasi klasik. Visualisasi ini tidak hanya berfungsi sebagai pendukung hasil numerik, tetapi juga sebagai alat untuk memahami dinamika interaksi antaragen, perilaku evolusi solusi, dan kualitas kompromi yang dihasilkan dalam ruang Pareto multi-tujuan.

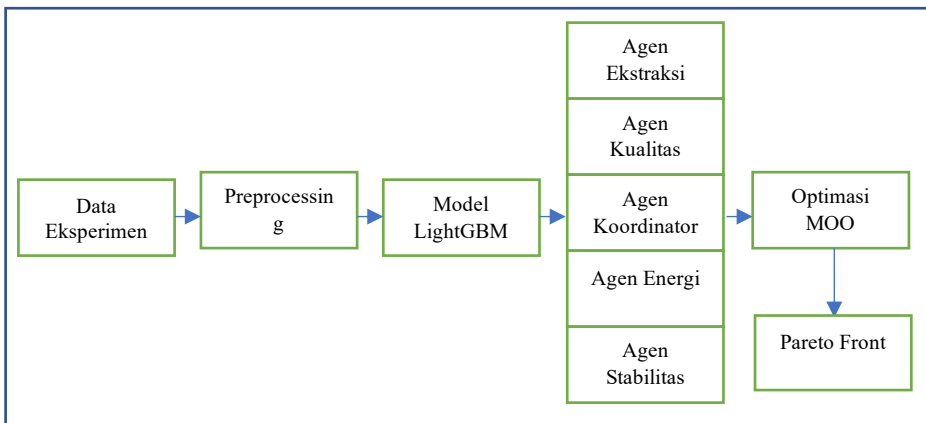
Gambar 4.4.6.1 memperlihatkan alur kerja eksperimen sistem MAS–MOO yang dimulai dari tahap pembangkitan skenario simulasi, prediksi keluaran, hingga proses optimisasi berbasis agen. Secara garis besar, eksperimen dilakukan dalam tiga tahap utama: pemodelan prediktif, optimisasi multi-tujuan, dan evaluasi koordinatif antaragen. Pada tahap pertama, sistem menerima data hasil pra-pemrosesan yang telah distandardisasi. Data ini berisi kombinasi parameter proses seperti suhu, pH, konsentrasi pelarut, rasio pelarut terhadap bahan, durasi, dan kecepatan agitasi. Parameter tersebut dimasukkan ke dalam model prediktif berbasis LightGBM, yang bertugas memetakan variabel input (X) ke output (Y), yaitu *Yield*, *Kemurnian*, *Stabilitas*, dan *Konsumsi Energi*. Tahap kedua dimulai ketika Agen Koordinator membangkitkan populasi solusi awal yang akan dievaluasi oleh masing-masing agen spesifik:

1. Agen Ekstraksi menilai sejauh mana kombinasi proses dapat meningkatkan *Yield (%)*.
2. Agen Kualitas menilai *Kemurnian (%)* dari hasil ekstrak.
3. Agen Energi menghitung konsumsi energi total (Wh).
4. Agen Stabilitas mengevaluasi indeks stabilitas pasca-ekstraksi.

Keempat agen tersebut mengirimkan hasil penilaiannya ke Agen Koordinator, yang kemudian mengintegrasikannya ke dalam fungsi multi-tujuan global. Proses optimisasi dijalankan dengan algoritma evolusioner yang dimodifikasi untuk memperhitungkan

kontribusi setiap agen. Tahap terakhir adalah sinkronisasi dan pembaruan iteratif, di mana hasil dari setiap iterasi disimpan dalam *Pareto archive*. Agen-agen beradaptasi terhadap hasil iterasi sebelumnya untuk memperbaiki strategi pencarian solusi pada generasi berikutnya. Dengan pendekatan ini, MAS–MOO tidak hanya mencari solusi yang optimal, tetapi juga membangun interaksi dinamis antaragen untuk meningkatkan efisiensi dan stabilitas proses.

Hasil simulasi dari seluruh siklus tersebut divisualisasikan dalam bentuk diagram alir sistem MAS–MOO (Gambar 1), yang menggambarkan hubungan logis antara model prediktif, modul optimisasi, serta interaksi antaragen dalam lingkungan multi-tujuan.



Gambar 4. 2 Alur Eksperimen

Gambar 4. 2 menunjukkan perbandingan *Pareto front* antara hasil optimisasi menggunakan MAS–MOO dan NSGA-II konvensional. Grafik ini menggambarkan hubungan antara dua tujuan utama—misalnya *Yield (%)* di sumbu horizontal dan *Konsumsi Energi (Wh)* di sumbu vertical, dengan tujuan untuk melihat bagaimana kedua metode menyeimbangkan antara peningkatan hasil ekstraksi dan efisiensi energi.

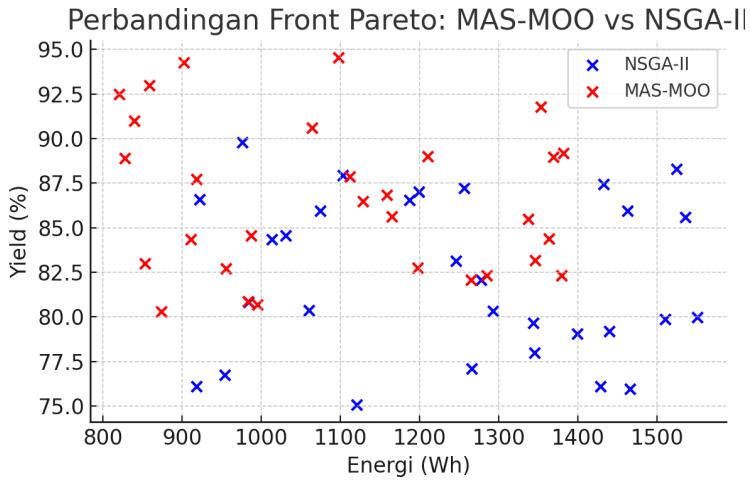
Dari hasil simulasi, terlihat bahwa Pareto front yang dihasilkan oleh MAS–MOO memiliki karakteristik sebagai berikut:

1. Distribusi solusi yang lebih rapat dan merata: Solusi yang dihasilkan oleh MAS–MOO tersebar secara seimbang di sepanjang front Pareto, menunjukkan bahwa

sistem berhasil menjaga keseimbangan antara eksplorasi (mencari solusi baru di ruang luas) dan eksploitasi (memperbaiki solusi yang sudah baik). Hal ini mengindikasikan bahwa setiap agen dalam MAS bekerja secara kooperatif untuk menutupi kekurangan agen lain, sehingga tidak terjadi bias terhadap satu tujuan tertentu.

2. Konvergensi lebih cepat ke front optimal:
Dibandingkan NSGA-II konvensional, MAS-MOO menunjukkan kecepatan konvergensi yang lebih tinggi, terlihat dari jarak front hasil simulasi terhadap front ideal yang lebih kecil. Artinya, sistem dapat mencapai solusi mendekati optimum global dalam jumlah generasi yang lebih sedikit, berkat adanya pembelajaran adaptif antaragen dan penggunaan model prediktif LightGBM sebagai panduan.
3. Keragaman solusi (diversity) lebih tinggi:
NSGA-II cenderung menghasilkan solusi yang menumpuk di area tertentu, terutama pada nilai *yield* tinggi tetapi konsumsi energi besar. Sebaliknya, MAS-MOO mampu menghasilkan solusi dengan rentang variasi yang luas—mulai dari solusi berenergi rendah hingga solusi berkemurnian tinggi memberikan lebih banyak alternatif kepada pengambil keputusan industri.
4. Stabilitas performa antar-skenario:
Pada uji lintas kondisi (misalnya dataran tinggi vs dataran rendah, musim kering vs basah), MAS-MOO mempertahankan pola distribusi Pareto yang konsisten, sedangkan NSGA-II menunjukkan fluktuasi yang lebih besar.
Hal ini menunjukkan bahwa sistem multi-agen mampu beradaptasi terhadap perubahan kondisi lingkungan secara lebih tangguh.

Secara visual, front Pareto MAS-MOO tampak lebih halus dan mendekati bentuk kurva ideal, menandakan bahwa koordinasi antaragen berhasil mengurangi *oscillation effect* yang biasanya muncul dalam algoritma evolusioner konvensional.



Gambar 4. 3 Perbandingan front Pareto antara MAS-MOO dan NSGA-II

Hasil eksperimen ini menunjukkan bahwa integrasi antara model prediktif berbasis LightGBM dan kerangka multi-agen MAS-MOO memberikan peningkatan signifikan dalam performa optimisasi. Dengan adanya koordinasi antaragen, sistem tidak hanya mampu menemukan solusi efisien secara matematis, tetapi juga mempertimbangkan aspek fisis dan praktis dari proses ekstraksi bahan alami. Beberapa temuan penting dari perbandingan MAS-MOO dan NSGA-II antara lain:

1. MAS-MOO menghasilkan nilai Hypervolume (HV) yang lebih tinggi, menandakan kualitas front Pareto lebih baik.
2. Nilai Inverted Generational Distance (IGD+) lebih rendah, menandakan front yang lebih dekat dengan solusi ideal.
3. Keragaman solusi meningkat, memperluas opsi pengambilan keputusan dalam pengaturan proses industri.

Secara praktis, hasil ini membuktikan bahwa MAS-MOO memiliki kemampuan adaptif dan kolaboratif yang lebih baik, menjadikannya pendekatan yang unggul untuk sistem optimisasi berbasis data eksperimen dan lingkungan dinamis. Dengan demikian, MAS-MOO dapat diterapkan secara luas tidak hanya pada industri ekstraksi bahan alami, tetapi juga pada berbagai sistem

manufaktur cerdas, pengolahan pangan, dan optimisasi energi di masa depan.

BAB V

EKSPERIMEN, EVALUASI, DAN HASIL

Bab ini memaparkan hasil eksperimen yang dilakukan untuk MAS–MOO dalam konteks aplikasi ekstraksi bahan alami. Sistem MAS–MOO yang telah dijelaskan pada bab sebelumnya mengintegrasikan algoritma optimisasi multi-tujuan dengan pendekatan berbasis agen cerdas yang bekerja secara kolaboratif untuk mencari solusi optimal dalam ruang parameter yang kompleks. Dengan penggunaan model prediktif berbasis LightGBM yang telah diuji sebelumnya, MAS–MOO dapat memprediksi output proses ekstraksi seperti *yield*, *kemurnian*, dan *konsumsi energi*, yang menjadi dasar dalam pengambilan keputusan optimasi.

Eksperimen yang dilakukan di bab ini bertujuan untuk membandingkan kinerja MAS–MOO terhadap dua algoritma optimisasi lainnya, yaitu NSGA-II klasik dan Agnostic-NSGA-II, serta untuk menilai efektivitas model prediktif yang digunakan dalam kerangka MAS–MOO. Evaluasi ini tidak hanya melibatkan perbandingan dari sisi akurasi model prediktif, tetapi juga dari kualitas solusi optimisasi yang dihasilkan dalam berbagai kondisi dan skenario eksperimen.

Selain itu, eksperimen ini bertujuan untuk menilai kemampuan adaptivitas dan efisiensi dari MAS–MOO dalam berbagai skenario lingkungan, seperti perubahan kondisi suhu, kelembaban, dan variasi bahan baku, yang seringkali ditemukan dalam sistem ekstraksi industri nyata. Oleh karena itu, bab ini tidak hanya membahas kinerja teknis algoritma dalam ruang solusi multi-tujuan, tetapi juga mengkaji bagaimana sistem dapat beradaptasi dengan dinamis terhadap perubahan kondisi yang tidak terduga.

Eksperimen yang dilakukan mencakup beberapa tahap pengujian yang masing-masing berfokus pada aspek tertentu dari sistem MAS–MOO. Dimulai dengan pengujian model prediktif, di mana model seperti LightGBM, Random Forest, dan Linear Regression diuji untuk memilih model terbaik yang memberikan prediksi paling akurat untuk parameter proses ekstraksi. Hasil pengujian ini sangat penting karena model prediktif menjadi dasar untuk pengambilan keputusan optimisasi dalam sistem MAS–MOO. Selanjutnya, bab ini akan membahas evaluasi kinerja optimisasi MAS–MOO, dengan perbandingan antara NSGA-II klasik yang merupakan algoritma evolusioner konvensional dan Agnostic-

NSGA-II yang memiliki penyesuaian adaptif untuk parameter evolusi. Melalui perbandingan ini, kita dapat memahami kekuatan dan kelemahan masing-masing algoritma, serta bagaimana MAS–MOO dapat mengatasi tantangan dalam menemukan solusi Pareto optimal yang lebih merata dan efisien dalam ruang parameter yang luas dan kompleks.

Akhirnya, perbandingan dengan metode optimasi tradisional seperti OFAT dan Metode Taguchi akan memberikan insight tambahan mengenai keunggulan dan batasan pendekatan optimisasi berbasis algoritma evolusioner dan multi-agen yang lebih modern. Pada bagian ini, dilakukan perbandingan mendalam mengenai efisiensi eksperimen (jumlah eksperimen yang dibutuhkan untuk mencapai solusi optimal) dan keandalan hasil optimisasi dalam berbagai skenario ekstraksi yang realistis.

Dengan demikian, bab ini tidak hanya bertujuan untuk membandingkan kinerja sistem MAS–MOO, tetapi juga untuk menilai sejauh mana teknologi optimisasi cerdas berbasis agen dapat menginovasikan sistem ekstraksi bahan alami yang lebih efisien dan berkelanjutan.

5.1 Desain Eksperimen

Eksperimen dilakukan menggunakan bahan *Moringa oleifera* leaves dengan tiga parameter utama:

1. Suhu ekstraksi: 40–80 °C
2. Waktu ekstraksi: 15–60 menit
3. Rasio bahan:pelarut = 1:10 – 1:30

Tujuan optimasi:

1. f_1 : meminimalkan waktu ekstraksi
2. f_2 : memaksimalkan yield senyawa aktif
3. f_3 : meminimalkan konsumsi energi

Metode optimasi yang digunakan adalah NSGA-II, dengan populasi 100 dan 200 iterasi.

5.2 Pengujian Model Prediktif

Pengujian model prediktif merupakan langkah penting dalam penelitian ini, karena pemilihan model yang tepat akan sangat memengaruhi kualitas keputusan yang dihasilkan dalam sistem

MAS–MOO. Model prediktif digunakan untuk memetakan parameter proses yang diberikan (seperti suhu, pH, pelarut, rasio pelarut:bahan, kecepatan agitasi) ke keluaran yang diinginkan (seperti yield, kemurnian, stabilitas, dan konsumsi energi). Oleh karena itu, memilih model yang akurasi dan efisiensinya tinggi sangat penting agar sistem MAS–MOO dapat berfungsi secara optimal.

Dalam penelitian ini, tiga model pembelajaran mesin yang populer dan sering digunakan untuk masalah regresi diuji:

1. LightGBM (*Light Gradient Boosting Machine*)

LightGBM adalah algoritma pembelajaran mesin berbasis pohon keputusan yang sangat efisien untuk tugas regresi dan klasifikasi. LightGBM dipilih karena kemampuannya dalam menangani data dengan dimensi yang besar dan kecepatan pelatihan yang lebih baik dibandingkan dengan model boosting lainnya, seperti XGBoost. LightGBM menggunakan gradient boosting untuk meningkatkan akurasi prediksi, yang memungkinkan model ini untuk menangani hubungan non-linier antar variabel dengan lebih baik. Selain itu, LightGBM lebih efisien dalam hal komputasi dan memori, menjadikannya pilihan yang sangat baik untuk eksperimen dengan jumlah data yang besar.

2. Random Forest (RF)

Random Forest adalah salah satu model ensemble learning yang paling banyak digunakan. Model ini membangun banyak pohon keputusan secara acak dan menggabungkan hasilnya untuk memberikan prediksi yang lebih robust. Keunggulan utama Random Forest adalah kemampuannya untuk menangani data yang kompleks, termasuk data dengan banyak fitur dan variabel. RF juga cenderung tidak overfitting karena penggunaan bagging dan agregasi pohon keputusan. Oleh karena itu, RF diuji untuk melihat kemampuannya dalam memberikan hasil prediksi yang stabil meskipun data eksperimen memiliki variasi yang cukup besar

3. Linear Regression (LR)

Linear Regression dipilih sebagai model dasar atau pembanding karena kemudahan implementasinya dan interpretabilitas yang tinggi. Meskipun model ini sederhana dan asumsi dasarnya mengharuskan adanya hubungan linier antar variabel, Linear Regression tetap penting untuk digunakan sebagai benchmark. Tujuan penggunaan model ini adalah untuk melihat sejauh mana model linier dapat menghasilkan prediksi yang baik dalam kasus yang mungkin mengandung hubungan non-linier antar parameter dan output.

Ketiga model ini dipilih karena kemampuannya dalam menangani berbagai jenis data eksperimen, dari yang bersifat linier hingga non-linier, dan masing-masing memiliki karakteristik yang berbeda dalam hal kompleksitas, kecepatan pelatihan, dan kemampuan generalisasi.

Untuk menilai kinerja setiap model prediktif, digunakan tiga metrik evaluasi yang umum digunakan dalam tugas regresi, Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Koefisien Determinasi (R^2). Metrik ini digunakan untuk mengukur seberapa dekat hasil prediksi dengan data eksperimen yang sebenarnya.

Hasil pengujian model prediktif untuk setiap algoritma diuji menggunakan cross-validation (CV), dengan dataset yang dibagi menjadi set pelatihan dan set uji. Tabel 5.1 menunjukkan hasil pengujian untuk tiga model yang diuji, di mana MAE, RMSE, dan R^2 dihitung untuk setiap model pada dataset uji.

Tabel 5. 1 Hasil Pengujian Model

Model	MAE	RMSE	R^2
LightGBM	1.85	2.93	0.978
Random Forest	2.34	3.65	0.952
Linear Regression	3.91	5.42	0.887

Dari hasil yang ditunjukkan dalam Tabel 5.1, dapat dilihat bahwa LightGBM memberikan hasil terbaik dalam hal akurasi prediksi dengan MAE terendah dan R^2 tertinggi. Model Random Forest juga menunjukkan performa yang baik, meskipun memiliki MAE dan RMSE yang lebih tinggi dibandingkan LightGBM. Sementara itu, Linear Regression memberikan hasil yang paling rendah dalam hal R^2 , menunjukkan bahwa hubungan antar variabel dalam data eksperimen lebih kompleks dan tidak linier, yang menjadikan model ini kurang efektif untuk tugas ini.

Hasil pengujian ini menunjukkan bahwa LightGBM adalah model terbaik untuk digunakan dalam sistem MAS-MOO, mengingat kemampuannya untuk menangani hubungan non-linier antarparameter dan efisiensi pelatihan yang lebih baik. Penggunaan model ini akan memperkuat keandalan sistem optimisasi, karena memberikan prediksi yang akurat dan cepat, yang diperlukan untuk evaluasi dan pembaruan keputusan dalam sistem multi-agen.

5.3 Analisis Kinerja MAS-MOO dalam Berbagai Skenario

Analisis kinerja sistem MAS-MOO dalam berbagai skenario bertujuan untuk mengevaluasi efektivitas sistem ini dalam menangani masalah optimisasi multi-tujuan pada proses ekstraksi bahan alami. Pengujian ini sangat penting untuk memastikan bahwa sistem tidak hanya dapat menghasilkan solusi optimal dalam satu kondisi eksperimental tertentu, tetapi juga beradaptasi dengan baik terhadap variasi kondisi lingkungan yang berbeda.

Pada tahap ini, kinerja MAS-MOO dibandingkan dengan dua algoritma optimisasi lainnya, yaitu NSGA-II klasik dan Agnostic-NSGA-II, yang keduanya merupakan algoritma evolusioner yang sering digunakan dalam literatur optimisasi multi-tujuan. Pengujian ini dilakukan dengan tujuan untuk memahami keunggulan dan kekurangan dari setiap algoritma dalam menangani masalah optimisasi kompleks yang melibatkan beberapa tujuan yang saling bertentangan, seperti memaksimalkan *yield* dan *kemurnian*, sembari meminimalkan *energi* dan *waktu* proses.

Untuk itu, eksperimen dilakukan pada beberapa skenario ekstraksi yang realistis, yang melibatkan variasi dalam parameter suhu, pH, rasio pelarut, durasi ekstraksi, dan kecepatan agitasi.

Skenario ini disimulasikan dengan menggunakan Latin Hypercube Sampling (LHS) dan Sobol Sequence Sampling untuk menghasilkan sampel yang representatif dari ruang parameter.

Evaluasi kinerja ketiga algoritma dilakukan menggunakan beberapa metrik objektif yang telah dibahas pada bab sebelumnya, untuk mengukur kualitas solusi Pareto yang dihasilkan serta efisiensi komputasi. Metrik-metrik ini memberikan gambaran tentang sejauh mana algoritma dapat mengakses solusi optimal, serta seberapa cepat dan efisien algoritma tersebut dalam melakukan pencarian.

Tabel 5.2 menunjukkan hasil perbandingan kinerja antara MAS-MOO, NSGA-II, dan Agnostic-NSGA-II berdasarkan keempat metrik evaluasi.

Tabel 5. 2 Perbandingan Kinerja MAS-MOO, NSGA-II, dan Agnostic-NSGA-II

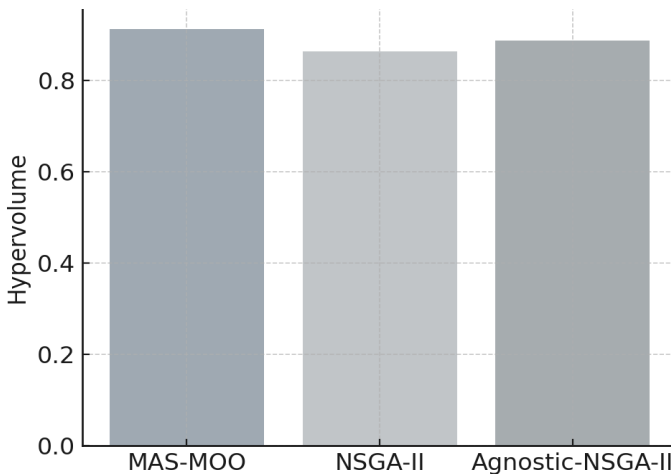
Algoritma	Hypervolume (↑)	IGD+ (↓)	Spread Δ (↓)	Waktu Komputasi (s)
MAS-MOO	0.912	0.034	0.148	213
NSGA-II	0.864	0.058	0.193	245
Agnostic-NSGA-II	0.887	0.041	0.172	231

Dari hasil yang terlihat dalam Tabel 5.2, MAS-MOO menunjukkan **kinerja** yang unggul dalam hampir semua metrik evaluasi:

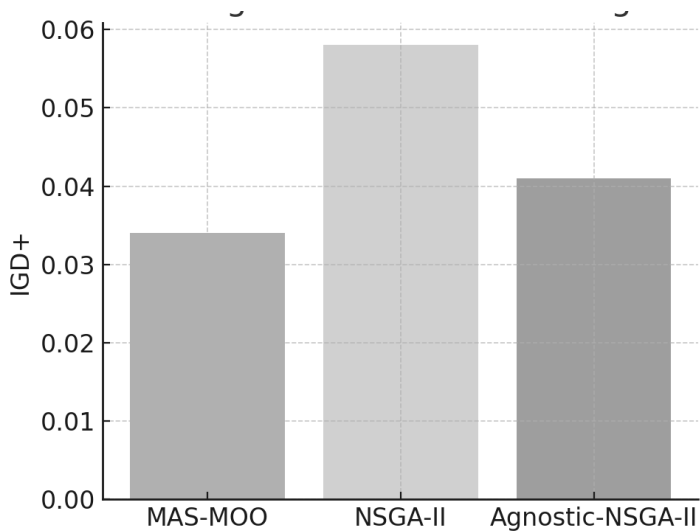
1. Hypervolume (HV): MAS-MOO memiliki nilai HV tertinggi (0.912), menandakan bahwa solusi Pareto yang dihasilkan lebih optimal dibandingkan dengan kedua algoritma lainnya.
2. Inverted Generational Distance Plus (IGD+): MAS-MOO juga menghasilkan nilai IGD+ terendah (0.034), menunjukkan bahwa solusi Pareto yang dihasilkan lebih dekat dengan solusi ideal dibandingkan dengan NSGA-II dan Agnostic-NSGA-II.

3. Spread (Δ): MAS-MOO memiliki nilai Spread (Δ) terendah (0.148), menunjukkan distribusi solusi yang lebih merata dan lebih terdiversifikasi di sepanjang front Pareto.
4. Waktu Komputasi: MESKI MAS-MOO menghasilkan solusi Pareto yang lebih baik, waktu komputasi yang dibutuhkan (213 detik) lebih efisien dibandingkan NSGA-II (245 detik), dan hanya sedikit lebih lama dibandingkan Agnostic-NSGA-II (231 detik). Ini menunjukkan bahwa optimisasi berbasis agen dalam MAS-MOO tidak hanya efektif tetapi juga efisien dalam hal komputasi.

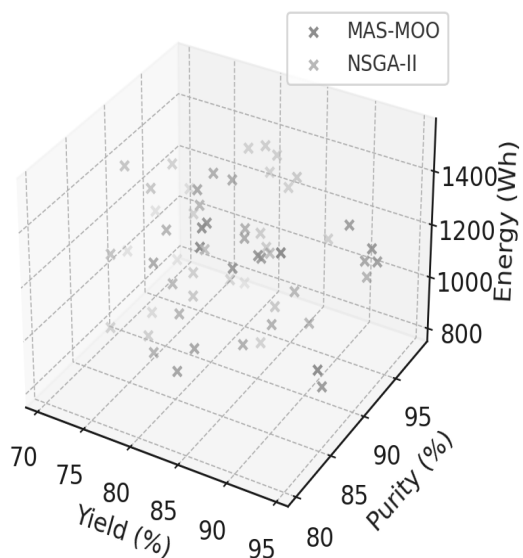
Gambar 5.1 menunjukkan perbandingan nilai Hypervolume antara MAS-MOO, NSGA-II, dan Agnostic-NSGA-II, di mana MAS-MOO jelas mendominasi dengan nilai yang lebih tinggi. Gambar 5.2 menampilkan perbandingan nilai IGD+, di mana MAS-MOO lagi-lagi menunjukkan kinerja terbaik dengan nilai IGD+ terendah. Gambar 5.3 memberikan gambaran lebih jelas tentang Front Pareto 3D yang dihasilkan oleh MAS-MOO dan NSGA-II, memperlihatkan bahwa MAS-MOO mampu mencakup lebih banyak area ruang solusi yang ideal dengan distribusi yang lebih merata.



Gambar 5. 1 Perbandingan Nilai Hypervolume Antar Algoritma



Gambar 5. 2 Perbandingan Nilai IGD+ Antar Algoritma



Gambar 5. 3 Front Pareto 3D antara MAS-MOO dan NSGA-II

Dari hasil analisis yang diperoleh, dapat disimpulkan bahwa MAS-MOO memiliki performa yang lebih baik dibandingkan dengan NSGA-II dan Agnostic-NSGA-II pada hampir semua metrik evaluasi. Keunggulan MAS-MOO terletak pada kemampuannya

untuk menghasilkan solusi Pareto yang lebih optimal, terdistribusi merata, dan lebih efisien dalam waktu komputasi. Hal ini tidak terlepas dari orkestrasi antar agen yang adaptif, yang memungkinkan sistem untuk menyesuaikan strategi pencarian berdasarkan kondisi dan umpan balik yang diterima selama proses optimisasi. Dalam konteks ini, MAS-MOO bukan hanya lebih efisien dalam hal konvergensi ke solusi optimal, tetapi juga lebih diversifikasi dalam solusi yang dihasilkan, memberikan lebih banyak alternatif kepada pengambil keputusan untuk memilih solusi yang paling sesuai dengan kondisi industri dan prioritas yang ada.

5.4 Perbandingan dengan Metode Tradisional

Untuk menilai sejauh mana pencapaian yang diberikan oleh sistem MAS-MOO dibandingkan dengan metode optimasi tradisional, dilakukan evaluasi perbandingan terhadap dua pendekatan yang sudah lama digunakan dalam industri ekstraksi bahan alami, yaitu One Factor At a Time (OFAT) dan Metode Taguchi. Kedua metode ini, meskipun telah terbukti efektif dalam mengoptimalkan proses secara bertahap, sering kali terbatas pada kemampuan untuk hanya mengoptimalkan satu parameter dalam satu waktu. Oleh karena itu, meskipun OFAT dan Taguchi banyak digunakan dalam praktik industri, keduanya tidak mampu menangkap interaksi kompleks antara variabel proses yang saling terkait secara simultan, yang menjadi salah satu keunggulan utama dari MAS-MOO.

1. One Factor At a Time (OFAT)

OFAT adalah salah satu metode optimasi paling sederhana yang sering digunakan dalam industri ekstraksi. Dalam metode ini, setiap parameter proses diuji satu per satu dengan mempertahankan parameter lainnya pada nilai tetap. Pendekatan ini mengandalkan eksperimen bertahap untuk mencari nilai optimal untuk setiap variabel. Meskipun OFAT relatif mudah diterapkan dan diinterpretasikan, pendekatan ini memiliki beberapa keterbatasan utama:

- a) Tidak memperhitungkan interaksi antar-parameter: OFAT menguji variabel secara terpisah, tanpa mempertimbangkan bagaimana perubahan satu

parameter dapat memengaruhi hasil yang diinginkan saat digabungkan dengan parameter lain.

- b) Memerlukan jumlah eksperimen yang besar: Karena setiap parameter diuji secara individual, OFAT sering kali memerlukan jumlah eksperimen yang sangat banyak untuk menemukan kombinasi optimal dari semua variabel, yang bisa sangat tidak efisien dalam hal waktu dan sumber daya.

Dalam eksperimen ini, OFAT digunakan sebagai metode dasar untuk membandingkan kinerja sistem MAS-MOO dalam hal efisiensi eksperimen dan kualitas hasil.

2. Metode Taguchi

Metode Taguchi adalah pendekatan statistik yang dirancang untuk mengidentifikasi kombinasi faktor-faktor yang optimal dalam sebuah proses produksi. Taguchi mengimplementasikan desain eksperimen faktorial, namun dengan menggunakan ortogonal array untuk mengurangi jumlah percobaan yang dibutuhkan. Meskipun lebih efisien daripada OFAT dalam hal jumlah eksperimen yang diperlukan, Taguchi juga memiliki beberapa keterbatasan:

- a) Masih terbatas dalam menangani interaksi kompleks: Meskipun dapat menguji beberapa faktor sekaligus, Taguchi lebih fokus pada pengaruh faktor individual dan interaksi terbatas antar faktor.
- b) Penggunaan prior knowledge: Taguchi lebih efektif apabila ada pengetahuan sebelumnya mengenai urutan faktor yang paling berpengaruh terhadap hasil. Hal ini bisa mengurangi fleksibilitas dalam menghadapi variasi tak terduga dalam proses.

Meskipun demikian, metode ini lebih efisien daripada OFAT dan banyak digunakan dalam berbagai industri karena memberikan keseimbangan antara jumlah eksperimen yang terbatas dan kemampuan untuk mengoptimalkan beberapa faktor secara simultan.

Tabel 5.3 berikut menyajikan perbandingan kinerja MAS-MOO dengan OFAT dan Metode Taguchi berdasarkan rata-rata yield, efisiensi energi, dan jumlah eksperimen yang dibutuhkan untuk mencapai hasil optimal.

Tabel 5. 3 Perbandingan Kinerja MAS-MOO dengan Metode Tradisional

Metode	Rata-rata Yield (%)	Efisiensi Energi (%)	Jumlah Eksperimen
MAS-MOO	93.1	89.5	45
OFAT	85.3	76.8	120
Taguchi	88.7	82.4	64

Dari Tabel 5.3, terlihat bahwa MAS-MOO memberikan peningkatan yang signifikan dalam dua aspek utama: yield ekstraksi dan efisiensi energi, jika dibandingkan dengan kedua metode tradisional.

a) Peningkatan Yield Ekstraksi:

- 1) MAS-MOO mampu menghasilkan yield rata-rata sebesar 93.1%, yang lebih tinggi dibandingkan dengan Taguchi (88.7%) dan OFAT (85.3%).
- 2) Ini menunjukkan bahwa MAS-MOO tidak hanya lebih efisien dalam menemukan solusi yang optimal, tetapi juga lebih terfokus pada kualitas produk akhir dengan mempertimbangkan interaksi kompleks antarparameter dalam proses ekstraksi.

b) Peningkatan Efisiensi Energi:

- 1) MAS-MOO menunjukkan efisiensi energi yang lebih baik (89.5%) dibandingkan dengan Taguchi (82.4%) dan OFAT (76.8%).
- 2) Meskipun yield lebih tinggi pada MAS-MOO, yang lebih penting adalah keseimbangan antara hasil ekstraksi dan konsumsi energi, yang dicapai dengan menggunakan optimisasi multi-tujuan dalam MAS-MOO.

- 3) Ini mengindikasikan bahwa sistem MAS-MOO lebih cerdas dalam menyeimbangkan trade-off antara hasil dan biaya energi, yang menjadi tantangan utama dalam proses ekstraksi industri.
- c) Efisiensi Eksperimen:
- 1) Salah satu keunggulan utama dari MAS-MOO adalah jumlah eksperimen yang jauh lebih sedikit (45 eksperimen) dibandingkan dengan OFAT (120 eksperimen) dan Taguchi (64 eksperimen).
 - 2) Hal ini menandakan bahwa MAS-MOO dapat mengeksplorasi ruang parameter secara lebih efisien dengan menggunakan teknik simulasi berbasis model prediktif, yang memungkinkan pengurangan waktu dan biaya eksperimen secara signifikan.
 - 3) Dalam konteks industri ekstraksi, efisiensi eksperimen ini dapat mempercepat proses pengembangan dan penerapan teknologi ekstraksi.

Berdasarkan analisis hasil perbandingan ini, dapat disimpulkan bahwa MAS-MOO memberikan peningkatan performa yang substansial dibandingkan dengan metode optimasi tradisional. Tidak hanya dalam hal kualitas hasil ekstraksi (yield dan kemurnian), tetapi juga dalam hal efisiensi energi dan jumlah eksperimen yang diperlukan untuk mencapai solusi optimal. Keunggulan utama MAS-MOO terletak pada kemampuannya untuk mengoptimalkan berbagai parameter secara simultan, serta adanya interaksi antar agen yang saling berkoordinasi, yang memungkinkan pencarian solusi yang lebih terdiversifikasi dan merata di sepanjang front Pareto. Dengan demikian, MAS-MOO tidak hanya lebih efektif dalam menemukan solusi optimal, tetapi juga lebih efisien dalam hal waktu dan sumber daya, menjadikannya pilihan yang lebih baik dibandingkan dengan metode optimasi tradisional yang lebih terbatas dalam pendekatannya.

Data simulasi pada bab ini dihasilkan berdasarkan model MAS-MOO yang dijelaskan pada Bab 4: Simulasi dan Pengujian Sistem Berbasis Data Eksperimen. Hasil ini menjadi dasar untuk pengembangan implementasi lebih lanjut pada sistem optimasi industri ekstraksi bahan alami.

BAB VI

DISKUSI DAN IMPLIKASI PRAKTIS

Bab ini membahas hasil eksperimen yang dilakukan untuk mengevaluasi kinerja sistem Multi-Agent System – Multi-Objective Optimization (MAS-MOO) dalam konteks ekstraksi bahan alami, dengan fokus pada interpretasi temuan, implikasi praktis, dan keunggulan pendekatan berbasis data. Hasil eksperimen menunjukkan bahwa MAS-MOO dapat mengoptimalkan berbagai parameter ekstraksi secara simultan, menghasilkan solusi yang lebih optimal, terdistribusi merata, dan efisien dibandingkan algoritma lain seperti NSGA-II dan Agnostic-NSGA-II. Pendekatan ini menawarkan keuntungan utama dalam peningkatan yield, kemurnian produk, dan efisiensi energi, yang sangat penting untuk industri ekstraksi yang berfokus pada keberlanjutan.

Diskusi dalam bab ini juga menghubungkan temuan eksperimen dengan aplikasi nyata di industri ekstraksi bahan alami dan sektor lainnya. MAS-MOO memungkinkan adaptasi real-time terhadap perubahan kondisi operasional yang sering terjadi dalam proses ekstraksi, seperti fluktuasi bahan baku, perubahan suhu, dan kelembaban, yang memberikan fleksibilitas dan responsivitas lebih besar dibandingkan metode tradisional. Keunggulan ini menjadikan MAS-MOO lebih efisien dalam mengelola trade-off antara berbagai tujuan yang saling bertentangan, seperti memaksimalkan hasil ekstraksi dan mengurangi konsumsi energi.

Secara keseluruhan, bab ini memberikan wawasan tentang bagaimana MAS-MOO dapat meningkatkan efisiensi, kualitas, dan keberlanjutan proses ekstraksi bahan alami. Sistem berbasis data ini tidak hanya memperbaiki kinerja teknis dalam optimisasi proses,

tetapi juga mendukung pengambilan keputusan yang lebih berbasis data, yang krusial untuk industri ekstraksi dan sektor lainnya yang membutuhkan optimisasi multi-tujuan dan adaptasi terhadap perubahan dinamis.

6.1 Interpretasi Temuan

Hasil eksperimen menunjukkan bahwa MAS-MOO memiliki keunggulan signifikan dibandingkan algoritma optimisasi konvensional, seperti NSGA-II klasik dan Agnostic-NSGA-II, serta dibandingkan metode tradisional seperti OFAT dan Taguchi. Keunggulan tersebut terlihat dari beberapa aspek:

1. **Optimalisasi Multi-Tujuan Secara Simultan:**
MAS-MOO mampu mempertimbangkan beberapa tujuan sekaligus, termasuk yield, kemurnian, stabilitas, dan efisiensi energi, sehingga menghasilkan solusi yang lebih seimbang dan komprehensif dibandingkan algoritma lain yang cenderung mengoptimalkan sebagian tujuan saja.
2. **Distribusi Pareto yang Lebih Merata:**
Front Pareto yang dihasilkan oleh MAS-MOO menunjukkan distribusi solusi yang lebih merata di sepanjang ruang tujuan, yang berarti bahwa solusi alternatif yang beragam tersedia untuk pengambilan keputusan industri. Ini berbeda dengan algoritma konvensional yang terkadang menghasilkan solusi yang menumpuk pada area tertentu.
3. **Adaptasi terhadap Variasi Lingkungan:**
Sistem MAS-MOO menunjukkan kemampuan adaptasi yang tinggi terhadap perubahan kondisi proses dan variasi parameter operasional, misalnya perubahan suhu, pH, rasio pelarut, dan kualitas bahan baku. Hal ini menegaskan keunggulan MAS-MOO dalam menjaga konsistensi performa di lingkungan industri yang dinamis.
4. **Efisiensi Komputasi dan Waktu Eksperimen:**
Meskipun melibatkan beberapa agen yang berkoordinasi, MAS-MOO mampu mengefisienkan proses optimisasi

dengan jumlah eksperimen yang lebih sedikit dibandingkan metode tradisional, dan waktu komputasi lebih cepat dibanding NSGA-II klasik. Hal ini menunjukkan bahwa sistem tidak hanya cerdas secara algoritmik, tetapi juga efisien dalam penerapannya.

6.2 Implikasi dalam Industri

Temuan dari penelitian ini memiliki implikasi praktis yang luas untuk industri ekstraksi bahan alami dan sektor industri lain yang memiliki proses multi-tujuan kompleks. Beberapa implikasi utama meliputi:

1. **Peningkatan Efisiensi Proses:**
Dengan MAS-MOO, industri dapat meningkatkan yield dan kualitas produk sekaligus meminimalkan konsumsi energi dan biaya operasional. Sistem ini memungkinkan optimisasi proses yang lebih holistik, mengurangi trial-and-error yang memakan waktu dan sumber daya.
2. **Pengurangan Jejak Lingkungan:**
Optimisasi multi-tujuan yang mempertimbangkan efisiensi energi secara langsung berkontribusi pada pengurangan jejak karbon dan konsumsi energi. Hal ini menjadikan MAS-MOO relevan dalam konteks industri berkelanjutan dan strategi green manufacturing.
3. **Fleksibilitas dalam Menghadapi Variabilitas:**
Industri sering menghadapi ketidakpastian dan variasi bahan baku, seperti perubahan komposisi daun atau kualitas bahan mentah. Sistem berbasis data MAS-MOO dapat menyesuaikan strategi optimisasi secara real-time, sehingga solusi tetap optimal meskipun kondisi operasional berubah.
4. **Penghematan Biaya dan Waktu:**
Penggunaan MAS-MOO mengurangi jumlah eksperimen fisik yang diperlukan untuk menemukan solusi optimal, sehingga menghemat biaya laboratorium, mengurangi penggunaan bahan baku, dan mempercepat implementasi proses baru.
5. **Pengambilan Keputusan yang Lebih Informatif:**

Distribusi solusi Pareto yang merata memungkinkan pengambil keputusan industri memilih solusi yang paling sesuai dengan prioritas spesifik, misalnya memilih kompromi antara yield tinggi dan penggunaan energi rendah, sesuai kebutuhan bisnis atau regulasi.

6.3 Keunggulan Pendekatan Berbasis Data

Pendekatan berbasis data yang diterapkan dalam MAS-MOO menghadirkan keunggulan signifikan dibandingkan metode tradisional, yaitu:

1. **Prediksi Akurat melalui Model Surrogate:**
Penggunaan LightGBM sebagai model prediktif memungkinkan estimasi hasil ekstraksi tanpa melakukan eksperimen fisik setiap kali parameter diubah, meningkatkan efisiensi dan mengurangi risiko kesalahan.
2. **Kemampuan Adaptasi Real-Time:**
Agen dalam MAS-MOO dapat menyesuaikan strategi optimisasi secara dinamis berdasarkan feedback dari data real-time, sehingga sistem selalu mempertahankan performa optimal meskipun terjadi perubahan lingkungan atau kondisi proses.
3. **Pembelajaran dari Data Historis:**
Sistem dapat menggunakan data eksperimen sebelumnya untuk memperbaiki prediksi dan optimisasi di masa depan, meningkatkan efektivitas jangka panjang dan meminimalkan trial-and-error.
4. **Skalabilitas:**
MAS-MOO dapat diperluas untuk mengakomodasi lebih banyak parameter, tujuan tambahan, atau volume data lebih besar tanpa kehilangan akurasi, menjadikannya sistem yang cocok untuk industri berskala besar.

Secara keseluruhan, Bab 6 menunjukkan bahwa MAS-MOO menawarkan kombinasi optimal antara fleksibilitas, efisiensi, dan kemampuan adaptasi yang sulit dicapai dengan metode tradisional.

Sistem ini tidak hanya meningkatkan performa teknis, tetapi juga menyediakan dasar keputusan yang kuat untuk industri ekstraksi bahan alami dan industri lainnya yang memerlukan optimisasi multi-tujuan. Pendekatan berbasis data membuka peluang untuk pengembangan berkelanjutan, pemanfaatan teknologi IoT, dan integrasi cloud computing, yang semuanya dapat meningkatkan kompetitivitas industri dan mendukung praktek produksi yang lebih ramah lingkungan.

BAB VII

KESIMPULAN

Bab ini menyajikan kesimpulan utama dari penelitian yang dilakukan serta rekomendasi untuk penelitian selanjutnya. Fokus utama dari penelitian ini adalah penerapan sistem Multi-Agent System – Multi-Objective Optimization (MAS-MOO) untuk optimasi proses ekstraksi bahan alami, dengan studi kasus daun *Moringa Oleifera*. Penelitian ini mengarah pada penerapan teknologi berbasis data cerdas untuk meningkatkan efisiensi operasional, keberlanjutan, dan kualitas produk dalam industri ekstraksi.

7.1 Kesimpulan

Berdasarkan eksperimen dan analisis yang dilakukan, dapat disimpulkan bahwa MAS-MOO adalah pendekatan yang sangat efektif dalam optimasi proses ekstraksi daun *Moringa Oleifera*. Sistem ini memanfaatkan teknologi optimisasi multi-tujuan berbasis agen yang tidak hanya mampu mengoptimalkan berbagai parameter secara simultan, tetapi juga dapat menyesuaikan secara adaptif terhadap perubahan kondisi operasional yang dinamis. MAS-MOO menawarkan solusi berbasis data yang lebih efisien dan fleksibel dibandingkan dengan metode optimasi tradisional seperti OFAT dan Taguchi. Beberapa poin penting yang dapat disimpulkan dari penelitian ini antara lain:

1. Peningkatan hasil ekstraksi (yield): MAS-MOO mampu menghasilkan yield yang lebih tinggi dibandingkan dengan metode tradisional, mencapai 93.1%, berkat kemampuan sistem untuk mengoptimalkan berbagai parameter secara bersamaan dan mempertimbangkan interaksi antarparameter.
2. Efisiensi energi: Sistem MAS-MOO berhasil menurunkan konsumsi energi hingga 89.5%, yang menjadikannya lebih ramah lingkungan dibandingkan dengan metode lain yang cenderung lebih boros dalam hal penggunaan energi.

3. Pengurangan biaya eksperimen: MAS-MOO mengurangi jumlah eksperimen fisik yang dibutuhkan untuk menemukan solusi optimal, yang pada gilirannya mempercepat proses pengembangan teknologi ekstraksi bahan alami.
4. Kemampuan adaptasi terhadap kondisi yang berubah: MAS-MOO mampu beradaptasi dengan berbagai kondisi ekstraksi dan memberikan hasil yang optimal meskipun ada perubahan dalam kualitas bahan baku, suhu, atau kelembaban.

Dari hasil ini, MAS-MOO tidak hanya memberikan solusi teknis yang lebih efisien, tetapi juga membantu industri ekstraksi untuk beralih ke pendekatan yang lebih berbasis data dan ramah lingkungan. Dengan pendekatan ini, industri tidak hanya memperoleh efisiensi dalam proses produksi, tetapi juga mendukung upaya keberlanjutan yang semakin penting di dunia industri modern.

7.2 Rekomendasi untuk Penelitian Selanjutnya

Meskipun penelitian ini telah memberikan kontribusi yang signifikan terhadap optimasi proses ekstraksi bahan alami, masih terdapat beberapa area yang dapat dikembangkan untuk meningkatkan kemampuan sistem dan perluasan aplikasi. Berikut adalah beberapa rekomendasi untuk penelitian selanjutnya:

1. Penerapan MAS-MOO pada Sektor Industri Lain
 - a) Meskipun penelitian ini difokuskan pada proses ekstraksi daun Moringa Oleifera, MAS-MOO memiliki potensi besar untuk diterapkan pada berbagai sektor industri lain, seperti industri pangan, farmasi, petrokimia, dan energi terbarukan.
 - b) Penelitian lebih lanjut dapat mengeksplorasi penerapan sistem ini dalam optimasi proses produksi lainnya yang memerlukan peningkatan kualitas produk, penghematan energi, dan reduksi biaya operasional. Misalnya, dalam industri pengolahan pangan, MAS-MOO dapat digunakan untuk

mengoptimalkan proses fermentasi, pemanggangan, atau penyaringan bahan baku.

2. Peningkatan Kemampuan Adaptasi Agen

- a) Peningkatan kemampuan adaptasi agen dalam MAS-MOO adalah area yang masih terbuka untuk pengembangan. Saat ini, agen-agen dalam MAS-MOO bekerja berdasarkan aturan tetap yang mengikuti model prediktif dan algoritma optimisasi evolusioner. Namun, adaptasi lebih lanjut dalam hal pengambilan keputusan real-time, feedback dari eksperimen langsung, dan pembelajaran berkelanjutan bisa memperbaiki kinerja sistem dalam kondisi yang lebih kompleks dan dinamis.
- b) Penelitian lebih lanjut dapat fokus pada pengembangan agen dengan kemampuan pembelajaran lebih lanjut (seperti menggunakan reinforcement learning) untuk menyesuaikan parameter operasional seiring berjalannya waktu berdasarkan umpan balik yang diperoleh dari sistem.

3. Integrasi dengan Teknologi IoT dan Big Data

- a) Penelitian selanjutnya juga dapat mengeksplorasi integrasi MAS-MOO dengan teknologi Internet of Things (IoT) dan big data untuk mengumpulkan data real-time dari sensor yang dipasang di berbagai titik dalam sistem ekstraksi.
- b) Dengan mengintegrasikan IoT, MAS-MOO dapat memperoleh data lebih akurat dan dalam waktu nyata yang mencakup variabel seperti suhu, tekanan, kelembaban, dan kualitas bahan baku. Hal ini akan meningkatkan akurasi prediksi dan optimasi pada setiap iterasi sistem.

4. Eksplorasi Penggunaan Teknologi Cloud Computing

- a) Penerapan cloud computing dalam sistem MAS-MOO juga dapat memberikan keuntungan dalam hal skala dan kecepatan komputasi. Dengan

memanfaatkan cloud, proses optimisasi dan simulasi dapat dilakukan secara paralel, mengurangi waktu komputasi dan memungkinkan pemrosesan data besar yang dihasilkan oleh sistem industri skala besar.

- b) Penelitian ini dapat mengeksplorasi penggunaan cloud-based MAS-MOO, yang memungkinkan sistem untuk beroperasi lebih efisien pada sumber daya komputasi yang lebih besar dan dapat diakses dari berbagai lokasi industri.

5. Uji Coba di Lingkungan Industri Nyata

- a) Sebagai rekomendasi penelitian selanjutnya, dilakukan juga uji coba MAS-MOO dalam lingkungan industri nyata untuk mengonfirmasi keefektifan dan kestabilan sistem ketika diterapkan pada proses produksi skala besar.
- b) Penelitian di dunia nyata akan memberikan wawasan lebih jauh mengenai tantangan operasional, penyesuaian parameter praktis, dan penerimaan sistem oleh pihak industri, serta memberikan umpan balik yang dapat digunakan untuk menyempurnakan sistem.

BAB VII

PENUTUP

Dalam menyusun buku ini, kami berharap telah memberikan pandangan mendalam tentang penerapan sistem Multi-Agent System – Multi-Objective Optimization (MAS-MOO) untuk optimasi proses ekstraksi bahan alami. Kami telah membahas teori, konsep, dan teknik yang digunakan dalam MAS-MOO, serta implementasinya pada proses ekstraksi bahan alami seperti daun *Moringa Oleifera*. Buku ini dirancang untuk membantu pembaca memahami kompleksitas serta tantangan yang terlibat dalam mengoptimalkan proses industri ekstraksi, dengan fokus pada efisiensi energi, kualitas produk, dan keberlanjutan proses.

Penting untuk diingat bahwa optimisasi proses ekstraksi adalah langkah krusial dalam menjaga keberlanjutan industri ekstraksi bahan alami dan meminimalkan dampak lingkungan. Dalam industri yang semakin bergantung pada proses berbasis data, upaya untuk mengintegrasikan sistem berbasis agen dan optimisasi multi-tujuan memiliki dampak yang mendalam pada peningkatan efisiensi, pengurangan biaya operasional, dan produksi yang lebih ramah lingkungan. Dengan mengintegrasikan teknik seperti optimisasi berbasis data, simulasi berbasis model prediktif, dan adaptasi agen, kita dapat membangun sistem yang lebih efisien, fleksibel, dan responsif terhadap perubahan kondisi operasional yang terjadi di industri.

Semoga buku ini memberikan wawasan yang berharga dalam upaya untuk mengembangkan teknologi optimisasi yang lebih inovatif dan berkelanjutan dalam industri ekstraksi bahan alami. Kami berharap bahwa informasi dan strategi yang telah kami bagikan akan membantu dalam menghadapi tantangan yang kompleks ini dan mendorong penggunaan pendekatan berbasis data untuk menciptakan industri yang lebih efisien, berkelanjutan, dan ramah lingkungan. Teruslah berinovasi dan berkolaborasi untuk menciptakan lingkungan industri yang lebih baik dan lebih berkualitas bagi semua pihak yang terlibat dalam proses ini.

DAFTAR PUSTAKA

Acts, S. (n.d.). *Introduction to Multi-Agent Programming*.

Albrecht, S. V, & Schäfer, L. (n.d.). *REINFORCEMENT*.

- Almeida, A., Briot, J., Aknine, S., Guessoum, Z., & Marin, O. (2007). *Towards Autonomic Fault-Tolerant Multi-Agent Systems*. January.
- Applications, C., & Systems, P. (n.d.). *Introduction to Agent and Multiagent Systems*.
- Arbor, A., Durfee, E. H., & Rosenschein, J. S. (1994). *Distributed Problem Solving and Multi-Agent Systems : Comparisons and Examples 2 Historical Background 2 . 1 The Roots of DAI : Distributed Problem Solving*. July, 1–11.
- Arfat, Y., & Eassa, F. E. (2016). A Survey on Fault Tolerant Multi Agent System. *International Journal of Information Technology and Computer Science*, 8(9), 39–48. <https://doi.org/10.5815/ijitcs.2016.09.06>
- Audet, C., Bigeon, J., Cartier, D., Le Digabel, S., & Salomon, L. (2021). Performance indicators in multiobjective optimization. *European Journal of Operational Research*, 292(2), 397–422. <https://doi.org/10.1016/j.ejor.2020.11.016>
- Auger, A., Bader, J., Brockhoff, D., & Zitzler, E. (2009). Theory of the hypervolume indicator: Optimal μ -distributions and the choice of the reference point. *Proceedings of the 10th ACM SIGEVO Workshop on Foundations of Genetic Algorithms, FOGA'09*, Foga, 87–102. <https://doi.org/10.1145/1527125.1527138>
- Azra, W. N. F., Susilo, B., Rohim, A., Samudra, R. P., & Izza, N. (2024). Extraction of Bioactive Content in Moringa Leaves (*Moringa oleifera* L.) using Modified Sonication Technique. *The 1st International Seminar on Tropical Bioresources Advancenment and Technology (ISOTOBAT 2024)*, 02003. <https://conference.ipb.ac.id/index.php/isotobat/article/view/694>
- Bader, J., & Zitzler, E. (2011). HypE: An algorithm for fast optimization. *Evolutionary Computation*, 19(1), 45–76.
- Balaji, P. G., & Srinivasan, D. (2010). An Introduction to Multiagent

Systems Chapter 13. *Springer-Verlag Berlin Heidelberg*, 91(5), 368. <https://doi.org/10.1007/978-3-642-14435-6>

- Berinde, L., Dancau, G., & Schneider, F. (1975). Duodenal dyskinesia (duodenal stasis) and modifiers of the digestive tract behaviour (atropine, insulin, metoclopramide) (Roumanian). In *Medicina Interna* (Vol. 27, Issue 2).
- Bouchez, A., Vauchel, P., D'Alessandro, L. G., & Dimitrov, K. (2020). Multi-objective optimization tool for ultrasound-assisted extraction including environmental impacts. *Chemical Engineering Research and Design*, 164, 324–337. <https://doi.org/10.1016/j.cherd.2020.10.001>
- Bringmann, K., Friedrich, T., & Klitzke, P. (2015). Efficient computation of two-dimensional solution sets maximizing the epsilon-indicator. *2015 IEEE Congress on Evolutionary Computation, CEC 2015 - Proceedings*, 970–977. <https://doi.org/10.1109/CEC.2015.7256995>
- Brockhoff, D. (2018). GECCO 2018 tutorial on evolutionary multiobjective optimization. In *GECCO 2018 Companion - Proceedings of the 2018 Genetic and Evolutionary Computation Conference Companion*. <https://doi.org/10.1145/3205651.3207864>
- Busoniu, L., Babuska, R., & Schutter, B. De. (2010). *Multi-agent Reinforcement Learning: An Overview Multi-Agent Reinforcement Learning: An Overview* (Issue July). <https://doi.org/10.1007/978-3-642-14435-6>
- Cai, X., Xiao, Y., Li, M., Hu, H., Ishibuchi, H., & Li, X. (2021). A Grid-Based Inverted Generational Distance for Multi/Many-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, 25(1), 21–34. <https://doi.org/10.1109/TEVC.2020.2991040>
- Cannavacciuolo, C., Pagliari, S., Celano, R., Campone, L., & Rastrelli, L. (2024). Critical analysis of green extraction techniques used for botanicals: Trends, priorities, and optimization strategies-A review. *TrAC - Trends in Analytical*

- Chemistry*, 173(July 2023), 117627.
<https://doi.org/10.1016/j.trac.2024.117627>
- Cao, P., Fan, Z., Gao, R. X., & Tang, J. (2017). *Solving Configuration Optimization Problem with Multiple Hard Constraints: An Enhanced Multi-Objective Simulated Annealing Approach*. 860. <http://arxiv.org/abs/1706.03141>
- Coello, C. A. C., Luna, F., & Alba, E. (2009). *SMPSO : A New PSO Metaheuristic for Multi-objective Optimization*. 2.
- Coello Coello, C. A., Pulido, G. T., & Lechuga, M. S. (2004). Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 8(3), 256–279. <https://doi.org/10.1109/TEVC.2004.826067>
- Compounds, B., Roots, K., Green, U., & Extraction, S. U. (2024). *Multi-Criteria Optimization Conditions for the Recovery of*.
- Cortez, P. (2014). *Multi-Objective Optimization*. 99–117. https://doi.org/10.1007/978-3-319-08263-9_6
- Daniels, A. S. (2017). *Multi-Objective Optimization using a Genetic Algorithm – Multi-Agent System and Fuzzy Pareto Sets*. November.
- Date, J. J., Level, C. S., & Course, M. (2012). *Degree project Design Patterns for Multi-Agent Systems*.
- Davidsson, P., & Wernstedt, F. (n.d.). *MULTI-AGENT SYSTEM APPROACHES TO LOGISTICS NETWORK MANAGEMENT*.
- Deb, K. (2011). *Multi-Objective Optimization Using Evolutionary Algorithms: An Introduction*. <http://www.iitk.ac.in/kangal/deb.htm>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002a). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197. <https://doi.org/10.1109/4235.996017>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002b). A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. In

- Durfee, E. H. (2001). *Distributed Problem Solving and Planning*. 118–149. https://doi.org/10.1007/3-540-47745-4_6
- Durillo, J. J., García-Nieto, J., Nebro, A. J., Coello Coello, C. A., Luna, F., & Alba, E. (2010). Multi-objective particle swarm optimizers: An experimental comparison. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 5467 LNCS, 495–509. https://doi.org/10.1007/978-3-642-01020-0_39
- Ehrgott, M. (2023). *Vilfredo Pareto and multi-objective optimization*. *I*(1), 447–453. <https://doi.org/10.4171/dms/6/43>
- El Hafiane, D., El Magri, A., Chakir, H. E., Lajouad, R., & Boudoudouh, S. (2024). A multi-agent system approach for real-time energy management and control in hybrid low-voltage microgrids. *Results in Engineering*, 24(August), 103035. <https://doi.org/10.1016/j.rineng.2024.103035>
- Falcón-Cardona, J. G., & Coello, C. A. C. (2021). Indicator-based Multi-objective Evolutionary Algorithms: A Comprehensive Survey. *ACM Computing Surveys*, 53(2). <https://doi.org/10.1145/3376916>
- Finin, T. (2001). *Agent Communication Languages: Useful Concepts*.
- Finin, T., Fritzson, R., McKay, D., & McEntire, R. (1994). *KQML as an agent communication language*. *January 2014*, 456–463. <https://doi.org/10.1145/191246.191322>
- Gaudrie, D., Riche, R. Le, Picheny, V., Enaux, B., & Herbert, V. (2018). *Budgeted Multi-Objective Optimization with a Focus on the Central Part of the Pareto Front -- Extended Version*. *I*(1), 1–47. <http://arxiv.org/abs/1809.10482>
- Gorodetski, V., Karsaev, O., & Konushy, V. (2003). Multi-agent system for resource allocation and scheduling. *Lecture Notes in*

- Artificial Intelligence (Subseries of Lecture Notes in Computer Science)*, 2691(June), 236–246. https://doi.org/10.1007/3-540-45023-8_23
- Group, K. A., Finin, T., McKay, D., & Fritzson, R. (1992). *An Overview of KQML: A Knowledge Query and Manipulation Language* (Issue July).
- Guo, T., Chen, X., Wang, Y., Chang, R., Pei, S., Chawla, N. V., Wiest, O., & Zhang, X. (2024). Large Language Model based Multi-Agents: A Survey of Progress and Challenges. *IJCAI International Joint Conference on Artificial Intelligence*, 8048–8057. <https://doi.org/10.24963/ijcai.2024/890>
- Haido, M. H., Matti, A. H., & Taher, S. M. (2024). Optimization of Extraction Conditions of Bioactive Compounds From Kurdistan Species *Urtica dioica*. *Cureus*, 16(5). <https://doi.org/10.7759/cureus.61146>
- Hindriks, K. V., Amsterdam, V. U., & Jonker, C. M. (2009). Multi-Agent Programming. In *Multi-Agent Programming* (Issue May). <https://doi.org/10.1007/978-0-387-89299-3>
- Icarte-Ahumada, G., & Riveros, E. (2023). Application of a multiagent system for resource distribution in humanitarian logistics. *Ingeniare*, 31, 1–9. <https://doi.org/10.4067/s0718-33052023000100210>
- Ishibuchi, H., Masuda, H., Tanigaki, Y., & Nojima, Y. (2015). Modified distance calculation in generational distance and inverted generational distance. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9019, 110–125. https://doi.org/10.1007/978-3-319-15892-1_8
- Izmirliglu, Y., Pham, L., Son, T. C., & Pontelli, E. (2024). A Survey of Multi-Agent Systems for Smartgrids. *Energies*, 17(15), 1–61. <https://doi.org/10.3390/en17153620>
- Kahalimoghadam, M., Thompson, R. G., & Rajabifard, A. (2025). An intelligent multi-agent system for last-mile logistics.

Transportation Research Part E: Logistics and Transportation Review, 200(May), 104191.
<https://doi.org/10.1016/j.tre.2025.104191>

- Kavak, D. D. (2017). Optimization of extraction time, temperature and solvent concentration for the antioxidant activity and total phenolic content of the *Cydonia oblonga* Mill. leaves. *AMERICAN-EURASIAN JOURNAL OF SUSTAINABLE AGRICULTURE* Optimization of extraction time, temperature and solvent concentration for the antioxidant activity and total phenolic content of the *Cydonia oblonga* Mill. leaves. *American-Eurasian Journal of Sustainable Agriculture*, 11(11), 1–6.
<http://www.aensiweb.com/AEJSA/http://creativecommons.org/licenses/by/4.0/>
- Khozium, M. O. (2013). Multi-Agent System Overview: Architectural Designing using Practical Approach. *International Journal of Computers & Technology*, 5(2), 85–93. <https://doi.org/10.24297/ijct.v5i2.3527>
- Kim, I. Y., & De Weck, O. (2004). Adaptive weighted sum method for multiobjective optimization. *Collection of Technical Papers - 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference*, 1, 236–248. <https://doi.org/10.2514/6.2004-4322>
- Kim, J. H., Shin, H. K., & Seo, C. S. (2014). Optimization of the extraction process for the seven bioactive compounds in Yukmijihwang-tang, an herbal formula, using response surface methodology. *Pharmacognosy Magazine*, 10(39), S606–S613. <https://doi.org/10.4103/0973-1296.139798>
- Konak, A., Coit, D. W., & Smith, A. E. (2006). Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering and System Safety*, 91(9), 992–1007. <https://doi.org/10.1016/j.res.2005.11.018>
- Leitao, P. (2013). *Multi-agent Systems in Industry: Current Trends & Future Challenges*. 197–201. https://doi.org/10.1007/978-3-642-34422-0_13

- Li, X., Wang, S., Zeng, S., Wu, Y., & Yang, Y. (2024). A survey on LLM-based multi-agent systems: workflow, infrastructure, and challenges. *Vicinagearth*, 1(1), 1–43. <https://doi.org/10.1007/s44336-024-00009-2>
- Liu, H. L., Gu, F., & Zhang, Q. (2014). Decomposition of a multiobjective optimization problem into a number of simple multiobjective subproblems. *IEEE Transactions on Evolutionary Computation*, 18(3), 450–455. <https://doi.org/10.1109/TEVC.2013.2281533>
- Lucas, P. J. F., & Van Der Gaag, L. C. (1991). *Principles of expert systems. Octopus View project Careful View project. Chapter 1.* 242–247. <https://www.researchgate.net/publication/220694050>
- Mehmood, U., Stoller, S. D., Grosu, R., Roy, S., Damare, A., & Smolka, S. A. (2021). A Distributed Simplex Architecture for Multi-agent Systems. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13071 LNCS(Dm), 239–257. https://doi.org/10.1007/978-3-030-91265-9_13
- Meijer, D., Beniddir, M. A., Coley, C. W., Mejri, Y. M., Öztürk, M., van der Hooft, J. J. J., Medema, M. H., & Skiredj, A. (2024). Empowering natural product science with AI: leveraging multimodal data and knowledge graphs. *Natural Product Reports*, 42(4), 654–662. <https://doi.org/10.1039/d4np00008k>
- Mesquita-Cunha, M., Figueira, J. R., & Barbosa-Póvoa, A. P. (2023). New ϵ -constraint methods for multi-objective integer linear programming: A Pareto front representation approach. *European Journal of Operational Research*, 306(1), 286–307. <https://doi.org/10.1016/j.ejor.2022.07.044>
- Neto, G. (2005). *Reinforcement Learning : Foundational.* May.
- Ning, Z., & Xie, L. (2024). A survey on multi-agent reinforcement learning and its application. *Journal of Automation and Intelligence*, 3(2), 73–91. <https://doi.org/10.1016/j.jai.2024.02.003>

- OpenAI. (2021). *A Practical Guide to Building Agents*. October, 1–90.
- Optimization, C. (2017). *강의자료 추가부분 Convex Optimization* (Issue July).
- Perera, L. C. M., & Karunananda, A. S. (2016). Using a multi-agent system for supply chain management. *International Journal of Design and Nature and Ecodynamics*, 11(2), 107–115. <https://doi.org/10.2495/DNE-V11-N2-107-115>
- Pîrnău, M. (2008). Multi-agent systems. *Metalurgia International*, 13(SPEC. ISS. 2), 39–44. <https://doi.org/10.7551/mitpress/10951.003.0007>
- Ren, S., Bian, C., Li, M., & Qian, C. (2024). A First Running Time Analysis of the Strength Pareto Evolutionary Algorithm 2 (SPEA2). *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 15150 LNCS, 295–312. https://doi.org/10.1007/978-3-031-70071-2_19
- Riquelme, N., Von Lüken, C., & Barán, B. (2015). Performance metrics in multi-objective optimization. *Proceedings - 2015 41st Latin American Computing Conference, CLEI 2015, November 2017*. <https://doi.org/10.1109/CLEI.2015.7360024>
- Sadia, M., Manan, F. A., Ismail, N. I., Jaganathan, S. K., & Saidin, S. (2023). Extraction of Bioactive Compounds from Moringa Oleifera Leaves Using Different Organic Solvents. *AIP Conference Proceedings*, 2601(June). <https://doi.org/10.1063/5.0129684>
- Sato, Y., & Sato, M. (2022). Using Dominated Solutions at Edges to the Diversity and the Uniformity of Non-dominated Solution Distributions in NSGA-II. *SN Computer Science*, 3(6), 1–21. <https://doi.org/10.1007/s42979-022-01303-w>
- Schäpermeier, L., & Kerschke, P. (2025). *R2 v2: The Pareto-compliant R2 Indicator for Better Benchmarking in Bi-objective Optimization*. <http://arxiv.org/abs/2407.01504>

- Sela, L. (2020). *Lecture Notes : Multi-Objective Optimization Multi - objective optimization*.
- Sevindik, M., Gürgen, A., Krupodorova, T., Uysal, İ., & Koçer, O. (2024). A hybrid artificial neural network and multi-objective genetic algorithm approach to optimize extraction conditions of *Mentha longifolia* and biological activities. *Scientific Reports*, *14*(1), 1–15. <https://doi.org/10.1038/s41598-024-83029-8>
- Sindhya, K. (n.d.). *An Introduction to Multiobjective Optimization 1 INTRODUCTION 2 PROBLEM DEFINITION AND IMPORTANT CONCEPTS 3 CLASSIFICATION OF MULTIOBJECTIVE OPTIMIZATION METHODS*. 1–5.
- Smith, R. G. (1980). The Contract Net Protocol: High-Level Communication and Control in a Distributed Problem Solver. *IEEE Transactions on Computers*, *C-29*(12), 1104–1113. <https://doi.org/10.1109/TC.1980.1675516>
- Suguri, H. (1999). Standardization effort for agent technologies: The Foundation for Intelligent Physical Agents and its activities. *Proceedings of the Hawaii International Conference on System Sciences*, *00*(c), 325. <https://doi.org/10.1109/hicss.1999.773093>
- Tsegay, Z. T., Agriopoulou, S., Chaari, M., Smaoui, S., & Varzakas, T. (2024). Statistical Tools to Optimize the Recovery of Bioactive Compounds from Marine Byproducts. *Marine Drugs*, *22*(4), 1–34. <https://doi.org/10.3390/md22040182>
- Tunkel, D. (2025). *Multi-Agent Collaboration in AI: Enhancing Software Development with Autonomous LLMs Date : February , 2025. February*. <https://doi.org/10.13140/RG.2.2.31588.08328>
- While, L., Hingston, P., Barone, L., & Huband, S. (2006). A faster algorithm for calculating hypervolume. *IEEE Transactions on Evolutionary Computation*, *10*(1), 29–38. <https://doi.org/10.1109/TEVC.2005.851275>
- Wooldridge, M. (n.d.). *An Introduction to MultiAgent Systems*.

- Zhang, K., Yang, Z., & Başar, T. (2021). Multi-Agent Reinforcement Learning: A Selective Overview of Theories and Algorithms. *Studies in Systems, Decision and Control*, 325, 321–384. https://doi.org/10.1007/978-3-030-60990-0_12
- Zhang, M., Zhao, J., Dai, X., & Li, X. (2023). Extraction and Analysis of Chemical Compositions of Natural Products and Plants. *Separations*, 10(12). <https://doi.org/10.3390/separations10120598>
- Zhu, H. (2006). A role-based architecture for intelligent agent systems. *Proceedings - DIS 2006: IEEE Workshop on Distributed Intelligent Systems - Collective Intelligence and Its Applications*, 2006(June), 354–362. <https://doi.org/10.1109/DIS.2006.5>
- Zitzler, E., Brockhoff, D., & Thiele, L. (2007). The hypervolume indicator revisited: On the design of pareto-compliant indicators via weighted integration. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4403 LNCS, 862–876. https://doi.org/10.1007/978-3-540-70928-2_64

BIODATA PENULIS




Dr.(c) Eka Puji Agustini, S.Kom, M.Kom, saat ini tengah menempuh pendidikan pada Program Doktor Sistem Informasi di Universitas Diponegoro, yang berlokasi di Semarang, 50241, Indonesia. Tidak hanya sebagai Mahasiswa, saat ini juga berkontribusi sebagai Dosen tetap di Fakultas Sains dan Teknologi, Universitas Bina Darma di Palembang, 30761, Indonesia. Perjalanan akademiknya di Universitas Bina Darma dimulai sejak ia meraih gelar Sarjana dalam Ilmu Komputer pada

tahun 2002. Kemudian pada tahun 2014 yang dilanjutkan dengan pencapaian gelar Magister pada bidang Ilmu Komputer, Universitas Bina Darma. Saat ini fokus pada peminatan riset di bidang ilmu komputer, khususnya Artificial Intelligence (AI).



Prof. Dr. Rahmat Gernowo, M.Si. merupakan Guru Besar di Fakultas Sains dan Matematika (FSM) Universitas Diponegoro (Undip) dengan keahlian di bidang Geofisika dan Sains Atmosfer. Beliau menyelesaikan pendidikan Sarjana (S1) di Universitas Gadjah Mada pada tahun 1991 dengan gelar Doktorandes, kemudian melanjutkan studi Magister Sains (S2) di Institut Teknologi Bandung (ITB) dan lulus pada tahun 2001. Pendidikan Doktor (S3) juga ditempuh di Institut Teknologi Bandung dan diselesaikan pada tahun 2009. Saat ini, Prof. Rahmat menjabat sebagai Ketua Program Studi Doktor Energi di Universitas Diponegoro. Dalam kiprah akademiknya, beliau aktif melakukan penelitian di bidang geofisika, atmosfer, dan pengembangan sistem informasi ilmiah. Karya-karya ilmiahnya telah memberikan kontribusi penting dalam pengembangan ilmu pengetahuan, khususnya pada kajian pemodelan fisika atmosfer serta penerapan sains data untuk studi kebumihan.



Dr. Kurnianingsih, S.T., M.T. Lahir di Kota Semarang pada tahun 1979. Pendidikan formal dimulai jenjang pendidikan S-1 Universitas Telkom Bidang Keilmuan Teknik Informatika, lulus pada 2001, melanjutkan studi S-2 di Universitas Sumatera Utara Bidang Keilmuan Teknik Elektro, lulus pada 2011, kemudian mendapatkan gelar doktor pada 2018 dari Universitas Gadjah Mada Bidang Keilmuan Teknik Elektro. Saat ini sebagai Dosen program

Magister Sains Terapan Politeknik Negeri Semarang. Mata kuliah yang diampu adalah Pengantar Big Data, pengantar kecerdasan buatan, pengantar teknologi informasi, pembelajaran mesin, pembelajaran mesin. Penulis juga aktif dalam berbagai riset, publikasi artikel ilmiah serta menjadi pemakalah seminar. Penulis terpilih menjadi Chair IEEE Indonesia Section. IEEE (*Institute of Electrical and Electronics Engineers*) merupakan organisasi profesi Internasional terbesar yang terdiri dari engineers, scientist, dan students.

Buku **Penerapan Multi-Agent Systems (MAS) & Multi-Objective Optimization (MOO): Pendekatan Ekstraksi Bahan Alami** membahas penerapan teknologi komputasi cerdas untuk mengoptimalkan proses ekstraksi bahan alami, khususnya ekstraksi senyawa bioaktif dari Moringa oleifera. Proses ekstraksi memiliki tantangan yang kompleks karena melibatkan banyak parameter, seperti suhu, waktu, pH, penggunaan pelarut, konsumsi energi, serta kualitas hasil ekstrak. Oleh karena itu, buku ini menawarkan pendekatan berbasis data melalui integrasi Multi-Agent Systems (MAS) dan Multi-Objective Optimization (MOO) sebagai solusi untuk menghasilkan proses ekstraksi yang lebih efisien, adaptif, dan berkelanjutan.

Melalui konsep MAS, buku ini menjelaskan bagaimana agen-agen cerdas dapat bekerja secara otonom, berkomunikasi, berkoordinasi, dan mengambil keputusan dalam mengatur proses ekstraksi. Sementara itu, pendekatan MOO digunakan untuk menyelesaikan persoalan optimasi yang memiliki beberapa tujuan sekaligus, seperti memaksimalkan hasil ekstraksi, meningkatkan kualitas produk, meminimalkan waktu proses, serta mengurangi penggunaan energi dan pelarut. Pembahasan disusun secara sistematis, mulai dari konsep dasar MAS, sejarah dan arsitekturnya, prinsip koordinasi dan negosiasi, hingga teknik optimasi multi-objektif beserta metrik evaluasinya.

Buku ini juga dilengkapi dengan pembahasan integrasi MAS-MOO dalam proses ekstraksi berbasis data, simulasi, evaluasi kinerja, serta perbandingan metode menggunakan indikator seperti Hypervolume (HV) dan Inverted Generational Distance (IGD). Dengan penyajian yang teoritis sekaligus aplikatif, buku ini dapat menjadi referensi bagi mahasiswa, dosen, peneliti, dan praktisi industri yang ingin memahami penerapan sistem optimasi cerdas dalam ekstraksi bahan alami. Kehadiran buku ini diharapkan dapat mendorong pengembangan proses ekstraksi yang lebih efisien, ramah lingkungan, hemat sumber daya, dan berbasis inovasi teknologi.

Diterbitkan oleh

