

**STUDI AWAL PENGAPLIKASIAN *MACHINE*
LEARNING DENGAN MODEL LSTM DALAM
MEMPREDIKSI TEMPERATUR KOLOM DISTILASI
REAKTIF UNTUK PRODUKSI DME**

Laporan Penelitian

Disusun untuk memenuhi tugas akhir guna mencapai gelar
sarjana di bidang ilmu Teknik Kimia

oleh:

Elvina Loice (6141901109)

Dosen Pembimbing:

Dr. Ir. Budi Husodo Bisowarno, M.Eng



**PROGRAM STUDI SARJANA TEKNIK KIMIA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS KATOLIK PARAHYANGAN
2023**



**PROGRAM STUDI SARJANA TEKNIK KIMIA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS KATOLIK PARAHYANGAN**

LEMBAR PENGESAHAN

Nama : Elvina Loice

NPM : 6141901109

Judul : Studi Awal Pengaplikasian *Machine Learning* Dengan Model LSTM Dalam
Memprediksi Temperatur Kolom Distilasi Reaktif Untuk Produksi DME

CATATAN :

Telah diperiksa dan disetujui,

Bandung, 7 Juli 2023

Pembimbing

Dr. Ir. Budi Husodo Bisowarno, M.Eng



**PROGRAM STUDI SARJANA TEKNIK KIMIA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS KATOLIK PARAHYANGAN**

LEMBAR REVISI

Nama : Elvina Loice

NPM : 6141901109

Judul : Studi Awal Pengaplikasian *Machine Learning* Dengan Model LSTM Dalam
Memprediksi Temperatur Kolom Distilasi Reaktif Untuk Produksi DME

CATATAN :

Bagian Intisari: Melengkapi Alinea Terakhir

Bagian Tinjauan Pustaka: Kelebihan Model LSTM

Bagian Pembahasan: Penjelasan Temperatur Tahap yang Dipilih, Penjelasan *Overfitting*

Bagian Lampiran: Menambahkan Lampiran *Script Python*

Telah diperiksa dan disetujui,

Bandung, 24 Juli 2023

Dosen Penguji 1

Dr. Ir. Tedi Hudaya, S.T, M.Eng.Sc.

Dosen Penguji 2

I Gede Pandega Wiratama, S.T., M.T



**PROGRAM STUDI SARJANA TEKNIK KIMIA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS KATOLIK PARAHYANGAN**

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini :

Nama : Elvina Loice

NPM : 6141901109

dengan ini menyatakan bahwa laporan penelitian dengan judul :

**STUDI AWAL PENGAPLIKASIAN *MACHINE LEARNING* DENGAN MODEL
LSTM DALAM MEMPREDIKSI TEMPERATUR KOLOM DISTILASI REAKTIF
UNTUK PRODUKSI DME**

Adalah hasil pekerjaan saya dan seluruh ide, pendapat atau materi dari sumber lain telah dikutip dengan cara penulisan referensi yang sesuai.

Pernyataan ini saya buat dengan sebenar-benarnya dan jika pernyataan ini tidak sesuai dengan kenyataan, maka saya bersedia menanggung sanksi sesuai dengan peraturan yang berlaku.

Bandung, 13 Juli 2023



Elvina Loice

(6141901109)

INTISARI

Proses distilasi yang merupakan proses yang umum dijumpai pada industri kimia merupakan proses yang membutuhkan energi yang besar. Distilasi reaktif merupakan salah satu jenis distilasi dengan hubungan antar variabel yang rumit karena mengintegrasikan proses distilasi dan reaksi dalam satu alat. Keunggulan unit kolom distilasi reaktif adalah kebutuhan biaya investasi dan biaya utilitas yang lebih rendah dibandingkan unit operasi reaktor dan kolom distilasi yang terpisah. Untuk mendapatkan kemurnian produk dan konversi reaktan pada proses distilasi reaktif maka pengoperasian serta pengendaliannya membutuhkan biaya yang besar serta energi yang banyak. Sehingga pengurangan biaya pada proses distilasi reaktif akan berdampak sangat besar bagi keseluruhan operasi pabrik. Maka proses pengendalian dengan *machine learning* akan digunakan untuk mengurangi biaya pengendaliannya karena dapat memprediksi temperatur kolom yang merupakan variabel inferensial untuk kemurnian produk.

Penelitian ini bertujuan untuk membuktikan keakuratan penggunaan *machine learning* dalam memprediksi temperatur kolom distilasi reaktif untuk produksi dimetil eter. Kolom distilasi reaktif dimodelkan dan disimulasikan secara tunak dengan menggunakan perangkat lunak ASPEN Plus®. Kemudian simulasi dilanjutkan dengan perangkat lunak ASPEN Plus Dynamic® untuk mendapatkan data profil temperatur kolom distilasi reaktif sebagai fungsi dari waktu. Pada penelitian ini model *machine learning* yang digunakan adalah model *Long-Short Term Memory* (LSTM). Model ini digunakan untuk memprediksi profil temperatur kolom distilasi reaktif dengan menggunakan data hasil simulasi ASPEN Plus Dynamic® sebagai data pelatihan. Penelitian ini menggunakan empat jenis metode optimasi yaitu, SGD, RMSprop, AdaGrad, dan Adam.

Pada penelitian ini, metode optimasi yang paling bagus adalah Adam dengan nilai MSE hasil pelatihan yang terkecil adalah 0,352 dan nilai R^2 hasil pelatihan yang paling mendekati satu adalah 0,999. Dikarenakan terjadi *overfitting* saat pelatihan, kinerja model saat simulasi prediksi dan pelatihan memiliki hasil yang berbeda. Nilai MSE hasil prediksi model LSTM dengan metode Adam yang terkecil adalah 0,415 untuk temperatur tahap 47 dan R^2 yang paling mendekati satu adalah 0,869 untuk temperatur kolom tahap 5. Untuk model LSTM dengan metode RMSprop nilai MSE hasil prediksi terkecilnya adalah 4,094 dan R^2 yang paling mendekati satu adalah 0,832. Hasil prediksi dengan metode optimasi AdaGrad memiliki MSE terkecil senilai 28,306 dan nilai R^2 terbagusnya sebesar 0,321. Dan untuk model dengan metode optimasi SGD nilai MSE hasil prediksi terkecilnya 40,520 dengan R^2 nya bernilai 0 semuanya. Hasil-hasil ini masih jauh dari nilai yang diinginkan yaitu MSE dibawah 10 dan nilai R^2 diatas 0,9, dan untuk memperbaiki hasil ini dapat dilakukan metode *early stopping* dan penambahan data pelatihan.

Kata kunci : distilasi reaktif, dimetil eter, *machine learning*, LSTM

ABSTRACT

The distillation process, commonly found in the chemical industry, requires a significant amount of energy. Reactive distillation, which integrates distillation and reaction processes in a single apparatus, is a type of distillation with complex interrelationships between variables. The advantage of the reactive distillation column unit lies in its lower investment and utility costs compared to separate reactor and distillation column units. To achieve product purity and reactant conversion in reactive distillation, its operation and control incur significant costs and consume a large amount of energy. Therefore, reducing costs in reactive distillation processes would have a substantial impact on overall plant operations. Hence, machine learning-based control processes will be utilized to minimize control costs as they can predict column temperatures, which are inferential variables for product purity.

The objective of this study is to demonstrate the accuracy of using machine learning to predict the temperature of a reactive distillation column for dimethyl ether production. The reactive distillation column is modeled and simulated using ASPEN Plus® software. The simulation is then extended using ASPEN Plus Dynamic® software to obtain the temperature profile data of the reactive distillation column over time. In this study, the machine learning model employed is the Long-Short Term Memory (LSTM) model. This model predicts the temperature profile of the reactive distillation column using data from ASPEN Plus Dynamic® simulation as training data. The study utilizes four types of optimization methods: SGD, RMSprop, AdaGrad, and Adam.

Among the optimization methods investigated in this study, Adam demonstrates the best performance, with a minimal Mean Squared Error (MSE) training result of 0.352 and a training result R^2 value closest to one, which is 0.999. However, due to overfitting during training, there is a discrepancy between the model's performance during simulation prediction and training. For the predicted LSTM model with the Adam optimization method, the smallest MSE value is 0.415 for the temperature at stage 47, and the R^2 value closest to one is 0.869 for the temperature of stage 5 in the column. Regarding the LSTM model with the RMSprop optimization method, the smallest MSE value for the predicted results is 4.094, and the R^2 value closest to one is 0.832. Meanwhile, the AdaGrad optimization method yields the smallest MSE value of 28.306, with the best R^2 value being 0.321. As for the model utilizing the SGD optimization method, the smallest MSE value for the predicted results is 40.520, and all R^2 values are equal to 0. These results are still far from the desired values, which are MSE below 10 and R^2 above 0.9, and to improve these results, the early stopping method and the addition of training data can be implemented.

Keyword : reactive distillation, dimethyl ether, machine learning, LSTM

KATA PENGANTAR

Puji syukur kepada Tuhan Yang Maha Esa atas berkat dan rahmat-Nya penulis dapat menyelesaikan laporan penelitian yang berjudul “Studi Awal Pengaplikasian *Machine Learning* dengan Model LSTM dalam Memprediksi Temperatur Kolom Distilasi Reaktif Untuk Produksi DME” dengan baik dan tepat waktu.

Dalam penyusunan laporan penelitian ini, penulis mendapatkan bimbingan, bantuan, dan dukungan dari berbagai pihak. Oleh karena itu, penulis hendak mengucapkan terima kasih secara khusus kepada:

1. Dr. Ir. Budi Husodo Bisowarno, M.Eng selaku dosen pembimbing yang telah memberikan saran, pengarahan, dan dukungan kepada penulis selama penulisan laporan penelitian.
2. Orangtua serta keluarga penulis yang selalu memberikan doa, perhatian, dan dukungan kepada penulis.
3. Teman-teman penulis yang telah memberikan kritik, saran, dan dukungan dalam menulis laporan penelitian ini.
4. Semua pihak lain yang secara langsung maupun tidak langsung telah memberikan bantuan dan dukungan selama penyusunan laporan penelitian.

Penulis menyadari bahwa laporan penelitian ini jauh dari kata sempurna, maka dari itu penulis memohon maaf sebesar-besarnya apabila terdapat kesalahan dalam penulisan kalimat maupun kata-kata yang kurang berkenan bagi pembaca. Penulis juga mengharapkan kritik dan saran yang membangun dari para pembaca agar dapat menjadi bekal bagi penulis untuk memperbaiki laporan penelitian ini. Akhir kata, penulis berharap agar laporan penelitian ini dapat memberikan manfaat tambahan bagi banyak pihak.

Bandung, Juni 2023



Elvina Loice
(6141901109)

DAFTAR ISI

COVER	i
LEMBAR PENGESAHAN	ii
SURAT PERNYATAAN	iii
LEMBAR REVISI	iv
KATA PENGANTAR	v
DAFTAR ISI	vi
DAFTAR GAMBAR	ix
DAFTAR TABEL	x
INTISARI	xi
ABSTRACT	xii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Tema Sentral Masalah	2
1.3 Identifikasi Masalah	2
1.4 Premis-Premis Penelitian	3
1.5 Hipotesis	4
1.6 Tujuan Penelitian	5
1.7 Manfaat Penelitian	5
1.7.1 Bagi Peneliti	5
1.7.2 Bagi Industri	5
BAB II TINJAUAN PUSTAKA	6
2.1 Sejarah <i>Artificial Intelligence</i> dan <i>Machine Learning</i>	6
2.2 AI dan <i>Machine Learning</i> dalam Industri Kimia	8
2.2.1 Optimasi Proses	12
2.2.2 Kontrol Proses	14
2.2.3 Predictive Modeling	15
2.3 Sistem Distilasi dalam <i>Process Engineering</i>	17
2.3.1 Distilasi	17
2.3.2 Distilasi reaktif	20
2.3.3 <i>Dividing wall column</i>	20
2.3.4 <i>Reactive dividing wall column</i>	22
2.4 Distilasi Reaktif untuk Produksi DME	23
2.4.1 DME	23

2.4.2 Sintesis DME.....	24
2.4.3 Desain Distilasi Reaktif untuk Produksi DME.....	27
2.4.4 Model dan Validasi ASPEN	28
2.5 <i>Machine Learning</i> untuk Proses Distilasi.....	33
2.6 <i>Deep Learning</i> (RNN, LSTM, GRU).....	35
2.6.1 <i>Deep Learning</i>	35
2.6.2 ANN (<i>Artificial Neural Network</i>)	36
2.6.3 RNN, LSTM, GRU	37
2.7 Metode Optimasi dalam <i>Machine Learning</i>	40
2.8 <i>Hyperparameter Tuning</i>	42
2.9 ASPEN.....	43
2.10 Python.....	44
BAB III METODOLOGI PENELITIAN	45
3.1 Pengumpulan dan Persiapan Data	46
3.2 Pemodelan LSTM.....	47
3.3 Pemilihan Kondisi Optimal untuk Model LSTM (<i>Hyperparameter Tuning</i>).....	48
3.4 Simulasi Model LSTM.....	49
3.5 Evaluasi Model LSTM.....	49
3.6 Lokasi dan Jadwal Kerja Penelitian.....	50
BAB IV PEMBAHASAN.....	52
4.1 Pengumpulan Data.....	52
4.2 Korelasi Pearson Rasio Refluks dan <i>Reboiler Duty</i> terhadap Temperatur Tahap 4, Tahap 5, dan Tahap 47	52
4.3 Model LSTM dengan Python Untuk Memprediksi Temperatur Kolom Distilasi Reaktif untuk Produksi DME.....	53
4.4 Hasil <i>Hyperparameter Tuning</i>	53
4.4.1 <i>Hyperparameter Tuning</i> untuk Rasio Refluks.....	54
4.4.2 <i>Hyperparameter Tuning</i> untuk <i>Reboiler Duty</i>	55
4.5 Pelatihan Model LSTM	56
4.5.1 Variasi RR.....	56
4.5.2 Variasi <i>Reboiler Duty</i>	60
4.6 Simulasi Model LSTM untuk Memprediksi Temperatur Kolom.....	63
4.6.1 Variasi Rasio Refluks.....	63
4.6.2 Variasi <i>Reboiler Duty</i>	65
4.7 Evaluasi Keakuratan Hasil Prediksi <i>Machine Learning</i> Menggunakan Model LSTM.....	66
BAB V KESIMPULAN DAN SARAN	68

5.1 Kesimpulan	68
5.2 Saran.....	68
DAFTAR PUSTAKA	69
LAMPIRAN A	72
<i>A.1 Hyperparameter Tuning Model</i>	<i>72</i>
<i>A.2 Predicting Model</i>	<i>75</i>

DAFTAR GAMBAR

Gambar 2.1. Hubungan antara AI dan machine learning	8
Gambar 2.2. Aplikasi utama AI dalam bidang rekayasa proses dan bidang terkait	10
Gambar 2.3. Aplikasi ANN pada kolom distilasi	13
Gambar 2.4. Skema kolom dehidrasi.....	16
Gambar 2.5. Diagram proses kolom distilasi.....	19
Gambar 2.6. Penyusunan dua kolom distilasi (a) secara langsung dan (b) secara tidak langsung .	21
Gambar 2.7. Penyusunan dua kolom distilasi dengan konfigurasi Perlyuk.....	21
Gambar 2.8. Dividing Wall Column.....	22
Gambar 2.9. Skema kolom distilasi reaktif untuk produksi DME.....	28
Gambar 2.10. Profil temperatur dan laju reaksi dari Literatur.....	31
Gambar 2.11. Profil temperatur dan laju reaksi hasil simulasi	31
Gambar 2.12. Profil temperatur hasil simulasi model dinamik	32
Gambar 2.13. Struktur RNN.....	38
Gambar 2.14. Tampilan utama ASPEN Plus®.....	43
Gambar 3.1. Bagan kerja penelitian	45
Gambar 4.1 Hasil Pelatihan Model LSTM dengan Metode Optimasi SGD untuk Variasi Rasio Refluks	56
Gambar 4.2 Hasil Pelatihan Model LSTM dengan Metode Optimasi AdaGrad untuk Variasi Rasio Refluks	57
Gambar 4.3 Hasil Pelatihan Model LSTM dengan Metode Optimasi RMSprop untuk Variasi Rasio Refluks	58
Gambar 4.4 Hasil Pelatihan Model LSTM dengan Metode Optimasi Adam untuk Variasi Rasio Refluks	59
Gambar 4.5 Hasil Pelatihan Model LSTM dengan Metode Optimasi SGD untuk Variasi <i>Reboiler Duty</i>	60
Gambar 4.6 Hasil Pelatihan Model LSTM dengan Metode Optimasi AdaGrad untuk Variasi <i>Reboiler Duty</i>	61
Gambar 4.7 Hasil Pelatihan Model LSTM dengan Metode Optimasi RMSprop untuk Variasi <i>Reboiler Duty</i>	62
Gambar 4.8 Hasil Pelatihan Model LSTM dengan Metode Optimasi Adam untuk Variasi <i>Reboiler Duty</i>	63
Gambar 4.9 Hasil Prediksi Model LSTM untuk Variasi Rasio Refluks +10%	64
Gambar 4.10 Hasil Prediksi Model LSTM untuk Variasi <i>Reboiler Duty</i> +10%	65

DAFTAR TABEL

Tabel 2.1. Contoh aplikasi machine learning dalam rekayasa proses	11
Tabel 2.2. Sifat fisik dari DME	24
Tabel 2.3. Perbandingan sintesis langsung dan tidak langsung DME	26
Tabel 2.4. Parameter desain optimal kolom distilasi reaktif.....	29
Tabel 3.1. Korelasi pada rentang pengaruh nilai R	47
Tabel 3.2. Parameter kondisi optimal untuk model	49
Tabel 3.3. Rencana jadwal kerja penelitian	50
Tabel 4.1 Rentang Perubahan Variabel	52
Tabel 4.2 Korelasi Pearson RR dan RD terhadap Temperatur Tahap 4, 5, dan 47	53
Tabel 4.3 Variasi Parameter untuk Hyperparameter Tuning	54
Tabel 4.4 Hasil Hyperparameter Tuning untuk Variasi Rasio Refluks	55
Tabel 4.5 Hasil Hyperparameter Tuning untuk Variasi Reboiler Duty	55
Tabel 4.6 Nilai MSE dan R2 untuk Run Variasi Rasio Refluks.....	64
Tabel 4.7 Nilai MSE dan R2 untuk Run Variasi Reboiler Duty.....	66

BAB I

PENDAHULUAN

1.1 Latar Belakang

Perkembangan industri yang semakin pesat menyebabkan munculnya proses-proses baru yang persamaan matematika antar variabelnya belum sepenuhnya dipahami sehingga sulit untuk dimodelkan. Model matematika dari proses baru ini diperlukan untuk memudahkan perancangan dan pengendalian proses dalam suatu industri. Pada proses dengan hubungan dan persamaan yang rumit, biaya yang besar serta waktu yang lama dibutuhkan untuk memodelkannya terlebih lagi untuk pengendaliannya. Cara-cara baru untuk memodelkan proses secara cepat dan hemat sedang dikembangkan oleh berbagai ilmuwan (Dobbelaere dkk., 2021).

Machine learning (ML) merupakan salah satu model komputasi yang dapat menghasilkan *output* dari sekumpulan data yang memiliki hubungan yang kompleks. Untuk mengaplikasikan *machine learning* ini diperlukan data yang banyak dan tersusun secara sistematis. Sudah banyak bidang yang mengaplikasikan *machine learning* untuk membantu analisa, mengambil keputusan, dan memprediksi hasil yang akan datang. Contoh aplikasi ML pada bidang lain adalah untuk klasifikasi DNA, analisa jaringan sosial, segmentasi pasar, analisa data astronomi, pengenalan suara, pengenalan wajah, dan lainnya (Cioffi dkk., 2020). Namun, pada industri kimia dan bidang teknik kimia *machine learning* ini masih belum banyak dimanfaatkan. Pengaplikasian ML pada industri kimia dipercaya dapat membantu untuk menurunkan kebutuhan energi, waktu, dan biaya untuk pengembangan suatu proses. Penggunaan ML juga dapat membantu pengendalian dari proses-proses baru berdasarkan data yang tersedia.

Distilasi merupakan salah satu proses dalam industri kimia yang umum ditemui, tetapi pengoperasian serta pengendaliannya membutuhkan energi yang besar. Salah satu jenis distilasi adalah distilasi reaktif yang pada pengoperasian serta pengendaliannya melibatkan hubungan antar variabel yang rumit karena mengintegrasikan proses distilasi dan reaksi dalam satu peralatan. Sehingga dibutuhkan biaya yang besar serta jangka waktu yang lama bagi peneliti untuk perancangan, pengoperasian, dan pengendalian kolom distilasi reaktif tersebut (Malone dan Doherty, 2000).

Pemodelan pengendalian kolom distilasi reaktif pada senyawa baru dipercaya dapat dilakukan dengan bantuan *machine learning*. *Machine learning* digunakan untuk

memprediksi temperatur kolom distilasi reaktif yang merupakan variabel *inferential* yang mewakili kemurnian produk. Sebelumnya ML dilatih terlebih dahulu menggunakan data-data dari kolom distilasi reaktif yang ingin diprediksi temperaturnya. Model ML yang dapat digunakan untuk memprediksi kelakuan proses ada tiga, yaitu *Recurrent Neural Network* (RNN), *Long-Short Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU). Ketiga model ini merupakan model *machine learning* yang dapat memprediksi hasil dari pengolahan data-data yang sudah ada.

Pada penelitian ini digunakan ML dengan model LSTM (*Long-Short Term Memory*) yang merupakan model kembangan dari RNN untuk memprediksi proses. Model LSTM ini dilatih menggunakan data-data yang dikumpulkan dari simulasi kolom distilasi reaktif untuk produksi DME menggunakan ASPEN. Penelitian ini menggunakan empat jenis metode optimasi yaitu, SGD, RMSprop, AdaGrad, dan Adam. Lalu akan ditentukan metode optimasi mana yang terbaik untuk digunakan pada model. Dengan model yang terbaik dilakukan prediksi temperatur kolom distilasi produksi DME kemudian ditentukan ketepatan dari hasil prediksi LSTM dengan data dari simulasi ASPEN.

Penelitian terkait penggunaan *machine learning* pada proses distilasi reaktif masih sangat sedikit. Sehingga diharapkan dengan penelitian ini dapat diketahui seberapa tepat hasil prediksi dari *machine learning* dengan model LSTM dalam memprediksi proses distilasi reaktif. Selanjutnya diharapkan hasil dari penelitian ini dapat diaplikasikan untuk pengendalian prediktif pada kolom distilasi reaktif.

1.2 Tema Sentral Masalah

Tema sentral masalah dari penelitian ini adalah mencari keakuratan penggunaan *machine learning* untuk memprediksi temperatur kolom distilasi reaktif untuk produksi DME menggunakan model LSTM.

1.3 Identifikasi Masalah

Berdasarkan tema sentral masalah yang ada, identifikasi masalah yang dapat dilakukan pada penelitian ini adalah sebagai berikut:

1. Bagaimana cara menggunakan *machine learning* untuk memprediksi temperatur kolom distilasi reaktif untuk produksi DME?
2. Bagaimana keakuratan *machine learning* dalam memprediksi temperatur kolom distilasi reaktif untuk produksi DME?

3. Bagaimana pengaruh metode optimasi terhadap keakuratan model LSTM dalam memprediksi temperatur kolom distilasi reaktif untuk produksi DME?

1.4 Premis-Premis Penelitian

1. Reaksi yang digunakan pada kolom distilasi reaktif untuk produksi DME adalah $2\text{CH}_3\text{OH} \leftrightarrow \text{CH}_3\text{OCH}_3 + \text{H}_2\text{O}$ (Bakhtyari dan Rahimpour, 2018; Wahid dan Putra, 2018).
2. Kinetika reaksi yang digunakan untuk reaksi dehidrasi metanol dengan katalis resin penukar ion asam sulfonat adalah $r_{\text{DME}} = kW_{\text{cat}}[\text{MeOH}]^m[\text{H}_2\text{O}]^n$ dimana $k = A \exp\left(-\frac{E_a}{RT}\right)$ (Lei dkk., 2011).
dengan W = berat jenis katalis (637 kg/m^3)
 A = tetapan Arrhenius ($5,19 \times 10^9 \text{ m}^3/\text{kg cat s}$)
 E_a = energi aktivasi ($133,8 \text{ Kj/mol}$)
 m = orde reaksi metanol ($1,51$)
 n = orde reaksi air ($-0,51$)
3. Resin yang digunakan dalam kolom distilasi reaktif untuk membantu proses reaksi adalah resin penukar ion asam sulfonat dengan asumsi tidak terjadi reaksi samping (Lei dkk., 2011).
4. Jumlah tahap pada kolom distilasi reaktif untuk produksi DME adalah 54 tahap, dengan tahap 1 merupakan kondensor dan tahap 54 merupakan *reboiler*. Tahap 2 hingga tahap 8 merupakan *rectrifying section*, tahap 9 hingga 42 merupakan *reaction section*, dan tahap 43 hingga 53 merupakan *stripping section* (Bildea dkk., 2017).
5. Metanol diumpankan masuk ke *preheater* dengan laju 546 kmol/jam , temperatur $25 \text{ }^\circ\text{C}$, dan tekanan 12 bar kemudian keluar dengan tekanan 12 bar dan temperatur $85,4 \text{ }^\circ\text{C}$ (Bildea dkk., 2017).
6. Rasio reflux yang digunakan adalah sebesar $6,117$ dan beban *reboiler* yang digunakan adalah sebesar $8,485 \text{ MW}$ (Bildea dkk., 2017).
7. Model termodinamika yang digunakan untuk pemodelan kolom distilasi reaktif adalah NRTL (Wahid dan Putra, 2018).
8. Spesifikasi data untuk *reflux drum* dan *sump* dihitung menggunakan persamaan $V = \frac{1}{4}\pi D^2 L + 2f_{\text{HV}}D^3$ (Marshall dan Jaquelyn, 2019).
dengan $f_{\text{HV}} = 2:1 \text{ elipsoidal head}$ ($0,0139$)

9. Pada bagian *hydraulic* digunakan *simple packing* karena kolom distilasi reaktif yang digunakan merupakan kolom dengan jenis *packing* yang memiliki diameter 2 m dan HETP (*Height Equivalent of Theoretical Plate*) sebesar 0,5 m (Bildea dkk., 2017; Marshall dan Jaquelyn, 2019)
10. Temperatur pada tahap 5 dan tahap 47 yang dapat dikendalikan dengan laju alir refluks dan beban *reboiler* digunakan sebagai *inferential variable* untuk menentukan kemurnian produk DME dan konversi metanol (Wahid dan Putra, 2018).
11. *Artificial neural network* (ANN) dapat diimplementasikan untuk mengembangkan model yang memprediksi temperatur dengan mengaplikasikannya pada proses distilasi (Macmurray dan Himmelblau, 1995).
12. *Deep learning* dapat diaplikasikan untuk pengembangan model yang memodelkan pengendalian dengan mengaplikasikannya pada proses distilasi (Ongsulee 2018).
13. Model ANN yang dilatih dengan pendekatan dua tahap dapat diaplikasikan untuk memprediksi proses reaksi kimia yang rumit pada suatu kolom distilasi reaktif (Thon dkk., 2021).
14. ANN dapat digunakan untuk mengestimasi komposisi menggunakan temperatur dari suatu kolom distilasi multikomponen (Bahar dkk., 2004).
15. *Machine Learning* dengan model *Recurrent Neural Network* (RNN) dapat diaplikasikan untuk memprediksi temperatur kolom distilasi dalam memproduksi n-butana (Kwon et al. 2021).
16. *Machine Learning* dengan model *Long Short-Term Memory* (LSTM) dapat diaplikasikan untuk memprediksi temperatur kolom distilasi dalam memproduksi n-butana (Kwon et al. 2021).
17. *Machine Learning* dengan model *Grated Recurrent Unit* (GRU) dapat diaplikasikan untuk memprediksi temperatur kolom distilasi dalam memproduksi n-butana (Kwon et al. 2021).
18. Model LSTM dengan metode optimasi Adam dan ukuran *batch* 128 merupakan model dengan RMSE terendah dan R^2 tertinggi dalam memprediksi temperatur pada proses distilasi untuk memproduksi n-butana (Kwon dkk., 2021).

1.5 Hipotesis

1. LSTM dapat digunakan untuk memprediksi temperatur keluaran kolom distilasi reaktif dengan terlebih dahulu dilatih menggunakan data-data yang sudah ada.

2. Metode optimasi Adam yang digunakan pada model LSTM memiliki nilai RMSE terendah dan R^2 tertinggi dalam memprediksi temperatur proses distilasi reaktif untuk produksi DME.
3. Model LSTM dengan metode optimasi Adam dapat memprediksi temperatur proses distilasi reaktif untuk produksi DME.

1.6 Tujuan Penelitian

1. Mengetahui metode optimasi yang paling baik pada model LSTM dalam memprediksi temperatur kolom distilasi reaktif untuk produksi DME.
2. Mengetahui ukuran *batch* paling baik untuk pelatihan model LSTM dalam memprediksi temperatur kolom distilasi reaktif untuk produksi DME.
3. Mengetahui keakuratan model LSTM dalam memprediksi temperatur kolom distilasi reaktif untuk produksi DME.

1.7 Manfaat Penelitian

1.7.1 Bagi Peneliti

Dengan penelitian ini diharapkan peneliti dapat memahami pemodelan *machine learning* dalam memprediksi kondisi suatu proses. Selain itu peneliti juga diharapkan dapat memahami apakah *machine learning* cukup akurat untuk digunakan sebagai *predictive controller* pada proses distilasi reaktif.

1.7.2 Bagi Industri

Diharapkan dengan adanya penelitian ini *machine learning* dapat diterapkan dalam proses-proses pada industri kimia. Diharapkan penggunaan *machine learning* dapat mengurangi kebutuhan energi dari proses distilasi reaktif. Selain itu, penggunaan ML untuk *predictive controller* dapat dikembangkan sebagai alternatif pengendali dalam industri.