

**KOMPARISASI ANTARA SUBTRACTIVE CLUSTERING DAN ADAPTIVE
NEURO-FUZZY DALAM MEMPREDIKSI EMISI KARBONDIOKSIDA
(STUDI KASUS DI PERUSAHAAN ALCOHOL PS. MADUBARU)**

SKRIPSI

**Diserahkan kepada Program Reguler
Untuk Memenuhi Persyaratan gelar Teknik Industridi
Universitas Islam Indonesia**



Nama : Mohammad Rais Rusyadi
No Mahasiswa : 09522222

**FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2017**

PERNYATAAN


Demi Allah, saya akui skripsi ini adalah hasil kerja saya sendiri kecuali kutipan dan ringkasan yang masing-masing dari mereka yang telah saya jelaskan sumbernya. Jika di masa depan dapat membuktikan bahwa pengakuan saya ini tidak benar dan melanggar peraturan hukum tertulis dan hak kekayaan intelektual maka saya bersedia bahwa sertifikat yang telah saya terima ditarik oleh Universitas Islam Indonesia

Yogyakarta, 09 Maret 2017

Moh Rais Rusyadi

PERSETUJUAN PEMBIMBING

**“KOMPARISASI ANTARA SUBTRACTIVE CLUSTERING DAN ADAPTIVE
NEURO-FUZZY DALAM MEMPREDIKSI EMISI KARBONDIOKSIDA
(STUDI KASUS DI PERUSAHAAN ALCOHOL PS. MADUBARU)”**



Disusun Oleh:

Nama : Mohammad Rais Rusyadi
No Mahasiswa : 09522222

Yogyakarta, 09 Maret 2017

Pembimbing

Prof. Dr. Ir. R. Chairul Shaleh. M.Sc.

LEMBAR PENGESAHAN PENGUJI

**KOMPARISASI ANTARA SUBTRACTIVE CLUSTERING DAN ADAPTIVE
NEURO-FUZZY DALAM MEMPREDIKSI EMISI KARBONDIOKSIDA
(STUDI KASUS DI PERUSAHAAN ALCOHOL PS. MADUBARU)**

TUGAS AKHIR

Oleh :

Nama : Moh Rais Rusyadi
No Mahasiswa : 09522222

Telah dipertahankan di depan sidang penguji sebagai satu syarat untuk memperoleh gelar
Sarjana Strata-1 Teknik Industri
Yogyakarta, Maret 2017

Tim Penguji

Prof. Dr. Ir. R. Chairul Shaleh. M.Sc.
Ketua

Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D.
Anggota 1

Nashrullah Setiawan, S.T., M.Sc.
Anggota 2

Mengetahui,
Ketua Program Studi Teknik Industri
Fakultas Teknologi Industri
Universitas Islam Indonesia

Yuli Agusti Rochman, S.T., M.Eng.

DEDIKASI

Saya mendedikasikan skripsi ini :

*" Untuk Ayahku dan Ibuku H.M.Chamid dan Hj.Darbanatul Jannah " Kalianlah alasan
untuk selalu bersemangat dan motivasiku untuk menyelesaikan segala masalah yang
selalu datang dalam hidup. You are my everything..*

*" Untuk keluarga saya " Walaupun kalian sangat menyebalkan dalam mendorong untuk
menyelesaikan skripsi ini tapi kalianlah yang terbaik...*

"Untuk semua yang berjasa dalam hidup saya" matur suwun..

MOTTO

"Jadilah kamu manusia yang pada kelahiranmu semua orang tertawa bahagia, tetapi hanya kamu sendiri yang menangis; dan pada kematianmu semua orang menangis sedih, tetapi hanya kamu sendiri yang tersenyum."

PERSEMBAHAN



Assalamu'alaikumWr.Wb.

Dengan karunia Allah SWT akhirnya tesis berjudul "Komparisasi Antara Subtractive Clustering Dan Adaptive Neuro-Fuzzy Dalam Memprediksi Emisi Karbondioksida; Studi Kasus di Perusahaan Alcoh Ps.Madubaru" bisa diselesaikan dengan baik.

Tujuan dari penyusunan skripsi ini adalah Pemenuhan sebagai parsial Persyaratan untuk tingkat Teknik Industri, Program Reguler, Universitas Islam Indonesia. Dengan penyelesaian Skripsi ini, pada kesempatan ini kami ingin mengucapkan terima kasih kepada:

1. Ibu saya Hj. Darbanatul Jannah.
2. Ayah saya H. M. Chamid.
3. Dekan Program Reguler Universitas Islam Indonesia.
4. Kepala Departemen Teknik Industri dan seluruh staf, Program Reguler, Universitas Islam Indonesia.
5. Prof. R. Chairul Saleh. MSc. sebagai pembimbing saya yang selalu memberikan semua arah dan motivasi untuk membuat skripsi ini lebih baik.
6. Semua pihak yang tidak dapat disebutkan satu persatu.

Saya menyadari bahwa pernyataan ini masih ada kekurangan, dan karena itu saya mohon untuk memberikan kritik dan saran untuk baik di masa depan. Saya berharap laporan ini dapat bermanfaat bagi kita semua. Amin.

Wassalamu'alaikumWr.Wb

Yogyakarta, 09 Maret 2017

Penulis

Moh. Rais Rusyadi

ABSTRAKSI

Penelitian ini melakukan perbandingan pengembangan model antara Subtractive Clustering dengan Adaptive Neuro-Fuzzy Inference System (ANFIS) untuk memprediksi emisi CO₂. Model prediksi ini dibangun berdasarkan atribut yang datang dari seluruh konsumsi energi dalam produksi termasuk konsumsi energi listrik, dan konsumsi batubara. Kinerja Subtractive Clustering dan ANFIS dapat diukur dengan menggunakan Root Mean Square Kesalahan (RMSE). Model yang diusulkan diperiksa dengan menggunakan set data primer yang dikumpulkan dari Perusahaan Alkohol di Bantul, Indonesia. Kumpulan data ini dibagi menjadi data training 60% dan data testing 40%. Hasil penelitian menunjukkan bahwa perbandingan antara Subtractive Clustering dan ANFIS memberikan RMSE yang memiliki selisih yang sangat kecil. Sehingga hampir tidak ada perbedaan selisih kesalahan dari perhitungan model. Model yang diusulkan memberikan kontribusi pengetahuan dan kesadaran tentang standar manufaktur hijau, salah satunya adalah tidak adanya polusi lingkungan selama proses produksi.

Kata kunci: Subtractive Clustering, Adaptive Neuro-Fuzzy Inference System, Prediksi, RMSE, emisi CO₂..

DAFTAR ISI

PERNYATAAN.....	ii
PERSETUJUAN PEMBIMBING	iii
LEMBAR PENGESAHAN PENGUJI.....	iv
DEDIKASI.....	v
MOTTO	vi
PERSEMBAHAN	vii
ABSTRAKSI	viii
DAFTAR ISI.....	ix
BAB I.....	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah.....	6
1.4 Tujuan Penelitian.....	7
1.5 Manfaat Penelitian.....	7
1.6 Sistematika Penulisan.....	8
BAB II	9
LATAR BELAKANG.....	9
2.1 Penelitian Induktif	9
2.2 Penelitian Deduktif.....	12
2.2.1 Manufaktur Hijau	12
2.2.2 Emisi CO2.....	13
2.2.3 Sumber Data.....	14
2.2.4 Logika Fuzzy	15
2.2.5 Adaptive Neuro-Fuzzy Inference System	17
2.2.6 <i>Subtractive Clustering</i>	20
2.2.7 Parameter Evaluasi.....	24
BAB III.....	25
METODOLOGI PENELITIAN	25
3.1 Lokasi dan Metode Penelitian	25
3.2 Proses Produksi	26
3.2.1 Unit Pemasakan (Cooking Unit)	26

3.2.2	Unit Fermentasi	30
3.2.3	Unit Destilasi	32
3.3	Pengumpulan Data	33
3.4	Perhitungan Emisi Karbondioksida.....	33
3.5	Pengolahan Data.....	34
3.6	Data Training dan Data Testing	35
3.7	Model <i>Subtractive Clustering</i> dan ANFIS	37
3.7.1	Model ANFIS-Sugeno	38
3.7.2	Parameter Evaluasi.....	48
BAB IV		50
PENGUMPULAN DAN PENGOLAHAN DATA		50
4.1	Data Penelitian	50
4.2	Hasil Penelitian	53
4.2.1	Model <i>Subtractive Clustering</i>	53
4.2.2	Model Adaptive Neuro-Fuzzy Inference System Design	61
BAB V		71
PEMBAHASAN		71
5.1	<i>Subtractive Clustering</i>	71
5.2	Model Perhitungan ANFIS.....	72
BAB VI		74
KESIMPULAN DAN SARAN		74
6.1	Kesimpulan.....	74
6.2	Saran.....	75
REFERENSI		76
LAMPIRAN		80

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pemanasan Global atau Global Warming adalah kenaikan suhu secara menyeluruh terhadap atmosfer, laut, dan daratan bumi. Pemanasan Global ini dapat menyebabkan dampak yang buruk bagi bumi. Suhu rata-rata global pada permukaan Bumi telah meningkat 0.74 ± 0.18 °C (1.33 ± 0.32 °F) selama seratus tahun terakhir. Intergovernmental Panel on Climate Change (IPCC) menyimpulkan bahwa, “sebagian besar peningkatan suhu rata-rata global sejak pertengahan abad ke-20 kemungkinan besar disebabkan oleh meningkatnya konsentrasi gas rumah kaca akibat aktivitas manusia” (IPCC, 2014).

Global warming adalah masalah yang timbul terutama akibat terlalu banyak gas rumah kaca di atmosfer, sehingga gas ini menyelimuti bumi dan memantulkan radiasi panas kembali ke permukaan bumi. Kehadiran gas rumah kaca di atmosfer menjadi terlalu berlebih karena adanya pembakaran bahan bakar fosil seperti batu bara, gas dan minyak bumi atau pembukaan lahan dan pembakaran hutan. Gas CO₂ memiliki resiko yang paling besar dalam perubahan iklim karena gas ini terus terakumulasi di atmosfer dalam jumlah yang besar. Sektor industri yang berkembang saat ini merupakan salah satu penyumbang CO₂ terbesar di bumi.

Karbon dioksida ditempatkan di daftar atas ancaman terhadap lingkungan. Penggunaan energi adalah sumber terbesar emisi gas. Ini mewakili sekitar 65 persen dari seluruh emisi gas, dan tingkat emisi diperkirakan akan meningkat jika tidak ada langkah-langkah akurat yang dilaksanakan. Selama dekade terakhir, pertumbuhan konsumsi energi dan emisi karbon dioksida lebih penting daripada tren pertumbuhan industri, itu berarti bahwa pengurangan konsumsi energi dan emisi karbon dioksida atau sedikit tidak

menyebabkan penurunan pertumbuhan industri. Mengingat pertumbuhan sektor manufaktur, diharapkan ada kekhawatiran serius tentang emisi karbon dioksida (Lin et al, 2014). Dalam upaya untuk meminimalkan emisi karbon dioksida, ada kebutuhan dari proses manufaktur baru, yang lebih dikenal sebagai manufaktur hijau yang cocok pembangunan berkelanjutan strategis (Paul et al, 2014). Oleh karena itu perlu dilakukan penelitian mengenai tingginya tingkat gas CO₂ yang dihasilkan dari sektor industri.

Penelitian ini dilakukan di sebuah pabrik alkohol bernama Madukismo (PS). Pabrik ini telah beroperasi sejak tahun 1959 di bawah organisasi bernama PT. Madu Baru. PS Madukismo menggunakan produk sampingan dari produksi gula yang disebut sebagai molase yang dapat dikonversi menjadi etanol. Kapasitas produksi PS Madukismo adalah sekitar 20.000 liter per hari atau 7.000.000 liter per tahun. Tingginya produksi PS Madukismo sangat signifikan terhadap emisi karbon dioksida, karena produksi alkohol menggunakan molase sebagai bahan baku dan proses yang akan melepaskan karbon dioksida melibatkan pemanfaatan energi yang sangat besar. Ini akan menjadi perhatian besar untuk meminimalkan emisi karbon dioksida karena akan berdampak pada lingkungan. Semua perusahaan manufaktur yang menggunakan energi besar untuk melakukan produksi dikategorikan sebagai perusahaan yang menghasilkan emisi CO₂ (Hektor dan Bernstonn 2008) termasuk industri spiritus. Peningkatan energi untuk melakukan produksi akan meningkatkan emisi CO₂, juga spiritus yang digunakan oleh para konsumen sehari-hari sebagai bahan bakar lampu, api pada eksperimen di laboratorium. Dalam mendukung upaya tersebut, perusahaan dapat mulai untuk memprediksi jumlah karbon dioksida yang dihasilkan dan menganalisis variabel yang dipengaruhi, sehingga perusahaan bisa memperkirakan dan mengontrol emisi karbon dioksida.

Ada beberapa metode yang umum digunakan untuk prediksi emisi karbon dioksida seperti jaringan syaraf tiruan (JST) yang telah dilakukan oleh (Chairul Saleh et al, 2015) dan penerapan pendekatan simulasi untuk memprediksi emisi karbon dalam industri gula (Chairul Shaleh et al, 2015). Metode lain untuk memprediksi emisi karbon dioksida disebut model abu multi-variabel baru (GM (1, N) (Wu et al, 2014). Sebuah

multi-variabel Model abu-abu baru (GM (1, N) digunakan untuk pemodelan dan peramalan emisi CO₂ di BRICS (Brasil, Rusia, India, China, dan Afrika Selatan) negara. Penelitian lain diterapkan Model Logistik atau Regresi Logistik untuk memprediksi emisi karbon dioksida dengan menganalisis hubungan antara variabel diskrit dan sekelompok variabel penjelas yang telah dilakukan oleh (Wu dan Wei, 2010).

Selain itu, untuk memprediksi emisi karbon dioksida, dibutuhkan metode yang dapat digunakan untuk memprediksi dan menghasilkan hasil yang memuaskan. Pada saat ini, peneliti telah menggunakan Subtractive Clustering.

Subtractive clustering merupakan perpanjangan dari *mountain clustering* diusulkan pada tahun 1995 oleh Chiu (Zhang, 2012). Sebelumnya, Yager dan Filev berhasil mengembangkan *mountain clustering* untuk analisis dalam mencari *cluster center*. Meskipun metode ini efektif untuk data dengan dimensi yang rendah, namun akan menjadi tidak efisien apabila diterapkan pada data dengan dimensi yang tinggi. Seperti yang telah dipaparkan oleh Chiu (1995), *subtractive clustering* merupakan salah satu metode yang relative sederhana dan cukup efektif untuk memperkirakan pusat *cluster* berdasarkan ukuran kepadatan titik data, dimana titik-titik data tersebut merupakan kandidat dari pusat *cluster* yang akan dicari

Ada beberapa metode estimasi yang biasa digunakan dan biasanya digolongkan ke dalam dua kategori (Wang dan Fu, 2005).

1. Metode Kualitatif.

Estimasi menggunakan metode kualitatif memerlukan pertimbangan dan penilaian dari para ahli. Metode ini secara khas digunakan, sebab data yang ada tidak representatif untuk melaksanakan proses estimasi.

2. Metode Kuantitatif

Metode ini digunakan jika data yang tersedia adalah cukup dan representatif. Beberapa model yang digolongkan sebagai metode kuantitatif adalah model regresi, model ekonometrik, dan analisis rangkaian waktu.

Bagaimanapun, metode yang dijelaskan di atas tetap mempunyai banyak kekurangan, karakteristik metoda kualitatif adalah subjektif, sehingga menjadikan metode ini kurang ilmiah. Kemudian, kekurangan metode kuantitatif adalah perlunya gudang database yang besar dan ini tidak dapat mengakomodir estimasi CO₂ yang dipengaruhi oleh banyak variabel. Oleh karena itu diperlukan metode estimasi yang lebih baik dan teliti dalam rangka mendapatkan hasil memuaskan. Salah satu metode penilaian yang belakangan ini sering digunakan adalah teknik komputasi lunak, model ini digunakan untuk menghitung dengan menyerupai inteligensi manusia dan mempunyai kemampuan untuk melakukan penyelidikan dalam lingkungan tidak pasti (Sumathi dan Surekha 2010).

Salah satu teknik komputasi lunak adalah Adaptive Neuro-Fuzzy Inference System (ANFIS), yang merupakan kombinasi Logika Fuzzy dan Jaringan Neural Artifisial. (Jang et al., 1997) menjelaskan bahwa ANFIS adalah suatu feed-forward jaringan neural tiruan di mana masing-masing lapisan adalah suatu neuro-fuzzy system component. ANFIS mempunyai kaidah algoritma belajar hibrida yang mengintegrasikan metoda penurunan lereng dan metode square paling sedikit menuju trainparameters. Dalam provagative algoritma maju, isyarat fungsional tampil ke depan sampai lapisan 4, dan parameter diidentifikasi melalui metode square paling sedikit untuk memperkecil kesalahan pengukuran. Dalam provagative mundur, parameter premis diperbarui dengan metoda penurunan gradien. ANFIS digunakan untuk memetakan karakteristik input yang digunakan untuk memasukkan fungsi-fungsi keanggotaan (MF's), memasukkan MF ke sekumpulan aturan if-then, aturan-aturan untuk sekumpulan karakteristik output, karakteristik output ke output MF's, dan output MF's ke output keluaran bernilai tunggal atau suatu keputusan yang berkaitan dengan output itu (Karami et al., 2013; Khoshnevisan et al., 2014).

Hosoz et al., (2013) menyatakan bahwa ANFIS dapat diaplikasikan untuk memprediksi emisi CO₂ dari mesin diesel yang menggunakan berbagai bahan bakar. Emisi CO₂ dalam studi ini didasarkan pada capaian variabel mesin, temperatur udara, spesifikasi bahan bakar, dan Efisiensi Brake Thermal. Hasil penelitian ini dapat dilihat

bahwa ANFIS mempunyai kemampuan baik untuk memecahkan estimasi emisi CO₂ dengan variabel-variabel yang telah diketahui. Studi lain dilakukan oleh (Noori et al. 2009) yang melakukan percobaan perbandingan antara model ANFIS dan Artificial Neural Network (ANN) untuk memprediksi konsentrasi karbon monoksida (CO) yang terdapat di atmosfer Bumi sehari-hari. Hasil dari penelitian ini menunjukkan bahwa model ANFIS memperoleh hasil terbaik jika dibandingkan dengan model ANN.

Penelitian komparasi adalah penelitian yang bersifat membandingkan. Penelitian ini dilakukan untuk membandingkan persamaan dan perbedaan dua atau lebih fakta dan sifat objek yang diteliti berdasarkan kerangka pemikiran tertentu. Menurut Nazir (2005 : 58) penelitian komparatif adalah sejenis penelitian deskriptif yang ingin mencari jawaban secara mendasar tentang sebab-akibat, dengan menganalisis faktor-faktor penyebab terjadinya ataupun munculnya suatu fenomena tertentu.

Berdasarkan banyak penelitian yang disebutkan di atas, terbukti bahwa ada begitu banyak metode yang baik untuk memprediksi emisi karbon dioksida. Penelitian ini akan membandingkan antara 2 teori yang dilakukan dalam menghitung estimasi emisi gas karbondioksida di PS MADUKISMO yaitu perhitungan yang dilakukan dengan metode ANFIS dan perhitungan yg dilakukan dengan metode Subtractive Clustering.

1.2 Rumusan Masalah

Berdasar pada latar belakang di atas, emisi CO₂ sebagai salah satu penyebab pemanasan global, menjadi isu yang mempengaruhi semua faktor. Sehingga untuk memecahkan permasalahan ini, diperlukan suatu metode yang dapat memprediksi emisi CO₂ dalam rangka menentukan tindakan yang bijak untuk mengurangi emisi CO₂. Berdasar pada penjelasan dalam studi latar belakang, pertanyaan riset dapat dirumuskan dan dibangun dengan pertanyaan-pertanyaan berikut:

- a. Bagaimana cara mengukur gas emisi CO₂ dengan menggunakan model estimasi Adaptive Neuro-Fuzzy Inference System dan *Subtractive Clustering* ?
- b. Bagaimana perbandingan hasil pengukuran gas emisi CO₂ dengan menggunakan Adaptive Neuro-Fuzzy Inference System dengan *Subtractive Clustering* ?

1.3 Batasan Masalah

Setiap penelitian perlu dibatasi. Karena itu, penelitian akan dilakukan pada hal-hal terbatas berikut:

1. Studi ini dilakukan pada industri spiritus di PS Madukismo, Bantul, Indonesia.
2. Studi ini berfokus pada emisi CO₂ dalam produksi spiritus di PS Madukismo.
3. Studi ini berfokus untuk memprediksi emisi CO₂ dengan menggunakan Adaptive Neuro Fuzzy Inference System dan *Subtractive Clustering*.
4. Pengumpulan data hanya terpusat untuk memprediksi emisi CO₂ yang mencakup energi listrik dan pembakaran batubara.
5. Proses kalkulasi dilakukan dengan menggunakan perangkat lunak MATLAB.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah:

1. Untuk memprediksi emisi CO₂ dengan menggunakan model Adaptive Neuro-Fuzzy Inferendce System dan *Subtractive Clustering*.
2. Untuk mengukur pencapaian estimasi model Adaptive Neuro-Fuzzy Inference System dan *Subtractive Clustering* mengenai emisi CO₂.
3. Untuk mengetahui perbedaan yang terjadi mengenai emisi CO₂ antara model Adaptive Neuro-Fuzzy Inference System dengan *Subtractive Clustering*.

1.5 Manfaat Penelitian

- a. Untuk penulis

Untuk menerapkan pengetahuan yang diperoleh selama penelitian, khususnya dalam meningkatkan pengetahuan tentang emisi karbon dan manufaktur hijau.

- b. Untuk akademik

Tesis ini dapat digunakan sebagai sarana referensi di perpustakaan Universitas Islam Indonesia mengenai masalah yang berkaitan dengan prediksi, emisi karbon dioksida dan penerapan manufaktur hijau.

- c. Untuk perusahaan

Hasil penelitian ini dapat memberikan informasi kepada perusahaan mengenai jumlah total emisi karbon dioksida yang dikeluarkan oleh perusahaan, analisis tentang variabel yang mempengaruhi perubahan emisi karbon dioksida, sehingga mudah-mudahan itu bisa digunakan sebagai sarana pertimbangan dalam melaksanakan konsep manufaktur hijau.

1.6 Sistematika Penulisan

BAB 1 KATA PENGANTAR

Berisi latar belakang masalah, perumusan masalah, pembatasan masalah, tujuan riset, dan sistematika penulisan tesis.

BAB 2 TINJUAN PUSTAKA

Dalam bab ini akan diberikan literatur riset pada studi deduktif dan induktif. Studi-studi induktif untuk menentukan studi-studi literatur riset sebelumnya. Selain itu, bab ini juga menguraikan latar belakang teori.

BAB 3 METODE PENELITIAN

Bab ini berkaitan dengan desain metodologi riset untuk membangun dan mengembangkan model-model, perangkat keras dan lunak, juga prosedur. Data riset akan dinilai, dan digunakan analisa untuk mengembangkan model Adaptive Neuro-Fuzzy Inference System dan *Subtractive Clustering* tentang emisi CO₂.

BAB 4 HASIL PENELITIAN

Bab ini memperkenalkan percobaan dan metode-metode pengujian yang digunakan untuk mengembangkan model Adaptive Neuro-Fuzzy Inference System dan *Subtractive Clustering*.

BAB 5 PEMBAHASAN

Bab ini membahas analisa-analisa hasil dan perbandingan antara eksperimentasi model Adaptive Neuro Fuzzy Inference System dengan model *Subtractive Clustering*.

BAB 6 KESIMPULAN DAN SARAN

Bab ini menyajikan kesimpulan hasil studi, kontribusi riset, dan saran untuk kebutuhan riset-riset lebih jauh.

REFERENSI

LAMPIRAN

BAB II

LATAR BELAKANG

Studi literatur akan dijelaskan dalam bab ini. Studi literatur dibagi menjadi dua bagian, yaitu induktif dan deduktif. Penelitian induktif diperoleh dari jurnal, penelitian terdahulu, dan majalah yang mempublikasikan secara berkala. Penelitian deduktif diperoleh dari buku mengenai teori dasar yang mendukung penelitian keseluruhannya. Kedua studi literatur ini digunakan untuk studi kontemporer.

2.1 Penelitian Induktif

Sektor industri merupakan penyumbang utama dari total emisi karbon dioksida di dunia (Oh et al, 2014). Pesatnya pertumbuhan di sektor industri menyebabkan efek buruk untuk rumah kaca. Emisi karbondioksida berada di bagian atas daftar ancaman terhadap lingkungan. Penggunaan energi terbesar yang diwakili oleh emisi CO₂ ini mewakili sekitar 65% dari seluruh emisi gas dan tingkat emisi yang diperkirakan akan meningkat jika tidak ada tindakan penanganan yang tepat. Perkembangan yang berlebihan di sektor industri membawa pengaruh buruk terhadap efek lingkungan. Pada pertumbuhan sektor manufaktur, diharapkan akan ada perhatian serius tentang emisi karbon dioksida (Lin et al, 2014). Dengan memprediksi karbon dioksida, memahami dan menganalisis variabel yang mempengaruhi emisi karbon dioksida bisa membantu perusahaan dalam upaya untuk mengurangi emisi karbon dioksida.

Saat ini, terdapat beberapa metode yang digunakan untuk memprediksi emisi karbon dioksida, yang memiliki batas yang berbeda, sebagai salah satu contoh seperti yang dibuat oleh (Abdelfatah et al, 2013) memprediksi karbon dioksida dengan menggunakan kecerdasan berkelompok. Dalam studi mereka, Particle Swarm Optimization (PSO) digunakan untuk menganalisis emisi CO₂ dunia memprediksi

berdasarkan pengkomsumsiannya. Penelitian lain yang menyeluruh mengenai emisi CO₂ adalah penelitian yang dilakukan oleh (Baareh, 2013). Penelitian ini difokuskan pada pemecahan prediksi emisi CO₂. Dalam penelitian ini, dia mengusulkan metode jaringan saraf tiruan (JST). Hasil model ANN yang diusulkan menunjukkan bahwa JST mampu menghasilkan kemampuan prediksi yang tinggi. Empat input dianggap dalam penelitian seperti minyak global, gas alam, batubara, dan konsumsi energi primer untuk membangun sistem. Prediksi dari emisi CO₂ juga dilakukan oleh (Wu et al, 2014). Sebuah Model Novel Multi-Variable (GM (1, N) digunakan untuk pemodelan dan peramalan emisi CO₂ di negara BRICS (Brasil, Rusia, India, China, dan Afrika Selatan). Penelitian mereka juga digunakan secara berlawanan oleh Accumulated Generating Operator (GOM (1, N), yang cocok untuk sampel peramalan terkecil (terbatas). Hal ini juga dapat digunakan untuk peramalan emisi CO₂ dalam kasus nyata lainnya untuk lebih memastikan efektivitasnya.. Metode lain disebut sebagai Logistic Model atau Regresi Logistik disarankan oleh seorang matematikawan Belanda, PE Verhulst (1838) yang dapat digunakan untuk memprediksi dengan menganalisis hubungan antara variabel diskrit dan sekelompok variabel penjelas yang telah dilakukan oleh (Wu dan Wei, 2010). Berdasarkan penelitian mereka, emisi karbon dari 30 wilayah administratif provinsi di Cina 2012-2020 dapat diperkirakan, dan intensitas karbon yang dikurangi juga dapat dihitung. Penelitian lain dilakukan dengan menggunakan analisis statistik dan prediksi emisi karbon dioksida di beberapa negara bagian timur dan utara India. Sebuah prosedur statistik, yaitu, metode Least Square dan Analisis Regresi Linear Berganda (MLRA) diterapkan untuk pengembangan model (Basak dan Nandi, 2014). Terdapat metode lain untuk prediksi yaitu dengan *Subtractive Clustering* dan Adaptif Neuro-Fuzzy Inference System (ANFIS).

Fuzzy Clustering adalah metode pengelompokan berdasarkan derajat keanggotaan yang mencakup himpunan *Fuzzy* sebagai dasar pembobotan bagi pengelompokan. Masing-masing data diberikan nilai kemungkinan untuk bisa bergabung ke setiap kelompok yang ada, yang berarti data tidak mutlak atau tegas menjadi anggota satu kelompok saja, tetapi juga mempunyai nilai kemungkinan untuk menjadi anggota

kelompok yang lain dengan drajat keanggotaan yang berbeda-beda. Data dengan derajat keanggotaan terbesar menunjukkan kecenderungan yang tinggi suatu data untuk menjadi anggota kelompok tertentu (Jang *et al.*, 1997).

Menurut Kusumadewi dan Purnomo (2004) *Subtractive Clustering* merupakan algoritma yang tidak terawasi, dalam artian jumlah *cluster* yang akan dibentuk belum diketahui. Pada prinsipnya metode ini didasarkan atas ukuran densitas (potensi) titik-titik data dalam suatu ruang (variabel). Titik dengan jumlah tetangga terbanyak akan dipilih sebagai pusat *cluster* ini akan dikurangi densitasnya. Kemudian algoritma akan memilih titik lain yang memiliki tetangga terbanyak untuk dijadikan sebagai pusat *cluster* yang lain. Hal ini dilakukan sampai semua titik diuji.

Pemodelan untuk proses kimia juga dapat dilakukan dengan pendekatan phenemenological (first principles) atau dengan pendekatan empirical (Istadi, 2006). Pengembangan dari permodelan proses dengan phenemenological memiliki banyak kesulitan dalam prakteknya. Oleh karena itu, diperlukan mencari pendekatan alternatif dari pemodelan proses ini, yaitu dengan Artificial Neural Network (ANN). Kekuatan dari ANN adalah struktur yang umum dan memiliki kemampuan untuk mempelajari dari data historikalnya (Desai dkk, 2008).

Adaptive Neuro-Fuzzy Inference System (ANFIS) adalah model arsitektur yang fungsional mirip dengan model rule base fuzzy Sugeno (Kusumadewi, 2006). ANFIS juga memiliki arsitektur yang sama dengan jaringan saraf dengan sedikit pembatasan. Dengan kata lain ANFIS adalah kombinasi mekanisme sistem inferensi fuzzy yang digambarkan dalam arsitektur jaringan saraf, selain memiliki kemampuan untuk mengekstrak pengetahuan yang merupakan karakteristik dari logika fuzzy, ANFIS juga memiliki kemampuan untuk melakukan pembelajaran yang merupakan karakteristik dari Artificial Neural Network (ANN).

ANFIS digunakan secara luas dalam estimasi atau perkiraan masalah. (Noori et al., 2009) menggunakan ANFIS untuk memprediksi konsentrasi harian emisi CO₂ yang ada di atmosfer bumi, di sisi lain (Hosoz et al., 2013) menggunakan ANFIS untuk memprediksi jumlah emisi CO₂ yang dihasilkan dari penggunaan mesin diesel.

Berdasarkan penelitian di atas dapat disimpulkan bahwa ANFIS dan *Subtractive Clustering* adalah model yang dapat digunakan dalam proses prediksi, tetapi tidak ada studi yang secara khusus menunjukkan kemampuan ANFIS dan *Subtractive Clustering* dalam memprediksi emisi CO₂ di lini produksi dari industri manufaktur. Jadi tujuan dari penelitian ini adalah untuk menerapkan model ANFIS dan *Subtractive Clustering* untuk memprediksi emisi CO₂ serta membandingkan hasil yang diperoleh dari 2 metode yang digunakan.

2.2 Penelitian Deduktif

penelitian deduktif akan menjelaskan mengenai emisi gas, manufaktur hijau, jejak karbon, Fuzzy Logic, Neural Networks, ANFIS, *Subtractive Clustering* dan variabel yang digunakan dalam Model ANFIS dan *Subtractive Clustering*.

2.2.1 Manufaktur Hijau

Manufaktur hijau merupakan pembahasan yang lebih penting dalam era sekarang ini. Beberapa tahun terakhir, proses manufaktur diharapkan untuk memahami manufaktur hijau karena masalah sosial dan lingkungan (Govindan, 2015). Oleh karena itu, praktek kegiatan manufaktur hijau wajib dilakukan untuk menyeimbangkan kejadian yang terjadi saat ini, bahkan proses manufaktur hijau tidak bisa dibuat pengecualian. Perindustrian selalu dikaitkan dengan fabrikasi yang mendorong pembangunan ekonomi di suatu negara. Tetapi industri selalu melakukan kegiatan yang menyebabkan kerugian di lingkungan seperti polusi dan limbah yang berasal dari proses manufaktur dan dampaknya dapat merusak ekosistem bumi. Sebuah industri yang baik adalah industri

yang telah dibangun tanpa mencemari lingkungan, atau yang memiliki tingkat polusi paling sedikit dan mampu mengatasi masalah limbah produksi. Industri yang menerapkan manufaktur hijau akan memiliki kinerja yang ramah lingkungan dan efisien dalam hal ekonomi.

Green Manufacturer (Manufaktur Hijau) adalah peningkatan ekonomi, seluruh sistem, dan pendekatan integrasi untuk pengurangan dan penghapusan semua aliran limbah yang berhubungan dengan desain, manufaktur, penggunaan dan pembuangan produk dan bahan (Bulent et al 2013). Standarisasi untuk mencapai manufaktur hijau itu harus tidak terjadi masalah dalam keamanan, tidak ada ancaman kesehatan pada operator dan pengguna produk, tidak ada pencemaran lingkungan, daur ulang limbah, dan pembuangan limbah selama proses produksi yang sebanyak mungkin (Gao et al, 2009). Pelaksanaan Manufaktur Hijau di lingkungan meliputi pengurangan limbah padat/cair, pengurangan sumber daya, penurunan konsumsi/bahan berbahaya/beracun berbahaya, dan pengurangan emisi. Sampah dan emisi sebagai hasil dari proses produksi dapat merusak ekosistem yang ada di bumi, selain itu bisa merusak kesehatan manusia. Oleh karena itu, sebuah inovasi diciptakan sebagai upaya untuk meminimalisasi efek negatif yang muncul dari pembangunan industri yang disebut sebagai manufaktur hijau (*Green Manufacture*). Lebih sederhana, manufaktur hijau termasuk kesadaran lingkungan di bidang manufaktur. Umumnya, tiga "R" yaitu produksi ulang (*remanufacture*), mengurangi (*reduce*), dan menggunakan kembali (*recycle*) adalah salah satu strategi utama manufaktur hijau, yang mencakup kegiatan seperti mengurangi volume sampah berbahaya, meminimalkan konsumsi pendingin sementara mesin, dan menghitung energi yang tepat campuran untuk memastikan sumber energi berkelanjutan (Dornfeld et al, 2013).

2.2.2 Emisi CO₂

Gas rumah kaca (GRK) adalah gas di atmosfer yang memiliki fungsi untuk menyerap radiasi inframerah dan juga berpartisipasi dalam perubahan Iklim (Kementerian Lingkungan Hidup, 2012). Dengan meningkatnya aktivitas manusia mulai dari era pra-

industri, saat ini emisi gas rumah kaca meningkat secara signifikan, itu menyebabkan pemanasan dan perubahan iklim global bumi. Gas yang dikategorikan sebagai gas rumah kaca adalah gas-gas yang mempengaruhi peningkatan emisi CO₂ secara langsung atau tidak langsung. Dalam konvensi PBB tentang perubahan iklim, Perubahan Iklim Konvensi Kerangka Kerja PBB tentang Perubahan Iklim (UNFCCC), hasil keputusan menjelaskan bahwa ada enam jenis gas rumah kaca, karbon dioksida (CO₂), Metana (CH₄), NitrousOxide (N₂O), sulfur heksafluorida (SF₆), Perfluorocarbons (PFC) dan hidrofluorokarbon (HFC). Antara enam gas rumah kaca dari, gas CO₂ adalah yang paling berkontribusi terhadap pemanasan global. Lebih dari 75% dari komposisi gas rumah kaca di atmosfer CO₂, sehingga untuk mengurangi perubahan iklim, hal pertama yang harus dilakukan adalah untuk mengurangi jumlah emisi CO₂ yang dihasilkan dari berbagai kegiatan. Shi et al, (2012).; Roos & Tjörnemo (2011) menjelaskan bahwa itu adalah sekitar lima miliar ton gas CO₂ lebih dari kapasitas serap dari biosfer.

Perusahaan industri adalah pusat untuk membuka jalan menuju masyarakat yang rendah karbon, karena sebagian besar input dan emisi karbon GHG dihasilkan dari produksi industri (Hoffmann dan Busch, 2008) . Suatu sumber emisi gas rumah kaca di sektor manufaktur adalah gas rumah kaca yang dihasilkan emisi dari penggunaan energi. Jenis-jenis energi yang digunakan dalam industri saat ini adalah energi fosil dan non-fosil. Energi yang digunakan sebagai bahan bakar untuk menjalankan mesin di perusahaan.

2.2.3 Sumber Data

Sumber data yang digunakan untuk memprediksi emisi CO₂ dalam penelitian ini adalah dari sumber semua energi termasuk energi listrik dan pembakaran batu bara, pertama harus diubah menjadi bagian dari emisi CO₂. Energi listrik yang digunakan untuk menjalankan motor listrik, pencahayaan, dan untuk tujuan lain yang berkaitan dengan proses produksi. Di sisi lain, batubara digunakan untuk boiler uap yang digunakan dalam distilasi energi unit. Energi listrik dan batubara dipilih sebagai variabel karena mereka langsung mempengaruhi perubahan emisi CO₂. Pembakaran bahan bakar fosil

menghasilkan CO₂ dari proses produksi dan transportasi dari pemasok ke konsumen (Wiedmann et al., 2006).

2.2.4 Logika Fuzzy

Logika Fuzzy adalah cara yang sesuai untuk memetakan ruang input ke dalam ruang output (Kusumadewi, 2003). Logika Fuzzy bekerja dengan fleksibel, ia dapat melaksanakan pemodelan fungsi linier kompleks dan mempunyai toleransi untuk ketidaktepatan data.

2.2.4.1 Himpunan Fuzzy

Teori himpunan Fuzzy diperkenalkan oleh Lotfi A. Zadeh pada 1965, himpunan fuzzy adalah perluasan teori himpunan klasik. Dalam teori himpunan klasik (Crisp) suatu elemen dalam himpunan A, hanya mempunyai 2 keanggotaan yang mungkin, yaitu menjadi anggota A atau tidak. Hanya ada dua tingkat keanggotaan dalam himpunan klasik, yaitu $\mu_A(x) = 1$ yang berarti x merupakan anggota A, dan $\mu_A(x) = 0$ untuk x bukan anggota A, konsep klasik ini berbeda dengan Logika Fuzzy yang menggunakan nilai-nilai dalam interval 0 dan 1. Suatu nilai dalam interval disebut derajat keanggotaan atau nilai keanggotaan yang ditandai dengan $\mu_A(X)$. Derajat keanggotaan adalah suatu nilai yang menunjukkan berapa banyak tingkat keanggotaan dari suatu elemen (x) dalam himpunan A.

2.2.4.2 Operator Dasar Zadeh untuk Operasi Himpunan Fuzzy

Ada beberapa operator dasar yang didefinisikan secara khusus untuk menggabungkan dan memodifikasi himpunan-himpunan Fuzzy (Kusumadewi, 2003). Nilai keanggotaan sebagai hasil dari dua himpunan disebut Firing Strength, penjelasan 3 operator dasar yang dibuat oleh Zadeh adalah sebagai berikut:

a. Operator DAN

Operator ini berhubungan dengan operasi irisan pada himpunan. Hasil operasi menggunakan operator DAN diperoleh dengan mengambil nilai keanggotaan terkecil di antara elemen-elemen dalam himpunan itu.

$$\mu_{A \cap B} = \min(\mu_A(x), \mu_B(y)) \dots\dots\dots (\text{Eq. 2.1})$$

b. Operator ATAU

Operator ini berhubungan dengan operasi union pada himpunan. Hasil menggunakan operator ATAU diperoleh dengan mengambil keanggotaan terbesar di antara elemen-elemen dalam himpunan.

$$\mu_{A \cup B} = \max(\mu_A(x), \mu_B(y)) \dots\dots\dots (\text{Eq. 2.2})$$

c. Operator BUKAN

Operator ini berhubungan dengan operasi imbalan dalam himpunan. Hasil menggunakan operator BUKAN diperoleh dengan mengurangi nilai keanggotaan elemen-elemen dengan nilai 1.

$$\mu_A = 1 - \mu_A(x) \dots\dots\dots (\text{Eq. 2.3})$$

2.2.4.3 Fuzzy Inference System

Fuzzy Inference System adalah satu set aturan dan metode kesimpulan yang tergabung dalam suatu struktur bersambung yang kemudian akan dilatih dan di adaptasi (Nikola, 2007). Metode ini sangat efisien, terutama jika digunakan untuk mengidentifikasi fungsi non-linear. Suatu contoh Fuzzy Inference System adalah metode sugeno. Metode ini diperkenalkan oleh Takagi-Sugeno Kang pada 1985. Dalam metode ini, himpunan fuzzy bukan merupakan output sistem (akibat). Akibat dari metode TSK untuk Fuzzy Inference System adalah persamaan linier dengan variabel yang sesuai dengan variabel input. Inilah penjelasan tentang Fuzzy Inference System menggunakan metoda TSK.

a. Model Fuzzy-Sugeno Orde-0

Model Sugeno-Fuzzy order-0 secara umum adalah:

JIKA (x_1 adalah A_1) $\bullet$ (x_2 adalah A_2) $\bullet$ (x_3 adalah A_3) $\bullet$ $\bullet$ (x_n adalah A_n) $\bullet$
MAKA $z=k$(Eq. 2.4)

Dengan A_n adalah suatu himpunan Fuzzy, n sebagai anteseden, simbol $\bullet$ adalah operator fuzzy (DAN atau ATAU) dan k adalah konstanta sebagai output atau akibat.

b. Model Fuzzy-Sugeno Orde-1

Model Sugeno Fuzzy order-1 secara umum adalah:

JIKA (x_1 adalah A_1) $\bullet$ $\bullet$ (x_n adalah A_n) $\bullet$ MAKA $z= p_1 \cdot x_1 + \dots + p_n \cdot x_n + q$(Eq. 2.5)

Dengan A_n adalah himpunan fuzzy ke n sebagai anteseden, lambang $\bullet$ adalah operator fuzzy (DAN atau ATAU), P_n adalah konstanta, n dan q juga konstanta pada sistem output. De-fuzzi-fikasi dilakukan dengan menghitung nilai rata-rata dengan formula berikut :

$$Z = \frac{\sum_{k=1}^M \alpha_k Z_k}{\sum_{k=1}^M \alpha_k} \dots\dots\dots (Eq. 2.6)$$

2.2.5 Adaptive Neuro-Fuzzy Inference System

Adaptive Neuro-Fuzzy Inference System (ANFIS) adalah kombinasi dari mekanisme Fuzzy Inference System yang diuraikan dalam neural architecture network, di samping mempunyai kemampuan untuk mengekstrak pengetahuan yang merupakan karakteristik logika fuzzy, ANFIS juga mempunyai kemampuan untuk melaksanakan pembelajaran yang merupakan karakteristik ANN. ANFIS digunakan secara luas untuk memecahkan masalah estimasi dan prediksi.

2.2.5.1 ANFIS Architecture


Arsitektur ANFIS secara fungsional sama dengan aturan fuzzy yang didasarkan pada model TSK orde-1 (Kusumadewi, 2006). Arsitektur ANFIS juga serupa dengan jaringan neural yang mempunyai fungsi radial dengan batasan tertentu. Model TSK model aturan dasar sebagai berikut:

JIKA (x_1 adalah A_1) • ... • (x_n adalah A_n) • MAKA $z = p_1 * x_1 + \dots + p_n * x_n + q$... (Eq. 2.7)

Jika firing strength untuk kedua aturan adalah w_1 dan w_2 , dan himpunan fuzzy $A_i, B_i, i = 1, 2$, maka rata-rata tertimbang dihitung dengan formula berikut:

$$y = \frac{w_1 y_1 + w_2 y_2}{w_1 + w_2} = \bar{w}_1 y_1 + \bar{w}_2 y_2 \dots \dots \dots (E.q. 2.8)$$

Jaringan ANFIS pada gambar di bawah terdiri atas lapisan-lapisan berikut:



Gambar 2.1 Arsitektur ANFIS

- Masing-masing neuron pada lapisan dasar melakukan penyesuaian ke arah parameter fungsi-fungsi aktivasi. Output tiap neuron adalah derajat keanggotaan yang diberikan oleh inplut fungsi-fungsi keanggotaan, yaitu: $\mu_{A1}(x_1)$, $\mu_{B1}(x_2)$, $\mu_{A2}(x_1)$, $\mu_{B2}(x_2)$. Fungsi-fungsi keanggotaan diberikan sebagai berikut:

$$\mu_x = \frac{1}{1 + \left(\frac{x-c}{a}\right)^{2b}} \dots \dots \dots (Eq. 2.9)$$

dengan a, b, dan c sebagai parameter, secara khas nilai parameter b = 1, c adalah nilai rata-rata dan a adalah nilai deviasi standar. Parameter-parameter ini disebut parameter premis. Jika nilai parameter-parameter ini berubah, bentuk kurva yang dihasilkan juga akan berubah.

- b. Masing-masing neuron pada lapisan kedua adalah neuron tetap, dan nilai output adalah hasil input dari lapisan dasar. Pada lapisan kedua, operator yang digunakan pada umumnya adalah operator DAN. Masing-masing simpul diperkenalkan sebagai firing strength nomor aturan i.
- c. Masing-masing neuron dalam lapisan ketiga adalah hasil kalkulasi perbandingan dari firing strength (w).

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \text{ with } i = 1, 2 \dots \dots \dots (\text{Eq. 2.10})$$

Hasil-hasil dalam lapisan ini disebut firing strength yang dinormalisir.

- d. Masing-masing neuron pada lapisan keempat adalah adaptif menuju simpul output.

$$\bar{w}_i f_1 = \bar{w}_i (C_{i1}x_1 + C_{i2}x_2 + C_{i0}) \dots \dots \dots (\text{Eq. 2.11})$$

$\bar{w}_1$ adalah firing strength yang dinormalisir pada lapisan ketiga dan { C_{i1} , C_{i2} , C_{i0} } merupakan parameter-parameter dalam neuron-neuron ini. Parameter-parameter dalam lapisan ini disebut parameter-parameter akibat.

- e. Masing-masing neuron pada lapisan kelima adalah simpul yang merupakan jumlah semua input.

2.2.5.2 Pembelajaran Algoritma Hybrid

Parameter output yang terjadi ketika parameter premis diperoleh, adalah suatu kombinasi linier parameter-parameter akibat, yakni:

$$y = \frac{w_1}{w_1 + w_2} y_1 + \frac{w_2}{w_1 + w_2} y_2 \dots \dots \dots (\text{Eq. 2.12})$$

$$= \bar{w}_1 (c_{11}x_1 + c_{12}x_2 + c_{10}) + \bar{w}_2 (c_{21}x_1 + c_{22}x_2 + c_{20})$$

$$= (\bar{w}_1 x_1) c_{11} + (\bar{w}_1 x_2) c_{12} + \bar{w}_1 c_{10} + (\bar{w}_2 x_1) c_{21} + (\bar{w}_2 x_2) c_{22} + \bar{w}_2 c_{20}$$

y output linier menuju parameter C_{ij} (i = 1,2 and j = 0,1,2).

Algoritma hybrid digunakan untuk mengeset parameter-parameter Cij maju, dan parameter-parameter $\{a_i, b_i, c_i\}$ mundur. Ketika parameter-parameter diset maju, input jaringan akan bergerak maju sampai lapisan keempat, dan parameter-parameter Cij akan diidentifikasi dengan menggunakan metode least-squares. Sedangkan pada langkah balik, sinyal kesalahan akan menyebar mundur, dan parameter-parameter $\{a_i, b_i, c_i\}$ akan ditingkatkan dengan metode *Gradient-Descent*. Fungsi-fungsi algoritma hybrid untuk mengidentifikasi parameter-parameter linier dengan mengkombinasikan *steepest descent* (SD) dan *least square error* (LSE).

2.2.6 *Subtractive Clustering*

Subtractive clustering merupakan perpanjangan dari *mountain clustering* diusulkan pada tahun 1995 oleh Chiu (Zhang, 2012). Sebelumnya, Yager dan Filev berhasil mengembangkan *mountain clustering* untuk analisis dalam mencari *cluster center*. Meskipun metode ini efektif untuk data dengan dimensi yang rendah, namun akan menjadi tidak efisien apabila diterapkan pada data dengan dimensi yang tinggi. Seperti yang telah dipaparkan oleh Chiu (1995), *subtractive clustering* merupakan salah satu metode yang relative sederhana dan cukup efektif untuk memperkirakan pusat *cluster* berdasarkan ukuran kepadatan titik data, dimana titik-titik data tersebut merupakan kandidat dari pusat *cluster* yang akan dicari.

Konsep dari *subtractive clustering* adalah menentukan daerah-daerah dalam suatu variabel yang memiliki densitas tinggi terhadap titik-titik disekitarnya. Titik dengan jumlah tetangga terbanyak akan dipilih sebagai pusat *cluster*. Titik yang sudah terpilih menjadi pusat *cluster* ini kemudian akan dikurangi densitasnya. Kemudian algoritma akan memilih titik lain yang memiliki tetangga terbanyak untuk dijadikan pusat *cluster* yang lain. Hal ini akan dilakukan berulang-ulang hingga semua titik diuji (Sri Kusumadewi dan Hari Purnomo, 2013).

Metode *subtractive clustering* tergolong metode *unsupervised clustering* dimana jumlah pusat *cluster* tidak diketahui. Metode ini menggunakan data sebagai kandidat dari

pusat *cluster*, sehingga beban komputasi tergantung dari jumlah data dan tidak bergantung dari dimensi data. Jumlah pusat *cluster* yang dicari ditentukan melalui proses iterasi untuk mencari titik-titik dengan jumlah tetangga terbanyak. Apabila terdapat n buah data yaitu $x_1, x_2, \dots, x_n$ dan dengan menganggap bahwa data-data tersebut sudah dalam keadaan normal, maka densitas suatu titik dapat dihitung dengan persamaan berikut

$$D_k = \sum_{j=1}^n e^{\left(\frac{|x_k - x_j|}{\left(\frac{r_a}{2}\right)^2}\right)} \dots\dots\dots (2.14)$$

Dimana

D_k : densitas titik ke-k

x_k : titik ke-k

r_a : konstanta positif

Dengan demikian, suatu titik data akan memiliki densitas yang besar jika titik tersebut memiliki banyak tetangga. Setelah menghitung densitas tiap-tiap titik, maka titik dengan densitas tertinggi akan terpilih menjadi pusat kelompok. Misalkan x_{cl} adalah titik yang terpilih menjadi pusat kelompok dan D_{cl} adalah ukuran densitasnya, selanjutnya densitas dari titik-titik di sekitarnya akan dikurangi dengan persamaan berikut

$$D_k = D_k - D_{cl} e^{\left(\frac{|x_k - x_j|}{\left(\frac{r_a}{2}\right)^2}\right)} \dots\dots\dots (2.15)$$

Dimana r_b adalah konstanta positif. Hal ini berarti bahwa titik-titik yang berada dekat dengan pusat kelompok x_{cl} akan mengalami pengurangan densitas secara besar-besaran. Hal ini akan berakibat titik-titik tersebut memiliki kemungkinan yang kecil untuk menjadi pusat kelompok berikutnya. Nilai r_b menunjukkan suatu lingkungan yang mengakibatkan titik-titik berkurang ukuran densitasnya. Nilai r_b diperoleh dari persamaan berikut

$$r_b = squash\ factor \times r_a \dots\dots\dots (2.16)$$

Biasanya *squash factor* bernilai 1.500. Dengan demikian r_b bernilai lebih besar dibandingkan r_a . Setelah densitas tiap -tiap titik diperbaiki, selanjutnya akan dicari pusat kelompok yang kedua yaitu x_{c2} . Setelah x_{c2} diperoleh, ukuran densitas tiap titik data akan diperbaiki kembali. Langkah-langkah ini dilakukan berulang-ulang sampai semua titik teruji. Pada implementasinya bisa digunakan 2 bilangan sebagai faktor pembanding, yaitu *accept ratio* dan *reject ratio*. Apabila hasil bagi antara potensi tertinggi suatu titik data dengan potensi tertinggi yang pertama kali diperoleh pada iterasi pertama lebih besar daripada *accept ratio*, maka titik data tersebut diterima sebagai pusat kelompok baru. Apabila hasil bagi antara potensi tertinggi suatu titik data dengan potensi tertinggi yang pertama kali diperoleh pada iterasi pertama lebih kecil daripada *accept ratio* namun lebih besar daripada *reject ratio*, maka titik data tersebut baru akan diterima sebagai pusat kelompok yang baru jika titik tersebut terletak pada jarak yang cukup jauh dengan pusat kelompok yang lainnya. Namun, jika hasil bagi antara potensi tertinggi suatu titik data dengan potensi tertinggi yang pertama kali diperoleh pada iterasi pertama lebih kecil daripada *accept ratio* maupun *reject ratio*, maka titik tersebut tidak akan diperhitungkan lagi untuk menjadi pusat kelompok yang baru.

Tahapan *subtractive clustering* menurut Sri Kusumadewi dan Hari Purnomo (2013) adalah sebagai berikut:

1. Input data yang akan dicluster: x_{ij} , dengan $i=1,2,\dots,n$; dan $j=1,2,\dots,m$
2. Tetapkan nilai:
 - a. r_j (jari-jari setiap atribut data); $j=1,2,\dots,m$
 - b. q (*squash factor*)
 - c. *accept ratio*
 - d. *reject ratio*
 - e. X_{min} (minimum data diperbolehkan)
 - f. X_{max} (maksimum data diperbolehkan)
3. Normalisasi

$$x_{ij} = \frac{x_{ij} - X_{min_j}}{X_{max_j} - X_{min_j}}$$

$$i=1,2,\dots,n; j=1,2,\dots,m$$

4. Tentukan potensi awal tiap-tiap titik data
 - a. $i = 1$
 - b. Kerjakan hingga $i = n$,
 - i. $T_j = x_{ij}$ (T_i merupakan data ke- i atribut ke- j), $j=1,2,\dots,m$
 - ii. Hitung:

$$Dist_{kj} = \left(\frac{T_j - x_{kj}}{r_j} \right), j=1,2,\dots,m; k=1,2,\dots,n$$
 - iii. Potensi awal

Jika $m=1$, maka:

$$Di = \sum_{k=1}^n e^{-4(Dist^2_{kj})}$$

Jika $m>1$, maka:

$$Di = \sum_{k=1}^n e^{-4\left(\sum_{j=1}^m Dist^2_{kj}\right)}$$
 - iv. $i = i + 1$
5. Cari titik dengan potensi tertinggi
 - a. $M = \max[Di | i=1,2,\dots,n]$
 - b. $h = 1$, sedemikian hingga $Di = M$
6. Tentukan pusat *cluster* dan kurangi potensinya terhadap titik-titik di sekitarnya
 - a. Center = []
 - b. $V_j = X_{hj}, j=1,2,\dots,m$
 - c. $C = 0$ (jumlah *cluster*)
 - d. Kondisi = 1
 - e. $Z = M$
 - f. Kerjakan jika (kondisi $\neq 0$) dan ($Z \neq 0$):
 - 1) Kondisi = 0 (sudah tidak ada calon pusat baru lagi)
 - 2) Rasio = Z/M
 - 3) Jika rasio $>$ rasio penerimaan, maka kondisi = 1; (ada calon pusat baru)

- 4) Jika tidak, maka rasio > rasio penolakan, (calon pusat baru akan diterima sebagai pusat jika keberadaannya akan memberikan keseimbangan terhadap data-data yang letaknya cukup jauh dengan pusat *cluster* yang telah ada)
7. Kembalikan pusat *cluster* dari bentuk ternormalisasi ke bentuk semula

$$\text{Center}_{ij} = \text{Center}_{ij} * (\text{Xmax}_j - \text{Wmin}_j) + \text{Xmin}_j$$
8. Hitung nilai sigma *cluster*
 1. $\sigma_j = r_j \times \frac{\text{Xmax}_j - \text{Xmin}_j}{\sqrt{8}}$

2.2.7 Parameter Evaluasi

Ada dua pertimbangan utama untuk mengukur akurasi estimasi. Yaitu tingkat perkembangan dan identifikasi model. Pengukuran akurasi diperlukan untuk menentukan nilai parameter. Kemudian setelah penilaian model telah dikembangkan dan digunakan untuk menghasilkan estimasi di masa mendatang, adalah perlu untuk mengakses akurasi secara periodik, untuk ketelitian, untuk mendeteksi defisiensi dalam model yang mungkin terjadi di lain waktu. Untuk studi yang memusat pada perbandingan beberapa model estimasi, umumnya menggunakan tiga index evaluasi, yaitu Mean Absolute Percentage Error (MAPE), Mean Square Errors (MSE) dan Root Mean Square Error (RMSE). Sedangkan studi ini ANFIS dan *Subtractive Clustering* menggunakan RMSE.

BAB III

METODOLOGI PENELITIAN

Bab ini mencakup penjelasan metodologi penelitian, yang terdiri dari studi berencana seperti: objek penelitian, proses produksi, metode penelitian, pengambilan data, langkah-langkah perhitungan emisi karbon dioksida, dan alat-alat penelitian.

3.1 Lokasi dan Metode Penelitian

Lokasi penelitian ini dilakukan di PS Madukismo yang terletak di Desa Padokan, Tirtonirmoto, Kabupaten Kasihan Bantul. Wilayah PT. Madubaru PS. Madukismo mencakup 5000 - 6000 ha dengan kapasitas produksi rata-rata 20.000 liter alkohol / hari atau 7.000.000 liter per tahun, PS Madukismo menghasilkan alkohol prima dan alkohol teknis. Perdana alkohol memiliki tingkat alkohol minimal 95% dan tidak mengandung aldehida. Sedangkan, alkohol teknis memiliki tingkat alkohol di bawah 95% dan mengandung aldehida. Selanjutnya, PS Madukismo juga memproduksi minyak Fussel, minyak Fussel adalah kombinasi dari non-etanol alkohol, seperti propanol, butanol, pentano, heksanol, isoamil alkohol, dan sebagainya. Minyak Fussel dijual sebagai bahan baku untuk produksi esensi atau penyedap makanan. Output produksi yang tinggi dari PS Madukismo menegaskan output tinggi emisi karbon. Sebagai peningkatan produksi spritus, itu juga meningkatkan jumlah emisi CO₂ yang dihasilkan. Kemudian, perusahaan dianjurkan untuk memahami tentang bahaya dan dampak dari efek Gas Rumah Kaca.

Pada 2012, Kementerian Lingkungan Hidup menegaskan bahwa setiap perusahaan wajib memiliki pengetahuan tentang bagaimana untuk menghitung gas rumah kaca yang dihasilkan dari proses produksi, dan juga dapat digunakan untuk menentukan grafik kecenderungan emisi tahunan yang diproduksi oleh suatu perusahaan dalam jangka waktu tertentu. Oleh karena itu, perusahaan dapat menentukan emisi gas tren output dalam

interval waktu tertentu yang dapat digunakan sebagai acuan untuk perbaikan terus-menerus untuk mengatasi tingginya jumlah emisi CO₂ yang dihasilkan.

Ruang lingkup penelitian adalah memprediksi emisi karbon dioksida selama proses produksi di sekitar area produksi berdasarkan konsumsi energi..


3.2 Proses Produksi

Proses produksi di PS Madukismo melewati empat tahap yaitu, Unit ramuan, Unit pembibitan bakteri, Unit fermentasi, dan unit distilasi.

3.2.1 Unit Pemasakan (Cooking Unit)

Cooking unit adalah proses pembuatan adonan yang mencakup dua jenis proses, yaitu proses pembuatan adonan untuk bakteri penyemaian dan yang kedua adalah untuk fermentasi. Fungsi Unit racikan adalah mengubah molase ke dalam medium fermentasi yang sesuai untuk khamir untuk membuatnya tumbuh optimal, khamir adalah organisme mikro-sel dikhususkan dengan ukuran sekitar 5-20 mikro yang digunakan sebagai mikroba dalam produksi alkohol.

Proses memasak meliputi proses ekstraksi pH dan proses pengenceran. Masukan molase asli di PS Madukismo masih pada batas yang terkonsentrasi yaitu $\pm 90^{\circ}\text{brix}$ atau 1,4074 kg / lt. Brix adalah jumlah larutan padat yang jelas dalam setiap 100 gram solusi.




Gambar 3.1 skema proses pemasakan

3.2.1.1 Proses Pembuatan Adonan untuk Pembibitan Bakteri

Proses ini dilakukan dalam tangki 3A dan 3B. Pada tahap awal, tangki diisi dengan 7600 liter air bersih sementara itu diaduk dalam mixer tuangkan 1400 L molase, total volume dalam tangki adalah 9000L. Gelar brix yang dicapai dalam tangki 3A adalah 14 °brix. Jika level mencapai lebih dari 14 °brix, air akan ditambahkan, sebaliknya jika tingkat mencapai kurang dari 14 obrix, beberapa tetes tebu akan ditambahkan. Adonan dalam tangki 3A akan transfer ke tangki bakteri level 3 (tangki 22) dan tangki bakteri utama (tangki 25).


Tank 3B mengalami tahap proses yang sama seperti tank 3A, tapi obrixin tank ini 18obrix, volume air 7200 L, dan 1800 L dipompa molase, adonan di dalam tangki ini akan transfer ke tangki 25.



Gambar 3.2 Skema proses produksi adonan untuk pembibitan bakteri

3.2.1.2 Proses Pembuatan Adonan Untuk Fermentasi

Proses ini dilakukan dalam tangki 8 yang memiliki tiga tangki sendiri, 8/1, 8/2, dan 8/3 tangki. Tahap ini menggunakan 3200 L air tawar dan 5800 L molase, sehingga total volume di setiap tangki berisi 9000 L. Adonan dalam tangki ini akan ditransfer ke tangki fermentasi yang tangki 26.



Gambar 3.3 Proses pembuatan adonan untuk fermentasi

3.2.1.3 Bagian Penempatan Bakteri

Proses penempatan bakteri meliputi penempatan bakteri pemula di laboratorium dan di pabrik yang bertujuan untuk mempersiapkan agarkhamir dapat mengoptimalkan produksi alkohol dalam tahap fermentasi.

3.2.1.4 Penempatan Bakteri Awal Di Dalam Laboratorium

Tahap ini bertujuan untuk memperbanyak khamir, produksi bakteri di laboratorium dilakukan dalam 48 jam, setelah itu, bakteri solusi siap untuk ditempatkan di dalam tangki di pabrik.

3.2.1.5 Penempatan Bakteri Awal Di Dalam Gudang

Tank yang digunakan dalam proses pembenihan bakteri:

1. Karlsberger Tank (Tank 19).
2. Bacteria Tank First Level (Tank 20).
3. Bacteria Tank Second Level (Tank 21).
4. Bacteria Tank Third Level (Tank 22).
5. Main Bacteria Tank (Tank 25).

Proses pembibitan bakteri di dalam tangki 19, 20, dan 21 dilakukan hanya sekali dalam setiap awal proses. Jika tidak, proses pada tangki 22 dan 25 akan berjalan terus menerus. Proses di masing-masing tangki dijelaskan sebagai berikut;

a. Karlsberger Tank (Tank 19)

Isi dengan 10 L molase adonan yang ditransfer dari tangki 3A, dan tambahkan 2 L penyemaian dari laboratorium, sehingga total volume dalam tangki adalah 12 L. Berikutnya, bibit menganggur selama 24 jam untuk mikroba berkembang biak. Kemudian, tangki 19 konten akan ditransfer ke tangki bakteri tingkat pertama (tangki 20).

b. Bakteri Tank Tingkat Pertama (Tank 20)

Diisi dengan 12 L bakteri dari tangki 19 diisi dan menambahkan 36 tetes L dari tangki 3A ditambahkan, sehingga total volume adalah 48 L. Solusinya adalah menunggu dalam tangki 20 selama 24 jam sebelum dipindahkan ke tangki bakteri tingkat kedua (tangki 21).

c. Bakteri Tank Tingkat II (Tank 21)

Diisi dengan 432 L molase dari tangki 3A dan menambahkan 48 bakteri L dari tangki 20, sehingga total volume adalah 480 L. Menganggur solusi dalam tangki selama 24 jam sebelum ditransfer to bacteria tingkat ketiga tangki (tangki 22).

d. Bakteri Tank Tingkat Ketiga (Tank 22)


Terdiri dari tiga tangki diatur secara paralel, tangki 22/1, 22/2, 22/3 dan. Tahap pengolahan di dalam tangki ini 480 L bakteri dari tangki 21 dialirkan ke tangki 22/1, maka 2530 L molasses dari tangki 3A ditambahkan sehingga total volume adalah 3010 L, dan menganggur selama 16 jam. Gelar brix dalam tangki 22/1 akan menurun karena khamir will aktif dalam 16 jam proses idle. Ini menurun dari 14 obrix to 13 obrix.

Setelah bakteri di dalam tangki 22/1 telah malas selama 16 jam, 350 L ditransfer ke tangki 22/2 dan sisanya mentransfer 2660 L ke tangki 25. Hal yang sama digunakan sebagai tangki 22/1 ditujukan untuk tangki 22/2, sehingga tangki 22/2 Volume akan 3010 L. Proses yang sama untuk tangki 22/3, sehingga tangki 22/1, 22/2, 22/3 dan akan

digunakan secara bergantian dan masing-masing tangki akan memiliki kekosongan selama 8 jam.

e. Main Bakteri Tank (Tank 25)

Terdiri dari tangki 25/1, 25/2, 25/3 dan, tahap pengolahan akan diilustrasikan sebagai berikut; 2660 bakteri L ditransfer dari tangki ke tangki 22 25/1 dengan penambahan 6340 L adonan dari tangki 3A dan 9000 L molasses dari tangki 3B, total volume adalah 18000 L. Menganggur solusi dalam tangki ini selama 16 jam sebelum transfer ke tangki 25/2 dan 25/3 dengan proses yang sama seperti tank 25/1. Tank ini bekerja bergantian, sehingga setiap tangki akan memiliki kekosongan selama 8 jam.




gambar 3.4 Pembenihan bakteri awal dalam skema pabrik

3.2.2 Unit Fermentasi

Fungsi stasiun adalah untuk mengubah bahan baku molasses menjadi alkohol dengan tingkat 9-10%, ada 10 tangki fermentasi yang disebut sebagai tangki 26. 18000 bakteri L yang telah dikembangkan selama 16 jam di dalam tangki bakteri utama (Tank 25) ditransfer ke tangki fermentasi kemudian tambahkan 9000 L molasses dari tangki 8/1 dan menambahkan 9000 L air tawar, setelah 2 jam kemudian, 9000 L molasses dari tangki 8/2 dan 9000 L air tawar ditambahkan, 2 jam berikutnya menambahkan lagi 9000 L molase

dari tangki 03/08 dan 9000 L air tawar. Total volume 72.000 L, tahap terakhir tambahkan 3000 L air segar untuk membuat total volume ke 75000 proses L.

Fermentasi terjadi selama 60 jam. Proses fermentasi ditandai dengan tidak ada perubahan dalam tingkat brix sebesar 7 °brix dan mengandung 10% alkohol. Reaksi proses fermentasi dirumuskan sebagai berikut:



Dimana:

$C_6H_{12}O_6$ = Glucose $2C_2H_5OH$ = Ethanol

$2CO_2$ = Carbondioxide

Fokus pengumpulan data adalah stasiun fermentasi yang tangki 26 yang memiliki 10 tank. Pada reaksi kimia ini tahap yang terjadi mengakibatkan emisi CO₂.





Figure 3.5 Skema unit proses fermentasi

3.2.3 Unit Destilasi

Proses penyulingan adalah salah satu cara untuk memisahkan campuran yang terdiri dari dua atau lebih komponen berdasarkan perbedaan titik dengan bantuan pemanasan mendidih sehingga kita mendapatkan komponen yang diinginkan dalam keadaan yang lebih murni. Peralatan distilasi yang digunakan adalah:

1. 3 Kolom Maische yang beroperasi adalah dua kolom aktif dan satu kolom siaga.
2. Kolom Voorloop
3. Kolom Rektifizer
4. Kolom Nachloop

Perusahaan perlu untuk menggunakan satu jenis steam boiler fire tube yang menggunakan batubara sebagai bahan bakar. Untuk satu shift kerja (8 jam), dibutuhkan setidaknya sebanyak 6.498 kg batu bara dan air sebanyak 41-42 m³. Proses pemanasan menggunakan uap yang memiliki suhu 110-120 oC dan tekanan 0,5 - 0,8 kg / cm³. Hasil dari proses distilasi yang Teknik Alkohol dan Alkohol superhalus.



Gambar 3.6 Skema unit proses distilasi.

3.3 Pengumpulan Data

Dataset diambil langsung dari alkohol gosok PT. Madubaru. Dataset diambil dari perusahaan data historis tentang semua konsumsi energi yang digunakan dari awal sampai akhir proses produksi, termasuk energi listrik selama proses produksi di kilowatt jam (kWh), pembakaran batu bara di kilogram (Kg). Untuk CO2 data emisi diperoleh dari total yang dipancarkan CO2 dari konsumsi energi listrik dan batubara. Energi listrik yang digunakan untuk menjalankan motor listrik, pencahayaan, dan untuk tujuan lain yang berkaitan dengan proses produksi. Di sisi lain, batubara digunakan untuk boiler uap yang digunakan di unit destilasi.

Energi listrik dan batubara dipilih sebagai atribut karena mereka langsung mempengaruhi perubahan emisi CO2. Sebuah peningkatan konsumsi energi dan bahan bakar fosil listrik akan diikuti dengan peningkatan emisi CO2 (Raghuvanshi et al, 2006).

$$\begin{bmatrix} x_i \begin{bmatrix} \text{Electrical Energy} \\ \text{Burning Coal} \end{bmatrix} \end{bmatrix} y_i = [\text{Carbon Dioxide Emission}] \quad (\text{Eq 3.15})$$

$X_i = \text{Input Attributes} \qquad Y_i = \text{Output}$

3.4 Perhitungan Emisi Karbondioksida

Untuk menghitung emisi CO2 yang, seluruh konsumsi energi harus diubah dulu menjadi nilai emisi CO2 (kgCO2). Ada beberapa langkah untuk menerapkan ini, pertama adalah untuk mengkonversi nilai energi listrik menjadi nilai emisi CO2. Kedua adalah mengkonversi nilai konsumsi batubara menjadi nilai emisi CO2. Ketiga menjumlahkan nilai emisi CO2 dari konsumsi energi listrik dan konsumsi batubara. Konversi energi listrik diperoleh dengan mengalikan jumlah energi yang digunakan dan nilai kalor atau faktor emisi.

$$E_{CO2}^E = A_{(E)} \times EF_{(E)} \dots\dots\dots (\text{Eq 3.1})$$

Description:

$E_{CO_2}^E$ = Total CO₂emisi dari konsumsi energi listrik (kg.CO₂)

$A_{(E)}$ = Pemakaian energi listrik (kWh)

$EF_{(E)}$ = Faktor emisi listrik (kg/kWh)

Nilai faktor emisi untuk listrik mengacu pada faktor emisi yang telah ditetapkan oleh PLN. Nilai faktor emisi listrik yaitu sebesar 0,725 kg / kWh (DNPI, 2014). Jumlah CO₂ emisi pembakaran bahan bakar fosil hasil tergantung pada banyak dan jenis bahan bakar terbakar. Jumlah bahan bakar direpresentasikan sebagai data aktivitas sementara jenis bahan bakar yang diwakili oleh faktor emisi. Persamaan umum yang digunakan untuk memperkirakan emisi CO₂ dari batubara adalah sebagai berikut:

$$E_{CO_2}^C = A_{(c)} \times EF_{(c)} \dots \dots \dots (Eq 3.2)$$

Deskripsi:

$E_{CO_2}^C$ = CO₂ Emisi Dari PembakaranBahan Bakar (Kg.CO₂)

$A_{(c)}$ = Konsumsi Energi Coal (TJ)

$EF_{(C)}$ = Faktor Emisi (Kg/TJ)

Dimana A(c) harus dikonversi pertama sebagai

$$A_{(c)} = Q \times P_v \dots \dots \dots (Eq 3.3)$$

Q = Jumlah Energi Yang Digunakan Coal (Kg)

P_v = Nilai Kalori (TJ/Kg)

3.5 Pengolahan Data

pengolahan data (*data pre-processing*) adalah teknik data mining yang melibatkan mengubah data mentah ke dalam format yang dimengerti dan tepat. Di dunia nyata, ketika berbagai jenis data atau data yang sama dikumpulkan untuk sumber yang berbeda di satu tempat, maka beberapa data banyak mengalami penyimpangan seperti data yang hilang,

kebisingan, tidak konsisten atau bahkan outlier. Pengolahan data adalah metode yang terbukti memecahkan masalah tersebut. Tujuan dan sasaran dari pengolahan data digunakan untuk mengurangi ukuran ruang input, memperlancar hubungan, menormalkan data, mengurangi data outlier dan untuk mengekstrak fitur data. Ada banyak teknik pengolahan data, salah satunya adalah transformasi data.

Dalam transformasi data, data diubah atau dikonsolidasikan ke dalam bentuk yang sesuai untuk penelitian. Transformasi data dapat melibatkan berikut:

1. Normalization
2. Smoothing
3. Aggregation
4. Generalization of data.

Normalisasi nilai input untuk setiap atribut yang diukur dalam pelatihan akan membantu mempercepat tahap belajar. Data normalisasi digunakan untuk menyamakan data antara atribut untuk mendapatkan bobot yang sama dalam perhitungan setiap atribut. Formula untuk menormalkan data sebagai berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \dots \dots \dots (\text{Eq. 3.4})$$

Setelah semua pengolahan data dilakukan, data yang telah dinormalisasi akan di denormalisasi untuk mengembalikan data yang nyata, dan denormalisasi digunakan untuk membandingkan hasil dari data real.

$$X = X'(X_{max} - X_{min}) + X_{min} \dots \dots \dots (\text{Eq. 3.5})$$

3.6 Data Training dan Data Testing


Pendekatan pemodelan dengan menggunakan ANFIS dan *Subtractive Clustering* mirip dengan teknik identifikasi sistem lainnya. Langkah pertama adalah membuat hipotesis parameter struktur model. Langkah selanjutnya adalah untuk mengumpulkan data input dan output yang akan digunakan untuk pelatihan. Dalam langkah ini pemodelan akan bekerja dengan baik jika data pelatihan sepenuhnya mewakili semua fitur dari data, untuk

menjaga pengukuran kebisingan. Sehingga pilihan yang tepat untuk menggunakan data pengujian sebagai model validasi (Wang, 1994). Tujuan validasi model adalah untuk melihat seberapa baik model FIS memperkirakan kumpulan data nilai output. Sehingga data yang telah dikumpulkan akan dibagi menjadi dua segmen data, segmen pertama adalah kumpulan data pelatihan, maka segmen terakhir adalah pengujian data set. Mengatur data pengujian berguna untuk memeriksa kemampuan generalisasi dari sistem inferensi fuzzy yang dihasilkan.

Ada beberapa jenis persentase untuk membagi kumpulan data yang dikumpulkan dari pengamatan, data pelatihan 90% dan data 10% pengujian, data pelatihan 80% dan 20% data uji, data pelatihan 70% dan 30% data uji, 60 Data% pelatihan dan data pengujian 40%, jenis persentase dipilih berdasarkan pengukuran masalah yang terdapat dalam model (Jang, 1993) dalam penelitian ini penelitian memilih data training 60% dan 40% data uji.

3.7 Model *Subtractive Clustering* dan ANFIS

Pengembangan model menggunakan *Subtractive Clustering* dan ANFIS



Gambar 3.1 Pengembangan Model

Lihat Gambar. 3.1, langkah pengembangan model estimasi dibahas dalam sub-bagian berikutnya. Sebagai penjelasan singkat tentang langkah ini. Mengembangkan Model ANFIS dan *Subtractive Clustering* untuk memperkirakan emisi CO₂. Dalam rangka untuk melakukan percobaan, software MATLAB digunakan untuk mengembangkan model.

3.7.1 Model ANFIS-Sugeno

Pada penelitian ini, penulis akan menyelidiki tentang emisi CO₂ yang dihasilkan oleh PS. Madukismo dengan menggunakan model ANFIS, sehingga hasil emisi CO₂ dapat diprediksi.

3.7.1.1 Arsitektur ANFIS

Arsitektur ANFIS terdiri dari 5 struktur. Langkah yang harus dilakukan sebelum menentukan jumlah neuron di setiap struktur adalah menentukan aturan yang akan membangun. Penelitian ini akan membangun 2 aturan, dengan 2 input dan 1 output. Input yang digunakan adalah energi listrik dan batubara, sedangkan output adalah emisi CO₂.

1. IF x_1 is A_1 and x_2 is B_1 THEN $y_1 = C_{11}x_1 + C_{12}x_2 + C_{10}$
2. IF x_1 is A_2 and x_2 is B_2 THEN $y_1 = C_{21}x_1 + C_{22}x_2 + C_{20}$

Dimana x_1 = energi listrik, x_2 = coal (batu bara) and y_1 = CO₂ emisi.

Arsitektur jaringan ANFIS yang memiliki 2 variabel input dengan dua aturan adalah:




Figure 3.2Arsitektur jaringan ANFIS Sugeno Model dengan 2 aturan

3.7.1.2 Output Lapisan Pertama

Output dari lapisan pertama adalah derajat keanggotaan, dengan menggunakan nilai standar deviasi dan nilai rata-rata. Mean dan deviasi standar menjadi c awal dan akan menghitung dengan persamaan berikut:

$$\mu_x = \frac{1}{1 + \left(\frac{x - c}{a}\right)^{2b}} \dots \dots \dots (\text{Eq. 3.6})$$

Perhitungan akan terjadi derajat keanggotaan sebagai μ_{A1} , μ_{A2} , μ_{B1} , μ_{B2} . Jumlah masing-masing derajat keanggotaan adalah 86 data, sesuai dengan jumlah data, dan total derajat keanggotaan yang telah ditemukan adalah $86 \times 4 = 344$.

3.7.1.3 Output Lapisan Kedua

Setiap neuron di lapisan kedua node yang outputnya adalah hasil dari input tetap, lapisan ini menggunakan operator AND, setiap node mewakili menembak kekuatan dari aturan-i. Output lapisan kedua dihitung dengan mengalikan derajat keanggotaan.

$$W_1 = (\mu_{A1} \times \mu_{B1}) \dots \dots \dots (\text{Eq. 3.7})$$

$$W_2 = (\mu_{A2} \times \mu_{B2}) \dots \dots \dots (\text{Eq. 3.8})$$

3.7.1.4 Output Lapisan Ketiga

Setiap neuron dalam struktur ketiga adalah simpul tetap yang dibuat oleh menghitung rasio dari firing strength aturan-i, nilai output dalam struktur ini disebut proses normalisasi firing strength (penembakan kekuatan).

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \text{ with } i = 1, 2 \dots \dots \dots (\text{Eq. 3.9})$$

3.7.1.5 Output Lapisan Keempat

Setiap neuron pada struktur ke empat adalah simpul adaptif terhadap keluaran tertentu.

$$\bar{w}_i f_1 = \bar{w}_i (C_{i1}x_1 + C_{i2}x_2 + C_{i0}) \dots \dots \dots (\text{Eq. 3.10})$$

Dengan $\bar{w}_i$ adalah normalisasi dari firing strength pada lapisan ketiga dan $\{C_{i1}, C_{i2}, C_{i0}\}$ yang parameter pada neuron itu. Parameter dalam struktur ini disebut parameter konsekuen.

3.7.1.6 Output Lapis Kelima

Semua neuron pada struktur kelima simpul tetap yang jumlah jumlah semua masukan.

$$\sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum_{i=1}^2 \bar{w}_i f_i}{\sum_{i=1}^2 \bar{w}_i} \dots \dots \dots (\text{Eq. 3.11})$$

3.7.1.7 Algoritma Hybrid

Output yang terjadi ketika parameter premis ditemukan adalah kombinasi linear dari parameter konsekuen, itu adalah:

$$\begin{aligned} y &= \frac{w_1}{w_1 + w_2} y_1 + \frac{w_2}{w_1 + w_2} y_2 \\ &= \bar{w}_1 (c_{11}x_1 + c_{12}x_2 + c_{10}) + \bar{w}_2 (c_{21}x_1 + c_{22}x_2 + c_{20}) \\ &= (\bar{w}_1 x_1) c_{11} + (\bar{w}_1 x_2) c_{12} + \bar{w}_1 c_{10} + (\bar{w}_2 x_1) c_{21} + (\bar{w}_2 x_2) c_{22} + \bar{w}_2 c_{20} \end{aligned}$$

Output y adalah linear untuk parameter C_{ij} ($i=1,2$ and $j=0,1,2$)

Hybrid Algorithm digunakan untuk parameter C_{ij} dalam maju (forward) dan akan mengatur parameter $\{a_i, b_i, c_i\}$ dalam ke belakang (backward). Ketika parameter memerintahkan forwardly, masukan jaringan akan menyebarkan sampai struktur keempat, dan parameter C_{ij} akan diidentifikasi dengan menggunakan metode least-squared. Sementara di belakang, sinyal kesalahan akan menyebarkan backwardly dan parameter $\{a_i, b_i, c_i\}$ akan diperbaiki dengan Gradient-Descent. Hybrid Algoritma bertujuan untuk mengidentifikasi parameter linear dengan mengelompokkan steepest descent (SD) dan kesalahan kuadrat terkecil (LSE).

3.7.7.1 Rekursif LSE

Rekursif LSE adalah salah satu kesalahan metode least-square. Jumlah parameter dilambangkan dengan n, maka untuk memecahkan matriks nxn metode inverse akan digunakan, dengan mengikuti:

$$P_n = (A_n^T A_n)^{-1} \dots\dots\dots (\text{Eq. 3.12})$$

$$\theta_n = P_n A_n^T y_n \dots\dots\dots (\text{Eq. 3.13})$$

Unsur M di vektor output y memiliki ukuran ukuran m x 1, dan n parameter θ memiliki sebuah ukuran n x 1, dengan line-I pada matrix $[A : y]$ Dilambangkan sebagai $[A_i^T : y]$. Iterasi mulai dari data (n + 1) dengan perhitungan P_{k+1} and θ_{k+1} dengan menggunakan persamaan sebagai berikut:

$$P_{k+1} = P_k - \frac{P_k a_{k+1} a_{k+1}^T P_k}{1 + a_{k+1}^T P_k a_{k+1}} \dots\dots\dots (\text{Eq. 3.14})$$


$$\theta_{k+1} = \theta_k + P_{k+1} a_{k+1} (y_{k+1} - a_{k+1}^T \theta_k) \dots\dots\dots (\text{Eq. 3.15})$$

3.7.7.2 Model Kesalahan Propagasi (*Error Propagation*)

Pada langkah ini, jaringan adaptif akan dilatih untuk mendapatkan nilai parameter a dan c berdasarkan persamaan 3.15. Parameter dan c ditingkatkan dengan menggunakan *model of error propagation gradient descent*. Jaringan adaptif yang kita gunakan dapat dilihat pada gambar 3.5, sehingga jumlah kesalahan persegi dapat menghitung dengan persamaan berikut:

$$E_p = \sum_{k=1}^{N(L)} (d_k - X_{L,k})^2 \dots \dots \dots (\text{Eq. 3.16})$$

Dimana $N(L)$ adalah neuron pada struktur-L, p adalah data-p.



Gambar 3.6. Adaptive Network dengan 5 Layer

a. Error Dalam Lapisan Kelima

Berdasarkan Layer adaptif terlihat pada gambar 3.2 yang memiliki 1 neuron pada struktur keluaran (Neuron 13), maka propagasi kesalahan dalam lapisan kelima dihitung dengan persamaan berikut:

$$\varepsilon_{13} = \frac{\partial E_p}{\partial x_{13}} = -2(d_{13} - x_{13}) = -2(y_p - y_{p'}) \dots \dots \dots (\text{Eq. 3.17})$$

Dimana y_p adalah target output pada latihan data-p dan $y_{p'}$ adalah output jaringan pada latihan data-p.

b. Error Dalam Lapisan Keempat

Kesalahan propagasi menuju lapisan keempat neuron 11, 12 dapat dirumuskan sebagai:

$$\varepsilon_{11} = \left(\frac{\partial E_p}{\partial x_{13}} \right) \left(\frac{\partial f_{13}}{\partial x_{11}} \right) = \varepsilon_{13} \left(\frac{\partial f_{13}}{\partial x_{11}} \right) = \varepsilon_{13}(1) = \varepsilon_{13} \dots \dots \dots (\text{Eq. 3.18})$$

$$\varepsilon_{12} = \left(\frac{\partial E_p}{\partial x_{13}} \right) \left(\frac{\partial f_{13}}{\partial x_{12}} \right) = \varepsilon_{13} \left(\frac{\partial f_{13}}{\partial x_{12}} \right) = \varepsilon_{13}(1) = \varepsilon_{23} \dots \dots \dots (\text{Eq. 3.19})$$

c. Error Dalam Lapisan Ketiga

Kesalahan propagasi menuju lapisan ketiga neuron 9, 10 dapat dirumuskan sebagai:

$$\varepsilon_9 = \left(\frac{\partial E_p}{\partial x_{13}} \right) \left(\frac{\partial f_{13}}{\partial x_{11}} \right) \left(\frac{\partial f_{11}}{\partial x_9} \right) = \varepsilon_{11} \left(\frac{\partial f_{11}}{\partial x_9} \right) = \varepsilon_{11} f_1 \dots \dots \dots (\text{Eq. 3.20})$$

$$\varepsilon_{10} = \left(\frac{\partial E_p}{\partial x_{13}} \right) \left(\frac{\partial f_{13}}{\partial x_{12}} \right) \left(\frac{\partial f_{12}}{\partial x_{10}} \right) = \varepsilon_{12} \left(\frac{\partial f_{12}}{\partial x_{10}} \right) = \varepsilon_{12} f_2 \dots \dots \dots (\text{Eq. 3.21})$$

d. Error Dalam Lapisan Kedua

Kesalahan propagasi terhadap struktur kedua yang neuron 7, 8, dapat dirumuskan sebagai:

$$\begin{aligned} \varepsilon_7 &= \left(\frac{\partial E_p}{\partial x_{13}} \right) \left(\frac{\partial f_{13}}{\partial x_{11}} \right) \left(\frac{\partial f_{11}}{\partial x_9} \right) \left(\frac{\partial f_9}{\partial x_7} \right) + \left(\frac{\partial E_p}{\partial x_{13}} \right) \left(\frac{\partial f_{13}}{\partial x_{12}} \right) \left(\frac{\partial f_{12}}{\partial x_{10}} \right) \left(\frac{\partial f_{10}}{\partial x_7} \right) \\ &= \varepsilon_9 \left(\frac{\partial f_9}{\partial x_7} \right) + \varepsilon_{10} \left(\frac{\partial f_{10}}{\partial x_7} \right) \\ &= \varepsilon_9 \left(\frac{w_2}{(w_1 + w_2)^2} \right) + \varepsilon_{10} \left(-\frac{w_2}{(w_1 + w_2)^2} \right) \end{aligned}$$

$$\varepsilon_7 = \frac{w_2}{(w_1+w_2)^2} (\varepsilon_9 - \varepsilon_{10}) \dots\dots\dots (\text{Eq. 3.22})$$

Kesalahan propagasi terhadap struktur kedua yang neuron 7, 8, dapat dirumuskan sebagai:

$$\varepsilon_8 = \frac{w_1}{(w_1+w_2)^2} (\varepsilon_{10} - \varepsilon_{19}) \dots\dots\dots (\text{Eq. 3.23})$$

e. Error Dalam Lapisan Pertama

Kesalahan propagasi terhadap struktur keempat adalah neuron 3, 4, 5 dan 6, dapat dirumuskan sebagai:

$$\varepsilon_3 = \varepsilon_7 \left(\frac{\partial f_7}{\partial x_3} \right) = \varepsilon_7 \mu_{B1}(x_2) \dots\dots\dots (\text{Eq. 3.24})$$

$$\varepsilon_4 = \varepsilon_8 \left(\frac{\partial f_8}{\partial x_4} \right) = \varepsilon_8 \mu_{B2}(x_2) \dots\dots\dots (\text{Eq. 3.25})$$

$$\varepsilon_5 = \varepsilon_7 \left(\frac{\partial f_7}{\partial x_5} \right) = \varepsilon_7 \mu_{A1}(x_1) \dots\dots\dots (\text{Eq. 3.26})$$

$$\varepsilon_6 = \varepsilon_8 \left(\frac{\partial f_8}{\partial x_6} \right) = \varepsilon_8 \mu_{A2}(x_1) \dots\dots\dots (\text{Eq. 3.27})$$

Setelah mendapatkan nilai parameter a dan c, nilai perubahan parameter a_{ij} dan c_{ij} (Δa_{ij} dan Δc_{ij}) akan dirumuskan sebagai:

$$\Delta a_{ij} = \eta \varepsilon_{aij} x_i \dots\dots\dots (\text{Eq. 3.28})$$

$$\Delta c_{ij} = \eta \varepsilon_{cij} x_i \dots\dots\dots (\text{Eq. 3.29})$$

Dengan h adalah tingkat yang berdiri pada interval [0,1], sehingga nilai baru-baru belajara a_{ij} dan c_{ij} adalah:

$$a_{ij} = a_{ij}(\text{initial}) + \Delta a_{ij} \dots\dots\dots (\text{Eq. 3.30})$$

$$c_{ij} = c_{ij}(\text{initial}) + \Delta c_{ij} \dots\dots\dots (\text{Eq. 3.31})$$

3.7.1.8 Model *Subtractive Clustering*

Metode *subtractive clustering* tergolong metode *unsupervised clustering* dimana jumlah pusat *cluster* tidak diketahui. Metode ini menggunakan data sebagai kandidat dari pusat *cluster*, sehingga beban komputasi tergantung dari jumlah data dan tidak bergantung dari dimensi data. Jumlah pusat *cluster* yang dicari ditentukan melalui proses iterasi untuk mencari titik-titik dengan jumlah tetangga terbanyak. Apabila terdapat n buah data yaitu $x_1, x_2, \dots, x_n$ dan dengan menganggap bahwa data-data tersebut sudah dalam keadaan normal, maka densitas suatu titik dapat dihitung dengan persamaan berikut

$$D_k = \sum_{j=1}^n e^{\left(\frac{|x_k - x_j|}{\left(\frac{r_a}{2}\right)^2} \right)} \dots\dots\dots (2.14)$$

Dimana

D_k : densitas titik ke- k

x_k : titik ke- k

r_a : konstanta positif

Dengan demikian, suatu titik data akan memiliki densitas yang besar jika titik tersebut memiliki banyak tetangga. Setelah menghitung densitas tiap-tiap titik, maka titik dengan densitas tertinggi akan terpilih menjadi pusat kelompok. Misalkan x_{cl} adalah titik yang terpilih menjadi pusat kelompok dan D_{cl} adalah ukuran densitasnya, selanjutnya densitas dari titik-titik di sekitarnya akan dikurangi dengan persamaan berikut

$$D_k = D_k - D_{cl} e^{\left(\frac{|x_k - x_j|}{\left(\frac{r_a}{2}\right)^2} \right)} \dots\dots\dots (2.15)$$

Dimana r_b adalah konstanta positif. Hal ini berarti bahwa titik-titik yang berada dekat dengan pusat kelompok x_{cl} akan mengalami pengurangan densitas secara besar-besaran. Hal ini akan berakibat titik-titik tersebut memiliki kemungkinan yang kecil untuk menjadi pusat kelompok berikutnya. Nilai r_b menunjukkan suatu lingkungan yang

mengakibatkan titik-titik berkurang ukuran densitasnya. Nilai r_b diperoleh dari persamaan berikut

$$r_b = \text{squash factor} \times r_a \dots\dots\dots(2.16)$$

Biasanya *squash factor* bernilai 1.500. Dengan demikian r_b bernilai lebih besar dibandingkan r_a . Setelah densitas tiap -tiap titik diperbaiki, selanjutnya akan dicari pusat kelompok yang kedua yaitu x_{c2} . Setelah x_{c2} diperoleh, ukuran densitas tiap titik data akan diperbaiki kembali. Langkah-langkah ini dilakukan berulang-ulang sampai semua titik teruji. Pada implementasinya bisa digunakan 2 bilangan sebagai faktor pembanding, yaitu *accept ratio* dan *reject ratio*. Apabila hasil bagi antara potensi tertinggi suatu titik data dengan potensi tertinggi yang pertama kali diperoleh pada iterasi pertama lebih besar daripada *accept ratio*, maka titik data tersebut diterima sebagai pusat kelompok baru. Apabila hasil bagi antara potensi tertinggi suatu titik data dengan potensi tertinggi yang pertama kali diperoleh pada iterasi pertama lebih kecil daripada *accept ratio* namun lebih besar daripada *reject ratio*, maka titik data tersebut baru akan diterima sebagai pusat kelompok yang baru jika titik tersebut terletak pada jarak yang cukup jauh dengan pusat kelompok yang lainnya. Namun, jika hasil bagi antara potensi tertinggi suatu titik data dengan potensi tertinggi yang pertama kali diperoleh pada iterasi pertama lebih kecil daripada *accept ratio* maupun *reject ratio*, maka titik tersebut tidak akan diperhitungkan lagi untuk menjadi pusat kelompok yang baru.

Tahapan *subtractive clustering* menurut Sri Kusumadewi dan Hari Purnomo (2013) adalah sebagai berikut:

9. Input data yang akan dicluster: x_{ij} , dengan $i=1,2,\dots,n$; dan $j=1,2,\dots,m$
10. Tetapkan nilai:
 - g. r_j (jari-jari setiap atribut data); $j=1,2,\dots,m$
 - h. q (*squash factor*)
 - i. *accept ratio*
 - j. *reject ratio*
 - k. $X_{\min}$ (minimum data diperbolehkan)
 - l. $X_{\max}$ (maksimum data diperbolehkan)

11. Normalisasi

$$x_{ij} = \frac{x_{ij} - Xmin_j}{Xmax_j - Xmin_j}$$

$$i=1,2,\dots,n; j=1,2,\dots,m$$

12. Tentukan potensi awal tiap-tiap titik data

c. $i = 1$

d. Kerjakan hingga $i = n$,

i. $T_j = x_{ij}$ (T_i merupakan data ke- i atribut ke- j), $j=1,2,\dots,m$

ii. Hitung:

$$Dist_{kj} = \left(\frac{T_j - x_{kj}}{r_j} \right), j=1,2,\dots,m; k=1,2,\dots,n$$

iii. Potensi awal

Jika $m=1$, maka:

$$Di = \sum_{k=1}^n e^{-4(Dist^2_{kj})}$$

Jika $m>1$, maka:

$$Di = \sum_{k=1}^n e^{-4\left(\sum_{j=1}^m Dist^2_{kj}\right)}$$

iv. $i = i + 1$

13. Cari titik dengan potensi tertinggi

c. $M = \max[D_i | i=1,2,\dots,n]$

d. $h = 1$, sedemikian hingga $D_i = M$

14. Tentukan pusat *cluster* dan kurangi potensinya terhadap titik-titik di sekitarnya

g. Center = []

h. $V_j = X_{hj}$, $j=1,2,\dots,m$

i. $C = 0$ (jumlah *cluster*)

j. Kondisi = 1

k. $Z = M$

l. Kerjakan jika (kondisi $\neq 0$) dan ($Z \neq 0$):

5) Kondisi = 0 (sudah tidak ada calon pusat baru lagi)

6) Rasio = Z/M

- 7) Jika $\text{rasio} > \text{rasio penerimaan}$, maka $\text{kondisi} = 1$; (ada calon pusat baru)
 - 8) Jika tidak, maka $\text{rasio} > \text{rasio penolakan}$, (calon pusat baru akan diterima sebagai pusat jika keberadaannya akan memberikan keseimbangan terhadap data-data yang letaknya cukup jauh dengan pusat *cluster* yang telah ada)
15. Kembalikan pusat *cluster* dari bentuk ternormalisasi ke bentuk semula
- $$\text{Center}_{ij} = \text{Center}_{ij} * (\text{Xmax}_j - \text{Wmin}_j) + \text{Xmin}_j$$
16. Hitung nilai sigma *cluster*

$$\sigma_j = r_j \times \frac{\text{Xmax}_j - \text{Xmin}_j}{\sqrt{8}}$$

3.7.2 Parameter Evaluasi

Evaluasi kinerja yang dirancang untuk mengevaluasi seberapa baik jaringan bisa belajar sehingga akan mudah dikenali bila dibandingkan dengan pola baru. Kesalahan generalisasi merupakan selisih antara output aktual dan target. Fungsi kesalahan yang paling umum digunakan dalam fungsi dukungan mesin vektor adalah *mean square error* (MSE). Kesalahan ini digunakan untuk memutuskan kapan untuk menghentikan proses pelatihan mesin dukungan vektor. Fungsi MSE didefinisikan sebagai berikut:

$$\text{Mean Square Error} = \frac{\sum(\text{actual} - \text{prediction})^2}{n} \dots\dots\dots (\text{Eq 3.33})$$

Mean Square Error adalah jumlah kesalahan kuadrat atau perbedaan antara nilai yang sebenarnya (aktual) dan nilai prediksi. Untuk menguji seberapa dekat pendekatan dengan nilai yang sebenarnya, langkah-langkah yang umum digunakan adalah root mean square error (RMSE) sebagai berikut:

$$\text{Root Mean Square Error} = \sqrt{\frac{\sum(\text{actual} - \text{prediction})^2}{n}} \dots\dots\dots (\text{Eq. 3.32})$$

Di mana n adalah total nilai pengamatan.

RMSE (*Root Mean Square Error*) adalah jumlah kesalahan kuadrat atau perbedaan antara aktual dan nilai prediksi kemudian membagi jumlah tersebut dengan jumlah waktu dan prediksi data yang kemudian tarik akar kuadrat. Perbedaan-perbedaan individual disebut residual saat perhitungan dilakukan atas sampel data yang digunakan untuk estimasi, dan disebut kesalahan prediksi ketika dihitung diluar sampel data.

BAB IV

PENGUMPULAN DAN PENGOLAHAN DATA

Bab ini menjelaskan pengumpulan data dan prosesnya, pemrosesan data akan melibatkan analisa hasil, beberapa eksperimen yang dilakukan berkaitan dengan proses data. Pembahasan khusus di bab ini adalah untuk mengembangkan model estimasi menggunakan Adaptive Neuro-Fuzzy Inference System dan model *Subtractive Clustering*.


4.1 Data Penelitian

Data yang digunakan adalah data primer yang diambil secara langsung dari bagian produksi PS Madukismo. Data ini seperti diuraikan pada bagian sebelumnya didasarkan pada data historis Januari, Pebruari, dan Juni 2015. Variabel input yang digunakan dalam studi ini adalah konsumsi energi listrik dalam kilowatt-jam (kWh) dan konsumsi batubara dalam kilogram (Kg), kemudian untuk variabel output yang digunakan adalah total emisi CO₂ dalam Kilogram-Carbon dioksida (KgCO₂). Tabel 4.1 menunjukkan data emisi CO₂ :

No	Electrical Energy (KWh)	COAL (Kg)	Total CO2 Emission (KgCO ₂)
1	8278,14	31350	62942,3424
2	8270,40	31000	62301,02993
3	8315,75	32000	64150,19625
4	8280,42	31000	62308,29222
5	8199,89	28170	57109,81266
6	8307,53	27880	56661,12506
7	8297,91	26070	53366,66222
8	8297,11	27060	55164,2128

No	Electrical Energy (KWh)	COAL (Kg)	Total CO2 Emission (KgCO ₂)
9	8277,05	14150	31701,36608
10	8329,69	12630	28978,76635
---	---	---	---
---	---	---	---
---	---	---	---
---	---	---	---
85	8316,76	22550	46986,99246
86	8336,07	22510	46928,34003

Table 4.1 Input Data



Gambar 4.1 Grafik Data Eksperimen

Kumpulan data dalam studi ini adalah non-linear seperti tampak di Gambar 4.1. Dalam hal ini, data harus diubah dulu ke ruang baru. Data input harus diubah menggunakan normalisasi data untuk menyamakan data di antara atribut untuk

memperoleh beban yang sama dalam kalkulasi tiap variabel. Tabel 4.2 menunjukkan hasil transformasi data.

No	ELECTRICAL ENERGY (Kwh)	COAL (Kg)	Total CO2 Emission (KgCO2)
1	0,40640308	0,77259887	0,772826222
2	0,37927117	0,760240113	0,760351005
3	0,538245001	0,795550847	0,796322161
4	0,414388048	0,760240113	0,760492275
5	0,132096442	0,660310734	0,659368154
6	0,509442811	0,650070621	0,650639998
7	0,475700897	0,586158192	0,586554017
8	0,472913114	0,621115819	0,621521111
9	0,40259115	0,165254237	0,165106934
10	0,587119413	0,111581921	0,112145197
---	---	---	---
---	---	---	---
19	0,316445531	1	1
---	---	---	---
---	---	---	---
35	0,463510732	0	0
---	---	---	---
---	---	---	---
72	1	0,503531073	0,505987201
73	0	0,524011299	0,522456674
---	---	---	---
---	---	---	---
84	0,234051014	0,466101695	0,465454365
85	0,541807373	0,461864407	0,462452634
86	0,609500515	0,460451977	0,46131169

Tabel 4.2 Data Normalisasi

4.2 Hasil Penelitian

Pada bab ini akan membahas mengenai hasil dari perhitungan menggunakan *Subtractive Clustering* dan ANFIS yang dijalankan menggunakan MATLAB.

4.2.1 Model Subtractive Clustering

Pada pengolahan dengan menggunakan metode *Subtractive Clustering*, data tidak perlu melalui tahap *preprocessing* terlebih dahulu, akan tetapi data tetap dibagi menjadi dua yaitu 60% data sebagai data training dan 40% data sebagai data testing. Tahap-tahap metode *Subtractive Clustering* adalah sebagai berikut:

1. Memasukkan data input dan data output

Data input dan data output dapat dimasukkan dengan mengetikkan *syntax* “tripdata” pada *command window software* MATLAB. Pada kolom datin, dimasukkan data input yang berupa *training data* dari data electrical energy dan coal. Sedangkan pada kolom datout, dimasukkan data output yang berupa co2 emission.

2. Merepresentasikan input dan output

Input dan output yang digunakan pada pengolahan data harus direpresentasikan di dalam *software* MATLAB dengan menggunakan *syntax* sebagai berikut:

```
>> tripdata
>> subplot(2,1,1)
plot(datin)
legend('electricalenergy','coal');
title('Input Variables','fontsize',10)
subplot(2,1,2)
plot(datout)
legend('co2emission');
title('Output Variable','fontsize',10)
```

Dari *syntax* di atas, dapat diketahui bahwa data input terdiri dari dua variabel yaitu electrical energy dan coal. Sedangkan data output terdiri dari satu variabel yaitu co2 emission.

3. *Cluster Data*

Pada tahap ini, dilakukan pengelompokan data dengan menggunakan *syntax* sebagai berikut:

```
[C,S] = subclust([datin datout],0.2);
```

Argumen pertama dalam *syntax* di atas menunjukkan data mana yang akan dikelompokkan, sedangkan argumen kedua menunjukkan jari-jari yang menjadi radius tiap kelompok (*cluster*) yang terbentuk. Selanjutnya, dilakukan tahap untuk menampilkan *cluster* yang terbentuk dengan menggunakan *syntax* sebagai berikut:

```
C %#ok<*NOPTS>
```

C menunjukkan seluruh pusat dari *cluster* yang terbentuk. Setiap baris dari C menunjukkan posisi *cluster*.

```
C =      0.4895  0.6190  0.6195
      0.4144  0.7602  0.7605
      0.5988  0.2073  0.2079
      0.3451  0.4654  0.4652
      0.3845  0.0830  0.0827
      0.5979  0.0293  0.0299
      0.4534  0.3192  0.3194
      0.3164  1.0000  1.0000
      0.5848  0.7218  0.7227
      0.2293  0.6713  0.6707
      0.6346  0.3902  0.3911
      0.8258  0.7119  0.7137
      0.1338  0.5113  0.5103
```


Syntax di atas memiliki 13 baris dan 3 kolom. Hal tersebut menunjukkan ada 13 *cluster* yang terbentuk dan 3 posisi *cluster* dalam tiap dimensi. Misalnya, pada *cluster* pertama letak *cluster* ada pada titik 0.4895, 0.6190, dan 0.6195 pada *cluster* kedua letak *cluster* ada pada titik 0.4144, 0.7602, dan 0.7605, dan seterusnya.

4. *Cluster Data Plot*

Setelah data terbentuk menjadi 13 *cluster*, tahap selanjutnya adalah menampilkan plot data yang menunjukkan *cluster* telah diidentifikasi dengan menggunakan variabel electrical energy dan co2 emission. *Syntax* yang digunakan adalah sebagai berikut:

```
>> clf;  
plot(datin(:,2), datout(:,1), '.', C(:,2),C(:,3),'r*')  
legend('Data points', 'Cluster centers', 'Location',  
'SouthEast')  
xlabel('electricalenergy','fontsize',10)  
ylabel('co2emission','fontsize',10)  
title('Data and Clusters in selected two dimensions of the  
input space','fontsize',10)
```

Pada *syntax* di atas, telah ditentukan label x dan label y pada plot yang akan dimunculkan. Selanjutnya akan muncul plot data sebagai berikut:



Gambar 4.2 *Cluster centers* pada variabel electrical energy dan co2 emission

Pada Gambar 4.13 di atas, diketahui label x pada plot data adalah variabel electrical energy dan label y pada plot data adalah variabel co2 emission. Sedangkan titik kecil berwarna biru menunjukkan *data points* dan bintang berwarna merah menunjukkan *cluster centers*. Selanjutnya digunakan syntax “S” untuk memunculkan nilai sigma yang menentukan kisaran pengaruh pusat *cluster* di setiap dimensi data sebagai berikut:

$$S = \begin{bmatrix} 0.0490 & 0.0707 & 0.0707 \end{bmatrix}$$

S yang muncul memiliki 3 kolom yang menunjukkan nilai sigma dari masing-masing dimensi *cluster*.

5. Membangkitkan *Fuzzy Inference System* (FIS)

Pada tahap ini digunakan syntax *genfis2* yang berfungsi untuk membangkitkan FIS menggunakan *Subtractive Clustering*. *genfis2* menggunakan *Subtractive Clustering* untuk mengelompokkan data dan menggunakan pusat *cluster* serta kisaran pengaruh pusat *cluster* untuk membangun FIS yang kemudian akan digunakan untuk memeriksa dan memahami pola yang terbentuk. Syntax yang digunakan adalah sebagai berikut:

```
myfis=genfis2(datin,datout,0.2);
```

Argumen pertama dalam *syntax* di atas menunjukkan variabel input, argument kedua menunjukkan variabel output, sedangkan argumen ketiga menunjukkan jari-jari yang menjadi radius *cluster*. Selanjutnya dilakukan tahap mendefinisikan variabel input dan variabel output dalam *syntax* untuk membangkitkan FIS. *Syntax* yang digunakan adalah sebagai berikut:

```
>> % Assign names to inputs and outputs
myfis = setfis(myfis, 'input',1,'name','electricalenergy');
myfis = setfis(myfis, 'input',2,'name','coal');
myfis = setfis(myfis, 'output',1,'name','co2emission');
```

Pada *syntax* diatas telah didefinisikan bahwa input 1 adalah electrical energy, input 2 adalah coal dan outputnya adalah co2 emission.

6. Output *Subtractive Clustering*

Tahap terakhir yang dilakukan adalah melihat hasil output dari metode *Subtractive Clustering* dengan menggunakan *syntax* “ruleedit(myfis)” dan “ruleview(myfis)”. *Syntax* “ruleedit(myfis)” digunakan untuk menampilkan aturan (*rules*) yang terbentuk dari model prediksi yang dihasilkan. Jumlah *rule* yang terbentuk sesuai dengan jumlah *cluster* data, yaitu tiga belas. Tiga belas *rule* tersebut adalah sebagai berikut:

1. If (electricalenergy is in1cluster1) and (coal is in2cluster1) then (co2emission is out1cluster1) (1)
2. If (electricalenergy is in1cluster2) and (coal is in2cluster2) then (co2emission is out1cluster2) (1)
3. If (electricalenergy is in1cluster3) and (coal is in2cluster3) then (co2emission is out1cluster3) (1)
4. If (electricalenergy is in1cluster4) and (coal is in2cluster4) then (co2emission is out1cluster4) (1)

5. If (electricalenergy is in1cluster5) and (coal is in2cluster5) then (co2emission is out1cluster5) (1)
6. If (electricalenergy is in1cluster6) and (coal is in2cluster6) then (co2emission is out1cluster6) (1)
7. If (electricalenergy is in1cluster7) and (coal is in2cluster7) then (co2emission is out1cluster7) (1)
8. If (electricalenergy is in1cluster8) and (coal is in2cluster8) then (co2emission is out1cluster8) (1)
9. If (electricalenergy is in1cluster9) and (coal is in2cluster9) then (co2emission is out1cluster9) (1)
10. If (electricalenergy is in1cluster10) and (coal is in2cluster10) then (co2emission is out1cluster10) (1)
11. If (electricalenergy is in1cluster11) and (coal is in2cluster11) then (co2emission is out1cluster11) (1)
12. If (electricalenergy is in1cluster12) and (coal is in2cluster12) then (co2emission is out1cluster12) (1)
13. If (electricalenergy is in1cluster13) and (coal is in2cluster13) then (co2emission is out1cluster13) (1)

Sedangkan *syntax* “ruleview(myfis)” digunakan untuk menampilkan model prediksi konsumsi solar berdasarkan metode *Subtractive Clustering*. Berikut ini adalah model prediksi yang dihasilkan:




Gambar 4.3 Output Subtractive Clustering

Setelah didapatkan model tersebut, kemudian model digunakan untuk mengujikan 40% *checking data*. Berikut ini adalah hasil rekapitulasi pengujian model

NO	Emisi Co2	prediksi 0,2
1	0,650891718	0,651
2	0,359577342	0,36
3	0,336904343	0,337
4	0,645343395	0,645
5	0,654753685	0,655
6	0,348995844	0,349
7	0,258103027	0,258
8	0,345576984	0,346
9	0,35939699	0,359
10	0,443969792	0,444
---	---	---
---	---	---
---	---	---
---	---	---
---	---	---
31	0,482446322	0,482
32	0,480140168	0,48
33	0,477865201	0,478
34	0,465454365	0,465
35	0,462452634	0,462
36	0,46131169	0,461

Tabel 4.3 Rekapitulasi pengujian *Subtractive Clustering* sebelum denormalisasi



Gambar 4.4 Plotting data *Subtractive Clustering*

Dari hasil tersebut kemudian akan dihitung nilai eror hasil rekapitulasi pengujian model prediksi *Subtractive Clustering* dengan menggunakan parameter nilai RMSE (Root mean squart eroor).

4.2.1 Nilai Eror Prediksi *Subtractive Clustering* Menggunakan RMSE

Dalam studi ini, untuk memprediksi jumlah emisi karbondioksida yang terjadi pada tingkat produksi PS.MADUBARU, peneliti menggunakan *Subtractive Clustering* dengan MATLAB r-2010a. Hasil yang diperoleh dalam mengembangkan model prediksi emisi CO₂ menggunakan *Subtractive Clustering* menunjukkan kesalahan prediksi atau RMSE dengan nilai 0,000211.


4.2.2 Model Adaptive Neuro-Fuzzy Inference System Design

Adaptif Inference System Neuro-Fuzzy adalah arsitektur yang fungsional mirip dengan aturan model dasar Sugeno fuzzy. Arsitektur ANFIS sama dengan jaringan saraf akan tetapi memiliki sedikit kendala tertentu. Bisa dikatakan bahwa ANFIS adalah kombinasi

mekanisme sistem inferensi fuzzy yang digambarkan dalam arsitektur jaringan saraf, selain memiliki kemampuan untuk mengekstrak pengetahuan yang merupakan karakteristik dari logika fuzzy, ANFIS juga memiliki kemampuan untuk belajar yang merupakan karakteristik Buatan Jaringan syaraf. Kumpulan data akan dibagi menjadi pelatihan (60%) dan tahap pengujian. (40%). Penentuan prediksi karbon dioksida menggunakan dukungan vektor algoritma mesin dengan software MATLAB diilustrasikan sebagai berikut:


1. Pemuatan Data

- a. Buka ANFIS GUI dengan mengetikkan Anfisedit dalam perintah baris MATLAB.
- b. Memuat data pelatihan diatur dari ruang kerja, pilih opsi berikut:
 - Type: Training
 - From: Workspace
- c. Klik Load data untuk membuka kotak dialog ruang kerja LoadFrom.



Gambar 4.5 Beban Data dari ruang kerja

- d. Ketiklah **traindata** seperti ditunjukkan dalam gambar berikut, dan klik **OK**.
- e. Kumpulan data training digunakan untuk melatih sistem fuzzy dengan menyesuaikan parameter-parameter fungsi keanggotaan yang merupakan model terbaik data ini, dan tampak dalam plot di pusat GUI sebagai kumpulan lingkaran.




Gambar 4.6 Training Data

Poros horisontal adalah **Data Set Index**. Index ini menandai baris di mana nilai data input diperoleh.

- f. Untuk memuat kumpulan data tes dari ruang kerja:
 - Pada bagian **Load Data** GUI, pilihlah **Testing** di kolom **type**.
 - Klik **Load Data** untuk membuka load dari kotak dialog ruang kerja.
 - Ketiklah data testing seperti nama variabel dan klik OK.

Data tes tampak dalam plot GUI sebagai **diamond** pada data training




Gambar 4.7 Load Testing Data

Langkah berikutnya adalah menetapkan awal fuzzy inference system bagi anfis untuk melatih.

2. Mengawali dan Menghasilkan FIS

Untuk menganalisa FIS menggunakan anfis:


- Pilihlah **Grid Partition**, metoda pemisahan default.
- Kliklah tombol **Generate FIS**. Klik tombol ini dan pilihlah jumlah fungsi keanggotaan. Hanya ada dua pilihan untuk fungsi keanggotaan output: **Constant dan Linear**. Pembatasan pilihan fungsi keanggotaan output ini, disebabkan anfis hanya beroperasi pada sistem jenis Sugeno.
- Isikan pada entri seperti ditunjukkan dalam gambar berikut, dan klik OK.



Gambar 4.8 FIS Structure Generation

3. Mengamati Struktur FIS

Setelah menghasilkan FIS, struktur model dapat dilihat dengan mengklik tombol **Structure** di bagian tengah sisi kanan editor. Editor nampak sebagai berikut:




Gambar 4.9 Anfis Model Structure

Kode warna cabang-cabang mencirikan aturan dan menandai apakah operator DAN, TIDAK, atau ATAU, digunakan atau tidak digunakan dalam aturan. Input diwakili oleh simpul paling kiri dan output oleh simpul paling kanan.

4. ANFIS Training

Pilihlah **Hibrida** sebagai metoda optimisasi parameter ANFIS. **Toleransi kesalahan** digunakan untuk membuat ukuran penghentian training, yang berkaitan dengan ukuran kesalahan. Training akan berhenti setelah kesalahan data training tersisa dalam toleransi ini. Nilai kesalahan yang dipilih adalah **0**. Langkah terakhir adalah memilih banyaknya jangka waktu training, jangka waktu yang dipilih adalah **200 epoch**. Setelah semua opsi dipilih, kemudian klik **Train Now**.




Gambar 4.10 Training Error Result

Kesalahan training tampak pada layar sebagai **. Hasil kesalahan adalah **0.0000259**.

5. Tes Data terhadap FIS Terlatih

Untuk menguji data FIS terlatih terhadap **Data Test** adalah pada kolom FIS tes ANFIS Editor. Ketika pengujian data tes terhadap FIS sedang bejalan, hasilnya tampak memuaskan.



Gambar 4.11 Testing Data against the Trained FIS

1.2 Hasil Eksperimen

Dalam studi ini, untuk memprediksi jumlah emisi karbondioksida yang terjadi pada tingkat produksi PS.MADUBARU, peneliti menggunakan Adaptive Neuro Fuzzy Inference System dengan MATLAB r-2010a. Hasil yang diperoleh dalam mengembangkan model prediksi emisi CO₂ menggunakan ANFIS menunjukkan kesalahan prediksi atau RMSE dengan nilai **0.0000259**. Hasil kesalahan data testing pada jangka waktu terakhir sebelum denormalisasi diperkenalkan pada Tabel 4.4.

NO	Normalisasi		Perbedaan
	Emisi Co2	Prediksi Co2	
1	0,4652	0,4652	-0,0000038
2	0,4355	0,4355	-0,0000015
3	0,1794	0,1794	0,0000009
4	0,1960	0,1960	0,0000132
5	0,0827	0,0827	0,0000061
6	0,2856	0,2856	0,0000102
7	0,3259	0,3259	-0,0000068
8	0,3194	0,3194	-0,0000079
9	0,5103	0,5103	0,0000074
10	0,4845	0,4845	-0,0000029
---	---	---	---
---	---	---	---
---	---	---	---
32	0.480140	0.480154	-0.0000133
33	0.477865	0.477930	-0.0000651
34	0.465454	0.465446	0.0000081
35	0.462453	0.462469	-0.0000159
36	0.461312	0.461332	-0.0000202

Tabel 4.4 Kesalahan yang terjadi pada jangka waktu terakhir sebelum denormalisasi

NO	Denormalisasi		Perbedaan
	Emisi Co2	Prediksi Co2	
1	62942.342	62942.496	-0.153
2	62301.030	62301.406	-0.376
3	64150.196	64149.129	1.067
4	62308.292	62308.424	-0.132
5	57109.813	57111.392	-1.579
6	56661.125	56661.834	-0.709
7	53366.662	53367.408	-0.746
8	55164.213	55164.845	-0.632
9	31701.366	31701.369	-0.003
---	---	---	---
---	---	---	---
---	---	---	---
33	47779.305	47782.649	-3.344
34	47141.302	47140.884	0.418
35	46986.992	46987.809	-0.817
36	46928.340	46929.380	-1.040

Table 4.5 Kesalahan yang terjadi pada jangka waktu terakhir setelah denormalisasi

Tabel 4.4 dan 4.5 menunjukkan hasil prediksi pada data posisi sebelum denormalisasi dan setelah denormalisasi, hasil yang menunjukkan nilai kesalahan terbesar yang terjadi pada data sebelum denormalisasi adalah **0.0001192** dan kesalahan terendah yang terjadi adalah **0.0000001**. Kemudian pada data setelah denormalisasi, hasil yang menunjukkan kesalahan terbesar yang terjadi adalah **6.129** dan hasil terendah adalah **0.003**.

BAB V

PEMBAHASAN

Bab ini membahas hasil yang telah diperoleh dari serangkaian penelitian dan kesesuaian antara hasil dan tujuan penelitian untuk melanjutkan kesimpulan.

5.1 *Subtractive Clustering*

Subtractive clustering merupakan perpanjangan dari *mountain clustering* diusulkan pada tahun 1995 oleh Chiu (Zhang, 2012). Konsep dari *subtractive clustering* adalah menentukan daerah-daerah dalam suatu variabel yang memiliki densitas tinggi terhadap titik-titik disekitarnya. Titik dengan jumlah tetangga terbanyak akan dipilih sebagai pusat *cluster*. Titik yang sudah terpilih menjadi pusat *cluster* ini kemudian akan dikurangi densitasnya. Kemudian algoritma akan memilih titik lain yang memiliki tetangga terbanyak untuk dijadikan pusat *cluster* yang lain. Hal ini akan dilakukan berulang-ulang hingga semua titik diuji (Sri Kusumadewi dan Hari Purnomo, 2013).

Untuk melakukan prediksi emisi karbon dioksida, peneliti menggunakan MATLAB R2009a. Kumpulan data dibagi menjadi data training 60% dan pengujian data 40%. Semua data set harus diubah atau dinormalkan dulu, untuk menyamakan data antara atribut untuk mendapatkan bobot yang sama dalam perhitungan setiap atribut.

Data pelatihan akan digunakan untuk menemukan nilai-nilai parameter yang optimal dari *Subtractive Clustering* dan menguji data yang akan digunakan untuk menentukan apakah parameter yang diperoleh dapat digunakan untuk memproses data.

Berdasarkan perhitungan nilai RMSE dalam *Subtractive Clustering*, nilai RMSE yang diperoleh adalah 0,000211 persen.

5.2 Model Perhitungan ANFIS

Adaptive Neuro-Fuzzy Inference System (ANFIS) adalah kombinasi dari mekanisme sistem inferensi fuzzy yang dijelaskan dalam arsitektur jaringan saraf, selain memiliki kemampuan untuk mengekstrak pengetahuan yang merupakan karakteristik dari logika fuzzy, ANFIS juga memiliki kemampuan untuk melakukan pembelajaran yang karakteristik JST. ANFIS digunakan secara luas untuk memecahkan masalah estimasi. Tujuan dari penelitian ini adalah untuk memprediksi nilai emisi karbon dioksida. Atribut yang digunakan untuk memprediksi emisi karbon dioksida adalah konsumsi energi listrik, dan konsumsi pembakaran batubara. Penelitian menggunakan mesin belajar pendekatan sebagai metode prediksi yang disebut ANFIS. Untuk melakukan prediksi emisi karbon dioksida, peneliti menggunakan perangkat lunak MATLAB r2010a.

ANFIS mengambil satu set data input dan memprediksi. Kumpulan data dibagi menjadi data training 60% dan pengujian data 40%. Semua data set harus diubah atau dinormalkan dulu, untuk menyamakan data antara atribut untuk mendapatkan bobot yang sama dalam perhitungan masing-masing variabel. Data pelatihan akan digunakan untuk menemukan nilai-nilai parameter yang optimal dari ANFIS dan menguji data yang akan digunakan untuk menentukan apakah parameter yang diperoleh dapat memproses data baru.

Setelah seluruh jaringan ANFIS lengkap, maka jaringan ANFIS akan dilatih dengan zaman maksimum = 200, toleransi error = 0. Berdasarkan percobaan yang telah dilakukan pada tabel 4.5 dan tabel 4.6, hasil yang ditunjukkan dari eksperimen menggunakan metode ANFIS didapatkan Kesalahan terkecil adalah 0,0000259. Maka tabel 4.3 dan tabel 4.4 menunjukkan hasil prediksi data posisi sebelum denormalized dan setelah denormalized, hasilnya menunjukkan nilai error terbesar yang terjadi pada data sebelum denormalized adalah 0,0001192 dan kesalahan terendah yang terjadi adalah

0,00000001. Kemudian pada data setelah denormalized, hasilnya menunjukkan kesalahan terbesar yang terjadi adalah 6,129 dan hasil terendah adalah 0,00

BAB VI

KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan dari hasil penelitian, kontribusi penelitian dan saran untuk penelitian lebih lanjut perlu diberikan.

6.1 Kesimpulan

Komparisasi merupakan sebuah cara untuk membandingkan beberapa teori dalam pemecahan suatu masalah yang sama. Dalam hal ini yang digunakan adalah dengan menggunakan *Subtractive Clustering* dan perhitungan ANFIS dengan menggunakan aplikasi yang sama yaitu MATLAB. Kedua teori tersebut digunakan untuk memprediksi emisi CO₂. Untuk mencapai tujuan penelitian, seluruh konsumsi energi yang digunakan dalam proses produksi yang ditetapkan sebagai atribut dari model. Penelitian ini mengambil satu set data input dan kemudian memprediksinya. Data dibagi menjadi data pelatihan dari 60% dan pengujian data 40%. Setelah hasil RMSE dari hasil prediksi *Subtractive Clustering* dan ANFIS diperoleh, hasil percobaan dari Model *Subtractive Clustering* dan ANFIS menunjukkan bahwa kedua model tersebut memiliki kemampuan yang baik dan akurasi yang baik untuk memecahkan masalah prediksi emisi CO₂. Kedua model memiliki selisih yang sangat kecil sehingga tidak ada perbedaan dari penggunaan kedua model tersebut karena memiliki nilai kesalahan RMSE yang kecil yaitu 0,000211 untuk *Subtractive Clustering* dan 0,0000259 untuk ANFIS.

6.2 Saran

Penelitian ini menunjukkan bahwa komparisasi sangat diperlukan dalam menentukan teori yang terbaik antara *Subtractive Clustering* dan ANFIS dalam memecahkan masalah prediksi pada emisi CO₂. Namun, ada beberapa rekomendasi yang timbul dari penelitian ini yang dapat diberikan bagi perusahaan dan sebagai panduan untuk penelitian lebih lanjut:

1. Dianjurkan bagi perusahaan untuk lebih memperhatikan efisiensi mesin yang dapat mengurangi produksi emisi karbon dioksida dari konsumsi energi.
2. Untuk penelitian lebih lanjut, optimasi berat atribut mungkin diperlukan untuk meningkatkan akurasi prediksi model *Subtractive Clustering* dan model ANFIS.

REFERENSI

- Abdallah, L and T, El-Shennawy. (2013). "Reducing Carbon Dioxide Emission from Electricity Sector Using Smart Electric Grid Application". Hindawi Publishing Corporation. Journal of Engineering Volume 2013, Article ID 845051, 8 pages <http://dx.doi.org/10.1155/2013/845051>
- Abdelfatah, Alaa., Moktar, Sahar., Sheta, Alaa., Solaiman, Basma. (2013). "Forecast Global Carbon Dioxide Emission Using Swarm Intelligence". International Journal of Computer Application. Volume 77-No.12 September 2013.
- Baareh, Abdel Karim. (2013). "Solving the Carbon Dioxide Emission Estimation Problem: An Artificial Neural Network Model". *Journal of Software Engineering and Applications*, 2013, 6, 338-342. (<http://www.scirp.org/journal/jsea>)
- Bali, Naveen. (2009). "Energy Intensive Industrial Subsidies and its Implication on Global Warming: Role of WTO. Indian Institute of Technology Kanpur.
- Basak, Pijush and Nandi, Sumit. (2014). "A statistical analysis and prediction of carbon dioxide emission in some eastern and northern states of India". International Journal of Environmental Sciences Volume 4, No 5, 2014.
- Bulent, Sezen and Sibel, YC. (2013). "Effects of green manufacturing and eco-innovation on sustainability performance. Procedia - Social and Behavioral Sciences 99 (2013) 154 – 163. [10.1016/j.sbspro.2013.10.481](https://doi.org/10.1016/j.sbspro.2013.10.481)
- Chairul, Saleh., Setiawan, Nashurllah., Feriyanto, Nur., Fauzy, Akhmad., Nurhidayati, Riza. (2015). "Application of Simulation Approach To Predict Carbon Emission In Sugar Industry". International Journal of Advanced Science Letters. American Scientific Publisher.
- Chairul, Saleh., Leuveano, Raden., Nizam, Mohammad., Deros, Baba., Dzakiyullah, Nur. (2015). "Prediction of CO₂ Emission Using An Artificial Neural Network: The

- Case of The Sugar Industry”. International Journal of Advance Science Letter. American Scientific Publisher
- Chang, Chi-Chung and Lin, Chih-Jen. (2013). “LIBSVM: A Library for Support Vector Machines”.ACM Transactions on Intelligent Systems and Technology.
- Dayaratne SP, Gunawardana KD. (2014). “Carbon Footprint Reduction: A Critical study of Rubber Production in Small and Medium Scale Enterprises in Sri Lanka”. Journal of Cleaner Production (2014), doi: 10.1016/j.jclepro.2014.09.101.
- Dornfeld, D., Yuan, C., Diaz, N., Zhang, T., Vijayaraghavan, A. (2013). “Introduction to Green manufacturing”. In: Green Manufacturing. Springer US, pp. 1e23.
- Gao, Y., Li, J, and Song, Y. (2009). “Performance Evaluation of Green Supply Chain Management: Based on Membership Conversion Algorithm”. 2009 ISECS International Colloquium on Computing, Communication, Control, and Management, 237-240.
- Govindan, Kannan.,Diabat, Ali., Shankar, K.Madan. (2015). “Analyzing the drivers of green manufacturing with fuzzy approach”. 2015 Elsevier Ltd. All rights reserved.[doi:10.1016/j.jclepro.2014.02.054](https://doi.org/10.1016/j.jclepro.2014.02.054)
- Grubb and Ellis. (2007). “Meeting the Carbon Challenge: The Role of Commercial Real Estate Owners, Users & Managers”, Chicago.
- IPCC, (2014). “Climate Change 2014: Synthesis Report”. Summary for Policymakers.
- Jones, Christopher; Kammen, Daniel (2011). "Quantifying Carbon Footprint Reduction Opportunities for U.S. Households and Communities".
- Lee, Yuh-Jye., Yeh, Yi-Ren., Pao, Hsing-Kuo. (2010). “Introduction To Support Vector Machines And Their Application In Bankruptcy Prognosis”. National Taiwan University of Science and Technology. Taipei. Taiwan.

- Lin, Boqiang., Moubarak, Mohamed., Ouyang, Xiaoling. (2014). “Carbon dioxide emissions and growth of the manufacturing sector: Evidence for China”. 2014 Elsevier Ltd. All rights reserved.
- Mandle, Anil Kumar., Jain, Pranita., Shrivastava, Shailendra Kumar. (2012). “Protein Structure Prediction using Support Vector Machine”. International Journal on Soft Computing (IJSC) Vol.3, No.1, February 2012
- Oh DY, Noguchi T, Kitagaki R, Park WJ. (2014). “CO₂emission reduction by reuse of building material waste in the Japanese cement industry”. Renew Sustain Energy Rev 2014;38:796e810
- Papajorgji, Petraq. (2012). “Enterprise Business Modelling, Optimization Techniques, and Flexible Information Systems”. IGI Publishing Hershey, PA, USA 2013.
- Paul, I.D., Bhole, G.P., Chaudhari, J.R. (2014). “A review on Green Manufacturing: It’s important, Methodology and its Application”. 3rd International Conference on Materials Processing and Characterization (ICMPC 2014). Procedia Materials Science 6 (2014) 1644 – 1649.[10.1016/j.mspro.2014.07.149](http://dx.doi.org/10.1016/j.mspro.2014.07.149)
- Paz, Juan F. De., Perez, Belen., Gonzalez, Angelica., Emilio, Chorchado, Juan M, Chorchado. (2010) “A Support Vector Regression Approach to Predict Carbon Dioxide Exchange”. Springer-Verlag Berlin Heidelberg.
- Perner, Petra. (2007). “Machine Learning and Data Mining in Patter Recognition”. 5th International Conference, MLDM 2007, Leipzig, Germany. Springer
- Raghuvanshi, S.P., Chandra, Avinash., Raghav, Ashok Kumar. (2006). “Carbon Dioxide Emission From Coal Based Power Generation In India”. Energy Conversion and Management 47 (2006) 427–441. Elsevier Ltd. All rights reserved.
- P. Ristoski, C. Bizer, H. Paulheim, Mining the Web of Linked Data with RapidMiner, *Web Semantics: Science, Services and Agents on the World Wide Web* (2015), <http://dx.doi.org/10.1016/j.websem.2015.06.004> Tan, M.J et al. (2015). “Support-vector regression machine technology for total organic carbon content prediction

- from wireline logs in organic shale: A comparative study”. *Journal of Natural Gas Science & Engineering* (2015), doi: 10.1016/j.jngse.2015.07.008.
- Wiedmann, Thomas, Jan Minx, John Barrett, and Mathis Wackernagel. (2006). “Allocating Ecological Footprints to Final Consumption Categories with Input-output Analysis.” *Ecological Economics* 56(1): 28–48.<http://linkinghub.elsevier.com/retrieve/pii/S0921800905002600> (December 12, 2014).
- Wiedmann, T. and Minx, J. (2008). A Definition of 'Carbon Footprint'. In: C. C. Pertsova, *Ecological Economics Research Trends: Chapter 1*, pp. 1-11, Nova Science Publishers, Hauppauge NY, USA. https://www.novapublishers.com/catalog/product_info.php?products_id=5999.
- Wu, Lifeng., Liu, Sifeng., Liu, Dinglin., Fang, Zhigeng., Xu, Haiyan. (2014). “Modelling and forecasting CO2 emissions in the BRICS (Brazil, Russia, India, China, and South Africa) countries using a novel multi-variable grey model”. Elsevier Ltd. All rights reserved
- Wu, Qunli and Wei, Jiabao. (2015). “Prediction of Inter-Provincial Carbon Dioxide Emission in China : Based on Logistic Model”. 2nd International Conference on Education Reform and Modern Management (ERMM 2015).
- YunqiangZhang ,Peilin Zhang. (2014) , Machine training and parameter settings with social emotional optimization algorithm for support vector machine, *Pattern Recognition Letters* (2014), doi: 10.1016/j.patrec.2014.11.011.

LAMPIRAN

No	Electrical Energy	COAL (Kg)	Total CO2 Emission
1	8278	31350	62942
2	8270	31000	62301
3	8316	32000	64150
4	8280	31000	62308
5	8200	28170	57110
6	8308	27880	56661
7	8298	26070	53367
8	8297	27060	55164
9	8277	14150	31701
10	8330	12630	28979
11	8260	12000	27784
12	8332	24580	50685
13	8305	30000	60510
14	8298	30000	60505
15	8329	29910	60364
16	8228	28480	57693
17	8354	16000	35117
18	8279	16880	36662
19	8252	37790	74621
20	8276	10420	24926
21	8333	10300	24749
22	8376	27650	56293
23	8277	29690	59926
24	8317	27800	56523
25	8253	28800	58293

No	Electrical Energy	COAL (Kg)	Total CO2 Emission
26	8306	20950	44073
27	8343	20520	43319
28	8300	26920	54912
29	8326	13450	30465
30	8317	9900	24011
31	8302	27000	55059
32	8293	27550	56051
33	8333	15340	33903
34	8343	10000	24212
35	8294	9470	23214
36	8261	22650	47128
37	8259	21810	45601
38	8312	14540	32435
39	8341	15000	33291
40	8272	11820	27466
41	8326	17540	37894
42	8282	18700	39969
43	8292	18510	39631
44	8200	23950	49445
45	8255	23200	48122
46	8260	36880	72974
47	8398	29630	59905
48	8211	20520	43223
49	8312	17000	36903
50	8346	17650	38108
51	8300	27890	56674
52	8287	19650	41698
53	8308	19000	40533

No	Electrical Energy	COAL (Kg)	Total CO2 Emission
54	8233	27760	56389
55	8299	28000	56873
56	8289	19350	41155
57	8357	16750	36482
58	8297	19250	40979
59	8275	19650	41689
60	8309	22030	46037
61	8256	20950	44037
62	8319	21930	45862
63	8262	22350	46584
64	8335	23630	48962
65	8259	21180	44457
66	8189	21670	45296
67	8336	25780	52868
68	8315	25280	51944
69	8283	24860	51158
70	8290	24690	50854
71	8317	23550	48803
72	8447	23730	49225
73	8162	24310	50072
74	8344	23980	49604
75	8221	22620	47045
76	8310	22430	46764
77	8291	22150	46242
78	8289	22710	47257
79	8210	23050	47818
80	8271	23350	48407
81	8231	23150	48015

No	Electrical Energy	COAL (Kg)	Total CO2 Emission
82	8293	23060	47896
83	8382	22960	47779
84	8229	22670	47141
85	8317	22550	46987
86	8336	22510	46928

Table 6.1 Input data sebelum normalisasi

ELECTRICAL ENERGY (Kwh)	COAL (Kg)	Total CO2 Emission
0,40640308	0,77259887	0,772826222
0,37927117	0,760240113	0,760351005
0,538245001	0,795550847	0,796322161
0,414388048	0,760240113	0,760492275
0,132096442	0,660310734	0,659368154
0,509442811	0,650070621	0,650639998
0,475700897	0,586158192	0,586554017
0,472913114	0,621115819	0,621521111
0,40259115	0,165254237	0,165106934
0,587119413	0,111581921	0,112145197
0,34304212	0,089336158	0,088904382
0,594774331	0,533545198	0,534388912
0,500238533	0,724929379	0,725506016
0,477462143	0,724929379	0,725414389
0,58478646	0,721751412	0,722666295
0,229287709	0,671257062	0,670711945
0,671287121	0,230579096	0,23155137

ELECTRICAL ENERGY (Kwh)	COAL (Kg)	Total CO2 Emission
0,411110519	0,261652542	0,261596543
0,316445531	1	1
0,399414878	0,033545198	0,033307195
0,597884446	0,02930791	0,029865817
0,750582182	0,641949153	0,643483796
0,401832549	0,713983051	0,714157337
0,543505035	0,647245763	0,647950496
0,319497207	0,682556497	0,682380966
0,502842363	0,405367232	0,405765283
0,634572185	0,390183616	0,391102616
0,483490517	0,616172316	0,616617235
0,574036864	0,140536723	0,1410645
0,54133582	0,015183616	0,015505679
0,489496104	0,618997175	0,619467925
0,457845854	0,638418079	0,638772994
0,598809541	0,207274011	0,207940929
0,634141797	0,018714689	0,019412188
0,463510732	0	0
0,345062482	0,46539548	0,465194318
0,33817425	0,435734463	0,435488042
0,52612228	0,179025424	0,179383218
0,625667451	0,195268362	0,196036223
0,38447883	0,082980226	0,082711384
0,575600191	0,284957627	0,285577136
0,420652933	0,325918079	0,325938489
0,453363165	0,31920904	0,319357069
0,133810644	0,511299435	0,510275591
0,323710306	0,484816384	0,484540814

ELECTRICAL ENERGY (Kwh)	COAL (Kg)	Total CO2 Emission
0,344087033	0,967867232	0,967959419
0,82575419	0,711864407	0,713742822
0,170592473	0,390183616	0,389236086
0,525776242	0,265889831	0,266297623
0,643820567	0,288841808	0,289738057
0,484188106	0,650423729	0,650891718
0,439000478	0,359463277	0,359577342
0,511723941	0,336511299	0,336904343
0,24674287	0,645833333	0,645343395
0,478095046	0,65430791	0,654753685
0,443472141	0,348870056	0,348995844
0,684446486	0,257062147	0,258103027
0,471885291	0,345338983	0,345576984
0,394168811	0,359463277	0,35939699
0,514364893	0,443502825	0,443969792
0,329621435	0,405367232	0,405068437
0,548609416	0,439971751	0,44057439
0,34828249	0,45480226	0,454607784
0,606668994	0,5	0,500871719
0,340241106	0,413488701	0,413237433
0,092778595	0,43079096	0,429554419
0,609815863	0,575918079	0,576847373
0,537134115	0,558262712	0,558889171
0,423020251	0,543432203	0,543590823
0,447020362	0,537429379	0,537680996
0,541030947	0,497175141	0,497781136
1	0,503531073	0,505987201
0	0,524011299	0,522456674

ELECTRICAL ENERGY (Kwh)	COAL (Kg)	Total CO2 Emission
0,635654219	0,512358757	0,513354392
0,207520582	0,464336158	0,463581056
0,519714238	0,457627119	0,458123961
0,450610115	0,447740113	0,447953109
0,442960894	0,467514124	0,467708048
0,168181417	0,479519774	0,478615398
0,380036754	0,490112994	0,490067152
0,242198618	0,483050847	0,482446322
0,459379962	0,479872881	0,480140168
0,772140547	0,476341808	0,477865201
0,234051014	0,466101695	0,465454365
0,541807373	0,461864407	0,462452634
0,609500515	0,460451977	0,46131169

Table 6.2 Input data setelah normalisasi

	Electrical Energy (Kwh)	Coal (Kg)	CO2 emission	Nilai kalor batubara (Tj/Ton)	Coal (Ton)	Coal Emission	Electricity Emission	Total CO2 Emission
01-Jan-15	8264,24	31350	62932,2655	0,0189	31,35	56940,6915	5991,574	62932,2655
02-Jan-15	8264,24	31000	62296,564		31	56304,99	5991,574	62296,564
03-Jan-15	8314,84	32000	64149,539	Faktor Emisi Batubara (Kg CO2/Tj)	32	58121,28	6028,259	64149,539
04-Jan-15	8264,24	31000	62296,564	96100	31	56304,99	5991,574	62296,564
05-Jan-15	8213,64	28170	57119,7783		28,17	51164,8893	5954,889	57119,7783
06-Jan-15	8314,84	27880	56666,4242	Faktor emisi listrik (Kg/Kwh)	27,88	50638,1652	6028,259	56666,4242
07-Jan-15	8314,84	26070	53378,9393	0,725	26,07	47350,6803	6028,259	53378,9393
08-Jan-15	8314,84	27060	55177,0664		27,06	49148,8074	6028,259	55177,0664
09-Jan-15	8264,24	14150	31692,0775		14,15	25700,5035	5991,574	31692,0775
10-Jan-15	8314,84	12630	28968,0017		12,63	22939,7427	6028,259	28968,0017
11-Jan-15	8264,24	12000	27787,054		12	21795,48	5991,574	27787,054
12-Jan-15	8314,84	24580	50672,6672		24,58	44644,4082	6028,259	50672,6672
13-Jan-15	8314,84	30000	60516,959		30	54488,7	6028,259	60516,959
14-Jan-15	8314,84	30000	60516,959		30	54488,7	6028,259	60516,959
15-Jan-15	8314,84	29910	60353,4929		29,91	54325,2339	6028,259	60353,4929
16-Jan-15	8213,64	28480	57682,8282		28,48	51727,9392	5954,889	57682,8282
17-Jan-15	8365,44	16000	35125,584		16	29060,64	6064,944	35125,584
18-Jan-15	8264,24	16880	36650,5492		16,88	30658,9752	5991,574	36650,5492
19-Jan-15	8264,24	37790	74629,1731		37,79	68637,5991	5991,574	74629,1731
20-Jan-15	8264,24	10420	24917,3158		10,42	18925,7418	5991,574	24917,3158
21-Jan-15	8314,84	10300	24736,046		10,3	18707,787	6028,259	24736,046
22-Jan-15	8365,44	27650	56285,3625		27,65	50220,4185	6064,944	56285,3625

21-Jan-15	8314,84	10300	24736,046		10,3	18707,787	6028,259	24736,046
22-Jan-15	8365,44	27650	56285,3625		27,65	50220,4185	6064,944	56285,3625
23-Jan-15	8264,24	29690	59917,2241		29,69	53925,6501	5991,574	59917,2241
24-Jan-15	8314,84	27800	56521,121		27,8	50492,862	6028,259	56521,121
25-Jan-15	8264,24	28800	58300,726		28,8	52309,152	5991,574	58300,726
26-Jan-15	8314,84	20950	44079,5345		20,95	38051,2755	6028,259	44079,5345
27-Jan-15	8365,44	20520	43335,2148		20,52	37270,2708	6064,944	43335,2148
28-Jan-15	8314,84	26920	54922,7858		26,92	48894,5268	6028,259	54922,7858
29-Jan-15	8314,84	13450	30457,3595		13,45	24429,1005	6028,259	30457,3595
30-Jan-15	8314,84	9900	24009,53		9,9	17981,271	6028,259	24009,53
31-Jan-15	8314,84	27000	55068,089		27	49039,83	6028,259	55068,089
01-Feb-15	8314,84	27550	56067,0485		27,55	50038,7895	6028,259	56067,0485
02-Feb-15	8314,84	15340	33890,1476		15,34	27861,8886	6028,259	33890,1476
03-Feb-15	8365,44	10000	24227,844		10	18162,9	6064,944	24227,844
04-Feb-15	8314,84	9470	23228,5253		9,47	17200,2663	6028,259	23228,5253
05-Feb-15	8264,24	22650	47130,5425		22,65	41138,9685	5991,574	47130,5425
06-Feb-15	8264,24	21810	45604,8589		21,81	39613,2849	5991,574	45604,8589
07-Feb-15	8314,84	14540	32437,1156		14,54	26408,8566	6028,259	32437,1156
08-Feb-15	8365,44	15000	33309,294		15	27244,35	6064,944	33309,294
09-Feb-15	8264,24	11820	27460,1218		11,82	21468,5478	5991,574	27460,1218
10-Feb-15	8314,84	17540	37885,9856		17,54	31857,7266	6028,259	37885,9856
11-Feb-15	8264,24	18700	39956,197		18,7	33964,623	5991,574	39956,197
12-Feb-15	8314,84	18510	39647,7869		18,51	33619,5279	6028,259	39647,7869

12-Feb-15	8314,84	18510	39647,7869	18,51	33619,5279	6028,259	39647,7869
13-Feb-15	8213,64	23950	49455,0345	23,95	43500,1455	5954,889	49455,0345
14-Feb-15	8264,24	23200	48129,502	23,2	42137,928	5991,574	48129,502
15-Feb-15	8264,24	36880	72976,3492	36,88	66984,7752	5991,574	72976,3492
16-Feb-15	8416,04	29630	59918,3017	29,63	53816,6727	6101,629	59918,3017
17-Feb-15	8213,64	20520	43225,1598	20,52	37270,2708	5954,889	43225,1598
18-Feb-15	8314,84	17000	36905,189	17	30876,93	6028,259	36905,189
19-Feb-15	8365,44	17650	38122,4625	17,65	32057,5185	6064,944	38122,4625
20-Feb-15	8314,84	27890	56684,5871	27,89	50656,3281	6028,259	56684,5871
21-Feb-15	8264,24	19650	41681,6725	19,65	35690,0985	5991,574	41681,6725
22-Feb-15	8314,84	19000	40537,769	19	34509,51	6028,259	40537,769
23-Feb-15	8213,64	27760	56375,0994	27,76	50420,2104	5954,889	56375,0994
24-Feb-15	8314,84	28000	56884,379	28	50856,12	6028,259	56884,379
25-Feb-15	8264,24	19350	41136,7855	19,35	35145,2115	5991,574	41136,7855
01-Jun-15	8365,44	16750	36487,8015	16,75	30422,8575	6064,944	36487,8015
02-Jun-15	8314,84	19250	40991,8415	19,25	34963,5825	6028,259	40991,8415
03-Jun-15	8264,24	19650	41681,6725	19,65	35690,0985	5991,574	41681,6725
04-Jun-15	8314,84	22030	46041,1277	22,03	40012,8687	6028,259	46041,1277
05-Jun-15	8264,24	20950	44042,8495	20,95	38051,2755	5991,574	44042,8495
06-Jun-15	8314,84	21930	45859,4987	21,93	39831,2397	6028,259	45859,4987
07-Jun-15	8264,24	22350	46585,6555	22,35	40594,0815	5991,574	46585,6555
08-Jun-15	8314,84	23630	48947,1917	23,63	42918,9327	6028,259	48947,1917
08-Jun-15	8314,84	23630	48947,1917	23,63	42918,9327	6028,259	48947,1917
09-Jun-15	8264,24	21180	44460,5962	21,18	38469,0222	5991,574	44460,5962
10-Jun-15	8213,64	21670	45313,8933	21,67	39359,0043	5954,889	45313,8933
11-Jun-15	8314,84	25780	52852,2152	25,78	46823,9562	6028,259	52852,2152
12-Jun-15	8314,84	25280	51944,0702	25,28	45915,8112	6028,259	51944,0702
13-Jun-15	8264,24	24860	51144,5434	24,86	45152,9694	5991,574	51144,5434
14-Jun-15	8314,84	24690	50872,4591	24,69	44844,2001	6028,259	50872,4591
15-Jun-15	8314,84	23550	48801,8885	23,55	42773,6295	6028,259	48801,8885
16-Jun-15	8466,64	23730	49238,8757	23,73	43100,5617	6138,314	49238,8757
17-Jun-15	8163,04	24310	50072,2139	24,31	44154,0099	5918,204	50072,2139
18-Jun-15	8365,44	23980	49619,5782	23,98	43554,6342	6064,944	49619,5782
19-Jun-15	8213,64	22620	47039,3688	22,62	41084,4798	5954,889	47039,3688
20-Jun-15	8314,84	22430	46767,6437	22,43	40739,3847	6028,259	46767,6437
21-Jun-15	8314,84	22150	46259,0825	22,15	40230,8235	6028,259	46259,0825
22-Jun-15	8264,24	22710	47239,5199	22,71	41247,9459	5991,574	47239,5199
23-Jun-15	8213,64	23050	47820,3735	23,05	41865,4845	5954,889	47820,3735
24-Jun-15	8264,24	23350	48401,9455	23,35	42410,3715	5991,574	48401,9455
25-Jun-15	8213,64	23150	48002,0025	23,15	42047,1135	5954,889	48002,0025
26-Jun-15	8314,84	23060	47911,9064	23,06	41883,6474	6028,259	47911,9064
27-Jun-15	8365,44	22960	47766,9624	22,96	41702,0184	6064,944	47766,9624
28-Jun-15	8213,64	22670	47130,1833	22,67	41175,2943	5954,889	47130,1833
29-Jun-15	8314,84	22550	46985,5985	22,55	40957,3395	6028,259	46985,5985
30-Jun-15	8314,84	22510	46912,9469	22,51	40884,6879	6028,259	46912,9469

Table 6.3 Kalkulasi Emisi Karbon Dioksida

