

**PEMBUATAN MODEL QUALITY CONTROL RAW MILL SEMEN
MENGUNAKAN METODE ARTIFICIAL NEURAL NETWORK DAN LONG-
SHORT TERM MEMORY
(STUDI KASUS: PT INDOCEMENT TUNGGAL PRAKARSA Tbk. PLANT-
CIREBON)
TUGAS AKHIR**

**Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Strata-1
Program Studi Teknik Industri - Fakultas Teknologi Industri
Universitas Islam Indonesia**



Nama : Naufal Zuhdi Yusuf
No. Mahasiswa : 20522248

**PROGRAM STUDI TEKNIK INDUSTRI PROGRAM SARJANA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2024**

PERNYATAAN KEASLIAN

Saya mengakui bahwa tugas akhir ini adalah hasil karya saya sendiri kecuali kutipan dan ringkasan yang seluruhnya sudah saya jelaskan sumbernya. Jika dikemudian hari ternyata terbukti pengakuan saya ini tidak benar dan melanggar peraturan yang sah maka saya bersedia ijazah yang telah saya terima ditarik kembali oleh Universitas Islam Indonesia.

Yogyakarta, 30 – 07 - 2024



Handwritten signature of Naufal Zuhdi Yusuf.

(Naufal Zuhdi Yusuf)
20522248

SURAT BUKTI PENELITIAN



SURAT KETERANGAN TO WHOM IT MAY CONCERN

Nomor : P.115/ITP/PKL-KET/VII/2024
Number

Yang bertanda tangan di bawah ini menerangkan bahwa
We the undersigned to certify that

Nama : Naufal Zuhdi Yusuf
Name

Nomor Pokok : 20522248
Register Number

Fakultas/Jurusan : Teknik Industri
Faculty/Section

Lembaga Pendidikan : Universitas Islam Indonesia
Education Institution

Terhitung mulai tanggal : 02 Mei **s/d** 31 Mei 2024
Starting from **until**

Telah melaksanakan : Tugas Akhir
Has been done

Di Departemen : Quality Control
of Department

PT INDOCEMENT TUNGGAL PRAKARSA Tbk. Palimanan-Cirebon
PT INDOCEMENT TUNGGAL PRAKARSA Tbk. Palimanan-Cirebon

Dengan Tema : Pembuatan Metode Quality Control Raw Mill
Theme **Semen Menggunakan Metode Artificial Neural Network dan Long Short Term Memory**

Demikian Surat Keterangan ini diberikan untuk dipergunakan seperlunya.
Thus, this certificate is made so that it can be useful.

Cirebon, 08 Juli 2024

Mengetahui,

Dedy Cahyadi
HRGA Department Head

Septiani Phatiwi
Pembimbing

LEMBAR PENGESAHAN PEMBIMBING

**PEMBUATAN MODEL QUALITY CONTROL RAW MILL SEMEN
MENGUNAKAN METODE ARTIFICIAL NEURAL NETWORK DAN LONG-
SHORT TERM MEMORY**

**(STUDI KASUS: PT INDOCEMENT TUNGGAL PRAKARSA Tbk. PLANT-
CIREBON)**



Yogyakarta, 30-07-2024

Dosen Pembimbing

(Danang Setiawan, S.T., M.T.)

LEMBAR PENGESAHAN DOSEN PENGUJI

**PEMBUATAN MODEL QUALITY CONTROL RAW MILL SEMEN
MENGUNAKAN METODE ARTIFICIAL NEURAL NETWORK DAN LONG-
SHORT TERM MEMORY
(STUDI KASUS: PT INDOCEMENT TUNGGAL PRAKARSA Tbk. PLANT-
CIREBON)**

TUGAS AKHIR

Disusun Oleh :

**Nama : Naufal Zuhdi Yusuf
No. Mahasiswa : 20522248**

**Telah dipertahankan di depan sidang penguji sebagai salah satu syarat untuk
memperoleh gelar Sarjana Strata-1 Teknik Industri Fakultas Teknologi Industri
Universitas Islam Indonesia**

Yogyakarta, 30 - Juli - 2024

Tim Penguji

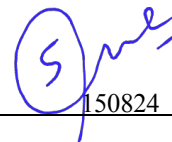
Danang Setiawan, S.T., M.T.
Ketua

Ir. Muchamad Sugarindra, S.T., M.T, IPM.
Anggota I

Wahyudhi Sutrisno, S.T., M.M., M.T
Anggota II





7-08-2024



150824

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



Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM
015220101

HALAMAN PERSEMBAHAN

Laporan Tugas Akhir ini saya buat untuk orang tua saya, yang sudah memberikan dukungan moril dan juga finansial kepada penulis selama berada di Yogyakarta dan berkuliah di Universitas Islam Indonesia. Tugas ini juga sebagai bentuk tolok ukur sejauh apa ilmu perindustrian yang sudah saya dapatkan selama berkuliah di Universitas Islam Indonesia.

MOTTO

“Barang siapa menelusuri jalan untuk mencari ilmu padanya, Allah akan memudahkan baginya jalan menuju surga.” (HR. Muslim).

Katakanlah: “Tiap-tiap orang berbuat menurut keadaannya masing-masing”. Maka Tuhanmu lebih mengetahui siapa yang lebih benar jalannya. (QS. Al Isra: 84)

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillahirabbil'alamin, segala puji dan syukur peneliti atas ke hadirat Allah Subhanahu Wa Ta'ala yang melimpahkan rahmat dan nikmat-Nya sehingga peneliti dapat menyelesaikan Tugas Akhir dan penyusunan Laporan Tugas Akhir di PT Indocement Tunggal Prakarsa Tbk. dapat terselesaikan dengan baik dan sesuai dengan waktu yang diharapkan. Tak lupa sholawat dan salam senantiasa peneliti haturkan kepada kepada Nabi Muhammad Shallallahu 'Alaihi Wa Sallam beserta keluarga, sahabat dan pengikutnya hingga akhir zaman yang telah berjuang dan membimbing kita dari zaman yang berjuang dan membimbing kita dari zaman kegelapan menuju jalan yang terang benderang untuk menggapai ridho Allah Subhanahu W Ta'ala.

Pelaksanaan Tugas Akhir merupakan salah satu prasyarat untuk memperoleh gelar sarjana Strata Satu (S1) pada Program Studi Teknik Industri Universitas Islam Indonesia. Dengan dilakukannya pelaksanaan Tugas Akhir ini diharapkan mahasiswa dapat mengetahui penerapan teori yang telah didapatkan dalam perkuliahan dan pengetahuan lapangan dalam dunia industri.

Penyusunan laporan tidak akan berhasil tanpa peran dari berbagai pihak, pada kesempatan kali ini peneliti mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Ir. Hari Purnomo M.T., IPU, ASEAN.Eng selaku Dekan Fakultas Teknologi Industri Universitas Islam Indonesia.
2. Bapak Muhammad Ridwan Andi Purnomo S.T., M.Sc., Ph.D., IPM selaku Ketua Program Studi Teknik Industri Program Sarjana Universitas Islam Indonesia.
3. Orang tua peneliti yang telah memberikan doa, semangat, motivasi, dan restu selama Tugas Akhir berlangsung.
4. Bapak Danang Setiawan, S.T., M.T. selaku dosen pembimbing Tugas Akhir yang telah memberikan bimbingan kepada peneliti.
5. Bapak Marlan O. Damanik selaku General Manager Operation yang telah menerima lamaran peneliti untuk menjalankan Tugas Akhir.
6. Bapak Dudy Gandjar selaku HR & GA Departement Head yang sudah menyelenggarakan kegiatan KP ini.
7. Bapak Erwan selaku selaku QC Process Department Head.
8. Ibu Septiani Pratiwi selaku pembimbing lapangan peneliti saat menjalankan tugas akhir.
9. Bapak Wahyu selaku Human Resource yang telah mengurus administrasi dan penerimaan proposal pengajuan Tugas Akhir.
10. Seluruh karyawan pada Training Centre Section yang telah menerima, menyelenggarakan, dan mendampingi selama pelaksanaan Tugas Akhir.
11. Seluruh pekerja PT Indocement Tunggal Prakarsa Tbk yang telah membantu peneliti dengan memberikan informasi dalam pelaksanaan Tugas Akhir.
12. Dimastyo Albani selaku pendamping peneliti selama menulis dan memasukan data tugas akhir.
13. Deandra Jauza Zahira selaku penyedia komoditas selama peneliti menjalankan tugas akhir.

ABSTRAK

Kontrol kualitas pada industri semen membutuhkan kecermatan dan intensitas yang tinggi selama proses. kualitas semen sangat bergantung pada klinker yang ditentukan dari stabilnya nilai modulus kimia yang dikendalikan oleh operator QC. permasalahan muncul ketika mesin yang menunjang proses QC seperti lengan robot mengalami *downtime* tidak terjadwal sehingga menyulitkan operator dalam menentukan modulus yang harus ditetapkan setiap 30 menit, akibatnya kualitas hasil klinker yang dihasilkan dibawah standar kualitas yang telah di tentukan dan tidak memenuhi permintaan pasar domestik untuk proyek nasional, sehingga menyebabkan perusahaan mengalami *opportunity loss*.. Penggunaan *machine learning* diduga mampu memberikan solusi mengendalikan kualitas pada industri semen. Long Short-Term Memory (LSTM) dan Artificial Neural Network (ANN) merupakan salah satu machine learning yang dapat memprediksi nilai modulus kimia dan campuran komposisi pada pembobotan *weighing feeder* di proses produksi semen. Hasilnya LSTM efektif dalam memprediksi modulus kimia dan campuran komposisi selama proses produksi. Hasil dari ANN *backpropagation* menunjukkan akurasi yang cukup baik dengan penggunaan data *input* dari hasil prediksi LSTM berupa modulus *Limestone Saturation Factor*, *Alumina modulus*, dan *Silica modulus* yang digunakan untuk menentukan pembobotan pada mesin *weighing feeder* yang mengendalikan bahan material berupa batu kapur, tanah liat, pasir besi, dan pasir silika, namun terdapat anomali selama pelatihan model karena data yang digunakan dalam penelitian diambil saat kondisi mesin tidak sepenuhnya dalam kondisi Steady State.

Kata kunci: LSTM, ANN, *Quality Control*, Produksi Semen.

DAFTAR ISI

PERNYATAAN KEASLIAN	ii
SURAT BUKTI PENELITIAN	iii
LEMBAR PENGESAHAN PEMBIMBING.....	iv
LEMBAR PENGESAHAN DOSEN PENGUJI.....	v
HALAMAN PERSEMBAHAN	vi
MOTTO	vii
KATA PENGANTAR	viii
ABSTRAK.....	ix
DAFTAR ISI.....	x
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
1.5 Batasan Penelitian.....	4
BAB II TINJAUAN PUSTAKA	6
2.1 Landasan Teori	6
2.2 Kajian Induktif.....	13
2.2.1 Semen Sebagai Komposit	13
2.2.2 Raw Material Semen (Komposisi).....	14
2.2.3 Produksi Semen.....	14
2.2.4 Proses Quality Control	15
2.2.5 Recurent Neural Network	18
2.2.6 Artificial Neural Network	24
BAB III METODE PENELITIAN	38
3.1 Penentuan Objek Penelitian	40
3.2 Identifikasi Masalah.....	40
3.3 Perumusan Masalah	40
3.4 Studi Literatur	41
3.4.1 Kajian Deduktif	41
3.4.2 Kajian Induktif	41
3.5 Instrumen Penelitian	41
3.6 Penentuan Variabel LSTM dan ANN.....	42
3.7 Pengumpulan Data Hasil QC.....	44
3.8 Penyortiran Data	44
3.9 Pengolahan Data LSTM.....	45
3.9.1 Pembentukan Model.....	45
3.9.2 Pengujian Model	46
3.9.3 Perbandingan Hasil Model	46
3.10 Pengolahan Data ANN.....	47
3.10.1 Pembentukan Model.....	47
3.10.2 Pengujian Model	48
3.10.3 Perbandingan Hasil	48

3.11	Analisis dan Pembahasan.....	48
3.12	Kesimpulan dan Saran	48
BAB IV	PENGUMPULAN DAN PENGOLAHAN DATA.....	50
4.1	Pengumpulan Data.....	50
4.1.1	Deskripsi Perusahaan	50
4.1.2	Mekanisme Proses Produksi dan Proses QC.....	52
4.1.3	Variabel Input dan Output RNN (LSTM).....	56
4.2	Pengolahan Data RNN-LSTM.....	58
4.2.1	Input Variabel LSTM.....	58
4.2.2	Pembentukan Model LSTM.....	58
4.2.3	Pengujian Hasil Jaringan Yang Telah Dilatih.....	65
4.2.4	Hasil Prediksi Komposisi.....	69
4.2.5	Perhitungan Modulus dan Data Input ANN.....	75
4.3	Pengolahan Data ANN.....	76
4.3.1	Arsitektur Jaringan	77
4.3.2	Input, Output, dan Pembagian Data ANN	79
4.3.3	Pembentukan Model ANN.....	79
4.3.4	Uji Coba Jaringan ANN	86
4.3.5	Evaluasi Jaringan ANN.....	88
4.3.6	Hasil Pembobotan ANN.....	90
BAB V	PEMBAHASAN.....	99
5.1	Implementasi Sistem QC berbasis RNN-LSTM dan ANN	99
5.2	Karakteristik Penggunaan RNN-LSTM Pada Raw Material	102
5.3	Prosedur Implementasi Sistem.....	106
6	BAB VI PENUTUP	107
6.1	Kesimpulan	107
6.2	Saran	108
6.2.1	Saran Untuk Peneliti Selanjutnya.....	108
7	DAFTAR PUSTAKA	109
8	LAMPIRAN.....	A-1

DAFTAR TABEL

Tabel 2.1 Rangkuman Penelitian Sebelumnya	8
Tabel 2.2 Akurasi Nilai MAPE.....	37
Tabel 4.1 Variabel Input dan Output RNN-LSTM.....	57
Tabel 4.2 <i>Input</i> Variabel LSTM	58
Tabel 4.3 Hasil Perbandingan Sampel SiO ₂	70
Tabel 4.4 Hasil Perbandingan Sampel Al ₂ O ₃	71
Tabel 4.5 Hasil Perbandingan Sampel Fe ₂ O ₃	71
Tabel 4.6 Hasil Perbandingan Sampel CaO.....	72
Tabel 4.7 Hasil Perbandingan Sampel MgO	73
Tabel 4.8 Hasil Perbandingan Sampel Na ₂ O	74
Tabel 4.9 Hasil Perbandingan Sampel K ₂ O	75
Tabel 4.10 Hasil Perbandingan Modulus Aktual dan Prediksi	75
Tabel 4.11 Pembobotan <i>Weighing Feeder</i>	76
Tabel 4.12 Variabel Input dan Output ANN.....	79
Tabel 4.13 Rincian Syntax dan Fungsi	81
Tabel 4.14 Hasil Perbandingan ANN Limestone	91
Tabel 4.15 Hasil Perbandingan ANN Silica Sand	94
Tabel 4.16 Hasil Perbandingan ANN Iron Sand.....	96
Tabel 5.1 Weighing Feeder 09:44:00	100
Tabel 5.2 Saturasi Komposisi dan Modulus 10:14:00	100
Tabel 5.3 Masukan Bobot Material 10:14:00	101
Tabel 5.4 Saturasi Komposisi dan Modulus 10:44:00.....	101
Tabel 5.5 Saturasi Komposisi dan Modulus 11:14:00 Aktual dan Prediksi	102
Tabel 5.6 Weighing feeder 10:44:00 Aktual dan ANN	102
Tabel 5.7 Perbandingan hasil prediksi	103

DAFTAR GAMBAR

Gambar 2.1 Fokus Penelitian.....	15
Gambar 2.2 Komputasi Proses Sampling	15
Gambar 2.3 Rumus Modulus	17
Gambar 2.4 Flow Diagram RNN.....	19
Gambar 2.5 Flow Diagram LSTM.....	20
Gambar 2.6 LSTM <i>Sequence to Sequence</i>	22
Gambar 2.7 Lapisan ANN	24
Gambar 2.8 Alur Model ANN	26
Gambar 2.9 Fungsi Aktivasi Hard Limit	28
Gambar 2.10 Fungsi Aktivasi Linear.....	28
Gambar 2.11 Fungsi Aktivasi Logistik.....	29
Gambar 2.12 Fungsi Aktivasi Treshold	29
Gambar 2.13 Fungsi Aktivasi Symetric Hard Limit.....	30
Gambar 2.14 Fungsi Aktivasi Bipolar Treshold	30
Gambar 2.15 Fungsi Aktivasi Saturasi Linear.....	31
Gambar 2.16 Fungsi Aktivasi Sigmoid Biner.....	31
Gambar 2.17 Fungsi Aktivasi Sigmoid Bipolar.....	32
Gambar 2.18 Lapisan Backpropagation.....	33
Gambar 3.1 Alur Penelitian	39
Gambar 4.1 Proses produksi semen secara menyeluruh.....	52
Gambar 4.2 Fokus Peneliti.....	53
Gambar 4.3 Syntax Input Data ke Matlab	59
Gambar 4.4 Syntax Pendefinisian Arsitektur LSTM.....	60
Gambar 4.5 Syntax Melatih Jaringan	62
Gambar 4.6 Hasil Pengujian Berlangsung.....	62
Gambar 4.7 Syntax Prediksi dan Hasil Prediksi LSTM	63
Gambar 4.8 Hasil Proses Uji Coba Model.....	64
Gambar 4.9 Hasil Uji Coba Semua <i>Output</i>	65
Gambar 4.10 Nilai RMSE dan MAE SiO ₂	66
Gambar 4.11 Nilai RMSE dan MAE Al ₂ O ₃	66
Gambar 4.12 Nilai RMSE dan MAE Fe ₂ O ₃	67
Gambar 4.13 Nilai RMSE dan MAE CaO.....	67
Gambar 4.14 Nilai RMSE dan MAE MgO.....	68
Gambar 4.15 Nilai RMSE dan MAE SO ₃	68
Gambar 4.16 Nilai RMSE dan MAE Na ₂ O	69
Gambar 4.17 Nilai RMSE dan MAE K ₂ O	69
Gambar 4.18 Hasil Prediksi SiO ₂	70
Gambar 4.19 Hasil Prediksi Al ₂ O ₃	70
Gambar 4.20 Hasil Prediksi Fe ₂ O ₃	71
Gambar 4.21 Hasil Prediksi CaO.....	72
Gambar 4.22 Hasil Prediksi MgO.....	73
Gambar 4.23 Hasil Prediksi SO ₃	73
Gambar 4.24 Hasil Prediksi Sampel Na ₂ O	74

Gambar 4.25 Hasil Prediksi K ₂ O	75
Gambar 4.26 Arsitektur ANN Pada Penelitian	77
Gambar 4.27 Arsitektur Pada Matlab	78
Gambar 4.28 Syntax Untuk Input Data	80
Gambar 4.29 Syntax Pre Processing Data	80
Gambar 4.30 Syntax Arsitektur Jaringan ANN	81
Gambar 4.31 Syntax Konfigurasi Jaringan	81
Gambar 4.32 Syntax Bobot Jaringan ANN	83
Gambar 4.33 Syntax Melatih Jaringan dan Hasil	83
Gambar 4.34 Hasil Weighing Feeder	84
Gambar 4.35 Hasil Validasi Performa Jaringan	85
Gambar 4.36 Syntax Bobot Akhir	85
Gambar 4.37 Syntax Data Uji	86
Gambar 4.38 Syntax Data Uji dan Parameter	87
Gambar 4.39 Syntax Evaluasi Jaringan ANN	88
Gambar 4.40 Hasil Regresi	89
Gambar 4.41 Hasil Regresi Kurang Memuaskan	90
Gambar 4.42 Hasil Pembobotan <i>Limestone</i>	91
Gambar 4.43 Hasil Pembobotan <i>Silica Sand</i>	93
Gambar 4.44 Hasil Pembobotan <i>iron sand</i>	96
Gambar 5.1 Improvisasi QC	99

BAB I

PENDAHULUAN

1.1 Latar Belakang

Industri semen merupakan satu dari sekian banyak industri yang ada di dunia ini. Secara umum semen merupakan sebuah bahan yang sangat dibutuhkan dalam peradaban manusia. Semen sendiri merupakan sebuah zat yang berbentuk tepung yang digunakan untuk merekatkan batuan penyusun suatu konstruksi yang dicampur dengan bahan tambahan seperti pasir dan air untuk mengaktifkan bahan kimia di dalamnya, secara umum semen adalah bubuk abu-abu gelap yang terbuat dari kapur atau Kalsium oksida (CaO), Silika dioksida (SiO_2), Alumina atau Aluminium Oksida (Al_2O_3), Besi (III) Oksida (Fe_2O_3), Magnesium Oksida (MgO), Sulfur Trioksida (SO_3), dan Alkali atau Kalium Oksida (K_2O) dan terakhir Natrium Oksida (Na_2O). Semen sendiri sudah dikenal sejak zaman romawi kuno tepatnya di daerah Pozzouli atau daerah dekat dengan Napoli di mana pertama kali ditemukan dalam bentuk bubuk atau serbuk berwarna coklat keputihan, dengan kandungan campuran antara batu kapur dan abu vulkanis, dan bangsa romawi memberinya nama pozzuolana. Kemudian pada tahun 1824 ada seorang insinyur berkebangsaan Inggris bernama Joseph Aspidin melakukan hak paten terhadap komposisi semen dengan nama Semen Portland. Semen ini agak berbeda dari semen yang sudah lama dikenal karena mengandung campuran tanah liat (Clay) di dalamnya sehingga mengubah sedikit warna campuran akhir dan mirip seperti daerah Portland Inggris yang mengandung banyak tanah liat (Rodgers, 2018).

Kebutuhan semen nasional sendiri sudah cukup menjadi acuan banyaknya permintaan produksi, Indonesia dewasa ini juga masuk dalam tahap pembangunan yang masif, mengutip dari badan pusat statistik dan laman Indonesian government Proyek Strategis Nasional atau PSN yang terhitung dari tahun 2016 sampai 2022 terdapat 152 proyek strategis nasional (PSN) yang sudah tuntas dan beroperasi penuh, hal ini tentu menjadi kebutuhan tersendiri akan permintaan semen yang banyak dan tentu meningkatkan daya saing antara perusahaan semen ke depannya. Indocement adalah salah satu perusahaan yang memasok semen ke pembangunan Ibukota Negara atau IKN dengan membutuhkan pasokan sebesar 1,1 juta ton dan juga di luarnya mencakup LRT dan MRT serta jalan bebas hambatan Patimban tahap dua yang membutuhkan sekitar 17 juta ton pasokan berdampak dengan adanya kenaikan sebesar 13% penjualan mengutip dari ekonomi.bisnis.com dengan judul “Indocement (INTP) Kecipratan Berkah IKN, Penjualan Semen Naik 9%” dengan Afiffah Rahmah Nurdifa sebagai penulis.

Sebagai salah satu perusahaan semen nasional tertua, Indocement ingin memastikan bahan yang dipakai untuk produksi berkualitas dan memenuhi standar baik nasional maupun internasional. Pada pabrik semen produksi dimulai dari penambangan untuk mengumpulkan bahan utama yaitu *Limestone* atau batu kapur, kemudian dilanjutkan ke bagian *Quality Control* atau QC untuk menentukan komposisi bahan untuk membuat tipe semen sesuai dengan kategori yang diinginkan, melalui QC ini lah pemantauan mencakup penjagaan kualitas dan memastikan jumlah produksi tidak mengalami hambatan. Secara umum, rasio pencampuran bahan baku menentukan kualitas hasil akhir semen dan klinker yaitu hasil pengkristalan pada mesin *Rotary Kiln*. Proses QC berlangsung selama 24 jam nonstop atau dengan kata lain selama proses produksi berjalan, karena dalam industri semen tidak ada produk *defect* sehingga QC berlangsung secara terus menerus. Kasus yang terjadi pada perusahaan Indocement *Plant Cirebon* adalah ketika terjadi kesalahan pada sistem QC, dalam hal ini mesin untuk melakukan sampling atau C..... B.... X.....(CBX) mengalami kerusakan sehingga hasil modulus tidak keluar dan perlu melakukan iterasi sampel secara manual yang membutuhkan waktu selama 15 menit maka dari itu operator harus menggunakan modulus sebelumnya untuk digunakan pada mesin pembobotan yang bernama *Raw Mix Proportion*, dengan kata lain kadar modulus pada komposisi yang dimasukkan kurang tepat sehingga bahan yang terlanjur masuk akan mempengaruhi kualitas akhir klinker yang nantinya akan menjadi bahan dasar semen, ketika hal tersebut terjadi maka semen yang diproduksi akan masuk ke dalam kategori semen lokal dan tidak bisa untuk digunakan pada semen berjenis OPC (Ordinary Portland Cement) hal inilah terjadinya *opportunity loss* akibat hilangnya potensi penjualan semen untuk mengisi pasar skala besar.

Proses QC sendiri dilakukan sebagai berikut, pertama laboratorian mengambil sampel dalam interval waktu tertentu (kasus Indocement adalah 30 menit), kemudian sampel dianalisis menggunakan mesin CBX di laboratorium dibantu dengan lengan robot selama proses nya. Setelah itu hasilnya akan diproses pada komputer. Indeks variabel modulus hasil CBX kemudian dikirimkan ke operator, setelahnya operator menyesuaikan aliran material melalui Komputer kepada *Weighing Feeder*, untuk penentuan bobot materialnya sendiri ada patokan atau rumus yang dijaga oleh sang operator yang disebut sebagai modulus saturasi kapur, atau *Limestone Saturation Factor* atau disingkat dengan kode LSF yang berfungsi sebagai pembagi kandungan kimia dan digunakan sebagai tolok ukur dalam pencampuran komposisi.

Kegiatan pada proses QC membutuhkan ketelatenan dan dedikasi karena prosesnya sangat krusial dan berdampak pada kualitas semen yang akan dihasilkan melalui proses produksi, pihak QC memegang kendali akan bahan yang masuk dan memastikan semuanya sesuai dengan standar komposisi untuk mencapai kualitas semen yang diinginkan (Morant & Albertos, 1988), salah satu solusi yang ditawarkan untuk meminimalisir tingkat kesalahan yang dibuat oleh manusia dan kemungkinan terjadinya *opportunity loss* akibat kurangnya informasi sampel modulus adalah dengan melakukan *assist* atau sistem semi otomatis. Kedepannya sistem semi otomatis akan menjadi suatu hal yang sangat penting dan memberikan banyak keuntungan, sistem yang diperbaiki dapat mengurangi kelelahan dan membantu operator dalam perencanaan bahan mentah yang mereka pakai. Salah satu cara yang dapat dilakukan untuk improvisasi sistem adalah dengan menggunakan *machine learning* (Wuest et al., 2016), karena *machine learning* dapat meniru dan mempelajari kebiasaan serta memprediksi hal yang bersifat repetitif dari masukan dan memberikan solusi melalui pengolahan data secara komprehensif. Beberapa metode untuk *machine learning* adalah seperti penggunaan ANN atau *Artificial Neural Network*, dan juga LSTM. Pada akhirnya kemungkinan perusahaan merugi karena berkurangnya jumlah pasokan klinker berkualitas untuk memproduksi semen berjenis OPC dapat ditekan dan target pasokan semen ke proyek-proyek besar dapat dimaksimalkan karena proses *quality control* berjalan lebih ketat dan memberikan hasil yang lebih akurat selama proses pencampuran bahan.

1.2 Rumusan Masalah

Rumusan masalah merupakan gambaran yang jelas tentang masalah yang ingin diselesaikan atau diperbaiki melalui penelitian. Berikut adalah rumusan masalah yang ditetapkan oleh peneliti:

1. Bagaimana implementasi model LSTM-ANN dalam mengurangi potensi kesalahan bahan material yang menyebabkan terjadinya *opportunity loss*?
2. Bagaimana akurasi, efektivitas dan karakteristik penggunaan LSTM-ANN terhadap bahan material dan Pembobotan *Raw Mix Proportion*?
3. Bagaimana solusi yang dapat diberikan kepada perusahaan terhadap implementasi RNN-LSTM dan ANN pada sistem QC perusahaan?

1.3 Tujuan Penelitian

Tujuan penelitian menjawab rumusan masalah. Berikut adalah tujuan pada penelitian kali ini:

1. Membentuk Model ANN-LSTM dan mengimplementasikannya pada sistem QC untuk mengurangi potensi *opportunity loss* berdasarkan data yang sudah didapatkan.
2. Mengetahui nilai akurasi, efektivitas, dan karakteristik penggunaan model LSTM-ANN dalam memproyeksikan data sampel dan *Raw Mix Proportion*.
3. Mendapatkan solusi untuk diajukan ke pihak Perusahaan sebagai bentuk implementasi sistem yang baru berbasis *machine learning* pada QC.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian tugas akhir ini bagi perusahaan dan peneliti adalah sebagai berikut:

1. Pihak PT Indocement Tungal Prakarsa Tbk.
Evaluasi dan usulan bisa menjadi solusi sederhana dari peneliti dan menjadi masukan bagi perusahaan ke depan.
2. Pihak Program Studi Teknik Industri Universitas Islam Indonesia.
Penelitian ini bisa menjadi program yang baik bagi kedua belah pihak antara perusahaan dan kampus untuk menjalin hubungan kerja sama yang lebih baik lagi ke depannya dan menjadikan UII sebagai kampus yang memberikan wadah untuk mahasiswa/i nya untuk melakukan kegiatan praktik langsung di perusahaan.
3. Pihak peneliti
 1. Dapat mengaplikasikan teori yang di dapat atau arahan dari dosen untuk dilakukan secara langsung di lapangan.
 2. Peneliti dapat menambah pengetahuan dan kemampuan dalam pemecahan masalah di lapangan melalui pembelajaran dan pengamatan.
 3. Menjadi tolok ukur kemampuan mahasiswa dalam menyelesaikan permasalahan yang dinamis.

1.5 Batasan Penelitian

Batasan penelitian digunakan untuk memberikan cakupan tertentu pada penelitian ini sehingga peneliti bisa fokus dalam pengambilan data dan mengabaikan hal di luar batasan, berikut adalah batasan yang terdapat di penelitian ini:

1. Penelitian dilakukan hanya sampai tahap usulan perbaikan tanpa uji coba langsung terhadap sistem QC.
2. Aspek biaya pada penelitian tidak dimasukkan ke dalam penelitian.
3. Perangkat lunak yang digunakan adalah Matlab dan Excel.

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

Kajian mengenai penelitian pada *Quality Control* pada seksi *raw mill* industri semen sudah cukup banyak beredar, namun jumlah dan inti bahasannya tidak secara spesifik menggunakan *Artificial Neural Network* dan *Recurrent Neural Network*, namun variabel penelitiannya mengarah pada sistem yang berjalan secara otomatis. Beberapa penelitian bersifat kualitatif dan campuran antara keduanya sehingga memunculkan banyak pandangan akan penyelesaian masalah untuk menuju era otomasi industri khususnya berbasis *machine learning*.

Penelitian untuk menyambut era industri 4.0 yang sekarang sudah mengarah ke 5.0 membutuhkan kajian yang menitik beratkan pada kebutuhan industri masif, produksi semen yang menyongsong pembangunan sangat diperlukan sebagai ujung tombak dan setiap produksinya membutuhkan efisiensi produksi tak terkecuali setiap seksinya pada perusahaan di mana otomatis industri dapat memberikan dampak yang sangat luas dan membuat efisiensi menjadi objek yang sangat digaugkan dalam penelitian-penelitian kedepan.

Pengaruh pembelajaran mesin dalam industri manufaktur dalam konteks paradigma Industri 4.0. Teknologi ini memungkinkan pabrik menerapkan sistem cerdas untuk mengumpulkan data secara terus-menerus dan menghasilkan kecerdasan yang dapat diambil melalui tindakan untuk meningkatkan efisiensi manufaktur. Pekerjaan yang bersifat repetitif dan cenderung membutuhkan bantuan berupa otomasi industri agar dapat mengurangi kelelahan dan juga meningkatkan efisiensi dalam penjalanannya, namun bukan tidak mungkin masih ada tantangan yang sangat besar untuk mencapai itu semua (Wuest et al., 2016).

Industri 4.0 telah memunculkan sektor baru di manufaktur disebut *SmartManufacturing* yang terbuka pintu untuk analisis di industri. Di mana hal ini mewakili berbagai komponen yang didistribusikan dalam domain Manufaktur Cerdas. Pendekatan ini didorong pemanfaatan IoT dan internet perangkat yang terhubung untuk menghasilkan barang. Tujuannya adalah untuk mengotomatiskan proses yang terlibat di dalam manufaktur untuk memaksimalkan efisiensi, meningkatkan keberlanjutan, manajemen rantai pasokan, dan mengidentifikasi sistem bahkan sebelum sistem tersebut mengalami hambatan, dan menerapkan volume produksi data yang sangat besar. Dengan penerapan analisis lanjutan pada industri data, produsen dapat memperoleh wawasan untuk mengoptimalkan produktivitas aset individu serta manusia secara

keseluruhan operasi manufaktur, kecerdasan buatan (AI) dan *Machine Learning* (ML)(Rai et al., 2021).

Sebagai tambahan, beberapa keuntungan yang akan didapatkan dengan penerapan sistem cerdas dan *machine learning* pada industri antara lain(Rai et al., 2021);

1. Meningkatkan efisiensi jalur perakitan (Line balancing) menggunakan data analitik.
2. Peningkatan Pengalaman Pelanggan, termasuk personalisasi dan menemukan nilai proporsi individual.
3. Pengelolaan inventori yang didasari oleh beberapa hal yaitu:
 - a. Transparansi dan informasi secara langsung terhadap penyimpanan inventori
 - b. Optimasi rute dalam pasokan
4. Meminimalkan kerugian yang berhubungan dengan keterlambatan, kerusakan, atau barang hilang dalam transportasi dan untuk menyediakan manajemen secara langsung terhadap aset yang mencakup peringatan secara langsung.
5. Mengurangi kesalahan dan koreksi selama pengembangan produk dan meningkatkan kualitas dan kemasan produk dengan cara:
 - a. Simulasi yang didukung analisis
 - b. Pemodelan produk
6. Pemeliharaan aset yang dapat diprediksi membantu meningkatkan umur asset waktu demi waktu mencakup:
 - a. Manajemen aset
 - b. Meningkatkan ketersediaan aset
 - c. Mendeteksi kesalahan dan cacat
 - d. Mencegah *downtime* yang tidak direncanakan
7. Meningkatkan visibilitas ke dalam *supply chain* dengan basis IoT berdasarkan basis data yang dimiliki

Dengan keseluruhan keuntungan yang ada, pada industri manufaktur semen ini, proses otomatisasi menggunakan *machine learning* dapat meningkatkan sisi mengurangi kesalahan dalam proses dan juga pengelolaan inventori yang lebih baik karena prediksi dan transparansi dalam perjalanan produksinya.

Berikut adalah penelitian yang berkaitan dengan ANN dan LSTM baik dengan objek yang sama maupun berbeda.

Tabel 2.1 Rangkuman Penelitian Sebelumnya

Rangkuman					
No	Author	Objek	ANN	LSTM	Hasil
1	(Putra & Ulfa Walmi, 2020)	Pertanian/Padi	✓		Implementasi sistem yang dirancang, diperoleh hasil prediksi dengan akurasi mencapai 88,14%
2	(Dananjaya et al., 2022)	Fondasi Tiang	✓		Penggunaan ANN dalam memprediksi kapasitas dukung fondasi tiang memiliki akurasi dengan nilai R2 0,91 dan nilai RMSE 861,6087.
3	(Hernández et al., 2023)	Helical Coil Heat Exchangers	✓		ANN menggambarkan secara memuaskan Dalam membentuk model dua fase.
4	(Lee et al., 2022)	Batuan Anisotropik	✓		Penelitian menunjukkan bahwa metode ANN berhasil divalidasi dengan uji numerik menggunakan batuan TI homogen, dengan hasil yang sangat cocok dengan

Rangkuman					
No	Author	Objek	ANN	LSTM	Hasil
					parameter masukan yang sebenarnya.
5	(Falcone et al., 2022)	RC/Beton yang diperkuat	✓		(ANN) adalah opsi yang layak dan efisien untuk analisis seismik.
6	(Soori et al., 2023)	Supply Chain	✓		Jaringan Syaraf Tiruan (JST) telah terbukti menjadi alat yang efektif di berbagai bidang, termasuk manajemen rantai pasok.
7	(Mumali, 2022)	Kompilasi Kajian Literatur	✓		
8	(GUODONG et al., 2015)	Cement QC	✓		Sistem ini menggabungkan perhitungan teoritis, buatan pengalaman dan optimasi tambahan untuk membentuk yang unik strategi pengendalian yang dapat menghadapi fluktuasi besar bahan baku dalam berbagai kondisi.

Rangkuman					
No	Author	Objek	ANN	LSTM	Hasil
9	(Knoerzer, 2024)	Termodinamika adiabatik	✓		ANN mampu untuk memprediksi adiabatik pemanasan kompresi pada tekanan tinggi konvensional (HPP) dan tinggi pemrosesan termal tekanan (HPTP).
10	(de-Prado-Gil et al., 2023)	Komposit Beton	✓		ANN mampu untuk membuat model dan perhitungan desain campuran beton, kendali mutu, dan jaminan mutu.
11	(Jin & Zheng, 2022)	Metrologikal/AI at Optik	✓		ANN dapat memperoleh pengetahuan target melalui pembelajaran, dan menyimpan bobot sambungan. Kemudian dapat menyesuaikan bentuk pengetahuan yang spesifik.

Rangkuman					
No	Author	Objek	ANN	LSTM	Hasil
12	(Bas et al., 2024)	Peramalan Pola Berjenis Time Series	✓		Penelitian ini menyimpulkan bahwa metode yang diusulkan secara efektif menangani data <i>outlier</i> .
13	(Taloba, 2022)	Perawatan Air	✓		Dalam penelitian ini, metode Jaringan Syaraf Tiruan (JST) digunakan untuk optimasi biaya dalam proses pengolahan air dan proses desalinasi dikembangkan secara efektif dengan menggunakan metodologi ini.
14	(Maisel et al., 2023)	Bahan Mentah		✓	Penggunaan LSTM dalam memprediksi bahan mentah untuk baterai dapat digunakan dengan efektif dengan beberapa tambahan jenis LSTM yang ada.

Rangkuman					
No	Author	Objek	ANN	LSTM	Hasil
15	(Prathama, 2018)	Rumah Sakit	✓		ANN mampu mendekati sistem pakar profesional yang dikembangkan oleh Mohammed dan Celik, di mana perkiraan biaya total ditemukan antara kisaran 2% dan 4% dari biaya sebenarnya.
16	(Varshini et al., 2024)	Prediksi Harga Bahan Mentah		✓	Hasil dari penelitian ini membuktikan tingkat efektivitas penggunaan metode LSTM untuk prediksi harga
17	(Al-Selwi et al., 2024)	Literatur Review		✓	Menjelaskan tentang tata cara, fungsi, dan juga teknik dalam pemodelan LSTM
18	(Yang et al., 2023)	Manufaktur		✓	Penggunaan LSTM menghasilkan tingkat efektivitas sebesar 33.19% dalam mendeteksi waktu improvisasi
19	(Weerakody et al., 2021)	Irregular Time Series		✓	RNN memiliki kemampuan unik

Rangkuman					
No	Author	Objek	ANN	LSTM	Hasil
					diadaptasi untuk memanfaatkan pola nilai yang hilang, interval waktu, dan ketergantungan temporal yang kompleks secara efektif.
20	(Kowsher et al., 2021)	Klasifikasi Koran	✓	✓	Model hybrid BiLSTM-ANN yang digunakan melampaui semua model yang menggunakan arsitektur lama. skor akurasi paling tinggi sebesar 93% untuk validasi & pengujian.

2.2 Kajian Induktif

Pada bagian ini membahas tentang teori-teori yang berkaitan dengan permasalahan yang diangkat dan metode yang digunakan dalam penelitian ini.

2.2.1 Semen Sebagai Komposit

Menurut (Frederick M Lea , 1999) Asal usul semen hidrolik berasal dari Yunani kuno dan Roma. Bahan yang digunakan adalah kapur dan abu vulkanik yang bereaksi perlahan dengan adanya air sehingga membentuk massa yang keras. Ini membentuk bahan penyemen mortir dan beton Romawi lebih dari 2.000 tahun yang lalu dan pekerjaan konstruksi berikutnya di Eropa Barat. Abu vulkanik yang ditambang di dekat tempat yang sekarang menjadi kota Pozzuoli,

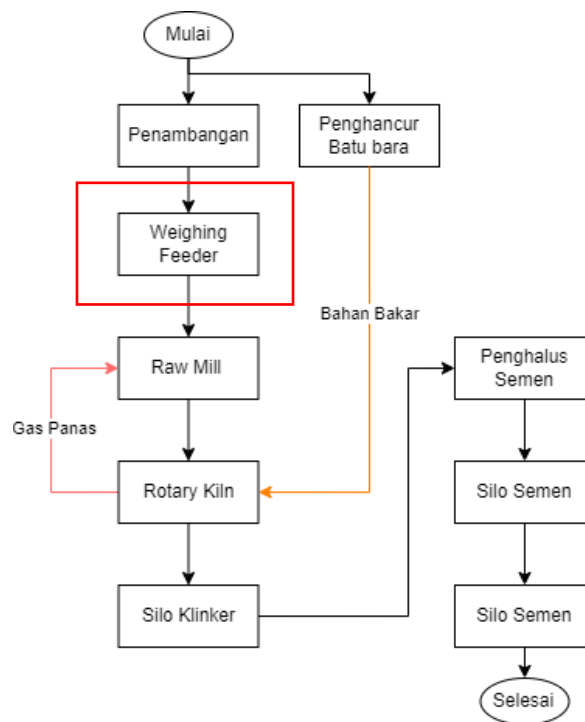
Italia, sangat kaya akan mineral aluminosilikat esensial, sehingga memunculkan semen pozzolana klasik di era Romawi. Sampai hari ini istilah pozzolana, atau pozzolan, mengacu pada semen itu sendiri atau pada aluminosilikat halus yang bereaksi dengan kapur dalam air untuk membentuk semen. Sedangkan menurut (Rodgers, 2018) setelah era Yunani pada tahun 1824 ada seorang insinyur berkebangsaan Inggris bernama Joseph Aspidin melakukan hak paten terhadap komposisi semen dengan nama Semen Portland. Semen ini agak berbeda dari semen yang sudah lama dikenal karena mengandung campuran tanah liat (Clay) di dalamnya sehingga mengubah sedikit warna campuran akhir dan mirip seperti daerah Portland Inggris yang mengandung banyak tanah liat.

2.2.2 *Raw Material Semen (Komposisi)*

Masih menurut (Frederick M Lea, 1999) Semen portland pada dasarnya terdiri dari senyawa kapur (kalsium oksida, CaO) yang dicampur dengan silika (silikon dioksida, SiO₂) dan alumina (aluminium oksida, Al₂O₃). Kapur diperoleh dari bahan baku berupa batu berkapur dan oksida lainnya diperoleh dari bahan berlempung (tanah liat). Bahan baku tambahan seperti pasir silika, besi oksida (Fe₂O₃), dan aluminium terhidrasi, Al(OH)₃ dapat digunakan dalam jumlah yang lebih kecil untuk mendapatkan komposisi yang diinginkan.

2.2.3 *Produksi Semen*

Perencanaan sumber daya dan pengelolaan bahan baku dilakukan *Resources Planning and Inventory Management of Material and Coal* dengan proses perencanaan dan pengendalian persediaan bahan baku yaitu pembelian pasir silika, pasir besi, copper slag, fly ash, gypsum, alat bantu gerinda, pozzolan, dan batu bara. Untuk bahan baku berupa batu kapur (*limestone*) dan tanah liat (*clay*) didapatkan dari penambangan oleh pihak perusahaan tersebut pada lokasi yang berada di belakang pabrik dengan luas (GUODONG et al., 2015). Tahapan pada proses produksi semen dimulai dari proses penambangan hingga masuk ke proses pengemasan, proses produksinya sendiri dijelaskan dalam diagram alir berikut:



Gambar 2.1 Fokus Penelitian



Gambar 2.2 Komputasi Proses Sampling

Sumber : (GUODONG et al., 2015)

2.2.4 Proses Quality Control

Menurut (Morant & Albertos, 1988) proses QC pada semen merupakan hal yang krusial karena mencakup pencampuran bahan dan juga kadar masing-masing bahan mentah sebelum kemudian masuk ke dalam mesin Raw Mill untuk dihaluskan. Proses QC sendiri terbagi menjadi beberapa seksi dimana terdapat uji fisik dan kimia, namun yang menjadi fokus

penelitian kali ini adalah QC pada bagian *Control Room* dimana prosesnya dititik beratkan untuk membuat semen yang sesuai dengan standar dimana jika diibaratkan pada sebuah restoran, maka pihak QC yang mengatur komposisi bahan agar dapat mencapai tujuan memproduksi klinker yang bagus. Proses QC sendiri berlangsung selama 24 jam nonstop atau dengan kata lain tanpa henti, karena dalam industri semen tidak ada produk *defect* sehingga QC berlangsung secara terus menerus. Secara umum material yang dipakai untuk memproduksi semen ada empat yaitu:

1. Batu kapur (Limestone/ CaO)

Batu Kapur adalah bahan baku utama dalam pembuatan semen, maka dari itu sifat fisik dan kimia batu kapur penting sebagai acuan proses produksi pembuatan semen serta alat-alat yang dipakai dalam pembuatannya.

2. Tanah Liat (Clay/ Al_2O_3)

Tanah liat mengandung senyawa penting seperti silika, alumina, dan juga besi yang digunakan dalam proses produksi semen. Tanah liat sendiri terkadang sudah bercampur dengan *limestone* saat penambangan sehingga pencampuran di *weighing feeder* terkadang tidak menggunakan *clay* tambahan karena kandungan *clay* yang sudah banyak dari alam di *limestone*nya.

3. Pasir Silika (SiO_2)

Pasir Silika sendiri adalah bahan dari pelapukan batuan yang mana memiliki kandungan mineral di dalamnya seperti kuarsa dan feldspar. Pasir silika dipakai untuk bahan baku penunjang akhir supaya kekuatan dari semen meningkat, pasir silika akan berfungsi dalam pengoreksi kadar di mana dalam tanah liat masih kurang kandungan silika.

4. Pasir Besi (Fe_2O_3)

Pasir Besi berfungsi dalam pembentukan C4AF yang mana dapat berpengaruh pada warna semen yang dihasilkan dan berguna dalam penghantaran energi panas dalam pembentukan klinker dari klin. Pasir Besi yang dipakai dalam proses produksi semen, supply bahannya sendiri berasal dari PT Krakatau Steel.

Bahan-bahan tersebut perlu dijaga komposisinya selama proses penggilingan material pada raw mill berlangsung menggunakan alat yang bernama *weighing feeder*. Indeks yang harus terpenuhi adalah sebagai berikut.

$$K = \frac{CaO - 1.65Al_2O_3 - 0.35Fe_2O_3}{2.8SiO_2},$$

$$n = \frac{SiO_2}{Al_2O_3 + Fe_2O_3},$$

$$p = \frac{Al_2O_3}{Fe_2O_3},$$

Gambar 2.3 Rumus Modulus

Atau menurut (Morant & Albertos, 1988) bisa juga dinyatakan dalam bentuk rasio oksida seperti kadar limestone (LS), Modulus Alimunium (AM) dan juga Modulus Silika (SM) sehingga didapati variable yang akan dikendalikan atau menjadi input adalah W1, W2, dan W3.

Rasio oksida nya sendiri adalah sebagai berikut,

1. Lime Saturation Factor

$$LS = \frac{100C}{2.8 \times S + 1.1 \times A + 0.8 F} \quad (2.1)$$

2. Alumunium Modulus

$$AM = \frac{A}{F} \quad (2.2)$$

3. Silica Modulus

$$SM = \frac{S}{A+F} \quad (2.3)$$

Keterangan:

C adalah kandungan kalsium oksida (CaO) dalam bahan baku.

S adalah kandungan silika (SiO₂) dalam bahan baku.

A adalah kandungan alumina (Al₂O₃) dalam bahan baku.

F adalah kandungan besi oksida (Fe₂O₃) dalam bahan baku

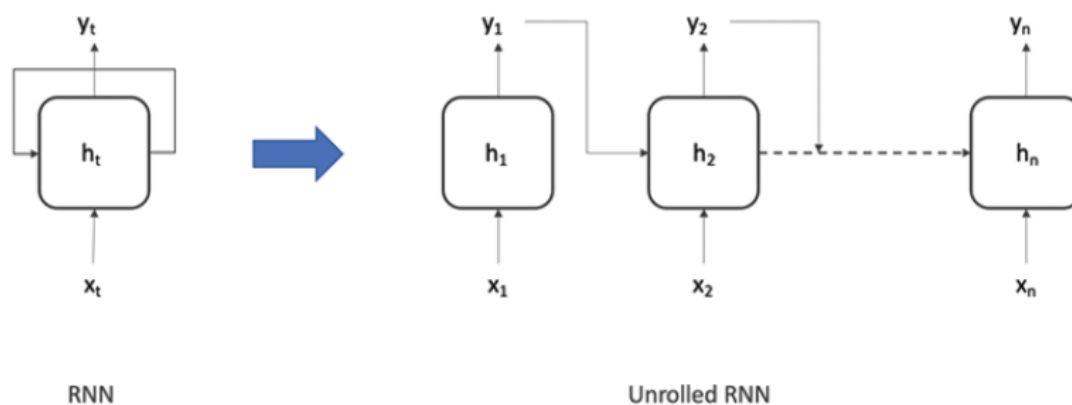
Biasanya pihak QC akan mengambil sampel dari tambang dan proses penyesuaian proporsi bahan nya akan ditentukan seperti berikut.

Laboratorian mengambil sampel secara manual dalam interval waktu tertentu (Case Indocement adalah 30 menit), kemudian sampel dianalisis di laboratorium. Setelah itu hasilnya akan diproses pada komputer. Indeks variabel (K, n, p) dikirimkan ke operator. Setelahnya operator menyesuaikan aliran material melalui Komputer kepada *Weighing Feeder*, namun pada kasus tertentu terdapat lonjakan komposisi sehingga intervensi operator sangat diperlukan

dalam menyesuaikan campuran bahan. Kemudian untuk mendapatkan modulus nilai dari masing-masing input diperlukan juga kandungan dari masing-masing bahan kimia yang ada, seperti nilai kalsium pada batu kapur (limestone), kemudian nilai silika, nilai tanah liat, sehingga mendapatkan ketetapan modulus pada rumus di atas.

2.2.5 *Recurrent Neural Network*

Pada masa sekarang penggunaan *deep learning* (DL) sangat penting, beberapa permasalahan bisa diselesaikan menggunakan beberapa jenis dalam machine learning, salah satunya adalah RNN atau biasa dikenal dengan *Recurrent Neural Network* (Al-Selwi et al., 2024). RNN pertama kali diperkenalkan pada era 1980an untuk pemecahan data yang bersifat *time series*, menurut sejarahnya koneksi antara lapisan pada RNN bisa melakukan prediksi untuk data yang sangat jauh berdasarkan pola yang ditemukan dengan waktu yang berkaitan. Namun walaupun kemudahan penggunaan RNN dalam mencari pola data, informasi, dan penggunaan dalam eksperimen, pada nyatanya tetap membutuhkan kemampuan yang mumpuni dan berpotensi menyulitkan jika tidak dibarengi dengan masukan atau *input* yang sesuai dengan studi kasus, beberapa faktor penyebabnya utama RNN adalah *vanishing gradient*, di mana gradien yang digunakan dalam pelatihan menjadi sangat kecil seiring dengan panjangnya urutan, sehingga sulit untuk menangkap data jangka panjang. Selain itu, RNN juga memiliki masalah terkait *exploding gradient*, di mana gradien menjadi sangat besar, menyebabkan ketidakstabilan selama pelatihan model. Sulitnya RNN dalam memproses beberapa informasi dari urutan yang panjang membuat RNN kurang efektif untuk penyelesaian data yang membutuhkan pemahaman konteks jangka panjang. Selain itu, pelatihan RNN cenderung lambat dan tidak stabil karena masalah gradien ini (Babcock Joseph & Bali Raghav, 2021). Setelah nya pada tahun 1977 ditemukan solusi untuk kelemahan dalam yang dimiliki RNN sehingga lebih akurat dan mampu dalam melakukan prediksi data yaitu dengan menambahkan memori eksplisit ke dalam jaringan. Hochreiter dan Schmidhuber adalah orang yang menemukan model pertama dari metode baru ini, yang akhirnya disebut sebagai *long short-term memory* (LSTM). Model baru ini mengintegrasikan lapisan tersembunyi khusus yang secara alami memiliki kecenderungan mempertahankan masukan atau input untuk jangka waktu yang lebih lama, sehingga lebih reliabel untuk memprediksi deret waktu yang lebih panjang (Korstanje Joos, 2021).



Gambar 2.4 Flow Diagram RNN


Sumber : (Babcock Joseph & Bali Raghav, 2021)

Dari gambar 2.4 menurut (Babcock Joseph & Bali Raghav, 2021) menguraikan lapisan-lapisan yang ada yaitu:

1. Masukan Sequence atau *input* awal yang biasanya dilambangkan dengan variabel X_{t-1}, X_t, X_{t+1} . Pada variabel ini RNN memproses perubahan pada setiap perubahan waktu yang dimulai dari $t - 1, t, t + 1$.
2. Hidden State atau bagian pemrosesan data, RNN memiliki hidden state yang dilambangkan sebagai $ht - 1, ht, ht + 1$. Hidden state ini adalah memori internal RNN yang berubah atau diperbaharui setiap berubah nya waktu dan membawa informasi dari waktu sebelumnya.
3. Recurent Connection atau koneksi berulang, setelah sebelum nya ada bagian yang disebut Hidden State, itulah yang digunakan untuk perhitungan pada bagaian jaringan ini. $ht - 1$, dari langkah waktu sebelumnya ($t - 1$) digunakan untuk menghitung *hidden state* ht pada langkah waktu saat ini (t). Hal yang sama juga terjadi pada (ht) akan digunakan untuk menghitung $Ht + 1$ pada langkah waktu berikutnya ($t + 1$).
4. *Output Sequence* atau keluaran sekuen, dilambangkan dengan $ot - 1, ot, ot + 1$ keluaran ini biasanya dihitung berdasarkan *hidden state* pada langkah waktu yang sama. Semua urutan tersebut terjadi berulang dengan mekanisme *looping* untuk memproses semua data yang ada agar dapat menemukan nilai yang diharapkan.

A. LSTM

Setelah mengetahui sejarah mengenai RNN pada sub bab sebelumnya, penelitian lanjutan akhirnya menemukan sebuah algoritma pemrosesan baru yang disebut dengan LSTM atau *Long Short-Term Memory*. Algoritma ini adalah jenis jaringan saraf buatan yang dirancang untuk memproses dan mengingat informasi dari urutan data dalam jangka waktu yang lama (Varshini et al., 2024). LSTM diciptakan untuk memperbaiki beberapa kelemahan utama dari *Recurrent Neural Networks* (RNN) sebelumnya, terutama masalah *vanishing gradient* yang membuat RNN sulit untuk mendapatkan dependensi jangka panjang dalam data. Berikut adalah gambaran mekanisme dari LSTM mengutip dari (Varshini et al., 2024).



Gambar 2.5 Flow Diagram LSTM

Sumber : (Korstanje Joos, 2021)

Dari gambar diatas menurut (Al-Selwi et al., 2024) menguraikan lapisan-lapisan yang ada yaitu:

1. *Input* atau masukan dalam variabel $X_t, h_t - 1$

LSTM menerima dua *input* utama: *input* pada waktu saat ini (x_t) dan *hidden state* dari waktu sebelumnya ($h_t - 1$).

2. *Forget Gate* atau gerbang lupa, berfungsi sebagai pintu untuk membuat informasi yang tidak penting atau sudah usang dihapus dari *cell state* sebelumnya ($c_t - 1$).
3. *Input Gate*

Input gate memutuskan informasi baru apa yang akan disimpan dalam *cell state*. Bagian ini sendiri terdiri dari dua:

- a. Fungsi sigmoid yang berfungsi menentukan nilai yang akan diperbaharui

$$F_t = \sigma(W_f(h_{t-1}, x_t) + b_f)$$

- b. Fungsi tanh yang berfungsi menghasilkan kandidat bar uke dalam *cell state*

$$C'_t = \tanh(W_c(h_{t-1}, x_t) + b_c)$$

4. Pembaharuan Cell

Cell state diperbarui dengan menggabungkan informasi lama yang telah dipilih oleh forget gate dan informasi baru yang dihasilkan oleh input gate, dengan cara mengalikan nilai informasi lama C_{t-1} dengan output dari *forget gate*.

$$C_t = F_t \times C_{t-1} + I_t \times C'_t$$

5. Output Gate

Gerbang ini memutuskan apa yang akan dihasilkan sebagai *output* dan *hidden state* baru. Ini juga menggunakan dua bagian yaitu:

a. Fungsi sigmoid menentukan bagian mana dari cell state yang akan digunakan untuk menghasilkan output.

$$O_t = \sigma(W_o(h_{t-1}, x_t) + b_o)$$

b. Fungsi tanh untuk mengubah *cell state* yang telah diperbarui untuk menghasilkan *hidden state* baru,

$$H_t = O_t \times \tanh C_t$$

6. Hidden State baru

Adalah hasil dari perhitungan sebelumnya sehingga menjadikan state baru. Dihitung dengan mengalikan *output* dari fungsi sigmoid *output gate* dengan hasil tanh dari *cell state* yang telah diperbarui. (h_t)

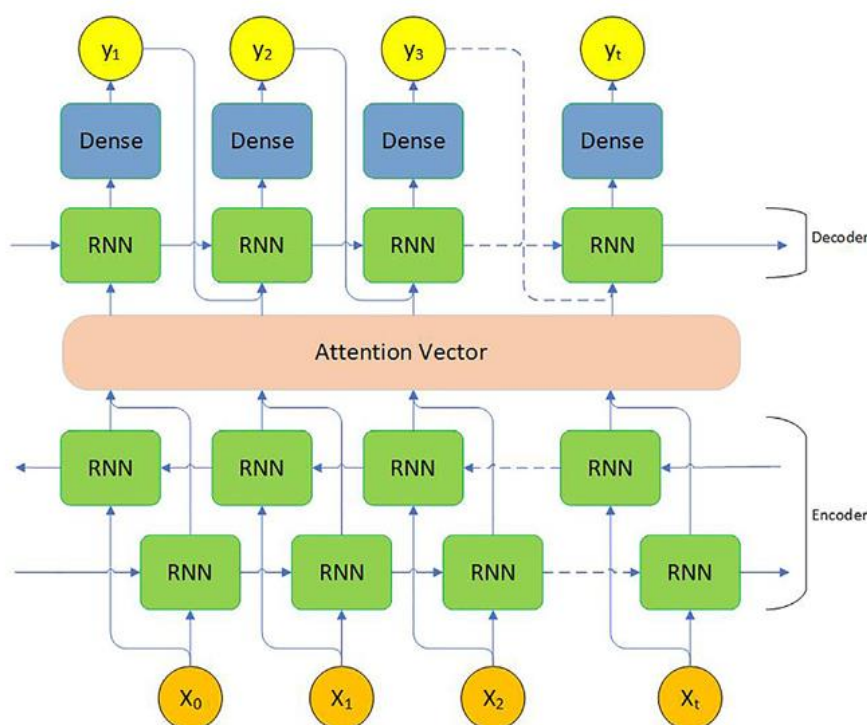
7. Output atau keluaran dipetakan dalam bentuk akhir bernilai (h_{t+1}).

Kesimpulan nya adalah penggabungan *cell state* ke bagian perhitungan, sedangkan *hidden state* memberikan model ingatan yang lebih luas akan informasi masa lalu. *Cell state* dapat dimodifikasi menggunakan *gate* atau gerbang, dengan tiga jenis gerbang yang ada dalam model LSTM yaitu, *forget gate*, *input gate*, dan *output gate*. Langkah awal melibatkan penentuan apakah akan menyimpan atau membuang informasi dari waktu sebelumnya. Proses ini mempertimbangkan *input ht - 1*, dan *xt* yang kemudian melewati lapisan *sigmoid*, menghasilkan nilai antara 0 dan 1. Jika keluarannya mendekati 0, *input* dianggap tidak relevan dan tidak disebarkan lebih lanjut. Sebaliknya, jika keluarannya mendekati 1, *input* dianggap relevan dan terus menyebar melalui jaringan.

B. Sequence to Sequence LSTM

Untuk jenis LSTM sendiri yang sampai sekarang sering digunakan ada beberapa seperti, *bidirectional LSTM*, *Covulutional LSTM*, dan *Sequence to Sequence LSTM* (Varshini et al.,

2024). Pada penelitian sekarang peneliti menggunakan jenis LSTM *Sequence to Sequence* karena data yang ada bersifat *sequential* dengan pertimbangan *monitoring* Sampel yang selalu berulang selama periode waktu tertentu dan hasil sampel setelah nya dipengaruhi oleh data yang sedang dijadikan perhitungan. Dalam penerapan model nya sendiri, model searah atau dua arah untuk data *sequence*, model *sequence to sequence* berhasil digunakan untuk tugas prediksi rangkaian waktu dan juga menyediakan teknologi yang baik untuk menangani data deret waktu yang tidak beraturan (Weerakody et al., 2021).



Gambar 2.6 LSTM *Sequence to Sequence*

Sumber : (Weerakody et al., 2021)

Pada gambar 2.6 bentuk arsitektur dari model LSTM berjenis *sequence to sequence*, dengan perubahan di beberapa bagian. RNN bagian bawah adalah *encoder* yang memampatkan informasi dalam urutan *input* ke *array* berdimensi tetap. RNN kedua bertindak sebagai *decoder* dan menghitung probabilitas urutan target, sampai menunjukkan hasil akhir. Penggunaan jenis LSTM ini sangat tepat untuk menghadapi data yang tidak komplit dalam barisan *sequence* nya, karena *decoder* dapat menghasilkan rangkaian waktu representatif baru yang dapat digunakan oleh sebuah prediksi lapisan layer atau tempat model mempelajari nilai untuk dimasukkan ke dalam rangkaian waktu masukan.

C. RMSE dan MAE

Setiap model yang dibuat haruslah mendapatkan validasi untuk bisa dikatakan kredibel dalam penggunaannya, tak terkecuali model LSTM. Pada *machine learning* validasi model biasanya dihitung dengan statistika untuk mengetahui hasil prediksi dengan hasil data aslinya. *Root Mean Squared Error* (RMSE) sering digunakan untuk memvalidasi model *Long Short-Term Memory* (LSTM) karena sejumlah alasan penting. Hal paling utama adalah, RMSE mengukur ketepatan prediksi dengan menghitung akar kuadrat dari rata-rata kuadrat kesalahan antara nilai yang diprediksi oleh model dan nilai aktual. Dengan begitu RMSE mengembalikan nilai eror dalam satuan yang sama dengan variabel target, ini membuat interpretasi hasil lebih mudah dan langsung. Selanjutnya, RMSE memberikan penilaian bobot lebih besar untuk kesalahan besar dibandingkan dengan kesalahan kecil karena kesalahan dikuadratkan sebelum dirata-ratakan. Sensitivitas ini terhadap *outlier* membantu mendeteksi prediksi yang sangat buruk dan memastikan model berfokus untuk mengurangi kesalahan besar, sehingga nilai RMSE yang kecil menjadikan nilai modelnya semakin valid. Selain itu, perhitungan RMSE relatif sederhana dan efisien secara komputasi, yang menjadikannya pilihan yang baik untuk digunakan dalam iterasi pengembangan model dan validasi. Banyak algoritma pembelajaran mesin, termasuk LSTM, dirancang untuk meminimalkan kesalahan kuadrat, sehingga menggunakan RMSE sebagai metrik evaluasi memastikan konsistensi antara tujuan pelatihan model dan evaluasi kinerjanya. Kombinasi alasan-alasan ini menjadikan RMSE sebagai metrik yang efektif dan populer untuk memvalidasi model LSTM (Varshini et al., 2024).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y-y_i)^2}{n}}$$

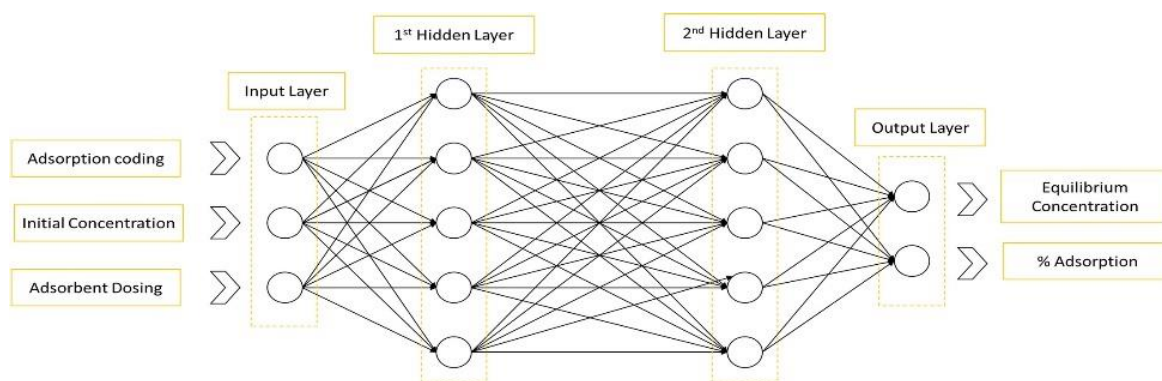
Sedangkan validasi statistika lain yang biasanya digunakan adalah MAE atau *Mean Square Error*. MAE adalah metrik alternatif yang menawarkan ketahanan lebih besar terhadap *outlier* atau sampel yang meleset dari rerata dibandingkan dengan RMSE, karena tidak melibatkan pengkuadratan *error*. MAE menghitung perbedaan absolut rata-rata antara data aktual dan nilai prediksi, memberikan nilai keseluruhan secara langsung (Chai & Draxler, 2014).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - y_i|$$

MAE dengan mudah menginterpretasikan metrik yang sedikit terpengaruh oleh data *outliers*, dan tidak mendapat pengurangan nilai secara ekstrem sebagaimana yang terjadi pada RMSE. Namun sama seperti RMSE nilai MAE yang kecil menandakan bahwa model yang dibuat memiliki validitas tinggi (Chai & Draxler, 2014).

2.2.6 Artificial Neural Network

Jaringan Syaraf Tiruan atau JST dalam Bahasa Inggris disebut *Artificial Neural Network* atau ANN merupakan sebuah model matematika yang mengikuti cara kerja otak manusia dalam memproses suatu data (Basheer & Hajmeer, 2000). Hal pertama yang perlu diperhatikan ketika kita mempertimbangkan penggunaan *Artificial Neural Network* (ANN) adalah sifat masalah yang ingin kita selesaikan. Demikian apakah masalah tersebut memerlukan pengawasan atau pendekatan tanpa pengawasan. Dengan kata lain, kita harus memahami apakah kita perlu **mengawasi proses** atau apakah kita dapat menggunakan pendekatan yang lebih **otonom** (Zupan, 1994). ANN, atau Jaringan Saraf Tiruan, adalah suatu struktur yang terdiri dari unsur-unsur yang diproses secara sederhana namun dapat beradaptasi dan saling terhubung, yang mampu melakukan perhitungan secara paralel untuk mengolah data dan mengekstrak informasi dari jumlah data yang besar. Seperti jaringan otak manusia, ANN adalah sistem pengolah informasi yang terdiri dari neuron atau *node*, dengan model yang terdiri dari tiga lapisan dan sejumlah *node* yang membentuk struktur yang menyerupai otak manusia. Untuk lebih jelasnya pada gambar berikut adalah bagaimana perbandingan model ANN dengan otak manusia.



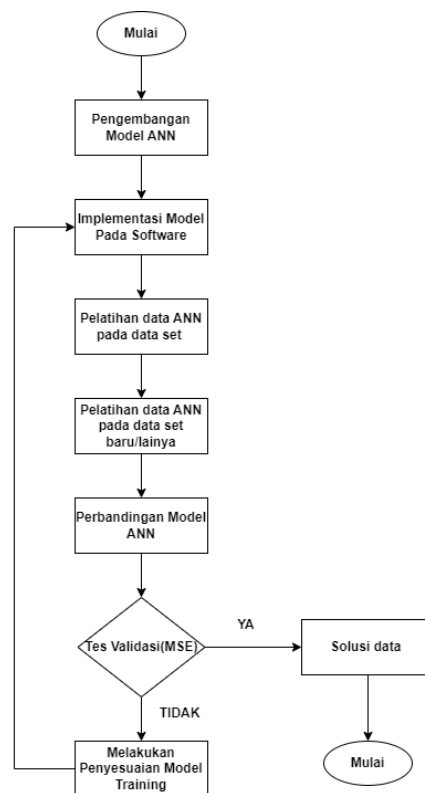
Gambar 2.7 Lapisan ANN

Sumber : (Sri Kusumadewi, 2003)

Dari gambar di atas menurut (Zupan, 1994) menguraikan lapisan-lapisan yang ada yaitu:

1. Layer masukan (input layer) merupakan bagian dari prediktif atau variabel independen.
2. Layer tersembunyi (hidden layer) terdiri dari *node* yang tidak teramati atau unit tersembunyi. Nilai dari setiap unit tersembunyi merupakan hasil dari beberapa fungsi dari suatu prediktor, dengan bentuk spesifik dari fungsi tersebut bergantung pada jenis jaringan dan preferensi pengguna.
3. Layer keluaran (output layer) memuat respons, pada awalnya terdiri dari variabel kategorial dengan dua kategori. Variabel kategorial ini diubah menjadi dua variabel indikator. Setiap unit keluaran adalah hasil dari fungsi yang diterapkan pada unit tersembunyi.

Pada proses pembobotan dan penjalanan model nya, ANN akan menimbang dan melakukan perhitungan mengikuti kemampuan otak manusia dalam neuron-neuron yang ada, sesuai dengan pembobotan variabel yang menjadi masukan di antara lapisan nya, dalam struktur Jaringan Saraf Tiruan (ANN), terdapat dua jenis bobot, yaitu *wsj* dan *wjk*. Bobot *wsj* menghubungkan neuron-neuron antara lapisan masukan dan lapisan tersembunyi. Sementara itu, bobot *wjk* menghubungkan neuron-neuron pada lapisan tersembunyi dengan lapisan keluaran. Selanjutnya, hasil di lapisan keluaran dievaluasi dan dibandingkan dengan target, dan kesalahan yang dihasilkan digunakan untuk menyesuaikan kembali bobot. Proses ini berulang hingga jaringan mampu memberikan hasil yang sesuai dengan yang diharapkan, sehingga pemilihan model akan sangat menentukan hasil yang akurat sesuai dengan nilai yang diharapkan dengan melakukan perubahan ada layer yang menjadi penghitung pada lapisan nya. Untuk lebih jelas nya berikut adalah *flow chart* dari metode ANN.



Gambar 2.8 Alur Model ANN

A. Metode *Learning*

Seperti yang sudah dijelaskan pada bagian diatas, ada beberapa hal yang menjadi perhatian pada saat melakukan *Learning* atau pembelajaran pada model ANN, dimana menurut (Zupan, 1994) akan terdiri dari beberapa pilihan dalam proses nya yaitu apakah kita harus mengawasi proses atau tidak terawasi menjadi otonom.

1. Pembelajaran Terawasi (Supervised Learning)

Pembelajaran terawasi dalam Jaringan Saraf Tiruan (ANN) mengacu pada proses di mana jaringan diberi contoh data masukan yang memiliki label atau target yang sesuai. Jaringan belajar untuk membuat korelasi antara data masukan dan label yang benar, dengan mengoptimalkan bobot dan parameter lainnya untuk meminimalkan kesalahan prediksi, dengan singkatnya metode pembelajaran ini sudah memiliki target yang akan dicapai berdasarkan data yang dijadikan sebagai variabel informasi atau variabel masukan. Diferensial antara pola *output* yang diperoleh dari pembelajaran dan pola target disebut sebagai kesalahan atau *error*. Jika kesalahan masih signifikan, itu menunjukkan perlunya

peningkatan pembelajaran lebih lanjut seperti yang sudah dijelaskan sebelumnya. Beberapa algoritma pembelajaran ini antara lain adalah:

1. *Hebb Rule*
 2. *Perceptron*
 3. *Delta Rule*
 4. *Backpropagation*
 5. *Heteroassociative Memory*
 6. *Bidirectional Associative Memory (BAM)*
 7. *Learning Vector Quantization (LVQ)*
2. Pembelajaran tidak terawasi (Otonom/Unsupervised Training)

Berbeda dengan pembelajaran terawasi, pembelajaran ini tidak memerlukan target *output* sebagai tujuannya, sehingga tidak dapat ditentukan hasil yang diharapkan selama proses pembelajaran. Dalam prosesnya, bobot disusun dalam suatu jarak tertentu yang bergantung pada nilai *input* yang diberikan. Tujuan dari pembelajaran ini adalah mengelompokkan unit-unit yang hampir sama dalam suatu area tertentu, sehingga umumnya pembelajaran ini sangat cocok untuk pengelompokan (klasifikasi) pola data.

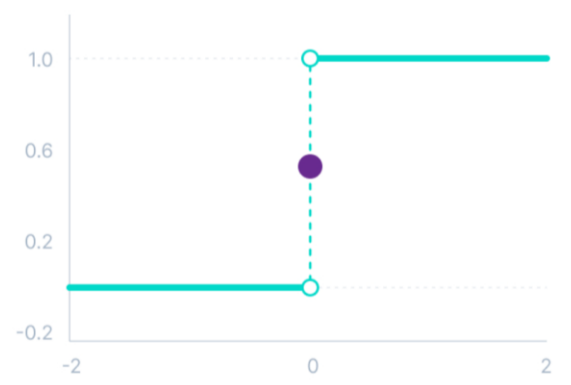
B. Fungsi Aktivasi

Fungsi aktivasi adalah suatu kondisi yang menentukan *input* dari neuron akan diteruskan atau tidak ke layer berikutnya (Zupan, 1994), sehingga ada beberapa fungsi aktivasi yang nantinya digunakan untuk perhitungan dan kalkulasi pada ANN. Mengutip dari (Basheer & Hajmeer, 2000) dan (Sri Kusumadewi, 2003) berikut adalah beberapa fungsi aktivasi yang biasa digunakan.

1. Fungsi Hard Limit

Fungsi ini digunakan dalam mengubah *input* dari suatu variabel yang memiliki nilai berkelanjutan menjadi *output* biner, yang dapat berupa 0 atau 1, pada jaringan saraf dengan hanya satu lapisan. Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = \begin{cases} 0, & \text{jika } x \leq 0 \\ 1, & \text{jika } x > 0 \end{cases}$$




Gambar 2.9 Fungsi Aktivasi Hard Limit

Sumber : (v7labs.com)

2. Fungsi Linear

Fungsi ini juga dikenal sebagai fungsi “Tanpa Aktivasi” atau “Tanpa Identitas” (Setiap *input* $\times 1.0$) adalah semua aktivasi yang ada sebanding dengan *input*. Fungsi ini tidak melakukan apa pun terhadap jumlah bobot masukan, ia hanya mengeluarkan nilai yang diberikan. Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = X \dots$$




Gambar 2.10 Fungsi Aktivasi Linear

Sumber : (v7labs.com)

3. Fungsi Sigmoid/Logistik

Fungsi ini melakukan aktivasi nilai sebenarnya dari semua nilai *input* dan *output* dengan rentang 0 hingga 1. Semakin besar nilai input (positif), semakin mendekati nilai *output* 1, sementara semakin kecil nilai input (negatif), semakin mendekati nilai *output* 0, secara matematis ditunjukkan dalam bentuk berikut.

$$Y = F(x) = \frac{1}{e^{-x}}$$




Gambar 2.11 Fungsi Aktivasi Logistik

Sumber : (v7labs.com)

4. Fungsi Treshold

Fungsi ini memanfaatkan ambang tertentu dan sering disebut sebagai fungsi ambang atau fungsi Heaviside. Ini adalah fungsi undak biner dengan ambang θ . Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = \begin{cases} 0, & \text{jika } x \leq \theta \\ 1, & \text{jika } x > \theta \end{cases}$$




Gambar 2.12 Fungsi Aktivasi Treshold

Sumber : (Sri Kusumadewi, 2003)

5. Fungsi Symetric Hard Limit

Fungsi bipolar menghasilkan *ouput* berupa 1, 0, atau -1, Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = \begin{cases} 0, & \text{jika } x > 0 \\ 1, & \text{jika } x = 0 \\ -1, & \text{jika } x < 0 \end{cases}$$




Gambar 2.13 Fungsi Aktivasi Symetric Hard Limit

Sumber : (Sri Kusumadewi, 2003)

6. Fungsi Bipolar Treshold

Fungsi ini hampir sama dengan biner *treshold* namun memiliki nilai berbeda, Fungsi bipolar dengan *threshold* menghasilkan *output* berupa 1, 0, atau -1. Fungsi bipolar dengan nilai ambang θ , Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = \begin{cases} 1, & \text{jika } x \geq \theta \\ -1, & \text{jika } x < \theta \end{cases}$$




Gambar 2.14 Fungsi Aktivasi Bipolar Treshold

Sumber : (Sri Kusumadewi, 2003)

7. Fungsi Saturasi Linear

Fungsi ini memiliki nilai 0 jika inputnya kurang dari -0,5, dan memiliki nilai 1 jika inputnya melebihi 0,5. Ketika *input* berada di antara -0,5 dan 0,5, outputnya sama dengan nilai *input* ditambah 0,5. Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = \begin{cases} 1; & \text{jika } x \geq 0 \\ x + 0.5, & \text{jika } -0.5 \leq x \leq 0.5 \\ 0; & \text{jika } x \leq -0.5 \end{cases}$$




Gambar 2.15 Fungsi Aktivasi Saturasi Linear

Sumber : (Sri Kusumadewi, 2003)

8. Fungsi Sigmoid Biner

Fungsi ini agak mirip dengan fungsi sigmoid/logistik namun memiliki nilai yang lebih kompleks, Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$F'x = \sigma f(x)[1 - f(x)]$$



Gambar 2.16 Fungsi Aktivasi Sigmoid Biner

Sumber : (Sri Kusumadewi, 2003)

9. Fungsi Sigmoid Bipolar

Fungsi ini memiliki *output* dari fungsi ini terletak antara -1 sampai 1. Secara matematis fungsi ini dinotasikan dalam bentuk berikut.

$$Y = F(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

Dengan

$$F'x = \frac{\sigma}{2} [1 + f(x)][1 - f(x)]$$

Pada dasarnya fungsi ini juga memiliki kemiripan dengan fungsi *hyperbolic tangen* dimana *range* yang dimiliki antara -1 sampai 1. fungsi ini dinotasikan dalam bentuk berikut.


$$Y = F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Atau

$$Y = F(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

Dengan

$$F'x = [1 + f(x)][1 - f(x)]$$




Gambar 2.17 Fungsi Aktivasi Sigmoid Bipolar

Sumber : (Sri Kusumadewi, 2003)

C. Backpropagation

Algoritma Backpropagation adalah salah satu metode yang paling umum digunakan untuk melatih Jaringan Saraf Tiruan (ANN). Tujuannya adalah untuk menyesuaikan bobot jaringan agar jaringan tersebut dapat menghasilkan output yang diinginkan untuk sejumlah masukan tertentu, algoritma ini adalah *learning* yang terawasi, sering digunakan oleh *perceptron* dengan lapisan-lapisan yang lebih dalam, bertujuan untuk mengadaptasi bobot-bobot yang terkoneksi dengan neuron-neuron dalam lapisan tersembunyinya. Berikut adalah tampilan lapisan *backpropagation*.



Gambar 2.18 Lapisan Backpropagation

Sumber : (Sri Kusumadewi, 2003)

Pada gambar tersebut, pembentukan jaringan terdiri dari variabel-variabel, salah satunya adalah variabel (x) sebagai lapisan *input*, kemudian (z) sebagai *hidden layer*, dan lapisan *output* (y), dimana setiap lapisan terdiri dari neuron yang terhubung. Pada bagian yang menghubungkan antara *input* dan *hidden layer* dinotasikan dalam v_{ij} , di mana bobot ini menghubungkan neuron pada lapisan input ke- i ke neuron ke- j pada lapisan tersembunyi. Selain itu, terdapat nilai bobot b_{11} dan b_{12} yang berperan sebagai bias menuju neuron pertama dan kedua di lapisan tersembunyi. Sementara itu, bobot yang menghubungkan lapisan tersembunyi dengan lapisan *output* disimbolkan sebagai w_k , dengan k mewakili neuron pada *output*. Bobot bias yang menghubungkan lapisan tersembunyi dengan lapisan *output* adalah b_2 .

ANN memiliki pembobotan masing-masing dari jalur yang terbentuk pada semua *node*. Setelah semua *node* ditetapkan nilainya maka dilakukan perhitungan. Menurut (Sri Kusumadewi, 2003) ada beberapa tahap dalam melakukan perhitungan dengan algoritma *backpropagation*.

1. Inisiasi bobot awal dengan nilai random yang kecil
2. Tetapkan maksimum epoch, target error, dan nilai learning
3. Inisiasi Epoch = 0 dan MSE = 1
4. Semua Langkah tadi dikerjakan selama epoch < maksimum epoch dan nilai MSE > target error.

- 1) Epoch = Epoch + 1
- 2) Langkah berikut dikerjakan untuk tiap pasangan elemen yang dilakukan pembelajaran.

Feedforward:

- a. Tiap input (X_i , $i = 1, 2, 3, \dots, n$) menerima masukan dari x_i , dan meneruskan masukan tersebut ke semua node pada lapisan yang ada di atasnya (*hidden layer*)
- b. Tiap node pada *hidden layer* (Z_j , $j = 1, 2, 3, \dots, p$) menjumlahkan sinyal-sinyal *input* yang memiliki bobot dengan rumus sebagai berikut:

$$z_{in_j} = b1_j + \sum_{i=1}^n X_i V_j$$

Penggunaan fungsi aktivasi untuk menghitung sinyal *output* dengan rumus sebagai berikut:

$$Z_j = f(Z_{in_j})$$

Sinyal itu dikirim ke semua *node* pada *layer* di atasnya (Unit Output)

Langkah pada bagian **b** dilakukan sebanyak jumlah lapisan *hidden layer*.

- c. Tiap-tiap unit *output* (Y_k , $k = 1, 2, 3, \dots, m$) menjumlahkan sinyal-sinyal *input* terbobot dengan rumus sebagai berikut:

$$y_{in_k} = b2_k + \sum_{i=1}^p Z_i W_{jk}$$

Penggunaan fungsi aktivasi untuk menghitung sinyal *output* dengan rumus sebagai berikut:

$$Y_k = f(Y_{in_k})$$

Sinyal itu dikirim ke semua node pada *layer* di atasnya (Unit Output).

Backpropagation:

- d. Tiap-tiap unit *output* (Y_k , $k = 1, 2, 3, \dots, m$) menerima target pola yang berhubungan dengan pola *input* pembelajaran, perhitungan *error* dengan rumus sebagai berikut.

$$\delta 2_k = (t_k - y_k) f'(y_{in_k})$$

$$\varphi_{2jk} = \delta_{2zj}$$

$$\beta_{2k} = \delta_k$$

Kemudian perhitungan antara koreksi bobot digunakan untuk memperbaiki nilai w_{jk} dengan rumus sebagai berikut.

$$\Delta w_{jk} = \alpha \varphi_{2jk}$$

Selanjutnya perhitungan koreksi bias yang nantinya akan digunakan untuk memperbaiki nilai b_{2k} dengan rumus sebagai berikut.

$$\Delta b_{2k} = \alpha \beta_{2k}$$

Langkah pada bagian **d** dilakukan sebanyak jumlah *hidden layer*, yaitu menghitung informasi *error* dari suatu *layer* ke *hidden layer* sebelumnya.

- e. Tiap-tiap unit tersembunyi ($Z_j, j = 1, 2, 3, \dots, p$) menjumlahkan delta inputnya (dari unit-unit yang berada pada lapisan di atasnya) dengan rumus sebagai berikut.

$$\delta_{inj} = \sum_{k=1}^m \delta_{2k} W_{jk}$$

Nilai diatas dikalikan dengan turunan fungsi aktivasinya untuk mendapatkan nilai informasi *error* dengan rumus sebagai berikut.

$$\delta_{1j} = \delta_{inj} f'(z_{inj})$$

$$\varphi_{1ij} = \delta_{1j} x_j$$

$$\beta_{1j} = \delta_{1j}$$

Setelahnya perhitungan koreksi bobot nantinya akan digunakan untuk memperbaiki nilai v_{ij} dirumuskan sebagai berikut.

$$\Delta v_{ij} = \alpha \varphi_{1ij}$$

Selanjutnya nilai koreksi bias yang akan digunakan untuk memperbaiki nilai b_{1j} dirumuskan sebagai berikut.

$$\Delta b_{1j} = \alpha \beta_{1j}$$

- f. Tiap-tiap unit output (Y_k , $k = 1, 2, 3, \dots, m$) memperbaiki bias dan bobotnya ($j = 0, 1, 2, \dots, p$), dengan rumus sebagai berikut.

$$W_{jk} (\text{baru}) = W_{jk} (\text{lama}) + \Delta W_{jk}$$

$$b_{2k} (\text{baru}) = b_{2k} (\text{lama}) + \Delta b_{2k}$$

Tiap *hidden layer* (Z_j , $j = 1, 2, 3, \dots, p$) memperbaiki bias dan bobotnya ($i = 0, 1, 2, \dots, n$) dengan rumus sebagai berikut.

$$V_{ij} (\text{baru}) = V_{ij} (\text{lama}) + \Delta V_{ij}$$

$$b_{1j} (\text{baru}) = b_{1j} (\text{lama}) + \Delta b_{1j}$$

3) Perhitungan MSE

MSE adalah singkatan dari *Mean Squared Error*, yang merupakan metrik evaluasi umum yang digunakan dalam berbagai jenis masalah pembelajaran mesin, termasuk dalam konteks Jaringan Saraf Tiruan (ANN). Ini digunakan untuk mengukur seberapa baik model memprediksi nilai target berkelanjutan.

a. Konsep Dasar

Pada hakikatnya, MSE menghitung nilai kuadrat selisih antara nilai prediksi dari model yang dibuat dengan nilai sebenarnya. Setiap titik pengujian akan dihitung dan nilai selisih dari prediksi dan nilai sebenarnya dengan kuadrat akan diambil.

b. Perhitungan

Untuk setiap titik data i , selisih antara nilai sebenarnya y_i dan nilai prediksi \hat{y}_i adalah $(y_i - \hat{y}_i)$. atau dengan rumus sebagai berikut.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2$$

Dimana n = jumlah data

Y_i = Nilai Target

Y'_i = Nilai Output

c. Interpretasi nilai

- Semakin rendah nilai MSE, semakin baik model dalam melakukan prediksi.
- Nilai MSE yang rendah menunjukkan bahwa model memiliki sedikit kesalahan dalam memprediksi data.
- Sebaliknya, nilai MSE yang tinggi menunjukkan bahwa model memiliki kesalahan yang besar dalam memprediksi data.

4) Perhitungan MAPE

Mean Absolute Percentage Error (MAPE) adalah sebuah metrik yang digunakan untuk mengukur akurasi suatu model prediksi dengan menghitung rata-rata kesalahan persentase absolut antara nilai yang diprediksi dan nilai aktual (Lewis & Colin David, 1982). Berikut adalah rincian nya.

a. Perhitungan

$$MAPE = \frac{\sum_{i=1}^N \frac{|Y_i - Y'_i|}{Y_i} \times 100\%}{n}$$

Keterangan

Y_i merupakan nilai aktual dari data

Y'_i merupakan nilai prediksi model

Nilai n merupakan banyak nya data.

Dengan demikian maka akan didapatkan persentase nilai *error* dari model secara rerata dengan distribusi ketetapan akurasi model sebagai berikut.

Tabel 2.2 Akurasi Nilai MAPE

Sumber : (Lewis & Colin David, 1982)

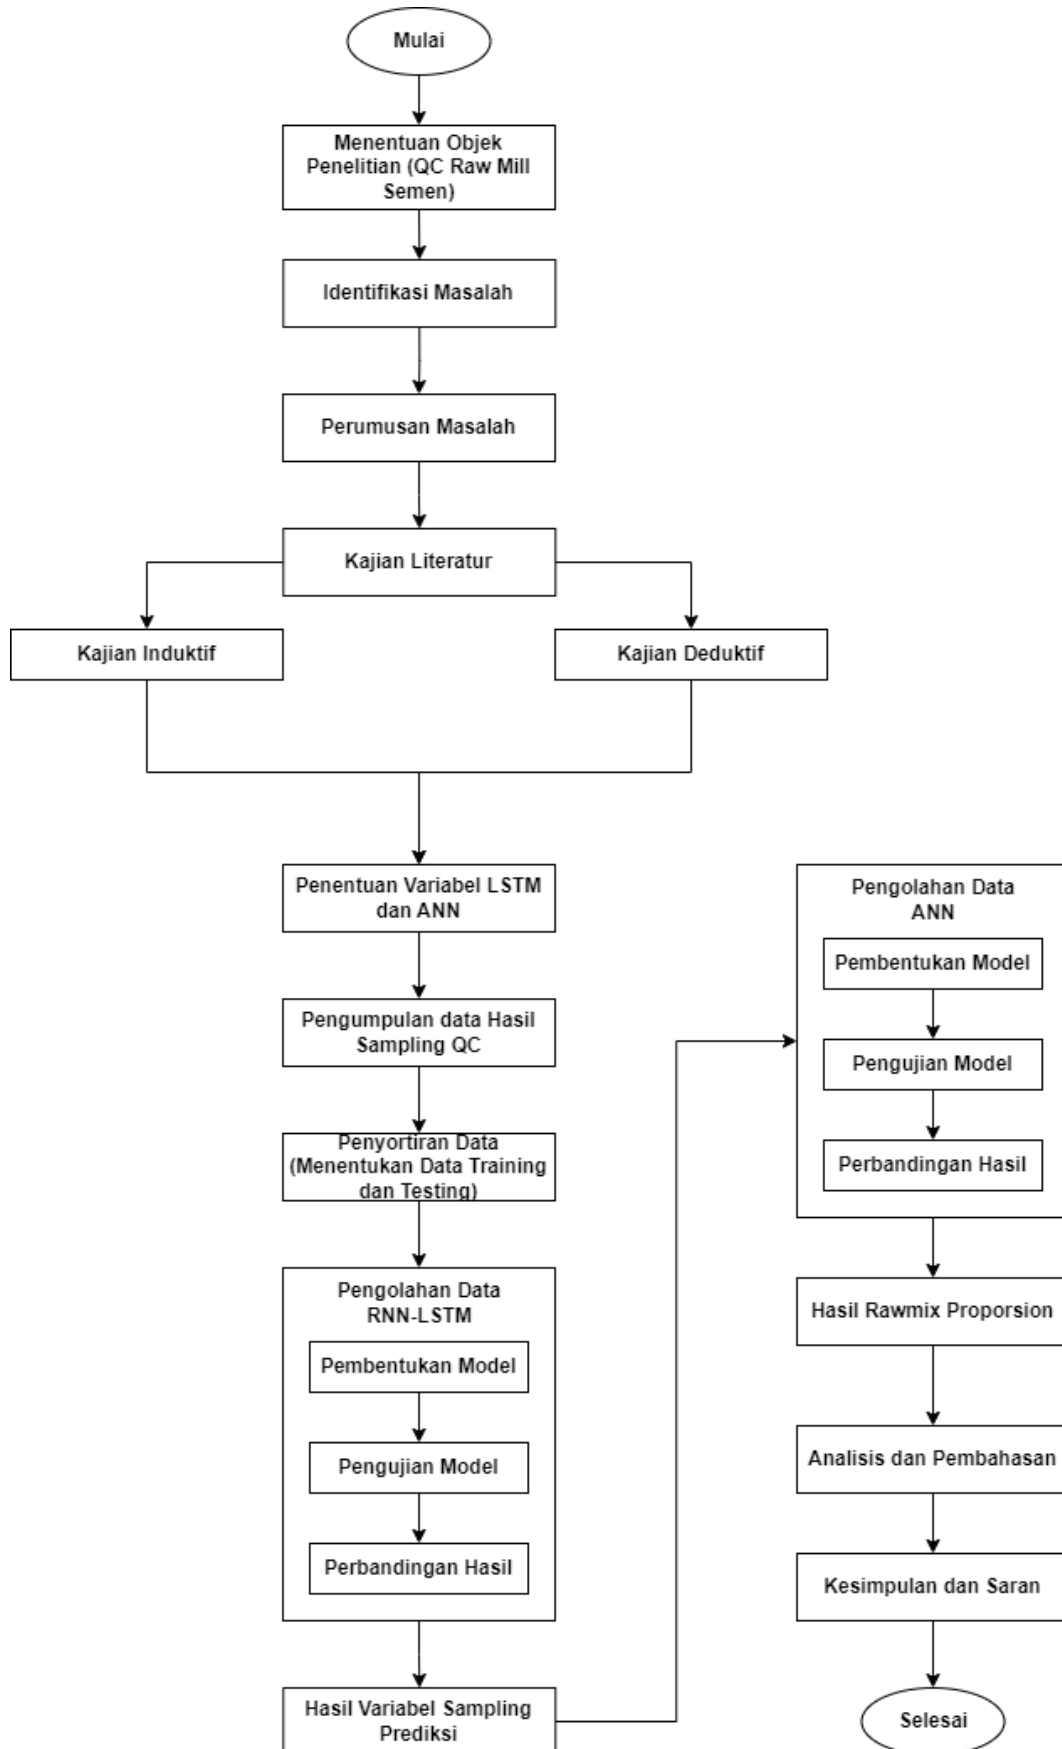
MAPE	< 10%	10% ≈ 19%	20% ≈ 49%	≥ 50%
Akurasi	Sangat Akurat	Akurat	Cukup Akurat	Tidak Akurat

BAB III

METODE PENELITIAN

Pada bagian ini, terdapat tahapan dan juga identifikasi permasalahan yang akan dibahas dalam penelitian. Selanjutnya perumusan masalah dan penentuan fokus pada penelitian juga akan dibahas dan dicantumkan dalam bentuk diagram *flow*, cakupan pembahasannya juga meliputi kajian pustaka yang terdiri dari kajian induktif dan deduktif dari penelitian sebelumnya dan juga penelitian terkait. Tahap selanjutnya adalah pengumpulan data dan juga pengolahan data, terkhusus untuk penelitian kali ini peneliti menggunakan *software* Matlab untuk menghitung setiap masukan dalam ANN.

Berikut adalah penjelasan keseluruhan alur penelitian ini dalam bentuk diagram *flow*.



Gambar 3.1 Alur Penelitian

3.1 Penentuan Objek Penelitian

Objek yang dijadikan penelitian adalah nilai ketetapan *Quality Control* untuk proses pencampuran semen pada seksi *raw mill* di perusahaan produksi semen PT Indocement Tungal Prakarsa.

3.2 Identifikasi Masalah

Pada tahapan ini, identifikasi masalah mulai ditentukan khususnya terkait dengan proses QC pada seksi *RawMill* di perusahaan produksi semen ini, proses yang bersifat repetitif ini perlu dilakukan improvisasi untuk membantu operator dalam penentuan nilai kadar kimia yang terdapat dari tambang untuk dicampur bahan adiktif dari proses produksi yang kemudian dimasukkan ke dalam *RawMill* untuk dicampur. Perusahaan memproduksi semen selama 24 jam nonstop dan terbagi menjadi tiga *shift* yang berbeda sehingga konsentrasi operator QC sangat diperlukan, setiap sampling membutuhkan waktu selama 30 menit untuk mengetahui kandungan dari bahan yang dicampur dan terkadang kesalahan *input* pada mesin pembobotan atau *weighing feeder* akan membuat sisa bahan yang masuk akan tetap berada di mesin Raw Mil sampai 30 menit ke depan karena perubahan komposisi yang dimasukkan memiliki *delay* selama 30 menit. Oleh karena itu keberadaan alat bantu atau sebuah instrumen sistem *asist* dapat mempermudah operator dalam menentukan atau memprediksi komposisi selama proses produksi berjalan, terutama dalam era transisi industri 4.0. Oleh karena itu peneliti melihat adanya perlu adanya perbaikan sistem pada sisi operator QC di *raw mill* ini untuk membantu mereka dalam identifikasi nilai bahan tambang atau kimia untuk menetapkan proporsi bahan adiktif yang tepat sesuai dengan rekomendasi dan penyesuaian hasil terutama ketika alat untuk melakukan proses sampling mengalami gangguan baik serius maupun tidak atau hasil sampling mengalami fluktuasi nilai, operator dapat mempertimbangkan hasil data QC melalui prediksi sebelumnya sehingga bisa menjaga kualitas semen yang optimal seperti standar perusahaan.

3.3 Perumusan Masalah

Tahapan ini menentukan masalah selanjutnya yang akan dijadikan sebagai tujuan dari penelitian. Berdasarkan identifikasi masalah ditetapkan oleh peneliti untuk melakukan pembelajaran sebuah sistem menggunakan machine learning dengan metode *Artificial*

Neural Network untuk membuat sebuah model yang bekerja seperti operator dalam melakukan identifikasi bahan komposisi produksi semen. Pembuatan model menggunakan data historis dari departemen produksi pada bagian QC dalam menentukan komposisi bahan adiktif yang mereka tambahkan berdasarkan tingkat dan kandungan yang mereka dapat dari tambang. Kemudian hasil model akan dibandingkan dengan data historis dari pihak QC untuk dinilai tingkat keakuratannya dan apakah model RNN dan ANN yang dibangun mampu menyamai operator yang bertugas untuk membantu mereka dalam kegiatan produksi.

3.4 Studi Literatur

Penelusuran literatur dilakukan untuk mencari bahan bacaan yang sesuai dengan topik penelitian ini. Secara keseluruhan, penelusuran literatur dapat dibagi menjadi analisis deduktif dan analisis induktif, yang dijelaskan sebagai berikut.

3.4.1 Kajian Deduktif

Penelitian ini mencakup analisis deduktif yang merupakan penyelidikan teoritis terhadap konsep-konsep ahli yang berkaitan dengan isu yang diteliti serta metode yang diterapkan. Pendekatan deduktif dalam penelitian ini meliputi, Semen Sebagai komposit, *Raw Material*, Sistem Produksi Semen, Proses QC *Raw Mill*, *Artificial Neural Network*.

3.4.2 Kajian Induktif

Penelitian induktif merupakan pengkajian yang bersumber dari hasil penelitian sebelumnya yang dapat dijadikan sebagai referensi atau perbandingan antara studi sebelumnya dengan penelitian yang sedang dilaksanakan. Dengan memperhatikan penelitian induktif ini, peneliti dapat memahami perbedaan antara penelitian terkini dengan penelitian-penelitian sebelumnya, memungkinkan mereka untuk menempatkan penelitian mereka dalam konteks yang tepat. Hal ini juga membantu menghindari duplikasi dan plagiarisme dalam penelitian.

3.5 Instrumen Penelitian

Pada penelitian kali ini, peneliti menggunakan gawai dan perangkat lunak pendukung selama penelitian berlangsung. Berikut adalah rincian alat penelitiannya.

1. Perangkat berjenis telepon genggam

Digunakan untuk melakukan dokumentasi dan pengambilan data mentah melalui pengambilan gambar atau foto.

2. Perangkat berjenis komputer portabel

Digunakan untuk melakukan komputasi data dengan perangkat lunak, spesifikasi komputer yang dipakai adalah sebagai berikut:

- Prosesor AMD Ryzen 5 4600HS
- RAM sebesar 16GB *Dual Channel*
- *Graphic Processing Unit* berjenis Nvidia GTX 1650TI
- Penyimpanan sebesar 512GB berjenis *Solid State Drive (SSD)*

3. Perangkat Lunak Matlab

Digunakan untuk melakukan komputasi model pada komputer portabel dengan spesifikasi sebagai berikut.

- Versi perangkat lunak Matlab R2022a
- Besar penyimpanan 30GB

Penggunaan perangkat di atas adalah sebagai penunjang peneliti dalam melaksanakan penelitian ini, adapun perbedaan perangkat yang dipakai memungkinkan hasil penelitian akhir yang berbeda.

3.6 Penentuan Variabel LSTM dan ANN

Variabel pada penelitian ini akan terbagi dua untuk masing-masing metode, dimulai dari penentuan variabel untuk *input* pada RNN LSTM hingga penentuan variabel untuk ANN. Penentuan variabel dilakukan berdasarkan kondisi lapangan/penelitian dengan referensi penelitian terdahulu atau penelitian sejenis yang mencakup beberapa kesamaan dalam menentukan nilai yang akan menjadi *input* dan *output*. Variabel yang ada didapatkan dari data historis perusahaan dan juga jurnal (Morant & Albertos, 1988) pada proses QC *raw mill* produksi semen. Variabel yang akan menjadi *input* pada penelitian ini yaitu.

1. Kadar *Limestone (LS)* (X1)

Kadar ini merupakan hasil pantauan mesin *Prompt Gamma Neutron Activation Analysis*. Mesin ini menganalisis zat kimia non-destruktif yang digunakan untuk menentukan komposisi unsur dalam sampel dengan memanfaatkan interaksi antara neutron dengan materi. Ketika sampel dikenai neutron, atom-atom dalam sampel dapat menyerap neutron dan kemudian menghasilkan gamma prompt.

Dengan mengukur energi dan intensitas gamma ini, pihak QC dapat menentukan komposisi unsur dalam sampel. Secara umum variabel ini memiliki rumus kimia dengan pembagian sebagai berikut.

$$LS = \frac{100C}{2.8 \times S + 1.1 \times A + 0.8 F}$$

2. Modulus Aluminium (AM) (X2)

Modulus aluminium merujuk pada kekuatan tekan aluminium yang menjadi patokan dalam pengujian semen. Prosedur pengujian modulus aluminium dilakukan untuk memverifikasi bahwa semen memenuhi standar kekuatan yang telah ditetapkan. Semakin tinggi nilai modulus aluminium, semakin tinggi kekuatan tekan semen tersebut. Pengukuran ini memiliki signifikansi penting karena kekuatan tekan yang optimal merupakan penanda utama kualitas semen yang akan diterapkan dalam berbagai proyek konstruksi. Secara umum variabel ini memiliki rumus kimia dengan pembagian sebagai berikut.

$$AM = \frac{A}{F}$$

Atau secara detail dinyatakan seperti berikut.

$$AM = \frac{Al_2O_3}{Fe_2O_3}$$

3. Modulus Silika (SM) (X3)

Modulus silika adalah faktor yang digunakan untuk menilai persentase silika dalam bahan mentah yang dipakai dalam produksi semen. Ini mengacu pada perbandingan antara kandungan silika (SiO_2) dan kandungan alumina (Al_2O_3) dalam bahan mentah tersebut. Pengukuran modulus silika mempunyai peran penting dalam pengendalian kualitas karena keseimbangan yang tepat antara silika dan alumina bisa berdampak pada kualitas akhir semen. Semakin tinggi nilai modulus silika, semakin tinggi pula proporsi silika dalam bahan mentah, dan hal ini bisa mempengaruhi sifat-sifat fisik dan kimia semen yang dihasilkan. Berikut adalah secara rumus kimianya.

$$SM = \frac{S}{A + F}$$

Atau secara detail dinyatakan seperti berikut.

$$SM = \frac{SiO_2}{Al_2O_3 + Fe_2O_3}$$

Adapun variabel keluaran atau *output* dari penelitian ini ada 3 yaitu, nilai campuran dari masing-masing bahan adiktif seperti; Pasir besi (Y1), Pasir Silika (Y2), dan juga Clay atau tanah liat (Y3).

3.7 Pengumpulan Data Hasil QC

Pengumpulan data dan informasi yang digunakan pada penelitian ini dilakukan dengan beberapa metode yang dijelaskan sebagai berikut.

1. Observasi

Pada observasi peneliti melakukan pengambilan data dengan cara melihat dan mengamati setiap kegiatan yang ada pada departemen QC, data yang ada digunakan oleh peneliti sebagai tolok ukur akurasi dan juga pencatatan yang akan menjadi data pendukung di luar data yang diberikan oleh pembimbing lapangan selama observasi.

2. Wawancara

Data utama pada penelitian ini didapatkan melalui wawancara mengingat data bersifat cukup sensitif, data merupakan hasil pemberian dari pembimbing lapangan dan juga parameter yang ada ditanyakan langsung kepada kepala departemen QC bagian Raw Mill.

3. Studi Literatur

Pada studi literatur, data digunakan untuk mencari parameter dan metode terbaik dalam melakukan data *training* untuk memberikan hasil dari ANN terbaik dan juga cara melakukan improvisasi proses *training* agar data menjadi lebih akurat, studi literatur juga digunakan untuk memberikan kemudahan dalam proses pengolahan data.

3.8 Penyortiran Data

Pada bagian ini data yang akan *ditraining* atau dilatih akan melalui proses sortir, guna mendapatkan kecukupan data dan juga memastikan tidak terjadinya lonjakan data secara tiba-tiba atau *spike* pada data. Data yang digunakan pada RNN-LSTM adalah semua hasil *Sampel QC* proses yang mencakup

- a. Kadar SiO₂
- b. Kadar Al₂O₃
- c. Kadar Fe₂O₃
- d. Kadar CaO
- e. MgO
- f. SO₃
- g. Na₂O
- h. K₂O

Data yang digunakan pada pembentukan model ANN adalah data primer yaitu.

1. Kadar *limestone*
2. Modulus alumunium
3. Modulus silika
4. Campuran Bahan Adiktif yang terdiri dari 3
 - a. Pasir besi
 - b. Pasir silika
 - c. Tanah liat

3.9 Pengolahan Data LSTM

Data yang sudah dapat akan dilakukan *training* menggunakan aplikasi Matlab dengan modul untuk membentuk model LSTM terlebih dahulu. LSTM di sini berfungsi sebagai alat atau metode untuk menentukan nilai modulus dengan memprediksi hasil kandungan kimia yang sudah diproses melalui mesin CBX. Jenis LSTM yang digunakan adalah *Sequence to Sequence* dan validasinya menggunakan MSE dan MAE.

3.9.1 Pembentukan Model

1. Pembagian data *training* dan *testing*

Pada tahap ini data akan dimasukkan ke dalam *software* untuk membentuk model LSTM. Data akan terdiri dari 2 tipe seperti yang sudah dijelaskan sebelumnya yaitu data *training* dan data *testing*. Data *training* digunakan untuk membentuk model LSTM sedangkan data *testing* digunakan untuk menguji jaringan yang telah dibangun dengan data yang tidak diinput dalam proses pembentukan jaringan. Data yang digunakan merupakan data produksi semen untuk membentuk *Clinker* dalam periode 2 *Pile* (gundukan material), dengan pembagian data tanggal 5-6 Mei digunakan sebagai *training* yang mencakup 120 data QC dan data tanggal 7-8 digunakan untuk

testing yang mencakup 120 data QC dengan rincian pengambilan data setiap 30 menit selama 24 jam produksi.

2. *Preprocessing data*

Preprocessing data dilakukan dengan tujuan untuk menormalkan data agar data masukan dan keluaran memiliki skala yang seragam. Dalam penelitian ini, dilakukan normalisasi data menggunakan metode rerata dan deviasi standar.

3. Komponen arsitektur jaringan

Bagian ini membentuk arsitektur jaringan pada Matlab menggunakan menu *script* editor, arsitektur jaringan sendiri merupakan bentuk dari komponen penyusun dari model yang nantinya akan bersinergi dalam menentukan hasil prediksi berdasarkan input atau masukan yang sudah ditentukan sebelumnya.

4. *Training parameter*

Pada bagian ini fungsinya adalah untuk memberikan batasan dan mengatur performa model yang sudah dibuat, setiap batasan atau parameter akan memberikan hasil prediksi yang berbeda dan menentukan akurasi yang sudah dimasukkan, semakin baik dalam menentukan batasan maka hasil prediksinya juga semakin akurat dan dapat dengan cepat menemukan titik konvergen.

3.9.2 *Pengujian Model*

Pada tahap ini, dilaksanakan evaluasi performa jaringan dengan menggunakan data baru yang tidak terlibat dalam fase pelatihan atau pembelajaran jaringan. Data yang dipilih untuk proses ini merupakan bagian dari kumpulan data historis yang ditetapkan sebagai data pengujian. Data harus berasal dari *pile* yang sama untuk menghindari perbedaan atau pembiasan data akibat adanya perbedaan material yang menjadi input utama pada proses. Namun tidak menutup kemungkinan adanya perbedaan pengambilan data dari *pile* untuk menguji sejauh apa perbedaan yang diprediksi oleh model.

3.9.3 *Perbandingan Hasil Model*

Hasil yang telah dikeluarkan atau diprediksi oleh model akan dibandingkan dengan sesama model yang ada dengan perbedaan *training* parameter yang berbeda juga, kemudian hasil juga akan dibandingkan dengan data historis dari perusahaan untuk melihat sebaik apa performa model yang sudah dibentuk, semakin akurat hasilnya maka model tersebut merupakan model yang baik dan dapat dilanjutkan untuk memprediksi

sedangkan jika hasilnya kurang akurat maka model tersebut perlu untuk dilakukan perubahan parameter.

3.10 Pengolahan Data ANN

Pada pengolahan ANN ini masih menggunakan *software* yang sama yaitu Matlab menggunakan *Skript* Editor dan menggunakan variabel input hasil prediksi dari LSTM sebelumnya. Fungsi ANN di sini adalah untuk menentukan pembobotan *weighing feeder* komposisi material.

3.10.1 Pembentukan Model

Sama seperti LSTM, pada bagian ini model ANN dibentuk dan mulai dimasukkan variabel yang dibutuhkan, perbedaannya adalah pada variabel ANN menggunakan data hasil prediksi menggunakan model LSTM, data variabelnya sendiri mencakup nilai LSF, AM, dan IM hasil perhitungan menggunakan data prediksi kandungan pada LSTM. Kemudian data *outputnya* adalah pembobotan *Weighing Feeder* yang terdiri dari 4 variabel utama yaitu nilai pembobotan *limestone*, *clay*, *iron sand*, dan *silica sand*. Urutan dalam pembentukan sendiri sebagai berikut.

1. Pembagian data *Training* dan *Testing*

Untuk data training dan testing menggunakan tanggal yang sama seperti dipakai pada LSTM, data yang digunakan merupakan data hasil output dari LSTM dengan pembobotan menggunakan data asli dari perusahaan.

2. PreProcessing Data

Hal yang sama juga dilakukan pada pembentukan model ANN ini yaitu melakukan normalisasi data dengan menggunakan z score sehingga nantinya data akan bernilai 0 dan 1 namun nilainya nanti akan dikembalikan ke semula ketika hasil prediksi sudah muncul.

3. Membentuk arsitektur Jaringan

Arsitektur jaringan di sini berfungsi sama seperti apa yang ada pada LSTM yaitu menentukan akan seperti apa prediksi yang dilakukand dan seberapa efisien hasil yang ingin ditentukan, untuk ANN sendiri memiliki fungsi aktivasi seperti yang sudah dijelaskan di bab sebelumnya, peneliti menggunakan fungsi aktivasi seperti ‘tansig’ dan ‘purelin’. Jumlah layer atau lapisan juga menentukan peforma model dalam melakukan prediksi.

4. Training Parameter

Hal yang sama juga terdapat pada training parameter di ANN, Training parameter pada model Artificial Neural Network (ANN) berfungsi untuk mengatur berbagai aspek dari proses pelatihan, yang dapat mempengaruhi performa akhir dari model. Semakin bagus parameter yang ditentukan ditunjukkan dengan akurasi model pada hasil akhir yang juga semakin akurat dan mendekati nilai konvergen pada validasi dengan MSE.

3.10.2 Pengujian Model

Pada bagian pengujian ini, langkah-langkah utama yang dilakukan melibatkan validasi dan evaluasi performa model yang telah dilatih. Model dilatih menggunakan data pelatihan dan kemudian diuji dengan data pengujian yang belum pernah dimasukkan ke model sebelumnya. Selama pengujian, prediksi yang dihasilkan oleh model dibandingkan dengan nilai sebenarnya dari data pengujian untuk menilai kinerjanya. Metode evaluasi yang sering digunakan meliputi penghitungan akurasi, *Mean Squared Error* (MSE), *Mean Absolute Error* (MAPE), dan koefisien determinasi (R^2).

3.10.3 Perbandingan Hasil

Hasil dari prediksi juga kemudian akan dibandingkan dengan data historis perusahaan untuk melihat sejauh apa hasil prediksinya dan apakah masih bisa dikatakan akurat.

3.11 Analisis dan Pembahasan

Analisis menggunakan RNN-LSTM dilakukan awal untuk memprediksi data yang nantinya akan digunakan pada *input* ANN. Analisis pada ANN mengidentifikasi pola dalam data QC dan memprediksi kualitas semen dengan tingkat akurasi tertentu. Jika nilai MSE yang rendah menunjukkan bahwa model memiliki kesalahan prediksi yang minim, sedangkan nilai MAPE yang terukur mengindikasikan bahwa rata-rata kesalahan prediksi relatif terhadap nilai aktual berada dalam rentang yang dapat diterima. Kedua metrik ini bersama-sama memberikan bukti kuat tentang kemampuan ANN dalam memahami dan mereplikasi dinamika produksi semen.

3.12 Kesimpulan dan Saran

Pada tahap ini merupakan akhir dari penelitian, hasil dari pembahasan dan juga pengujian ANN akan memberikan solusi dari permasalahan dan juga jawaban dari rumusan

masalah. Hasil yang telah dibuat akan disampaikan kepada pihak perusahaan dan juga menjadi pembelajaran lanjut untuk penelitian yang akan datang.

BAB IV

PENGUMPULAN DAN PENGOLAHAN DATA

4.1 Pengumpulan Data

Pada bagian ini diuraikan hasil dari pengumpulan data sesuai dengan tahapan yang telah diuraikan pada Bab III Metode Penelitian. Pada bagian ini juga diuraikan gambaran umum proses bisnis / sistem amatan. Pengumpulan data pada penelitian ini dimulai dengan melakukan pengamatan pada proses sampling, proses sampling sendiri berlangsung setiap hari dan pengambilan samplingnya dilakukan setiap 30 menit sekali dengan catatan tidak ada masalah pada mesinnya.

4.1.1 Deskripsi Perusahaan

PT Indocement Tunggal Prakarsa selaku produsen semen nasional yang sudah berdiri selama 48 tahun harus tetap mempertahankan kualitas dan variasi produk sesuai dengan tuntutan pasar agar tetap bisa memenuhi kebutuhan semen domestik dan mampu juga untuk memberikan penetrasi pasar internasional. Komitmen Indocement menjadi pemain utama pada industri semen tanah air harus dibarengi dengan kemampuan produksi yang mumpuni.

Pada 2001, HeIdlebergCement Group menjadi pemegang saham mayoritas melalui entitas anaknya, Kimmeridge Enterprise Pte. Ltd., setelah mengakuisisi 61,7% saham Perseroan. Pada 2008, HeIdlebergCement AG mengalihkan seluruh sahamnya di Indocement kepada Birchwood Omnia Ltd. (Inggris), yang 100% dimiliki oleh HeildelbergCement Group.

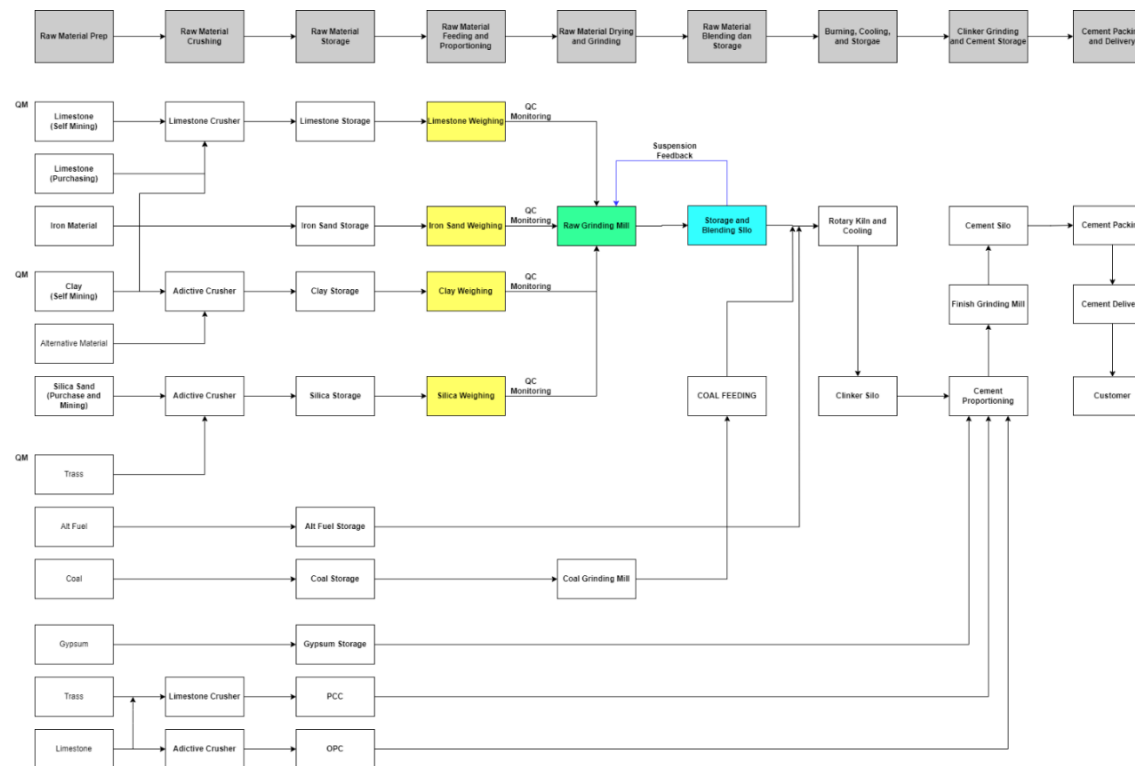
Pada 2009 Birchwood omnia Ltd., menjual 14,1% sahamnya kepada publik, sehingga kepemilikan saham Indocement oleh HeIdlebergCement AG melalui Birchwood Omnia di Perseroan menjadi 51%. Pada Oktober 2016, Perseroan mulai mengoperasikan pabrik ketiga belas yang disebut Lokasi 14 di Kompleks Pabrik Citeureup, yang merupakan pabrik semen terintegrasi terbesar milik Indocement dengan kapasitas desain terpasang mencapai 4,4 juta ton semen per tahun dan juga merupakan pabrik semen terbesar yang pernah dibangun oleh Indocement dan HeildelbergCement Group. Saat ini Perseroan telah mempunyai 13 pabrik dengan total kapasitas produksi

tahunan sebesar 25,5 juta ton semen. Sepuluh pabrik berlokasi di Kompleks Pabrik Citeureup, Bogor, Jawa Barat; dua pabrik di Kompleks Pabrik Cirebon, Cirebon, Jawa Barat; dan satu pabrik di Kompleks Pabrik Tarjun, Kotabaru, Kalimantan Selatan.

PT Indocement Tunggul Prakarsa dalam menjalankan kegiatan proses produksi membutuhkan beberapa bahan baku yang harus disiapkan. Perencanaan sumber daya dan pengelolaan bahan baku dilakukan Resources Planning and Inventory Management of Material and Coal dengan proses perencanaan dan pengendalian persediaan bahan baku yaitu pembelian pasir silika, pasir besi, copper slag, fly ash, gypsum, alat bantu gerinda, pozzolan, dan batu bara. Untuk bahan baku berupa batu kapur (*limestone*) dan tanah liat (*clay*) didapatkan dari penambangan oleh pihak perusahaan tersebut pada lokasi yang berada di belakang pabrik. Produksi semen sendiri dimulai dari penambangan untuk mengumpulkan bahan utama yaitu Limestone atau batu kapur, kemudian dilanjutkan ke bagian QC untuk menentukan komposisi bahan untuk membuat tipe semen sesuai dengan kategori yang diinginkan, melalui QC ini lah pemantauan proses produksi terus dilakukan selama 24 jam nonstop, proses nya sendiri mencakup bagaimana sebuah semen akan diproduksi dan penentuan kualitas yang diinginkan dari masing-masing Perusahaan berdasarkan kategori produk yang mereka punya, secara umum, rasio pencampuran bahan baku menentukan kualitas hasil akhir semen dan klinker yaitu hasil pengkristalan pada mesin Rotary Kiln, dan dalam hal ini Indocement ingin memastikan bahan yang dipakai untuk produksi berkualitas dan memenuhi standar baik nasional maupun internasional.

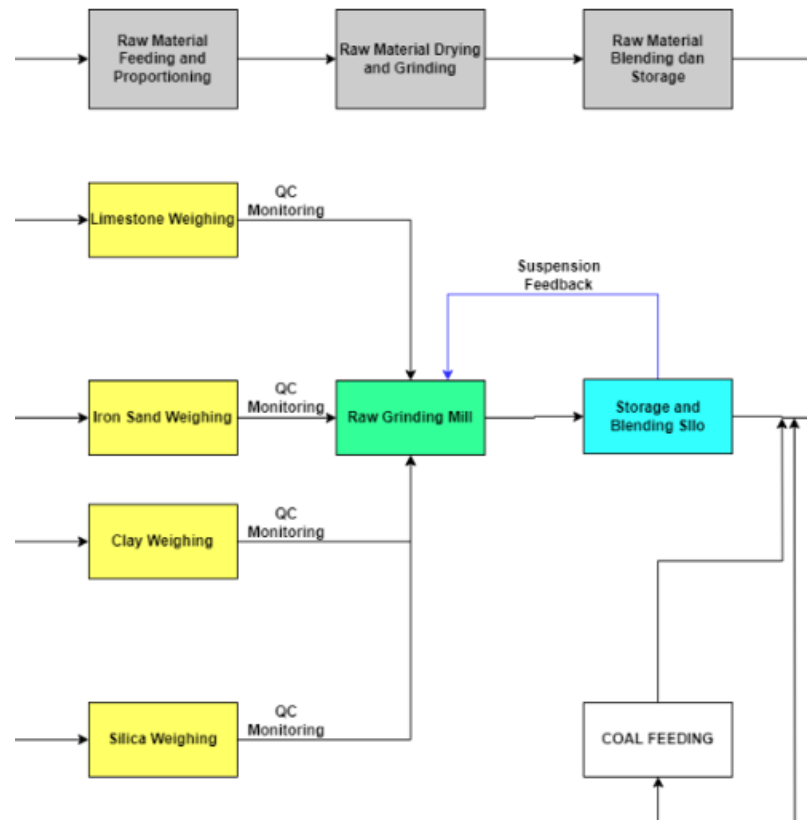
4.1.2 Mekanisme Proses Produksi dan Proses QC

Pada perjalanan produksinya, perusahaan memiliki alur yang digunakan sebagai standar pada proses. Berikut adalah alur operasional produksi semen yang terdapat di Indocement.



Gambar 4.1 Proses produksi semen secara menyeluruh

Sedangkan penelitian ini berfokus pada proses seksi *Quality Control* di laboratorium proses, pada gambar 4.1 fokus peneliti adalah pada bagian yang berwarna kuning, hijau, dan biru. Bagian tersebut merupakan bagian dimana rotasi informasi terkait proses QC terjadi. Berikut adalah rinciannya.



Gambar 4.2 Fokus Peneliti

Deskripsi secara umum dari gambar proses QC adalah sebagai berikut:

a. Seksi Persiapan Bahan Mentah (Raw Material Prep)

Pada seksi ini semua bahan dipersiapkan baik dari pembelian (Outsourcing) maupun proses penambangan di belakang pabrik, untuk bahan yang dipersiapkan antara lain mencakup bahan utama dan bahan tambahan.

Bahan utama digunakan untuk pembuatan klinker yaitu bahan utama dalam pembuatan semen dan kemudian bahan adiktif yang mencakup bahan bakar dan bahan tambahan untuk campuran semen sesuai dengan jenis nya masing-masing.

b. Penghancuran Bahan Mentah (Raw Material Crushing)

Pada seksi ini bahan mentah yang masih berbentuk bongkahan dihancurkan, utamanya adalah batu kapur, dan juga tras yang biasanya didatangkan dalam bentuk bongkahan yang cukup besar. Material dihancurkan menggunakan *Crusher* dengan ukuran akhir sebesar 1-2cm, material bahan bakar seperti batu bara juga dihancurkan untuk kemudian nantinya akan disimpan dalam penyimpanan sementara sebelum masuk ke proses selanjutnya.

c. Penyimpanan Bahan Mentah (Raw Material Storage)

Pada proses ini semua bahan mentah akan disimpan menggunakan *reclaimer* yang dimana membawa material dari *crusher* menggunakan *belt conveyor*, pada bagian bahan utama seperti *limestone* atau batu kapur akan membentuk *pile* atau gundukan material yang belum homogen sehingga biasanya terjadi fluktuasi campuran kadar kimia yang berbeda dan berpola. Campuran bahan dengan kadar CaO tinggi biasanya diletakan pada lapisan terluar gundukan dengan campuran yang lebih homogen berada di tengah gundukan. Untuk bahan lain nya seperti pasir silika, tanah liat, dan juga pasir besi dilakukan penyimpanan yang sama dengan *limestone* namun campuran nya sudah homogen.

d. Penimbangan Bahan Mentah dan Proses Sampel (Raw Material Feeding and Proportioning)

Pada bagian ini peneliti ingin melakukan improvisasi sistem, proses nya adalah dengan melakukan *monitoring* pada empat bahan utama dalam proses pembuatan semen seperti batu kapur (*limestone*), tanah liat, pasir besi, dan pasir silika. Semua bahan tersebut ditimbang menggunakan *weighing feeder* untuk kemudian dimasukkan ke dalam mesin *raw mill* menggunakan bantuan komputer semi otomatis, pada komputer operator memantau penggunaan bahan dengan persentase

tertentu untuk kemudian mengatur timbangan yang sesuai jika komputer tidak mampu memenuhi modulus yang ditentukan. Modulus dinilai pada saat proses raw mill selesai yang artinya sudah berada dalam silo atau penyimpanan, sehingga proses QC harus berhati-hati karena hasil komposisi akan didapatkan setiap 30 menit atau setelah setengah dari raw mill proses masuk ke dalam silo penyimpanan, jika modulus nya terjadi ketidakseimbangan maka operator harus melakukan koreksi secara manual kepada alat timbang untuk memberikan proporsi modulus yang lebih baik.

e. Pengerinan Bahan Mentah dan Proses Penghalusan (Raw Material Drying and Grinding)

Pada bagian inilah semua bahan yang sebelumnya sudah ditimbang dihaluskan, pada plant Cirebon sendiri menggunakan 2 jenis penghalus yaitu *ball steel* dan *vertical roller mill*. Untuk masing-masing mesin memiliki total tonase yang berbeda dimana pada vertical roller memiliki kapasitas yang lebih besar. Setelah nya material akan menjadi halus dan menyerupai tepung yang akan dilanjutkan pada homo silo karena sifat material sudah dicampur dan homogen dengan kadar masing-masing yang sudah ditentukan sebelumnya dan diawasi oleh bagian QC.

f. Pencampuran dan Penyimpanan Bahan Mentah (Raw Material Blending and Storage)

Pada bagian ini bahan yang sudah dicampur dan dihaluskan akan disimpan pada silo, pada bagian ini juga lah proses QC mendapatkan sampel dari material yang sudah ada, biasanya material akan membentuk pola tertentu karena campuran dari tambang yang sudah disusun pada *pile* sehingga saat masuk ke dalam proses penghalusan akan membentuk tren tertentu terutama jika bagian dari pile sudah habis dan akan berpindah *pile* baru pada *storage*.

g. Pembakaran, Pendinginan, dan Penyimpanan Klinker (Burning, Cooling, and Storage)

Pada bagian ini campuran yang berada pada homo silo akan masuk ke suspension preheater untuk dipanaskan, kemudian akan masuk ke pembakaran di Rotary Kiln, setelah pembakaran hasil dari produk Kiln adalah klinker yang merupakan komponen utama dalam membuat semen, klinker didinginkan menggunakan udara bertekanan yang kemudian dibawa ke klinker silo sebelum nantinya akan dihaluskan pada proses semen mill.

h. Penghalusan Klinker dan Penyimpanan (Clinker Grinding and Storage)

Pada bagian ini klinker yang sudah disimpan akan dibawa ke proses penghalusan dan pencampuran dengan bahan lain seperti gypsum dan tras dengan proporsi tertentu,, untuk semen dengan kualitas tertinggi yang biasanya digunakan pada proyek besar dan konstruksi adalah OPC dengan komposisi klinker terbanyak sedangkan untuk produk yang lebih rendah dan untuk penggunaan konsumen umum seperti PCC atau semen dengan merek tiga roda dan rajawali menggunakan bahan klinker yang lebih sedikit dengan rasio bahan campuran yang lebih banyak.

i. Pengemasan Semen dan Pengiriman (Cement Packing and Delivery)

Pada bagian ini menandakan akhir dari proses pembuatan semen dengan pengemasan pada *paper bag*, untuk bobot nya sendiri adalah 40 dan 50 kg dan disesuaikan dengan permintaan pasar, setelah nya semen yang sudah dikemas akan dibawa dengan menggunakan *truck* ke terminal semen pada kota tertentu.

4.1.3 Variabel Input dan Output RNN (LSTM)

Variabel yang nantinya akan digunakan pada proses pembentukan jaringan RNN berjenis LSTM ini berdasarkan studi literatur dan kondisi peneliti diputuskan menggunakan 9 Input yang meliputi; waktu, kadar SiO_2 , Al_2O_3 , Fe_2O_3 , CaO , MgO , SO_3 , Na_2O , dan K_2O . Nantinya data *training* atau pembelajaran akan mencakup semuanya dengan *output* hasil menggunakan masing-masing kadar kimia yang nantinya akan dilakukan uji RMSE untuk mengetahui seberapa akurat prediksi jaringan dengan menggunakan LSTM ini. Berikut adalah data yang nantinya akan digunakan pada aplikasi Matlab untuk memprediksi.

Tabel 4.1 Variabel Input dan Output RNN-LSTM

Tanggal	Waktu	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	SO ₃	Na ₂ O	K ₂ O
05/05/2024	23:44:00	13,2	3,79	2,05	44,06	0,84	0,49	0,08	0,16
06/05/2024	00:14:00	13,64	3,82	1,89	43,89	0,93	0,47	0,01	0,18
06/05/2024	00:44:00	13,34	3,49	1,85	43,99	0,88	0,45	0,16	0,16
06/05/2024	01:14:00	13,4	3,8	1,9	44,12	0,92	0,43	0,04	0,15
06/05/2024	01:44:00	12,99	3,96	2,02	44,06	0,91	0,43	0,1	0,17
06/05/2024	02:39:00	12,51	3,55	1,95	44,4	1,01	0,42	0,1	0,13
06/05/2024	02:44:00	12,42	3,35	1,96	44,49	0,9	0,4	0,06	0,13
06/05/2024	03:14:00	12,34	3,37	2,01	44,4	0,95	0,4	0,07	0,13
06/05/2024	03:44:00	12,63	3,72	2,04	44,32	0,95	0,38	0,07	0,14
...
10/05/2024	22:09:00	12,5	3,83	2,14	44,11	1,2	0,58	0,09	0,25
10/05/2024	22:39:00	12,27	3,79	2,12	44,11	1,16	0,57	0,06	0,25
10/05/2024	23:09:00	12,37	3,75	2,06	44,18	1,15	0,55	0,09	0,24
10/05/2024	23:38:00	12,51	3,65	2,04	44,24	1,1	0,55	0,08	0,23
10/05/2024	23:46:00	12,94	3,47	2,02	44,04	1,07	0,53	0,07	0,22

4.2 Pengolahan Data RNN-LSTM

Pada bagian ini diuraikan hasil dari pengolahan data sesuai dengan tahapan yang telah diuraikan pada Bab III Metode Penelitian. Gambar atau tabel yang dipaparkan diberikan penjelasan. Pada bagian ini belum dilakukan analisa terhadap hasil dari pengolahan data.

4.2.1 Input Variabel LSTM

Untuk *input* variabel yang akan dilatih dan diprediksi menggunakan data pada tanggal 5, 6, dan 7 Mei 2024. Data untuk prediksi sendiri menggunakan data dari tanggal 7 sampai tanggal 10 Mei 2024. Berikut adalah data yang dipilih sesuai dengan input yang nantinya akan digunakan pada metode ANN.

Tabel 4.2 *Input Variabel LSTM*

Waktu	SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O
23:44:00	13,2	3,79	2,05	44,06	0,84	0,49	0,08	0,16
00:14:00	13,64	3,82	1,89	43,89	0,93	0,47	0,01	0,18
00:44:00	13,34	3,49	1,85	43,99	0,88	0,45	0,16	0,16
01:14:00	13,4	3,8	1,9	44,12	0,92	0,43	0,04	0,15
01:44:00	12,99	3,96	2,02	44,06	0,91	0,43	0,1	0,17
02:39:00	12,51	3,55	1,95	44,4	1,01	0,42	0,1	0,13
02:44:00	12,42	3,35	1,96	44,49	0,9	0,4	0,06	0,13
03:14:00	12,34	3,37	2,01	44,4	0,95	0,4	0,07	0,13
03:44:00	12,63	3,72	2,04	44,32	0,95	0,38	0,07	0,14
...
22:09:00	12,5	3,83	2,14	44,11	1,2	0,58	0,09	0,25
22:39:00	12,27	3,79	2,12	44,11	1,16	0,57	0,06	0,25
23:09:00	12,37	3,75	2,06	44,18	1,15	0,55	0,09	0,24
23:38:00	12,51	3,65	2,04	44,24	1,1	0,55	0,08	0,23
23:46:00	12,94	3,47	2,02	44,04	1,07	0,53	0,07	0,22

4.2.2 Pembentukan Model LSTM

Pada bagian ini peneliti mulai membentuk model lstm dengan menggunakan jenis *Sequence To Sequence* karena dirasa paling cocok digunakan untuk kasus seperti ini (Weerakody et al., 2021).

Berikut adalah langkah-langkah yang diperlukan:

1. Memasukan file Excel kedalam Matlab untuk dibaca oleh komputer.

```
% Membaca data dari file Excel
% data Training
Xtrain= xlsread('Data Input.xlsx',4, 'A70:I119');
```

```

Ytrain= xlsread('Data Input.xlsx',4, 'B120:B169');

% Membaca data dari file Excel
% data Testing
Xtest = xlsread('Data Input.xlsx',4, 'A30:I69'); % Data input untuk
testing
Ytest = xlsread('Data Input.xlsx',4, 'B70:B109'); % Data target
untuk testing

% mengubah format cell

XtrainCell = mat2cell(Xtrain, size(Xtrain, 1), ones(1, size(Xtrain,
2)));
YtrainCell = mat2cell(Ytrain, size(Ytrain, 1), ones(1, size(Ytrain,
2)));
XtestCell = mat2cell(Xtest, size(Xtest, 1), ones(1, size(Xtest,
2)));
YtestCell = mat2cell(Ytest, size(Ytest, 1), ones(1, size(Ytest,
2)));

```

Gambar 4.3 Syntax Input Data ke Matlab

Syntax yang digunakan untuk memasukkan data adalah *Xtrain* dengan variabel perintah *xlsread* dengan maksud untuk membaca *file* berjenis *.xls* yang merupakan bawaan *file* dari excel, kemudian variabel ('Data Input.xlsx',4, 'A30:I69') menandakan bahwa nama file nya adalah data *input*, dengan halaman file ke 4 dan rentang pengambilan datanya dimulai dari kolom baris A ke 30 sampai baris I kolom ke 69. Data tersebut merupakan variabel *input* untuk data yang akan dilatih dengan jumlah 9 yang mencakup waktu sampai kadar kimia. Sedangkan untuk data yang akan dijadikan data *output* sekaligus validasi adalah salah satu kadar kimia yaitu SiO₂ dengan rentang baris B kolom ke 70 sampai baris B kolom ke 169. Nantinya semua kadar kimia akan satu persatu diuji untuk kemudian dihitung modulus nya sehingga menjadi *input* pada prediksi *weighing feeder* menggunakan ANN.

2. Pendefinisian Arsitektur LSTM

```

% definisikan LSTM arc

inputSize = 9;

numResponses = 1;

numHiddenUnits = 250;

layers = [ sequenceInputLayer(inputSize)

          lstmLayer(numHiddenUnits)

```

```

fullyConnectedLayer(numResponses)
regressionLayer];
opts = trainingOptions('adam',...
'InitialLearnRate', 0.001, ...
'MaxEpochs', 1000, ...
'MiniBatchSize', 64, ...
'Verbose', true, ...
'ValidationData', {Xtest, Ytest}, ...
'Plots', 'training-progress');

```

Gambar 4.4 Syntax Pendefinisian Arsitektur LSTM

Pada bagian ini arsitektur LSTM dibentuk, *syntax* tersebut berfungsi sebagai parameter dari model yang dibuat dan nantinya akan bertanggung jawab untuk memberikan performa selama proses pelatihan berlangsung. Bagian pertama ditandai dengan pembentukan arsitektur dengan *syntax*

```
inputSize = 9;
```

```
numResponses = 1;
```

```
numHiddenUnits = 250;
```

Syntax diatas diartikan dengan input yang berjumlah sembilan variabel dengan jumlah keluaran satu yaitu masing-masing dari hasil komposisi bahan yang nantinya akan diprediksi, proses prediksi sendiri nantinya akan dilakukan secara berulang untuk mendapatkan semua hasil dari prediksinya. Syntax selanjutnya adalah jumlah hidden unit atau jumlah layer yang ada, pada penelitian ini peneliti menggunakan jumlah *hidden* layer sebanyak 250 untuk dijadikan acuan awal saat melakukan proses iterasi atau *epoch*. Setelah nya adalah pengaturan atau opsi pelatihan dimana di sini peneliti melakukan parameter untuk menghasilkan prediksi yang berbeda dan bisa saja akurat atau tidak akurat sama sekali, untuk awalan *syntax* yang diberikan adalah sebagai berikut.

```
opts = trainingOptions('adam',...
```

```
  'InitialLearnRate', 0.001, ...
```

```
  'MaxEpochs', 1000, ...
```

```
  'MiniBatchSize', 64, ...
```

```
  'Verbose', true, ...
```

```
  'ValidationData', {Xtest, Ytest}, ...
```

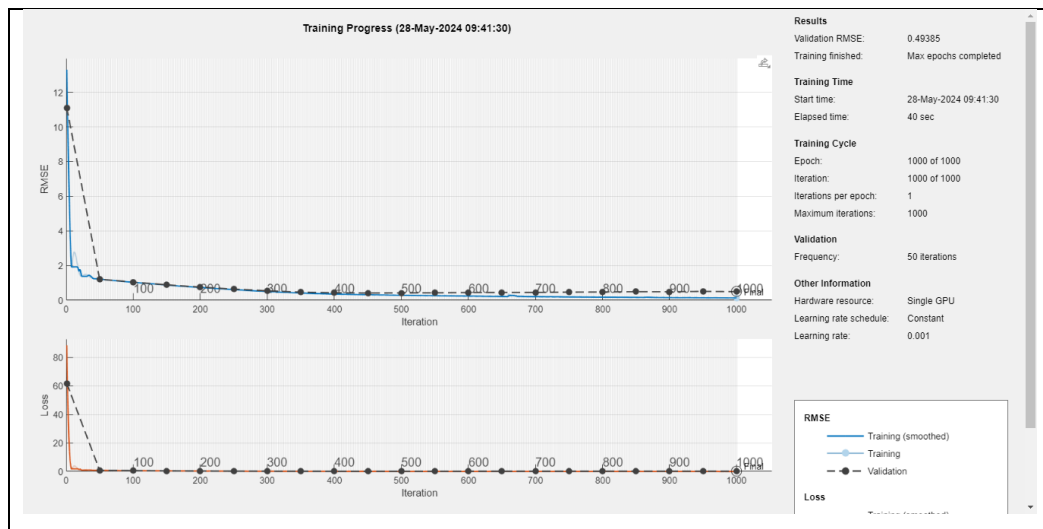
```
  'Plots', 'training-progress');
```

Pada *syntax* diatas dijelaskan opsi aplikasi yang dipakai adalah adam dengan *initial learn rate* berjumlah 0,001, fungsi dari *initial learn rate* adalah untuk menentukan laju pembelajaran awal yang digunakan oleh algoritma optimasi saat melatih model. Memberikan terlalu besar bisa saja berdampak lamanya proses pelatihan dan menyebabkan model mengalami *overfitting*. *Overfitting* adalah kondisi dimana model mempelajari terlalu banyak data latih sehingga sangat baik dalam memprediksi namun saat dihadapi oleh perubahan data dalam uji, hasilnya bisa saja sangat berbeda dengan data aslinya karena model tidak menerima data yang mengalami distorsi walau sedikit, namun pada kenyataannya setiap data tidak ada yang benar-benar rapi dan baik sehingga sebisa mungkin mengurangi jumlah *initial learn rate* untuk mencegah model mengalami *overfitting*. Setelahnya ada Max Epoch atau jumlah iterasi pelatihan, semakin banyak jumlah pelatihan juga model akan mengalami *overfitting*, saat peneliti mencoba menggunakan jumlah epoch kurang dari 1000 model mengalami *underfitting* atau kebalikan dari *overfitting*, sehingga peneliti memutuskan menggunakan nilai minimum yang sudah menghasilkan pola data prediksi yang lebih baik dengan nilai minimum 1000 *epoch*. Setelah itu ada *mini batch size* yang berfungsi menentukan jumlah sampel data yang digunakan dalam satu epoch pembaruan bobot selama proses pelatihan. *Mini-batch size* adalah *hyperparameter* yang dapat disesuaikan untuk meningkatkan kinerja pelatihan. Ukuran *batch* yang berbeda dapat mempengaruhi laju konvergensi dan kualitas model yang dihasilkan, biasanya ukuran yang digunakan adalah kelipatan bilangan biner dimulai dari 8, 16, 32 dan seterusnya, pada penelitian kali ini digunakan nilai 64. Setelahnya ada variabel *Verbose* yang bernilai *True* atau benar, fungsi dari opsi ini adalah untuk memonitor jalannya pelatihan sehingga bisa dilakukan *early stop* jika dirasa model mengalami *overfitting* atau *underfitting* sehingga tidak membutuhkan banyak waktu untuk menunggu sampai hasil akhirnya keluar dan bisa mengoreksi opsi pelatihan pada arsitektur jaringan. Terakhir ada tes uji validasi untuk memastikan model yang dibuat valid dengan membandingkan dengan data historis asli atau aktual pada hari hasil prediksi ditampilkan, nilai dari validasi sendiri ditunjukkan dengan *Xtest* dan *Ytest*, kemudian ditampilkan dalam bentuk plot pada baris kode selanjutnya.

3. Melatih Jaringan LSTM Single Layer

```
% Melatih Jaringan
net = trainNetwork(Xtrain, Ytrain, layers, opts);
```

Gambar 4.5 Syntax Melatih Jaringan



Gambar 4.6 Hasil Pengujian Berlangsung

Di bagian ini semua hasil pada proses pembentukan sebelumnya ditampilkan, *syntax* melatih jaringan ini ditambahkan dengan memasukkan perintah `net = trainNetwork(Xtrain, Ytrain, layers, opts);`

Syntax diatas berfungsi untuk mengeksekusi hasil pada pembentukan arsitektur dengan menyatukan semua variabel pelatihan seperti Xtrain, Ytrain, dengan layer yang berisi perintah seperti berikut.

```
layers = [ sequenceInputLayer(inputSize)
```

```
lstmLayer(numHiddenUnits)
```

```
fullyConnectedLayer(numResponses)
```

```
regressionLayer];
```

dan juga training ops yang berisi pengaturan parameter yang sudah dibahas pada tahap sebelumnya, pada gambar 4.6 juga ditampilkan hasil dari *verbose* yang bernilai *True* dimana proses pelatihan ditampilkan selama program berjalan.

4. Melakukan prediksi dan menampilkan hasil prediksi

```

% Prediksi
Ypred = predict(net, Xtest);

% Validasi RMSE
figure,
rmse = sqrt(mean((Ypred - Ytest).^2));
disp(['RMSE: ', num2str(rmse)]);
histogram(Ytest - Ypred)
title("RMSE = " + rmse)
ylabel("Frequency")
xlabel("Error")

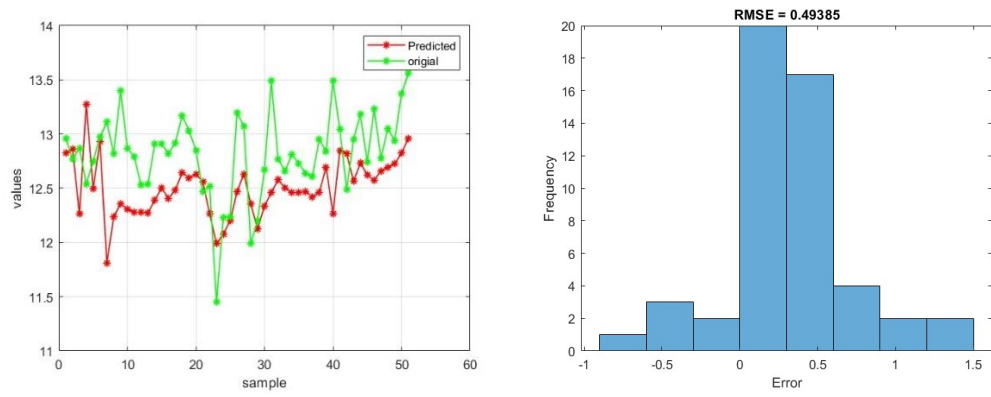
% Validasi MAE
MAE = mean(abs(Ytest - Ypred));

% Menampilkan hasil
figure,
plot(Ypred,'r-','LineWidth',1),hold on
plot(Ytest,'g-','LineWidth',1) , hold all;
xlabel('Jumlah Sampel')
ylabel('Kadar Kimia')
grid on
legend('Prediksi','Aktual');
disp(['MAE: ', num2str(MAE)]);
title("MAE = " + MAE)

```


Gambar 4.7 Syntax Prediksi dan Hasil Prediksi LSTM

Pada tahap ini, adalah proses memasukkan kode terakhir sebelum modul LSTM nya benar-benar bisa digunakan, bagian awalan diberikan perintah untuk melakukan prediksi dengan *syntax* `Ypred = predict(net, Xtest)`. Nilai dari prediksi adalah net dengan `Ypred` adalah variabel prediksi nya dan `Xtest` adalah nilai uji yang dijadikan perintah kepada model untuk melakukan proyeksi prediksi. Setelah perintah untuk validasi RMSE seperti yang sudah dijelaskan pada bab 3, sebuah model dikatakan valid jika telah melakukan hasil uji RMSE dan MAE. Berikut adalah hasil yang ditampilkan pada percobaan pertama dimana menandakan bahwa model tidak mengalami kendala saat proses program berjalan.




Gambar 4.8 Hasil Proses Uji Coba Model


5. Hasil Pengujian Ke Semua Sampel




Sampel Al₂O₃



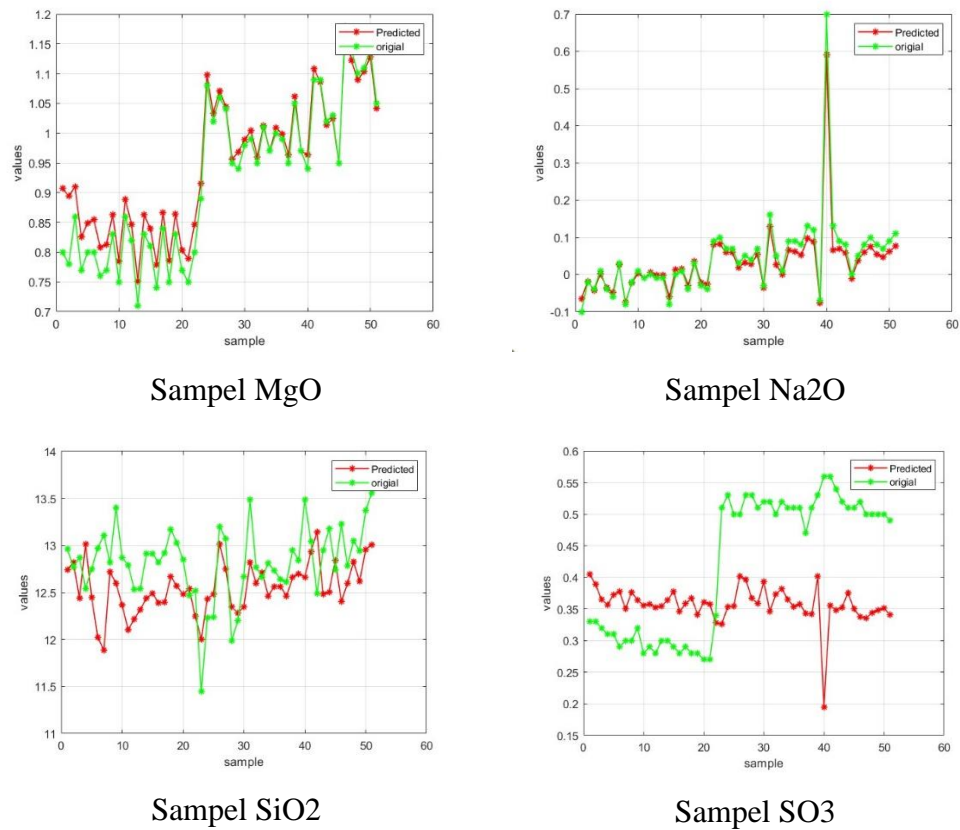
Sampel CaO



Sampel Fe₂O₃



Sampel K₂O



Gambar 4.9 Hasil Uji Coba Semua *Output*

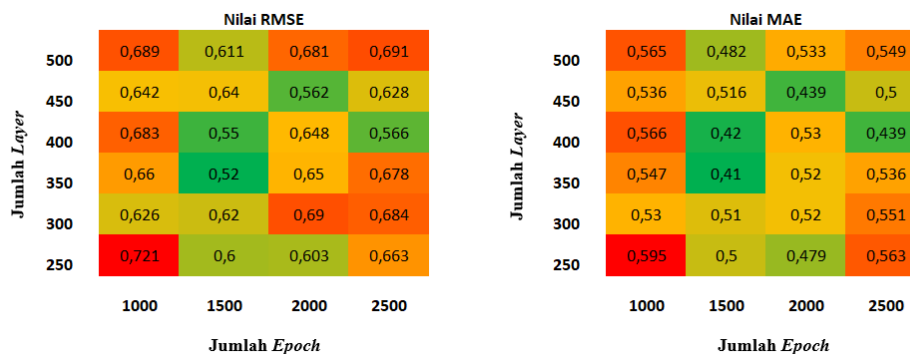
Pada bagian ini model yang sudah berhasil berjalan akan diimplementasikan kepada seluruh variabel *output* yang nantinya akan dijadikan acuan untuk prediksi, untuk mengubah variabel *output* dilakukan pada *syntax* 4.3 dengan mengganti huruf awalan di excel yang mewakili kolom pada excel tersebut.

4.2.3 Pengujian Hasil Jaringan Yang Telah Dilatih

Pada bagian ini semua Sampel yang ada akan dilakukan uji *trial and error* untuk mencari nilai RMSE dan MAE terkecil dengan melakukan perubahan pada jumlah *hidden layers* dan jumlah *Epoch* yang hasilnya akan dicatat untuk mendapatkan nilai terkecil, semua hasil akan divisualisasikan dalam bentuk kolom warna dengan rentang hijau untuk nilai terkecil dan merah untuk nilai terbesar. Setiap Sampel akan diuji dengan jumlah *hidden layers* dimulai dari 250 sampai 500 dengan *Epoch* yang dimulai dari 1000 sampai 2500 (Al-Selwi et al., 2024). Berikut adalah hasil masing-masing Sampel yang dilakukan *Trial and Error*.

1. Sampel SiO₂

Berikut adalah hasil RMSE dan MAE dari *trial and error*




Gambar 4.10 Nilai RMSE dan MAE SiO₂

Dari hasil tersebut dipilih 2 nilai yaitu antara jumlah *layer* 350 sampai 400 dengan *epoch* di angka 1500. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.

2. Sampel Al₂O₃

Berikut adalah hasil RMSE dan MAE dari *trial and error*

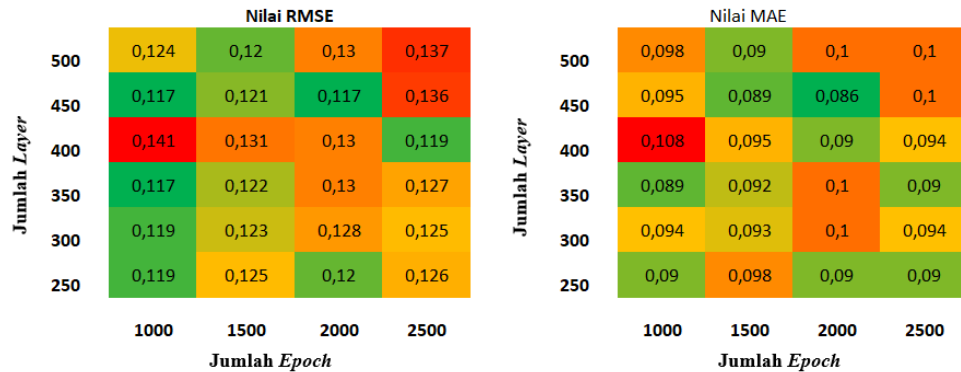


Gambar 4.11 Nilai RMSE dan MAE Al₂O₃

Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 350 dengan *epoch* di angka 1000. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.

3. Sampel Fe₂O₃

Berikut adalah hasil RMSE dan MAE dari *trial and error*

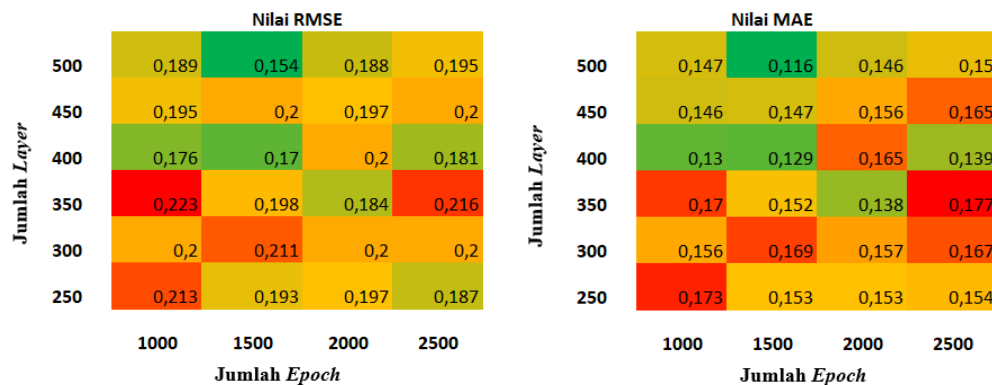


Gambar 4.12 Nilai RMSE dan MAE Fe₂O₃

Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 450 dengan *epoch* di angka 2000. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.

4. Sampel CaO


Berikut adalah hasil RMSE dan MAE dari *trial and error*



Gambar 4.13 Nilai RMSE dan MAE CaO

Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 500 dengan *epoch* di angka 1500. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.


5. Sampel MgO



Gambar 4.14 Nilai RMSE dan MAE MgO

Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 450 dengan *epoch* di angka 1000. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.


6. Sampel SO3



Gambar 4.15 Nilai RMSE dan MAE SO3

Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 500 dengan *epoch* di angka 1000. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.


7. Sampel Na2O



Gambar 4.16 Nilai RMSE dan MAE Na2O

Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 450 dengan *epoch* di angka 1000. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.

8. Sampel K2O



Gambar 4.17 Nilai RMSE dan MAE K2O


Dari hasil tersebut dipilih satu nilai yaitu jumlah *layer* 300 dengan *epoch* di angka 2500. Nilai RMSE dan MAE yang kecil memungkinkan dilakukan nya percobaan lanjutan untuk mencari data prediksi yang konvergen.

4.2.4 Hasil Prediksi Komposisi

Pada bagian ini, hasil dari setiap Sampel akan dilakukan uji lebih lanjut dengan mengubah parameter agar semakin mendekati nilai konvergen, setiap komposisi akan menggunakan nilai RMSE dan MAE terkecil dari hasil percobaan jumlah *layer* dan juga jumlah *epoch* yang sebelumnya sudah dilakukan. Pada bagian ini juga nantinya nilai akhir dari prediksi akan digunakan untuk nilai inisiasi *input* pada metode berikutnya yaitu ANN. Berikut

adalah hasil dari setiap Sampel yang dilakukan optimasi variabel dan opsi pelatihan agar semakin mendekati nilai yang baik.

1. Sampel SiO₂



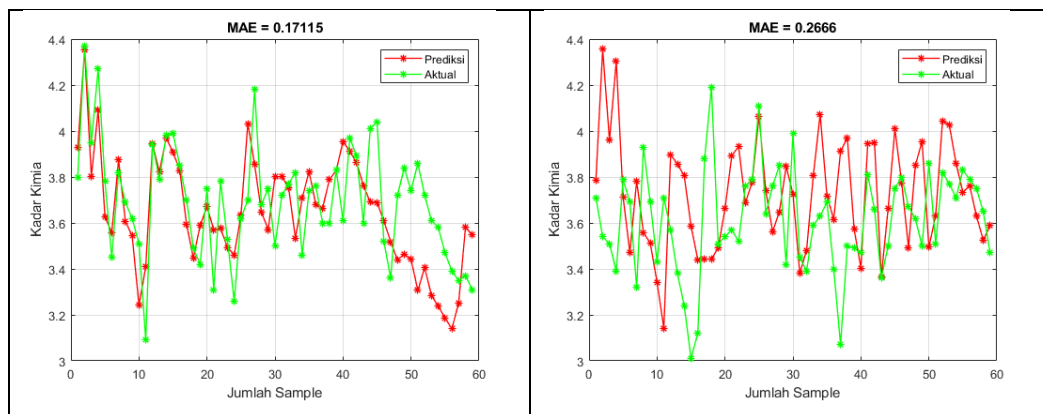
Gambar 4.18 Hasil Prediksi SiO₂

Hasil perbandingan prediksi dengan nilai aktual SiO₂ tertera pada tabel berikut.

Tabel 4.3 Hasil Perbandingan Sampel SiO₂

Tanggal	Waktu	SiO ₂ Prediksi	SiO ₂ Aktual
07/05/2024	18:00:00	13,07	12,72
07/05/2024	18:06:00	13,07	13,01
07/05/2024	18:36:00	12,89	12,34
07/05/2024	19:06:00	12,34	13,67
07/05/2024	19:36:00	12,06	12,65
...
10/05/2024	22:09:00	12,25	12,5
10/05/2024	22:39:00	12,23	12,27
10/05/2024	23:09:00	12,30	12,37
10/05/2024	23:38:00	12,21	12,51
10/05/2024	23:46:00	12,40	12,94

2. Sampel Al₂O₃




Gambar 4.19 Hasil Prediksi Al₂O₃

Hasil perbandingan prediksi dengan nilai aktual Al₂O₃ terdapat pada tabel berikut.

Tabel 4.4 Hasil Perbandingan Sampel Al₂O₃

Tanggal	Waktu	Al ₂ O ₃ Prediksi	Al ₂ O ₃ Aktual
07/05/2024	18:00:00	3,93	3,8
07/05/2024	18:06:00	4,35	4,37
07/05/2024	18:36:00	3,80	3,95
07/05/2024	19:06:00	4,09	4,27
07/05/2024	19:36:00	3,63	3,78
...
10/05/2024	22:09:00	3,86	3,83
10/05/2024	22:39:00	3,73	3,79
10/05/2024	23:09:00	3,76	3,75
10/05/2024	23:38:00	3,63	3,65
10/05/2024	23:46:00	3,53	3,47

3. Sampel Fe₂O₃



Gambar 4.20 Hasil Prediksi Fe₂O₃


Hasil perbandingan prediksi dengan nilai aktual Fe₂O₃ terdapat pada tabel berikut.

Tabel 4.5 Hasil Perbandingan Sampel Fe₂O₃

Tanggal	Waktu	Fe ₂ O ₃ Prediksi	Fe ₂ O ₃ Aktual
07/05/2024	18:00:00	1,92	2,04
07/05/2024	18:06:00	2,08	2,11
07/05/2024	18:36:00	2,28	2,19
07/05/2024	19:06:00	2,30	2,34
07/05/2024	19:36:00	2,23	2,21
...
10/05/2024	22:09:00	2,09	2,14
10/05/2024	22:39:00	2,10	2,12
10/05/2024	23:09:00	2,10	2,06

Tanggal	Waktu	Fe2O3 Prediksi	Fe2O3 Aktual
10/05/2024	23:38:00	2,06	2,04
10/05/2024	23:46:00	2,11	2,02

4. Sampel CaO




Gambar 4.21 Hasil Prediksi CaO

Hasil perbandingan prediksi dengan nilai aktual CaO terdapat pada tabel berikut.

Tabel 4.6 Hasil Perbandingan Sampel CaO

Tanggal	Waktu	CaO Prediksi	CaO Aktual
07/05/2024	18:00:00	44,16	3,8
07/05/2024	18:06:00	44,14	4,37
07/05/2024	18:36:00	44,00	3,95
07/05/2024	19:06:00	43,60	4,27
07/05/2024	19:36:00	44,08	3,78
...
10/05/2024	22:09:00	44,06	44,25
10/05/2024	22:39:00	44,08	44,21
10/05/2024	23:09:00	44,04	44,11
10/05/2024	23:38:00	44,04	44,05
10/05/2024	23:46:00	44,03	44,18

5. Sampel MgO




Gambar 4.22 Hasil Prediksi MgO

Hasil perbandingan prediksi dengan nilai aktual MgO terdapat pada tabel berikut.

Tabel 4.7 Hasil Perbandingan Sampel MgO

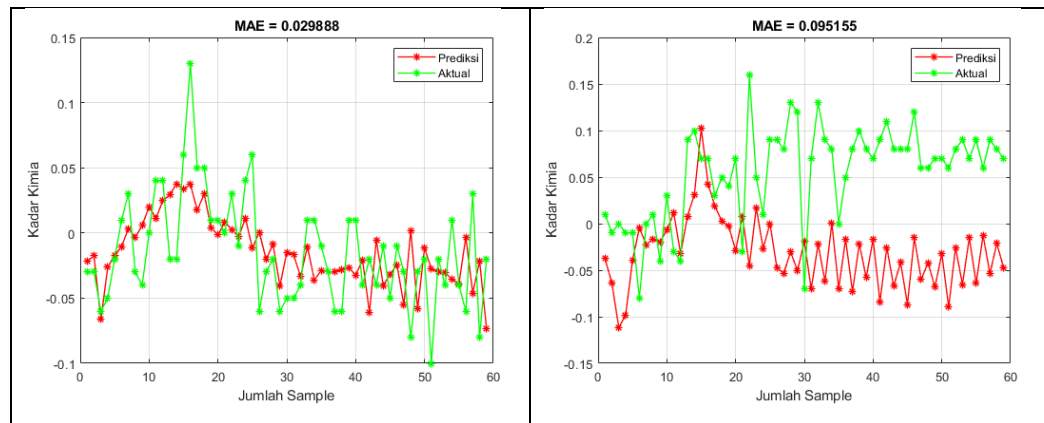
Tanggal	Waktu	MgO Prediksi	MgO Aktual
07/05/2024	18:00:00	1,01	1
07/05/2024	18:06:00	1,05	1,05
07/05/2024	18:36:00	0,94	0,93
07/05/2024	19:06:00	0,93	0,92
07/05/2024	19:36:00	0,91	0,9
...
10/05/2024	22:09:00	0,79	1,2
10/05/2024	22:39:00	0,79	1,16
10/05/2024	23:09:00	0,78	1,15
10/05/2024	23:38:00	0,79	1,1
10/05/2024	23:46:00	0,78	1,07

6. Sampel SO₃Gambar 4.23 Hasil Prediksi SO₃

Hasil perbandingan prediksi dengan nilai aktual SO₃ terdapat pada tabel berikut.

Tanggal	Waktu	SO3 Prediksi	SO3 Aktual
07/05/2024	18:00:00	0,41	0,4
07/05/2024	18:06:00	0,40	0,41
07/05/2024	18:36:00	0,37	0,36
07/05/2024	19:06:00	0,38	0,39
07/05/2024	19:36:00	0,36	0,37
...
10/05/2024	22:09:00	0,38	0,58
10/05/2024	22:39:00	0,36	0,57
10/05/2024	23:09:00	0,34	0,55
10/05/2024	23:38:00	0,33	0,55
10/05/2024	23:46:00	0,32	0,53

7. Sampel Na₂O




Gambar 4.24 Hasil Prediksi Sampel Na₂O

Hasil perbandingan prediksi dengan nilai aktual Na₂O terdapat pada tabel berikut.

Tabel 4.8 Hasil Perbandingan Sampel Na₂O

Tanggal	Waktu	Na ₂ O Prediksi	Na ₂ O Aktual
07/05/2024	18:00:00	-0,02	-0,03
07/05/2024	18:06:00	-0,02	-0,03
07/05/2024	18:36:00	-0,07	-0,06
07/05/2024	19:06:00	-0,03	-0,05
07/05/2024	19:36:00	-0,02	-0,02
...
10/05/2024	22:09:00	-0,02	0,09
10/05/2024	22:39:00	-0,06	0,06
10/05/2024	23:09:00	-0,01	0,09
10/05/2024	23:38:00	-0,05	0,08
10/05/2024	23:46:00	-0,02	0,07

8. Sampel K2O



Gambar 4.25 Hasil Prediksi K2O

Hasil perbandingan prediksi dengan nilai aktual K2O terdapat pada tabel berikut.

Tabel 4.9 Hasil Perbandingan Sampel K2O

Tanggal	Waktu	K2O Prediksi	K2O Aktual
07/05/2024	18:00:00	0,19	0,2
07/05/2024	18:06:00	0,18	0,2
07/05/2024	18:36:00	0,21	0,21
07/05/2024	19:06:00	0,23	0,27
07/05/2024	19:36:00	0,17	0,18
...
10/05/2024	22:09:00	0,16	0,25
10/05/2024	22:39:00	0,16	0,25
10/05/2024	23:09:00	0,17	0,24
10/05/2024	23:38:00	0,16	0,23
10/05/2024	23:46:00	0,17	0,22

4.2.5 Perhitungan Modulus dan Data Input ANN

Dengan berakhirnya prediksi menggunakan LSTM maka langkah selanjutnya adalah perhitungan prediksi penggunaan data modulus hasil prediksi sebagai acuan untuk manual *input* pada *software* ketika terjadinya fluktuasi. Nilai modulus sendiri didapatkan dari perhitungan manual pada aplikasi *excel* menggunakan rumus yang sudah dibahas pada bab 3. Datanya sendiri berjumlah sebanyak 117 data dan sebanyak 70 persen digunakan sebagai data latih dan 30 persen untuk data uji pada model. Berikut adalah data modulus yang nantinya akan dipakai sebagai *input* dari model dan juga perbandingannya dengan hasil prediksi.

Tabel 4.10 Hasil Perbandingan Modulus Aktual dan Prediksi

No	LSF	SM	AM/IM	LSF'	SM'	AM/IM'
----	-----	----	-------	------	-----	--------

1	106,64	2,18	1,86	103,08	2,24	2,05
2	102,66	2,01	2,07	101,53	2,03	2,10
3	108,3	2,01	1,08	103,54	2,12	1,67
4	97,15	2,07	1,82	105,56	1,93	1,78
5	109,69	2,28	1,83	110,44	2,06	1,63
6	115,15	2,13	1,64	111,01	2,14	1,66
7	111,57	2,06	1,82	107,38	2,10	1,85
8	111,57	2,06	1,82	105,04	2,27	1,72
9	107,55	2,23	1,73	104,08	2,32	1,69
...
113	107,86	2,09	1,79	108,54	2,06	1,85
114	109,72	2,08	1,79	109,07	2,10	1,78
115	109,35	2,13	1,82	108,42	2,10	1,80
116	108,79	2,20	1,79	109,60	2,15	1,76
117	105,77	2,36	1,72	108,32	2,20	1,67
AVG	106,77	2,23	1,76	105,78	2,19	1,74

Sedangkan untuk variabel target nya sendiri sebanyak empat yaitu sebagai yang termuat pada tabel berikut.

Tabel 4.11 Pembobotan *Weighing Feeder*

Limestone	Clay	Silica Sand	Iron Sand
95,1	1,6	1,6	1,7
95,1	1,6	1,6	1,7
94,54	1,73	1,82	1,91
95,81	0	2,32	1,9
94,7	0	3,41	1,89
97	0	1	1,68
95,7	0	2,62	1,68
95,81	0	2,54	1,65
95,74	0	2,56	1,7
...
94,7	1	2,26	2,04
94,67	1	2,32	2,01
94,78	0,6	2,9	1,72
94,84	0,57	2,86	1,73
94,56	0,6	3,09	1,75


4.3 Pengolahan Data ANN

Pada bagian ini diuraikan hasil dari pengolahan data sesuai dengan tahapan yang telah diuraikan pada Bab III Metode Penelitian. Gambar atau tabel yang dipaparkan diberikan penjelasan. Pada bagian ini belum dilakukan analisa terhadap hasil dari pengolahan data.

4.3.1 Arsitektur Jaringan

Pada umumnya, lapisan pada ANN berjenis *Backpropagation* memiliki 3 lapisan seperti, lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Masing-masing pada lapisan tersebut terdapat neuron atau syaraf yang berfungsi memproses data yang masuk. Khusus bagian *input* dan *output* jumlah neuron disesuaikan dengan jumlah variabelnya, sedangkan pada lapisan tersembunyi tidak ada aturan khusus untuk berapa jumlah neuron yang ada dikarenakan banyak sekali skenario yang mungkin terjadi dan lebih disesuaikan dengan studi kasus atau penelitian yang sedang dijalankan pada model, sehingga cara terbaik untuk menentukan hasil model yang kita buat memiliki akurasi yang tinggi adalah dengan melakukan uji coba atau trial and error (Putra & Ulfa Walmi, 2020) sama seperti yang terdapat pada lapisan RNN-LSTM. Hal yang perlu diperhatikan untuk lapisan tersembunyi adalah bahwa penambahan jumlah lapisan dapat meningkatkan risiko overfitting dan memperpanjang waktu eksekusi. Oleh karena itu, selalu pilih jaringan dengan performa terbaik yang menggunakan jumlah neuron yang sedikit (Firmansyach et al., 2023).


Berikut adalah arsitektur yang nantinya digunakan pada pelatihan data pada penelitian kali ini yang dijabarkan pada gambar di bawah.



Gambar 4.26 Arsitektur ANN Pada Penelitian

Pada gambar 4.26 lapisan pertama merupakan lapisan *input* dengan variabel yang mencakup kadar *lime saturation factor* (LSF), *Alumina Modulus* (AM), dan yang terakhir adalah *Silica Modulus* (SM), dengan lapisan *output*nya adalah proporsi

pembobotan pada *weighing feeder* di masing-masing mesin. Untuk jumlah neuronnnya sendiri berjumlah j pada simbol z_j yang mengonotasikan jumlah tertentu dengan menggunakan cara uji coba pada masing-masing kemungkinan *hidden layer* terbaik pada neuron yang ada. Selain lapisan dan neuron pada ANN *Backprop* ada yang dinamakan pembobotan awal dan pembobotan akhir yang merupakan penghubung antara lapisan *input* dengan *hidden layer* pertama dan juga penghubung antara lapisan *hidden layer* dengan *output layer*.



Gambar 4.27 Arsitektur Pada Matlab

Sedangkan gambar diatas adalah konfigurasi yang nantinya akan digunakan pada aplikasi Matlab yang merupakan susunan dari lapisan-lapisan ANN, terdiri dari kotak pertama yang berlaku sebagai *input*, masuk ke bagian pembobotan atau disimbolkan dengan W dan dihitung dengan nilai biasnya, kemudian lanjut ke lapisan kedua yaitu lapisan *output*.

4.3.2 Input, Output, dan Pembagian Data ANN

Input pada ANN sendiri menggunakan 3 data sebagai parameter utama yaitu LSF, SM, dan AM. Ketiga data tersebut didapat dari hasil perhitungan manual menggunakan *excel* yang rumusnya sudah dibahas pada bab 3, dan merupakan hasil peramalan menggunakan RNN-LSTM. Sedangkan data yang digunakan untuk *outputnya* adalah data untuk pembobotan pada *weighing feeder* yang digunakan oleh operator. Data yang digunakan pada *input* ANN sendiri merupakan prediksi tanggal 7 Mei 2024 sampai tanggal 10 Mei 2024 dengan total data sebanyak 117 dengan pembagian 70% akan digunakan sebagai data latih dan 30% sebagai data uji untuk melakukan prediksi pembobotan pada *weighing feeder* bagi operator. Berikut adalah data yang nantinya akan digunakan.

Tabel 4.12 Variabel Input dan Output ANN

No	X1	X2	X3	Y1	Y2	Y3	Y4
1	103,08	2,24	2,05	95,1	1,6	1,6	1,7
2	101,53	2,03	2,10	95,1	1,6	1,6	1,7
3	103,54	2,12	1,67	94,54	1,73	1,82	1,91
4	105,56	1,93	1,78	95,81	0	2,32	1,9
5	110,44	2,06	1,63	94,7	0	3,41	1,89
6	111,01	2,14	1,66	97	0	1	1,68
7	107,38	2,10	1,85	95,7	0	2,62	1,68
8	105,04	2,27	1,72	95,81	0	2,54	1,65
9	104,08	2,32	1,69	95,74	0	2,56	1,7
...
113	108,54	2,06	1,85	94,7	1	2,26	2,04
114	109,07	2,10	1,78	94,67	1	2,32	2,01
115	108,42	2,10	1,80	94,78	0,6	2,9	1,72
116	109,60	2,15	1,76	94,84	0,57	2,86	1,73
117	108,32	2,20	1,67	94,56	0,6	3,09	1,75
AVG	105,78	2,19	1,74	95,1			

4.3.3 Pembentukan Model ANN

Pada bagian ini peneliti membangun model ANN *Backprop* menggunakan aplikasi Matlab. Untuk data nya sendiri akan disimpan semuanya pada Excel untuk kemudian dimasukkan ke dalam aplikasi Matlab, Adapun urutan pembangunan model akan dijelaskan sebagai berikut.

1. Input data dari excel ke matlab

```
Data = xlsread ('Data Input.xlsx',5,'A2:D81');
X = Data(:,1:3);
Y = Data(:,4);
```



Gambar 4.28 Syntax Untuk Input Data

Pada syntax diatas digunakan untuk menginput data dari excel ke matlab, pada syntax kali ini agak berbeda dengan yang digunakan pada LSTM namun fungsinya tetap sama. Membaca data excel pada matlab menggunakan perintah `xlsread` dengan format ('nama file', 'halaman sheet', 'range data'). Kemudian X dan Y merupakan penamaan variabel yang digunakan pada pelatihan. Perlu dicatat X dan Y di sini tidak merepresentasikan kartesius namun matriks, sehingga penamaan variabel dengan random, huruf tersebut bisa saja digunakan yang lain seperti A dan B atau D dan C sesuai keinginan. Dengan demikian maka matriks X dan Y sudah terbentuk dimana matriks X mencakup Kolom A sampai B dengan matriks Y mencakup kolom D. Untuk setelah nya output dari matriks Y akan berubah menjadi variabel lain nya seperti output yang sudah dijelaskan pada sub bab sebelum nya.

2. Pre-Processing data

```
% Mengkalkulasi data X untuk rata-rata dan standar deviasi
X_mean = mean(X);
X_std = std(X);

% Menormalkan data X
X_norm = (X - X_mean)./ X_std;

% Mengkalkulasi data Y untuk rata-rata dan standar deviasi
Y_mean = mean(Y);
Y_std = std(Y);

% Menormalkan data Y
Y_norm = (Y - Y_mean)./ Y_std;
```

Gambar 4.29 Syntax Pre Processing Data

Pada bagian ini, data yang sudah dimasukkan ke dalam matlab akan diubah ke dalam skala tertentu. Fungsi dari normalisasi data adalah untuk membuat model belajar dengan cepat. Lebih lanjut normalisasi data juga berfungsi untuk mengurangi *noise* atau lonjakan pada data jika tidak dibuat dalam bentuk kala 0 dan 1. Untuk jenis normalisasi nya sendiri menggunakan Z-Score yang berfungsi menormalkan data sehingga memiliki *mean* 0 dan standar deviasi 1.

3. Membuat model ANN

```
%membuat arsitektur jaringan
```

```

hiddenLayerSize = 15;

net = feedforwardnet([hiddenLayerSize, 1], 'trainbfg');

% Mengatur fungsi aktivasi untuk lapisan tersembunyi dan output
net.layers{1}.transferFcn = 'tansig'; % Lapisan tersembunyi
net.layers{2}.transferFcn = 'purelin'; % Lapisan output

```

Gambar 4.30 Syntax Arsitektur Jaringan ANN

Pada bagian ini peneliti sudah mulai membuat model dari ANN nya itu sendiri, *syntax hiddenlayer size* menunjukkan jumlah lapisan tersembunyi yang berjumlah 14, kemudian setelah nya *net feed forward* merupakan perintah untuk membuat lapisan jaringan feedforward, setelahnya variabel jumlah lapisan dan juga 'trainbfg' yang merupakan akronim perintah untuk *backpropagation* pada modul ANN ini. Pada bagian selanjutnya yaitu ungsi aktivasi lapisan, dimana pada lapisan tersembunyi pertama menggunakan aktivasi 'tansig' dan aktivasi untuk *output* layer atau lapisan keluaran menggunakan fungsi 'purelin'. Jenis dan fungsi aktivasi sudah dibahas pada bab 3.

4. Konfigurasi jaringan

```

% Mengonfigurasi jaringan
net = configure(net, X_norm', Y_norm');

% Mengatur parameter pelatihan
net.trainParam.epochs = 150; % Jumlah epoch
net.trainParam.lr = 0.01; % Learning rate
net.trainParam.goal = 0.01; % Error goal
net.trainParam.show = 25; % Interval untuk menampilkan
hasil pelatihan
net.trainParam.max_fail = 50; % Jumlah maksimal epoch tanpa
perbaikan pada validasi
net.trainParam.min_grad = 1e-6;% Gradient minimum

```

Gambar 4.31 Syntax Konfigurasi Jaringan

Pada bagian ini, sebelum model digunakan untuk pembelajaran data, dilakukan pembentukan parameter untuk memastikan kinerja model baik dan dapat mencapai konvergen. Pada bagian parameter digunakan sebagai berikut:

Tabel 4.13 Rincian Syntax dan Fungsi

Syntax	Fungsi
--------	--------

<code>net.trainParam.epochs = 150;</code>	Berfungsi sebagai jumlah iterasi
<code>net.trainParam.lr = 0.01;</code>	Berfungsi sebagai laju pembelajaran, Deskripsi: Learning rate menentukan seberapa besar perubahan bobot jaringan pada setiap langkah pembaruan. Nilai 0.01 menunjukkan bahwa bobot akan disesuaikan dengan langkah-langkah kecil untuk mencegah overshooting.
<code>net.trainParam.goal = 0.01;</code>	Berfungsi sebagai target kesalahan selama pelatihan berlangsung. Pembelajaran akan berhenti jika nilai mean squared error (MSE) jaringan mencapai atau turun di bawah nilai ini. Dalam hal ini, pelatihan akan berhenti jika MSE kurang dari atau sama dengan 0,01.
<code>net.trainParam.show = 25;</code>	Berfungsi untuk menunjukkan hasil pelatihan atau pelatihan berlangsung yang dapat dimonitoring, akan mulai muncul ketika menyentuh epoch ke 25.
<code>net.trainParam.max_fail = 50;</code>	Berfungsi menurunkan jumlah epoch selama pelatihan jika dirasa MSE tidak pernah melakukan perbaikan selama 50 epoch berturut-turut, pelatihan akan dihentikan. Syntax ini membantu mencegah overfitting dengan menghentikan pelatihan ketika jaringan tidak lagi memperbaiki performa pada data validasi.
<code>net.trainParam.min_grad = 1e-6;</code>	Berfungsi untuk menghentikan pelatihan jika sudah mencapai konvergensi. Pelatihan akan berhenti jika ukuran gradien jaringan (perubahan bobot) turun di bawah 1e-6. Ini digunakan untuk menghentikan pelatihan ketika perubahan bobot menjadi sangat kecil, yang menunjukkan bahwa jaringan telah mencapai konvergensi.

5. Memberikan bobot jaringan

```
% Menetapkan bobot dan bias secara manual
net.IW{1,1} = rand(hiddenLayerSize, size(X_norm, 2)) * 0.1; %
Bobot input-hidden
net.b{1} = rand(hiddenLayerSize, 1) * 0.1; %
Bias untuk lapisan tersembunyi
net.LW{2,1} = rand(1, hiddenLayerSize) * 0.1; %
Bobot hidden-output
net.b{2} = rand(1, 1) * 0.1;
```

Gambar 4.32 Syntax Bobot Jaringan ANN

Pada bagian ini, model diberikan bobot inisiasi yang berfungsi untuk menguatkan hubungan antar jaringan, dalam hal ini jaringan yang dimaksud adalah jaringan lapisan tersembunyi dan lapisan output. Algoritma *backpropagation* menggunakan gradien dari fungsi kesalahan atau *error function* dengan menghitung setiap pembobotan untuk memperbaiki nilai pembelajaran. Hal ini dilakukan menggunakan metode *gradient descent*, di mana bobot-bobot diperbarui dalam arah yang berlawanan dengan gradien untuk mengurangi eror.

6. Melatih Jaringan dan Menampilkan Hasil

```
% Melatih jaringan
net = train(net, X_norm', Y_norm');

% Menguji jaringan dengan data yang dinormalisasi
Y_pred_norm = net(X_norm');

% Denormalisasi hasil prediksi (jika diperlukan)
Y_denorm = Y_pred_norm * Y_std + Y_mean;


% menampilkan hasil training
figure;
hold on;
plot(Y, 'o', 'MarkerFaceColor', 'w', 'MarkerEdgeColor', 'b');
plot(Y_denorm, '*', 'MarkerFaceColor', 'r', 'MarkerEdgeColor', 'r');

% Set labels and title
xlabel('Data ke-');
ylabel('Target/Output');
title('Hasil pengujian dengan data pelatihan: Target (o), Output (*)');
```

Gambar 4.33 Syntax Melatih Jaringan dan Hasil


Di bagian ini, model dijalankan untuk melakukan pembelajaran, hasil dari pembelajaran akan dilakukan dinormalisasi untuk mengembalikan ke nilai

asli dari data, kemudian hasil dari pelatihan juga ditampilkan menggunakan fungsi *figure*.



Gambar 4.34 Hasil Weighing Feeder

Gambar 4.34 merupakan hasil dari prediksi awal menggunakan data yang sama digunakan untuk pelatihan berjumlah 80 data.



Gambar 4.35 Hasil Validasi Performa Jaringan

Sedangkan gambar 4.35 merupakan performa model selama melakukan pelatihan dengan memvalidasi menggunakan MSE atau *mean square error*. Didapati hasil dari pelatihan dengan nilai MSE terkecil jatuh saat model mencapai *epoch* ke 22, namun karena pengaturan dari model sendiri harus mencapai jumlah 275 maka model mengalami pembiasan data.

7. Menilai bobot akhir

```
% Menambahkan bobot akhir
final_input_weights = net.IW{1,1};
final_hidden_biases = net.b{1};
final_hidden_weights = net.LW{2,1};
final_output_biases = net.b{2};

% Menampilkan bobot dan bias akhir
disp('Bobot input-hidden akhir:');
disp(final_input_weights);

disp('Bias hidden layer akhir:');
disp(final_hidden_biases);

disp('Bobot hidden-output akhir:');
disp(final_hidden_weights);

disp('Bias output layer akhir:');
disp(final_output_biases);
```

Gambar 4.36 Syntax Bobot Akhir

Selain inisiasi bobot di awal, algoritma *backpropagation* juga menghasilkan bobot-bobot akhir yang diperoleh dari proses pelatihan jaringan. Algoritma *backpropagation* memanfaatkan nilai *error* dari *output* untuk mengubah bobot-bobotnya dengan cara mundur atau *backward*. Bobot akhir dapat dilihat menggunakan *syntax* 4.36.

4.3.4 Uji Coba Jaringan ANN

Setelah modelnya sudah berjalan dan bisa melakukan prediksi, langkah selanjutnya adalah menambahkan data uji atau tes data sebanyak 30 data yang merupakan pembagian data pada awal. Data ini digunakan sebagai prediksi untuk pembobotan pada *weighing feeder*. *Syntax* untuk memasukkan data sendiri terdapat pada gambar berikut.

1. Menambahkan file baru ke Matlab

```
Data = xlsread('Data Input.xlsx', 5, 'A2:D81');
Data2 = xlsread('Data Input.xlsx', 5, 'A82:D118');

X = Data(:, 1:3);
Y = Data(:, 4);
Xtest = Data2(:, 1:3);
Ytest = Data2(:, 4);

% Mengkalkulasi data X dan Xtest untuk rata-rata dan standar
deviasi
X_mean = mean(X);
X_std = std(X);

Xtest_mean = mean(Xtest);
Xtest_std = std(Xtest);

% Menormalkan data X dan Xtest menggunakan rata-rata dan standar
deviasi dari X
X_norm = (X - X_mean) ./ X_std;
Xtest_norm = (Xtest - Xtest_mean) ./ Xtest_std;

% Mengkalkulasi data Y untuk rata-rata dan standar deviasi
Y_mean = mean(Y);
Y_std = std(Y);

Ytest_mean = mean(Ytest);
Ytest_std = std(Ytest);

% Menormalkan data Y
Y_norm = (Y - Y_mean) ./ Y_std;
Ytest_norm = (Ytest - Ytest_mean) ./ Ytest_std;
```

Gambar 4.37 Syntax Data Uji

Pada bagian ini, data baru dengan variabel Data2 adalah bagian yang terpisah dan sudah ditentukan saat awal, yaitu sebanyak 117 data akan dibagi menjadi 70% data digunakan untuk pelatihan dan 30% datanya digunakan untuk data uji. Dengan demikian Data2 berjumlah 34 data. Sama seperti data latih data uji dilakukan proses normalisasi dengan menggunakan Z score.

2. Memasukkan Parameter dan Data Uji

```
%membuat arsitektur jaringan
hiddenLayerSize = 12;

net = feedforwardnet([hiddenLayerSize, 1], 'trainbfg');

% Mengatur fungsi aktivasi untuk lapisan tersembunyi dan output
net.layers{1}.transferFcn = 'logsig'; % Lapisan tersembunyi
net.layers{2}.transferFcn = 'purelin'; % Lapisan output

% Mengonfigurasi jaringan
net = configure(net, X_norm, Y_norm);

% Menetapkan bobot dan bias secara manual
net.IW{1,1} = rand(hiddenLayerSize, size(X_norm, 1)) * 0.1; %
Bobot input-hidden
net.b{1} = rand(hiddenLayerSize, 1) * 0.1; %
Bias untuk lapisan tersembunyi
net.LW{2,1} = rand(1, hiddenLayerSize) * 0.1; %
Bobot hidden-output
net.b{2} = rand(1, 1) * 0.1;

% Mengatur parameter pelatihan
net.trainParam.epochs = 275; % Jumlah epoch
net.trainParam.lr = 0.1; % Learning rate
net.trainParam.goal = 0.1; % Error goal
net.trainParam.show = 25; % Interval untuk menampilkan
hasil pelatihan
net.trainParam.max_fail = 500; % Jumlah maksimal epoch tanpa
perbaikan pada validasi
net.trainParam.min_grad = 0;% Gradient minimum

% Melatih jaringan
[net, tr] = train(net, X_norm, Y_norm);

% Menguji jaringan dengan data yang dinormalisasi
Y_pred_norm = net(Xtest_norm);
```

Gambar 4.38 Syntax Data Uji dan Parameter

Pada bagian ini, data uji yang sudah dinormalisasi dimasukkan ke dalam model seperti gambar 4.38, syntax awalan adalah mengatur parameter yang sesuai dengan data uji, seperti fungsi aktivasi lapisan yang diganti menggunakan 'logsig' untuk lapisan *hidden* dan 'purelin' untuk lapisan output. Pada *syntax* konfigurasi jaringan, digunakan data latih seperti yang

sudah dijelaskan sebelumnya dan pada syntax menguji jaringan barulah menggunakan data yang sebelumnya sudah dimasukkan, pada gambar syntax yang berfungsi menambahkan data uji berwarna merah. Pada bagian ini juga semua data seperti *output* dimasukkan dengan mengganti setiap variabel pada *input* data nya hingga mendapatkan semua data yang dibutuhkan.

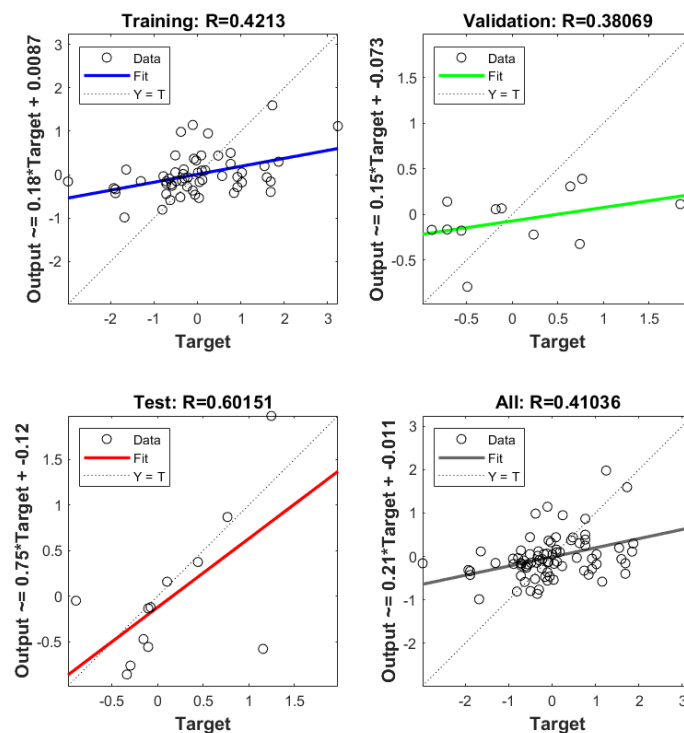
4.3.5 Evaluasi Jaringan ANN

Pada bagian ini jaringan atau model yang sudah jadi dan dilakukan iterasi untuk melakukan pembelajaran pada data akan dinilai akurasi menggunakan regresi dalam bentuk gambar, evaluasi jaringan dilakukan dengan menganalisis korelasi antara dua variabel dan membuat plot data untuk memvisualisasikan hubungan tersebut. *Syntax* untuk menganalisis korelasi linier pada hasil pengujian jaringan adalah sebagai berikut.

```
%membuat hasil regresi secara visual
scatter(x, y, 'b'); % scatter plot of original data (blue dots)
hold on;
plot(x, y_pred, 'r'); % plot of fitted line (red line)
xlabel('x');
ylabel('y');
title('Regression Plot');
hold off;
```

Gambar 4.39 Syntax Evaluasi Jaringan ANN


Syntax 4.39 akan memberikan hasil regresi dari model yang sudah dilakukan pembelajaran. Nantinya tampilan model akan menjadi seperti ini.



Gambar 4.40 Hasil Regresi

Pada gambar 4.40, grafik pelatihan ditunjukkan dengan warna biru. Garis ini menunjukkan seberapa baik *output* jaringan (prediksi) mendekati dengan target sebenarnya selama fase pelatihan. Koefisien determinasi R nya yaitu sebesar 0,4213 menunjukkan hubungan yang cukup kuat antara *output* dan target. Selanjutnya adalah garis validasi yang ditunjukkan dengan warna hijau. Garis ini menunjukkan seberapa bagus model terhadap data validasi, nilai R yang mencapai 0,38 menunjukkan model sudah cukup bagus dalam melakukan prediksi terhadap data validasi nya, namun tidak sebaik performa pada data pelatihan. Selanjutnya adalah garis merah yang melambangkan garis uji atau *test*. Garis ini menunjukkan performa jaringan pada data uji, yang sepenuhnya terpisah dari data pelatihan dan validasi, dengan kata lain hal ini lah yang kita cari pada saat melakukan uji data pada ANN, pada gambar model menunjukkan hasil R dengan nilai 0,61 yang menunjukkan bahwa model dapat memprediksi data uji dengan akurat sesuai dengan validasi data uji nya. Terakhir merupakan garis performa jaringan pada seluruh data (pelatihan, validasi, dan uji). Koefisien determinasi R sebesar 0.41036 menunjukkan hubungan yang moderat antara *output* dan target untuk seluruh *dataset*. Hal ini tentu tidak bisa seluruh nya mengalami grafik yang bagus atau mendekati nilai 1,

karena nilai yang tinggi pada model latih memungkinkan terjadinya *overfitting* pada saat data uji digunakan model untuk melakukan prediksi. Contohnya pada gambar berikut.

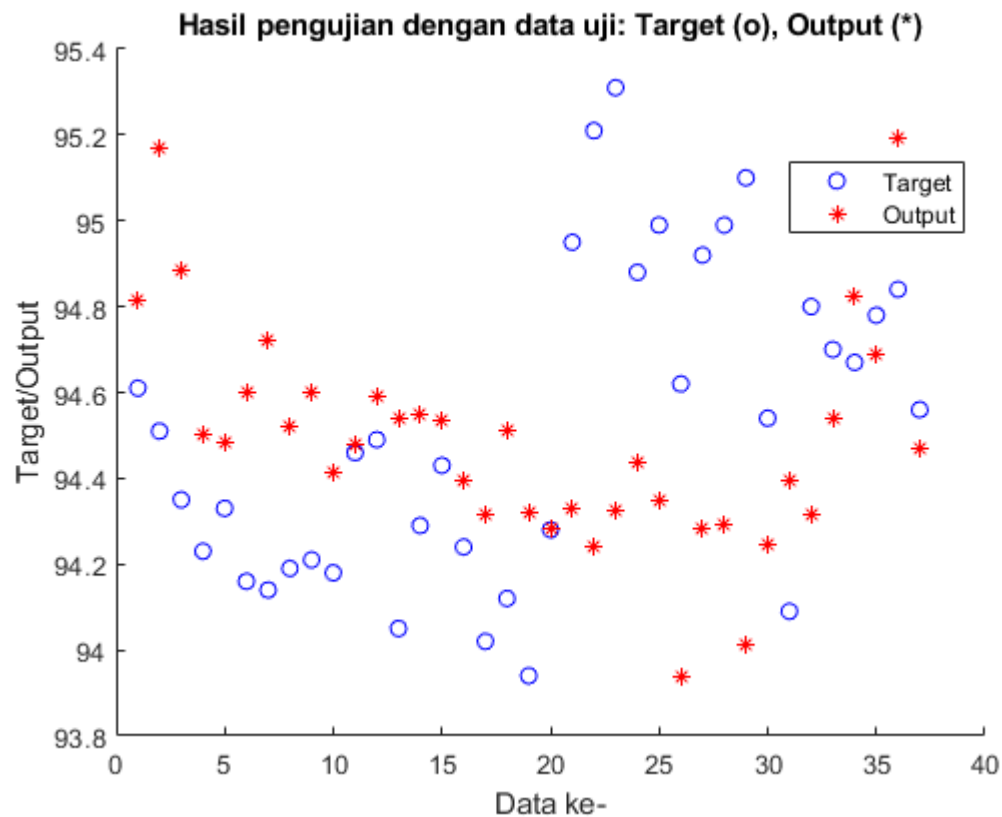


Gambar 4.41 Hasil Regresi Kurang Memuaskan

Pada gambar 4.41, nilai koefisien R pada data latih menunjukkan nilai yang cukup baik yaitu 0,686 akan tetapi performa model dalam melakukan prediksi sangat buruk menggunakan data uji dan mendapatkan nilai koefisien R mencapai -0,006. Oleh karena itu perlu dilakukan pengujian yang sangat hati-hati dalam menentukan parameter pelatihan pada ANN *backpropagation*.

4.3.6 Hasil Pembobotan ANN

Pada bagian ini hasil dari setiap implementasi *output* ANN dijabarkan, nilai dari akurasi prediksi pembobotan akan mengacu pada tabel 2.2. berikut adalah hasil pembobotannya.

1. Nilai Persentase Bobot *Limestone*Gambar 4.42 Hasil Pembobotan *Limestone*

Pada gambar 4.42 menampilkan hasil pembobotan *weighing feeder* dengan jenis material *Limestone*. Hasil dari pembobotan menunjukkan hal yang cukup akurat dimana ada beberapa titik nilai prediksi bobot dan nilai aktual yang mencapai konvergensi, namun di beberapa titik mengalami distorsi. Data prediksi berjumlah 38 data dengan nilai persentase tertinggi terdapat pada data ke 36 dengan nilai prediksi 95,19 dan nilai terendah terdapat pada data ke 26 dengan nilai 93,94. Berikut adalah rincian perbandingan dari data aktual dan data prediksinya.


Tabel 4.14 Hasil Perbandingan ANN *Limestone*

Data ke-	Bobot <i>Limestone</i> Aktual	Bobot <i>Limestone</i> ANN	Error Abs	Persentase Error
1	94,61	94,81	0,204	0,22%
2	94,51	95,17	0,661	0,70%
3	94,35	94,89	0,537	0,57%
4	94,23	94,50	0,274	0,29%

5	94,33	94,48	0,152	0,16%
6	94,16	94,60	0,442	0,47%
7	94,14	94,72	0,580	0,62%
8	94,19	94,52	0,329	0,35%
9	94,21	94,60	0,390	0,41%
10	94,18	94,41	0,233	0,25%
11	94,46	94,48	0,021	0,02%
12	94,49	94,59	0,102	0,11%
13	94,05	94,54	0,491	0,52%
14	94,29	94,55	0,258	0,27%
15	94,43	94,54	0,105	0,11%
16	94,24	94,39	0,153	0,16%
17	94,02	94,31	0,294	0,31%
18	94,12	94,51	0,393	0,42%
19	93,94	94,32	0,379	0,40%
20	94,28	94,28	0,005	0,00%
21	94,95	94,33	0,622	0,66%
22	95,21	94,24	0,971	1,02%
23	95,31	94,32	0,986	1,03%
24	94,88	94,44	0,445	0,47%
25	94,99	94,35	0,640	0,67%
26	94,62	93,94	0,684	0,72%
27	94,92	94,28	0,637	0,67%
28	94,99	94,29	0,697	0,73%
29	95,1	94,01	1,087	1,14%
30	94,54	94,24	0,296	0,31%
31	94,09	94,40	0,307	0,33%
32	94,8	94,32	0,485	0,51%
33	94,7	94,54	0,159	0,17%

34	94,67	94,82	0,152	0,16%
35	94,78	94,69	0,092	0,10%
36	94,84	95,19	0,354	0,37%
37	94,56	94,47	0,091	0,10%
38	94,52	94,81	0,204	0,22%
Rerata	94,52	94,49		
Maximum	95,31	95,19		
Minimum	93,94	93,94		
MAPE	0,420%	Sangat Akurat		

2. Nilai Persentase Bobot *Silica Sand*



Gambar 4.43 Hasil Pembobotan *Silica Sand*


Pada gambar tersebut menunjukkan hasil pembobotan *weighing feeder* dengan jenis material *Silica Sand*. Hasil dari pembobotan menunjukkan hal yang cukup akurat dimana ada beberapa titik nilai prediksi bobot dan nilai aktual yang mencapai konvergensi, namun di beberapa titik mengalami distorsi. Data prediksi berjumlah 38 data dengan nilai

persentase tertinggi terdapat pada data ke 22 dengan nilai prediksi 4,06 dan nilai terendah terdapat pada data ke 36 dengan nilai 2,19. Berikut adalah rincian perbandingan dari data aktual dan data prediksi nya.

Tabel 4.15 Hasil Perbandingan ANN Silica Sand

Data ke-	Bobot Silica Sand Aktual	Bobot Silica Sand ANN	Error Abs	Persentase Error
1	3,19	3,15	0,038	1%
2	3,13	2,23	0,904	29%
3	3,23	3,09	0,144	4%
4	3,81	3,10	0,713	19%
5	3,71	2,87	0,841	23%
6	3,72	3,80	0,077	2%
7	4,06	3,14	0,923	23%
8	4,03	2,96	1,073	27%
9	3,91	2,64	1,269	32%
10	4,05	3,97	0,083	2%
11	3,82	3,56	0,256	7%
12	3,75	3,04	0,714	19%
13	4,15	3,07	1,079	26%
14	3,91	2,86	1,051	27%
15	3,66	3,46	0,202	6%
16	3,76	2,99	0,775	21%
17	3,98	2,96	1,022	26%
18	2,99	2,95	0,037	1%
19	3,01	3,84	0,828	28%
20	2,94	2,94	0,000	0%
21	2,46	2,94	0,480	20%
22	2,27	4,04	1,766	78%
23	2,16	3,55	1,389	64%
24	2,31	2,86	0,547	24%

25	2,17	3,18	1,015	47%
26	2,29	3,74	1,445	63%
27	2,14	3,07	0,935	44%
28	2,05	2,91	0,863	42%
29	1,98	3,78	1,801	91%
30	2,34	3,78	1,444	62%
31	2,47	2,98	0,511	21%
32	2,24	2,99	0,752	34%
33	2,26	3,05	0,792	35%
34	2,32	2,96	0,640	28%
35	2,9	3,01	0,108	4%
36	2,86	2,19	0,668	23%
37	3,09	3,26	0,165	5%
38	3,19	3,15	0,038	1%
<hr/>				
Rerata	3,06	3,16		
Maximum	4,15	4,04		
Minimum	1,98	2,19		
MAPE	27,134%	Cukup Akurat		
<hr/>				

3. Nilai Persentase Bobot *Iron Sand*Gambar 4.44 Hasil Pembobotan *iron sand*

Pada gambar tersebut menunjukkan hasil pembobotan *weighing feeder* dengan jenis material *Silica Sand*. Hasil dari pembobotan menunjukkan hal yang cukup akurat dimana ada beberapa titik nilai prediksi bobot dan nilai aktual yang mencapai konvergensi, namun di beberapa titik mengalami distorsi. Pada data tertentu mengalami kenaikan yang sangat ekstrem sehingga ANN gagal dalam memprediksi, data prediksi sendiri berjumlah 38 data dengan nilai persentase tertinggi terdapat pada data ke 4 dengan nilai prediksi 2,15 dan nilai terendah terdapat pada data ke 22 dengan nilai 1,79. Berikut adalah rincian perbandingan dari data aktual dan data prediksinya.

Tabel 4.16 Hasil Perbandingan ANN Iron Sand

Data ke-	Bobot Iron Sand Aktual	Bobot Iron Sand ANN	Error Abs	Persentase Error
1	1,6	2,07	0,469	29%
2	1,68	1,97	0,294	17%
3	1,71	2,03	0,321	19%

4	1,7	2,15	0,447	26%
5	1,7	1,95	0,250	15%
6	1,7	1,84	0,145	9%
7	1,7	1,88	0,185	11%
8	1,78	1,98	0,198	11%
9	1,88	1,96	0,078	4%
10	1,77	1,83	0,057	3%
11	1,72	1,88	0,156	9%
12	1,76	2,02	0,256	15%
13	1,8	2,10	0,301	17%
14	1,8	1,93	0,126	7%
15	1,91	1,88	0,032	2%
16	2	2,01	0,011	1%
17	2	2,06	0,055	3%
18	2,89	1,91	0,978	34%
19	3,05	1,85	1,201	39%
20	2,78	2,05	0,732	26%
21	1,59	2,03	0,444	28%
22	1,52	1,79	0,265	17%
23	1,53	1,90	0,372	24%
24	2,81	2,04	0,773	28%
25	2,84	1,96	0,878	31%
26	2,09	1,86	0,230	11%
27	1,94	2,00	0,060	3%
28	1,96	2,04	0,082	4%
29	1,92	1,85	0,069	4%
30	2,12	1,89	0,232	11%
31	2,44	2,09	0,350	14%
32	1,96	2,10	0,141	7%

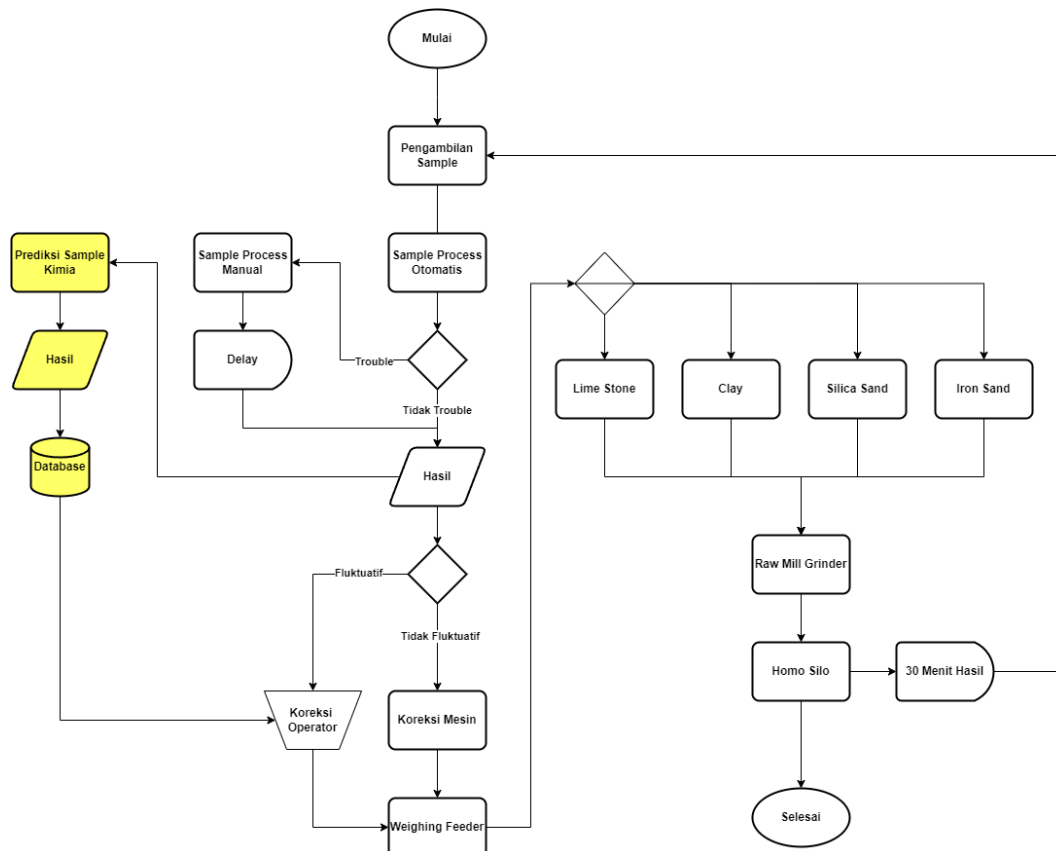
33	2,04	2,05	0,012	1%
34	2,01	2,00	0,010	1%
35	1,72	2,01	0,287	17%
36	1,73	1,96	0,233	13%
37	1,75	1,90	0,146	8%
38	1,6	2,07	0,469	29%
<hr/>				
Rerata	1,97	1,97		
Maximum	3,05	2,15		
Minimum	1,52	1,79		
MAPE	14,007%	Akurat		
<hr/>				

BAB V

PEMBAHASAN

5.1 Implementasi Sistem QC berbasis RNN-LSTM dan ANN

Pada bagian ini hasil dari perhitungan yang sudah didapatkan dan bentuk prediksi akan coba diimplementasikan pada sistem, pada sistem awalan, proses QC berjalan tanpa adanya bantuan *machine learning* (ML) bertipe RNN-LSTM dan masih manual dalam memasukkan penentuan modulus nilai LSF, AM, dan SM sehingga waktu yang ada untuk menentukan bobot *weighing feeder* akan terhambat dan menunggu hasil dari proses sampling oleh mesin. Dengan adanya sistem *machine learning* yang ditambahkan, proses penentuan modulus tidak perlu berpatokan pada hasil mesin sampling setiap 30 menit sekali, namun operator akan memiliki tambahan informasi berupa tren komposisi bahan mentah yang mereka kontrol selama proses produksi berlangsung. Berikut adalah gambaran *flow diagram* pada proses QC yang diusulkan peneliti pada perusahaan.



Gambar 5.1 Improvisasi QC

Gambar merupakan bentuk diagram alur QC yang sudah tingkatkan efisiensinya oleh peneliti dalam bentuk usulan yang nantinya dapat memberi informasi tambahan pada operator *Weighing Feeder*, pada proses awal berjalan operator melakukan koreksi *input* berdasarkan data sampling untuk mencapai modulus yang ingin dicapai, dengan tambahan sistem baru data hasil sampling alih-alih disimpan pada *database*, data diolah menggunakan RNN-LSTM untuk melihat pola sampling ke depan nya, proses ini kemudian akan memberikan gambaran kepada operator untuk mengetahui modulus yang akan dicapai tanpa harus menunggu hasil sampling setiap 30 menit, dengan hal ini juga maka proses iterasi pada QC dapat dikurangi sehingga dapat dikurangi. Secara umum pengurangan proses iterasi sampling ini tidak dibahas oleh peneliti karena tidak masuk dalam bahasan, namun diduga pengurangan iterasi dapat meminimalisir terjadinya kerusakan pada mesin sampling.

Untuk lebih jelasnya peneliti akan coba menjabarkan skema sampling pada saat kondisi terjadi kendala pada mesin sampling utama dengan kondisi data yang cukup fluktuatif sesuai dengan *flow chart* proses nya. Adanya asumsi kendala pada mesin sampling digunakan untuk memetakan permasalahan yang umum terjadi pada departemen QC dimulai dari tahap pertama hingga akhir.

a. Proses pengambilan Sampel dan Hasil Modulus

Pada studi kali ini peneliti akan mengambil contoh proses sampling pada tanggal 10 Mei 2024 dimulai pada 09:44:00 sampai pukul 11:14:00 dengan target LSF yang ditetapkan berdasarkan rata-rata nilai adalah 106,77 satuan masa. Pada saat pukul 09:44:00 bobot yang dimasukkan ke dalam komputer *weighing feeder* adalah sebagai berikut.

Tabel 5.1 Weighing Feeder 09:44:00

Limestone	Clay	Silica Sand	Iron Sand
94,19	0	4,03	1,78

Pada tabel 5.1.1 nilai persentase bahan limestone adalah sebesar 94.19 dan dilanjutkan dengan bobot clay sebanyak 0 persen, pasir silika sebanyak 4.03 persen dan pasir besi sebanyak 1.78 persen. Setelah nya 30 menit kemudian atau pada pukul 10:14:00 hasil sampel bahan kembali masuk ke departemen QC dan diproses pada mesin sampling, setelah nya didapati nilai komposisi dan modulus sebagai berikut.

Tabel 5.2 Saturasi Komposisi dan Modulus 10:14:00

SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O	LSF	SM	AM
-------------	--------------	--------------	------------	------------	------------	-------------	------------	------------	-----------	-----------

13,49 3,45 2,13 43,77 0,94 0,56 0,7 0,19 101,24 2,42 1,62

Pada kondisi ini operator harus menaikkan nilai LSF yang masih berada di angka 101.24 dimana hal ini ketetapan reratanya adalah sebesar 106,773 satuan masa.

b. Penetapan bobot material

Maka dengan demikian operator harus menaikkan nilai persentase bobot pada komputer untuk *weighing feeder* sebagai berikut.

Tabel 5.3 Masukan Bobot Material 10:14:00

Limestone	Clay	Silica Sand	Iron Sand
94,21	0	3,91	1,88

c. Hasil Sampling Setelah Material Masuk

Dengan masuk nya bahan *limestone* sebanyak 94.21 persen, *clay* atau tanah liat sebanyak 0 persen, pasir silika sebanyak 3.91 persen, dan Pasir besi sebanyak 1.88 persen maka dalam 30 menit ke depan rincian komposisi kimianya adalah sebagai berikut.

Tabel 5.4 Saturasi Komposisi dan Modulus 10:44:00

SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O	LSF	SM	AM
13,04	3,39	2,08	44,18	1,09	0,56	0,13	0,18	105,57	2,38	1,63

Seperti yang terlihat pada tabel 5.1.4 nilai LSF nya mengalami kenaikan sebesar 4.33 satuan masa karena persentase nilai *limestone* dan pasir silika pada *weighing feeder* mengalami peningkatan dan juga persentase silika diturunkan. Dengan demikian kadar LSF satuan masa nya masih kurang untuk memenuhi standar rata-rata sebesar 106,773. Maka operator harus menambahkan persentase bobot *limestone* kedalam mesin *weighing feeder*.

d. Asumsi Kendala Mesin

Ketika mengalami kendala, maka pada pukul 10:44:00 operator harus memasukkan nilai pembobotan pada komputer, namun karena mesin nya mengalami kendala maka operator harus menunggu hasil sampling sampai mesin beroperasi kembali atau menggunakan perkiraan secara manual. Namun dengan adanya improvisasi proses, dapat diketahui kemungkinan tren komposisi yang terjadi. Maka operator akan melihat kondisi trend sampling yang akan masuk di jam setelah nya atau pada pukul 11:14:00 nya sebagai berikut.

Tabel 5.5 Saturasi Komposisi dan Modulus 11:14:00 Aktual dan Prediksi

SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O	LSF	SM	AM
12,49	3,59	1,95	44,25	1,09	0,54	0,09	0,16	109,31	2,25	1,84
12,40	3,48	2,11	44,16	0,82	0,35	-0,02	0,16	108,80	2,22	1,65

Dengan masukan nilai pada *weighing feeder* sebagai berikut.

Tabel 5.6 Weighing feeder 10:44:00 Aktual dan ANN

Limestone	Clay	Silica Sand	Iron Sand
94,46	0	3,82	1,72
94,48	-	3,56	1,88

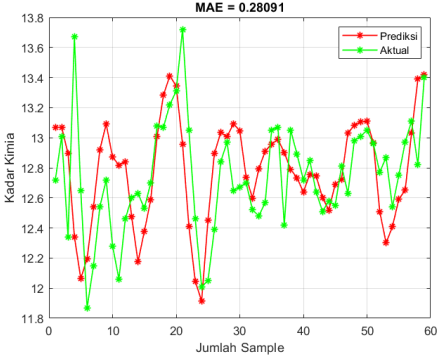
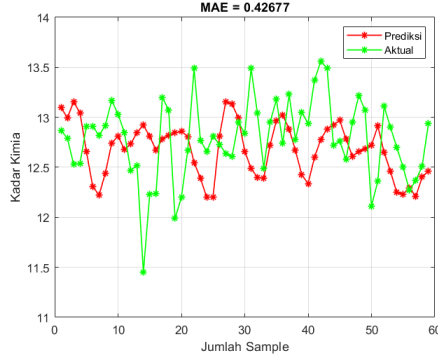
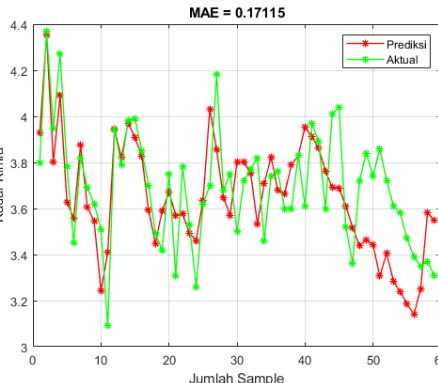
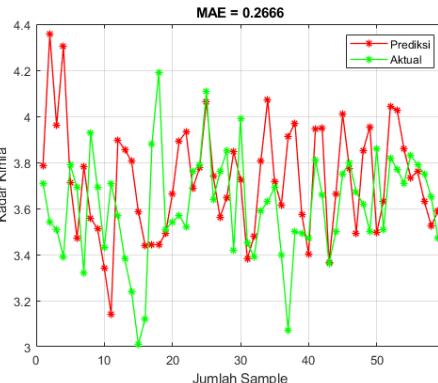
Hasil dari tabel 5.1.5 menunjukkan bahwa data aktual dari proses sampling yang didapatkan 30 menit kemudian atau di jam 11:14 menunjukan nilai LSF yang terlampaui naik sebesar 109.31 dengan selisih 2.32 dari nilai ketetapan yang ada. Dengan demikian maka adanya prediksi yang bercetak tebal di tabel menunjukkan nilai LSF yang juga naik sebesar 108.80, hasil tersebut didapatkan dengan waktu 30 menit lebih cepat dari seharusnya dan operator bisa melakukan preventif dengan cara mengurangi nilai pembobotan pada mesin *weighing feeder*, terbukti juga hasil aktual dari operator yang memasukkan nilai sebesar 94.46 karena mengikuti nilai pembobotan sebelumnya pada angka 94.21 seperti yang tertera pada tabel 5.1.3 dan ingin menaikkan nilai modulus LSF sedikit, hasil di mesin homo silo menunjukkan nilai LSF yang terlampaui jauh, dengan demikian operator bisa menurunkan nilai *Limestone* di *weighing feeder* dengan perlahan dan tidak hanya mengandalkan intuisi nilai sebelumnya sehingga dapat meningkatkan akurasi hasil pembobotan.


5.2 Karakteristik Penggunaan RNN-LSTM Pada Raw Material

Pada penelitian ini, peneliti menemukan bahwa akurasi pada LSTM memiliki kekurangan yang cukup menjadi perhatian. LSTM diambil berdasarkan hasil sampling pada tanggal 6 Mei 2024 sampai 8 Mei 2024. Setelahnya model LSTM digunakan untuk memprediksi keluaran komposisi pada tanggal 8 sampai 10 Mei 2024. Pada hari pertama prediksi, model LSTM menunjukkan performa yang cukup baik dengan tingkat akurasi yang tinggi. Namun, pada hari kedua, akurasi prediksi mulai menurun, ditandai dengan meningkatnya nilai *Mean Absolute Error* (MAE) sebagai parameter yang biasa dipakai untuk menentukan sebuah model *machine learning* mengalami degradasi akurasi atau

tidak. Peningkatan MAE ini menunjukkan bahwa prediksi model semakin tidak akurat namun masih dalam batas yang wajar, akan tetapi secara umum bahan utama pada proses produksi yang disimpan dalam bentuk tumpukan atau *pile* pada hari ke tiga akan habis dan berganti menjadi *pile* baru sehingga hasil yang kurang akurat pada hari ke dua dan tiga tidak menjadi masalah, karena peran operator dalam menjalankan prosedur QC tidak diganti. Berikut adalah perbandingan spesifik antara kandungan empat sampel utama komposisi seperti SiO₂, Al₂O₃, Fe₂O₃, dan CaO.

Tabel 5.7 Perbandingan hasil prediksi

			
Kandungan SiO₂			
<p>Prediksi Tanggal 8-9 Mei</p> <p>Nilai MAE = 0.280</p>		<p>Prediksi Tanggal 9-10 Mei</p> <p>Nilai MAE = 0.426</p>	
			
Kandungan Al₂O₃			
<p>Prediksi Tanggal 8-9 Mei</p> <p>Nilai MAE = 0.171</p>		<p>Prediksi Tanggal 9-10 Mei</p> <p>Nilai MAE = 0.266</p>	




Kandungan Fe₂O₃

Prediksi Tanggal 8-9 Mei

Prediksi Tanggal 9-10 Mei

Nilai MAE = 0.059

Nilai MAE = 0.124



Kandungan CaO

Prediksi Tanggal 8-9 Mei

Prediksi Tanggal 9-10 Mei

Nilai MAE = 0.049

Nilai MAE = 0.126

Pada tabel 5.7 dapat terlihat untuk pengujian pada kandungan SiO₂ memiliki nilai MAE yang bertambah pada hari berikutnya terhitung sejak tanggal 8 Mei 2024, nilai MAE nya naik sebesar 0.146 yang mengindikasikan adanya kesalahan prediksi dan menjauhnya model dari konvergensi. Penyebab menurunnya akurasi pada hari kedua dan ketiga dapat disebabkan oleh penggunaan parameter yang kurang ideal dan sangat sensitif dalam model LSTM. Hal ini menunjukkan bahwa model LSTM perlu diatur dan disesuaikan lebih lanjut dengan penggunaan spesifik terhadap material yang sedang diuji untuk mengatasi sensitivitas parameter dan meningkatkan stabilitas prediksi. Meskipun demikian, hasil ini memberikan informasi berharga bagi operator mesin *weighing feeder* pada proses QC s. Dengan informasi tambahan ini, proses QC diharapkan dapat dikurangi

jumlah iterasinya, sehingga meningkatkan efisiensi operasional. Hasil prediksi dari LSTM digunakan sebagai input untuk model ANN dengan parameter *Lime Saturation Factor* (LSF), *Alumina Modulus* (AM), dan *Silica Modulus* (SM) yang telah diketahui melalui proses forecasting. ANN yang digunakan dalam penelitian ini adalah jenis *backpropagation*, yang terkenal dengan kemampuannya untuk menentukan proporsi pembobotan bahan mentah dengan akurasi tinggi.

Hasil implementasi ANN menunjukkan kinerja yang memuaskan dalam menentukan proporsi pembobotan bahan mentah pada mesin *weighing feeder*. ANN mampu mengoptimalkan proses ini dengan lebih efisien dibandingkan metode konvensional. Akurasi yang tinggi dalam menentukan proporsi bahan mentah memastikan bahwa kualitas semen yang dihasilkan tetap konsisten dan memenuhi standar yang diinginkan.

5.3 Prosedur Implementasi Sistem

Hasil model yang dibahas pada sub bab 4.2.4 merupakan keluaran data dari aplikasi Matlab dengan versi R2022a dan komputasi menggunakan komputer portabel dengan spesifikasi prosesor AMD Ryzen 5 4600HS, RAM sebesar 16GB, GPU menggunakan Nvidia GTX 1650TI dengan durasi rata-rata hasil sampel keluar dalam kisaran 3 menit untuk jumlah *epoch* di bawah 1000 dan 5 sampai 10 menit untuk jumlah *epoch* lebih dari 1000, maka dengan ini rata-rata waktu yang dibutuhkan untuk melakukan total iterasi pada setiap komponen sampel kimia adalah 40-50 menit.

Hal yang perlu diperhatikan dalam implementasinya, waktu 40-50 menit tadi hanya dilakukan satu kali saat sampel sudah masuk dan setelahnya operator dapat menggunakan hasilnya sebagai acuan untuk sampling berikutnya, namun data yang dipakai memiliki karakteristik khusus untuk memastikan hasil dari prediksi memiliki hasil yang cukup baik diantaranya adalah penggunaan data masukan dari *pile* yang sama, sehingga kemungkinan terjadinya MAE yang besar dan jauh dari konvergensi dapat diminimalisir. Hal ini disebabkan karena perbedaan *pile* memungkinkan perbedaan signifikan juga terhadap komposisinya sehingga LSTM tidak efektif dalam membaca data karena data yang diprediksi berbeda dengan masukan yang sudah diproses sebelumnya.

BAB VI

PENUTUP

6.1 Kesimpulan

Setelah semua perhitungan dan pembahasan telah dilakukan pada bab sebelumnya, peneliti akhirnya dapat menyampaikan Kesimpulan yang menjawab rumusan masalah dari peneliti, berikut adalah Kesimpulan yang didapatkan.

1. Pembentukan model RNN- LSTM dan ANN serta implementasinya, menjadikan operator dapat mengetahui tren komposisi bahan kimia dan modulus yang ada terutama ketika mesin sampling mengalami masalah sehingga proses QC pada pembobotan mesin *weighing feeder* dapat dilakukan dengan baik dan terkendali. Hal ini dapat mengurangi terjadinya *opportnity loss* karena kesalahan operator dalam melakukan campuran komposisi lebih akurat.
2. Karakteristik penggunaan RNN-LSTM agaknya berbeda dengan penggunaan pada bidang lain. Seperti yang telah dibahas pada bab sebelumnya, bahan material mentah memiliki karakteristik yang lebih sensitif dan tidak mudah diprediksi, terjadinya perbedaan *pile* akan membuat hasil akurasi prediksi mengalami penurunan, hal ini dibuktikan dengan nilai MAE yang semakin besar pada hari ke dua. Namun efektivitas penggunaan machine learning pada penelitian terbukti bisa dilakukan dan memberikan dampak signifikan pada operator saat bertugas.
3. Solusi yang dapat diberikan kepada perusahaan adalah dengan melakukan *redeisgn* pada sistem proses QC seperti yang sudah dijabarkan pada peneliti. Data yang sebelum nya hanya disimpan pada *database* perusahaan dapat digunakan untuk mencari pola data pada proses QC dan memberikan operator gambaran mengenai akan seperti apa proses yang terjadi kedepan nya bahkan memberikan hasil 30 menit lebih cepat, namun perlu juga dilakukannya pelatihan kepada operator terkait dengan harapan bisa melakukan penyesuaian kinerja agar tidak terpaku pada penggunaan *machine learing*, bagaimanapun operator juga dituntut untuk lebih teliti dalam bekerja mengawasi jalan nya produksi.

6.2 Saran

Penerapan *machine learning* berjenis RNN-LSTM dan ANN dalam mengolah data dirasa cukup efektif dengan hasil yang memuaskan, namun pada penelitian ini bukan berarti bebas dari kendala, maka dengan ini peneliti ingin memberikan saran, harapannya dengan memberikan saran-saran ini, penelitian di masa mendatang dapat memperbaiki dan mengembangkan penelitian mereka menggunakan cara, alat, atau metode yang berbeda dengan tujuan memperluas pengembangan ilmu Teknik Industri. Berikut ini dilampirkan beberapa saran yang diharapkan bermanfaat bagi penelitian berikutnya.

6.2.1 Saran Untuk Peneliti Selanjutnya

Permasalahan yang umum terjadi adalah kurangnya data untuk melakukan pelatihan pada model. Kinerja *machine learning* sangat dipengaruhi oleh hasil masukan data untuk mesin belajar, kurangnya data dapat menjadikan hasil prediksi kurang akurat.

- Saran untuk penelitian serupa kedepannya bisa mengambil data secara langsung dengan *software*, tidak manual seperti yang sekarang dilakukan peneliti. Memasukkan data secara manual juga berpotensi mengalami terjadinya salah data.
- Kemudian penggunaan metode yang lebih sederhana untuk melakukan prediksi bahan mentah seperti ARIMA juga bisa menjadi solusi dan dapat membandingkan hasil yang lebih komprehensif karena peneliti menyadari kurangnya data ketika hasil prediksi sudah keluar, namun dalam penelitian ini peneliti diuntungkan dengan adanya proyeksi bahan mentah yang habis ketika dipakai selama 3-4 hari sehingga penggunaan LSTM dalam memprediksi, walau nilainya menjadi kurang akurat di hari 2-3 tidak menjadi permasalahan yang serius.
- Kemudian untuk pengambilan data ANN sendiri peneliti juga mendapati kondisi operasional mesin yang tidak *steady state* sehingga data yang ada tidak sepenuhnya menggambarkan kondisi operasional yang ideal. Sehingga penelitian selanjutnya bisa menyesuaikan waktu pengambilan datanya dengan kondisi perusahaan setelah melakukan *maintenance* besar atau *overhaull* yaitu pada bulan Agustus setiap tahunnya.

DAFTAR PUSTAKA

- Al-Selwi, S. M., Hassan, M. F., Abdulkadir, S. J., Muneer, A., Sumiea, E. H., Alqushaibi, A., & Ragab, M. G. (2024). RNN-LSTM: From applications to modeling techniques and beyond—Systematic review. In *Journal of King Saud University - Computer and Information Sciences* (Vol. 36, Issue 5). King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2024.102068>
- Babcock Joseph, & Bali Raghav. (2021). *Generative AI with Python and TensorFlow 2*. Packt Publishing.
- Bas, E., Egrioglu, E., & Cansu, T. (2024). Robust training of median dendritic artificial neural networks for time series forecasting. *Expert Systems with Applications*, 238. <https://doi.org/10.1016/j.eswa.2023.122080>
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. In *Journal of Methods Microbiological Journal of Microbiological Methods* (Vol. 43). www.elsevier.com/locate/jmicmeth
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Dananjaya, R. H., Sutrisno, S., & Fitriady, S. (2022). PENERAPAN ARTIFICIAL NEURAL NETWORK (ANN) DALAM MEMREDIKSI KAPASITAS DUKUNG FONDASI TIANG. *Matriks Teknik Sipil*, 10(4), 419. <https://doi.org/10.20961/mateksi.v10i4.65034>
- de-Prado-Gil, J., Martínez-García, R., Jagadesh, P., Juan-Valdés, A., González-Alonso, M.-I., & Palencia, C. (2023). To determine the compressive strength of self-compacting recycled aggregate concrete using artificial neural network (ANN). *Ain Shams Engineering Journal*, 102548. <https://doi.org/10.1016/j.asej.2023.102548>
- Falcone, R., Ciaramella, A., Carrabs, F., Strisciuglio, N., & Martinelli, E. (2022). Artificial neural network for technical feasibility prediction of seismic retrofitting in existing RC structures. *Structures*, 41, 1220–1234. <https://doi.org/10.1016/j.istruc.2022.05.008>
- Firmansyach, W. A., Hayati, U., & Wijaya, Y. A. (2023). ANALISA TERJADINYA OVERFITTING DAN UNDERFITTING PADA ALGORITMA NAIVE BAYES DAN DECISION TREE DENGAN TEKNIK CROSS VALIDATION. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 7, Issue 1).
- GUODONG, L., XIN, W., DUO, W., XIAOHONG, W., & HONGLIANG, Y. (2015). *Intelligent Control System for Cement Raw Mill Quality Based on Online Analysis*. 161–165. <https://doi.org/10.15224/978-1-63248-044-6-126>
- Hernández, J. A., Solís-Pérez, J. E., Parrales, A., Mata, A., Colorado, D., Huicochea, A., & Gómez-Aguilar, J. F. (2023). A conformable artificial neural network model to improve the void fraction prediction in helical heat exchangers. *International Communications in Heat and Mass Transfer*, 148. <https://doi.org/10.1016/j.icheatmasstransfer.2023.107035>
- Jin, X., & Zheng, S. (2022). Measurement and calibration of optical instruments based on metrological calibration method and artificial neural network. *Optik*, 170479. <https://doi.org/10.1016/j.ijleo.2022.170479>
- Knoerzer, K. (2024). Leveraging artificial intelligence for simplified adiabatic compression heating prediction: Comparing the use of artificial neural networks with

- conventional numerical approach. *Innovative Food Science and Emerging Technologies*, 91. <https://doi.org/10.1016/j.ifset.2023.103546>
- Korstanje Joos. (2021). *Advanced Forecasting with Python: With State-of-the-Art Models Including LSTMs, Facebook's Prophet, and Amazon's DeepAR*. Apress.
- Kowsher, M., Tahabilder, A., Islam Sanjid, M. Z., Prottasha, N. J., Uddin, M. S., Hossain, M. A., & Kader Jilani, M. A. (2021). LSTM-ANN & BiLSTM-ANN: Hybrid deep learning models for enhanced classification accuracy. *Procedia Computer Science*, 193, 131–140. <https://doi.org/10.1016/j.procs.2021.10.013>
- Lee, Y., Yim, J., Hong, S., & Min, K. B. (2022). Application of artificial neural network for determining elastic constants of a transversely isotropic rock from a single-orientation core. *International Journal of Rock Mechanics and Mining Sciences*, 160. <https://doi.org/10.1016/j.ijrmms.2022.105277>
- Lewis, & Colin David. (1982). *Industrial and business forecasting methods : a practical guide to exponential smoothing and curve fitting*. Butterworth Scientific.
- Maisel, F., Neef, C., Marscheider-Weidemann, F., & Nissen, N. F. (2023). A forecast on future raw material demand and recycling potential of lithium-ion batteries in electric vehicles. *Resources, Conservation and Recycling*, 192. <https://doi.org/10.1016/j.resconrec.2023.106920>
- Morant, F., & Albertos, P. (1988). *QUALITY CONTROL OF RAW MATERIALS BLENDING IN THE CEMENT INDUSTRY*.
- Mumali, F. (2022). Artificial neural network-based decision support systems in manufacturing processes: A systematic literature review. *Computers and Industrial Engineering*, 165. <https://doi.org/10.1016/j.cie.2022.107964>
- Prathama, A. Y. (2018). PENDEKATAN ANN (ARTIFICIAL NEURAL NETWORK) UNTUK PENENTUAN PROSENTASE BOBOT PEKERJAAN DAN ESTIMASI NILAI PEKERJAAN STRUKTUR PADA RUMAH SAKIT PRATAMA. *Jurnal Teknosains*, 7(1), 14. <https://doi.org/10.22146/teknosains.30139>
- Putra, H., & Ulfa Walmi, N. (2020). Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 6(2), 100–107. <https://doi.org/10.25077/teknosi.v6i2.2020.100-107>
- Rai, R., Tiwari, M. K., Ivanov, D., & Dolgui, A. (2021). Machine learning in manufacturing and industry 4.0 applications. In *International Journal of Production Research* (Vol. 59, Issue 16, pp. 4773–4778). Taylor and Francis Ltd. <https://doi.org/10.1080/00207543.2021.1956675>
- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial neural networks in supply chain management, a review. *Journal of Economy and Technology*, 1, 179–196. <https://doi.org/10.1016/j.ject.2023.11.002>
- Sri Kusumadewi. (2003). *Artificial intelligence (teknik dan aplikasinya)* (1st ed.). Graha Ilmu.
- Taloba, A. I. (2022). An Artificial Neural Network Mechanism for Optimizing the Water Treatment Process and Desalination Process. *Alexandria Engineering Journal*, 61(12), 9287–9295. <https://doi.org/10.1016/j.aej.2022.03.029>
- Varshini, A., Kayal, P., & Maiti, M. (2024). How good are different machine and deep learning models in forecasting the future price of metals? Full sample versus sub-sample. *Resources Policy*, 92. <https://doi.org/10.1016/j.resourpol.2024.105040>
- Weerakody, P. B., Wong, K. W., Wang, G., & Ela, W. (2021). A review of irregular time series data handling with gated recurrent neural networks. *Neurocomputing*, 441, 161–178. <https://doi.org/10.1016/j.neucom.2021.02.046>

- Wuest, T., Weimer, D., Irgens, C., & Thoben, K. D. (2016). Machine learning in manufacturing: Advantages, challenges, and applications. *Production and Manufacturing Research*, 4(1), 23–45. <https://doi.org/10.1080/21693277.2016.1192517>
- Yang, C. L., Atinafu Yilma, A., Sutrisno, H., Woldegiorgis, B. H., & Nguyen, T. P. Q. (2023). LSTM-based framework with metaheuristic optimizer for manufacturing process monitoring. *Alexandria Engineering Journal*, 83, 43–52. <https://doi.org/10.1016/j.aej.2023.10.006>
- Zupan, J. (1994). *Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them**. <https://www.researchgate.net/publication/251626579>
- Indocement (INTP) Kecipratan Berkah IKN, Penjualan Semen Naik 9% (bisnis.com)

LAMPIRAN

LAMPIRAN 1 : FOTO DATA KOMPOSISI SAMPLING

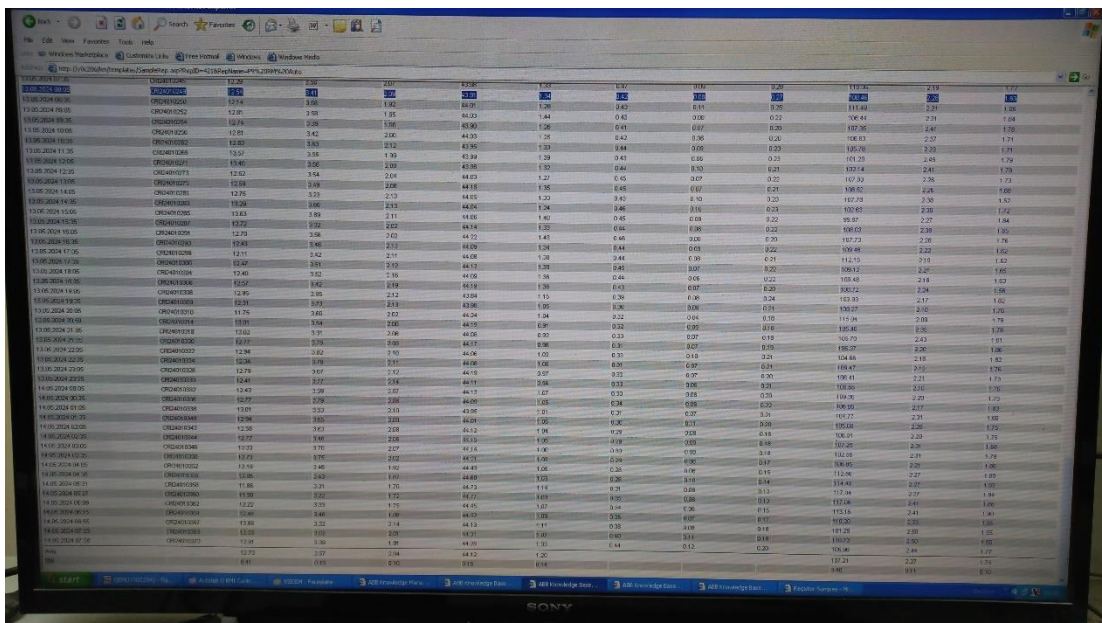
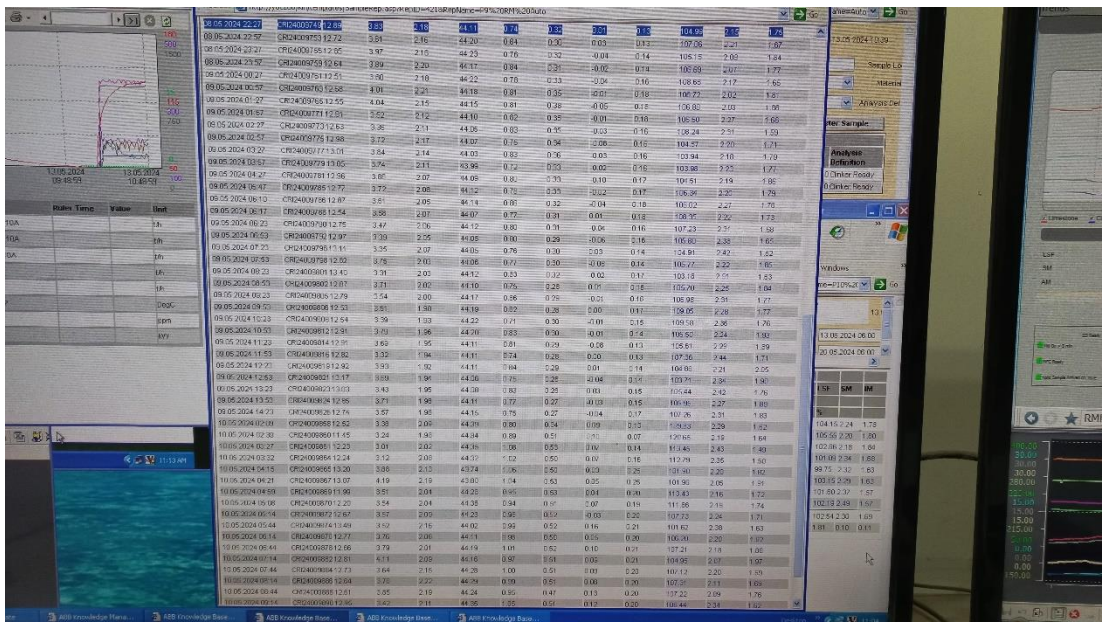
08.05.2024 22:27	CRI24009749	12.89	3.83	2.18	44.11	0.74	0.32	0.01	0.13	104.99	2.15	1.75
08.05.2024 22:57	CRI24009753	12.72	3.61	2.16	44.20	0.84	0.30	0.03	0.13	107.06	2.21	1.67
08.05.2024 23:27	CRI24009755	12.85	3.97	2.16	44.23	0.76	0.32	-0.04	0.14	105.15	2.09	1.84
08.05.2024 23:57	CRI24009759	12.64	3.89	2.20	44.17	0.84	0.31	-0.02	0.14	106.69	2.07	1.77
09.05.2024 00:27	CRI24009761	12.51	3.60	2.18	44.22	0.78	0.33	-0.04	0.16	108.65	2.17	1.65
09.05.2024 00:57	CRI24009763	12.58	4.01	2.21	44.18	0.81	0.35	-0.01	0.18	106.72	2.02	1.81
09.05.2024 01:27	CRI24009765	12.55	4.04	2.15	44.15	0.81	0.38	-0.05	0.18	106.89	2.03	1.88
09.05.2024 01:57	CRI24009771	12.81	3.52	2.12	44.10	0.82	0.35	-0.01	0.18	106.50	2.27	1.66
09.05.2024 02:27	CRI24009773	12.63	3.36	2.11	44.05	0.83	0.35	-0.03	0.16	108.24	2.31	1.59
09.05.2024 02:57	CRI24009775	12.98	3.72	2.17	44.07	0.75	0.34	-0.08	0.16	104.57	2.20	1.71
09.05.2024 03:27	CRI24009777	13.01	3.84	2.14	44.03	0.83	0.36	-0.03	0.16	103.94	2.18	1.79
09.05.2024 03:57	CRI24009779	13.05	3.74	2.11	43.99	0.72	0.33	-0.02	0.16	103.98	2.23	1.77
09.05.2024 04:27	CRI24009781	12.96	3.86	2.07	44.09	0.80	0.33	-0.10	0.17	104.51	2.19	1.86
09.05.2024 04:57	CRI24009785	12.77	3.72	2.08	44.12	0.78	0.33	-0.02	0.17	106.34	2.20	1.79
09.05.2024 05:10	CRI24009786	12.87	3.61	2.05	44.14	0.86	0.32	-0.04	0.18	106.02	2.27	1.76
09.05.2024 05:17	CRI24009788	12.54	3.58	2.07	44.07	0.77	0.31	0.01	0.18	108.35	2.22	1.73
09.05.2024 05:23	CRI24009790	12.75	3.47	2.06	44.12	0.80	0.31	-0.04	0.16	107.23	2.31	1.68
09.05.2024 05:53	CRI24009792	12.97	3.39	2.05	44.05	0.80	0.29	-0.06	0.16	105.80	2.38	1.65
09.05.2024 07:23	CRI24009796	13.11	3.35	2.07	44.05	0.76	0.30	0.03	0.14	104.91	2.42	1.62
09.05.2024 07:53	CRI24009798	12.82	3.75	2.03	44.06	0.77	0.30	-0.08	0.14	105.77	2.22	1.85
09.05.2024 08:23	CRI24009801	13.40	3.31	2.03	44.12	0.83	0.32	-0.02	0.17	103.18	2.51	1.63
09.05.2024 08:53	CRI24009802	12.87	3.71	2.02	44.10	0.75	0.28	0.01	0.16	105.70	2.25	1.84
09.05.2024 09:23	CRI24009805	12.79	3.54	2.00	44.17	0.86	0.29	-0.01	0.16	106.98	2.31	1.77
09.05.2024 09:53	CRI24009806	12.53	3.51	1.98	44.19	0.82	0.28	0.00	0.17	109.05	2.28	1.77
09.05.2024 10:23	CRI24009808	12.54	3.39	1.93	44.22	0.71	0.30	-0.01	0.15	109.58	2.36	1.76
09.05.2024 10:53	CRI24009812	12.91	3.79	1.96	44.20	0.83	0.30	-0.01	0.14	105.50	2.24	1.93
09.05.2024 11:23	CRI24009814	12.91	3.69	1.95	44.11	0.81	0.29	-0.08	0.13	105.61	2.29	1.89
09.05.2024 11:53	CRI24009816	12.82	3.32	1.94	44.11	0.74	0.28	0.00	0.13	107.36	2.44	1.71
09.05.2024 12:23	CRI24009819	12.92	3.93	1.92	44.11	0.84	0.29	0.01	0.14	104.88	2.21	2.05
09.05.2024 12:53	CRI24009821	13.17	3.69	1.94	44.06	0.75	0.28	-0.04	0.14	103.71	2.34	1.90
09.05.2024 13:23	CRI24009823	13.03	3.43	1.95	44.08	0.83	0.28	0.03	0.15	105.44	2.42	1.76
09.05.2024 13:53	CRI24009824	12.85	3.71	1.96	44.11	0.77	0.27	-0.03	0.15	105.95	2.27	1.89
09.05.2024 14:23	CRI24009826	12.74	3.57	1.96	44.15	0.75	0.27	-0.04	0.17	107.26	2.31	1.83
10.05.2024 02:09	CRI24009858	12.52	3.38	2.09	44.39	0.80	0.34	0.09	0.13	109.83	2.29	1.62
10.05.2024 02:39	CRI24009860	11.45	3.24	1.98	44.84	0.89	0.51	0.10	0.07	120.65	2.19	1.64
10.05.2024 03:27	CRI24009861	12.23	3.01	2.02	44.35	1.08	0.53	0.07	0.14	113.45	2.43	1.49
10.05.2024 03:32	CRI24009864	12.24	3.12	2.08	44.32	1.02	0.50	0.07	0.16	112.79	2.35	1.50
10.05.2024 04:15	CRI24009865	13.20	3.88	2.13	43.74	1.06	0.50	0.03	0.26	101.90	2.20	1.82
10.05.2024 04:21	CRI24009867	13.07	4.19	2.19	43.80	1.04	0.53	0.05	0.25	101.96	2.05	1.91
10.05.2024 04:59	CRI24009869	11.99	3.51	2.04	44.28	0.95	0.53	0.04	0.20	113.43	2.16	1.72
10.05.2024 05:08	CRI24009870	12.20	3.54	2.04	44.36	0.94	0.51	0.07	0.19	111.86	2.19	1.74
10.05.2024 05:14	CRI24009872	12.67	3.57	2.09	44.23	0.98	0.52	-0.03	0.20	107.73	2.24	1.71
10.05.2024 05:44	CRI24009874	13.49	3.52	2.16	44.02	0.99	0.52	0.16	0.21	101.62	2.38	1.63
10.05.2024 06:14	CRI24009876	12.77	3.76	2.06	44.11	0.95	0.50	0.05	0.20	106.20	2.20	1.82
10.05.2024 06:44	CRI24009878	12.66	3.79	2.01	44.19	1.01	0.52	0.10	0.21	107.21	2.18	1.88
10.05.2024 07:14	CRI24009882	12.81	4.11	2.09	44.16	0.97	0.51	0.09	0.21	104.95	2.07	1.97
10.05.2024 07:44	CRI24009884	12.73	3.64	2.15	44.28	1.00	0.51	0.09	0.20	107.12	2.20	1.69
10.05.2024 08:14	CRI24009886	12.64	3.76	2.22	44.29	0.99	0.51	0.08	0.20	107.31	2.11	1.69
10.05.2024 08:44	CRI24009888	12.61	3.85	2.19	44.24	0.95	0.47	0.13	0.20	107.22	2.09	1.76
10.05.2024 09:14	CRI24009890	12.95	3.42	2.11	44.35	1.05	0.51	0.12	0.20	106.44	2.34	1.62

Date/Time	ID	SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O	LSF	SM	M
06.05.2024 23:44	CR2400948813.20	3.73	2.06	44.06	0.84	0.49	0.08	0.16	103.07	2.26	1.95	
06.05.2024 00:14	CR2400948913.24	3.82	1.89	43.89	0.93	0.47	0.01	0.18	89.91	2.39	2.02	
06.05.2024 00:44	CR2400948413.34	3.49	1.95	43.99	0.68	0.45	0.16	0.16	103.08	2.50	1.89	
06.05.2024 01:14	CR2400948613.40	3.80	1.90	44.12	0.92	0.43	0.04	0.15	102.05	2.35	2.00	
06.05.2024 01:44	CR2400947012.99	3.96	2.02	44.06	0.51	0.43	0.10	0.17	104.02	2.17	1.96	
06.05.2024 02:39	CR2400947212.51	3.56	1.96	44.40	1.01	0.42	0.10	0.13	109.89	2.28	1.83	
06.05.2024 02:44	CR2400947412.42	3.35	1.96	44.49	0.90	0.40	0.06	0.13	111.19	2.34	1.71	
06.05.2024 03:14	CR2400947812.34	3.37	2.01	44.44	0.95	0.40	0.07	0.13	111.81	2.30	1.67	
06.05.2024 03:44	CR2400947912.83	3.72	2.04	44.32	0.95	0.38	0.07	0.14	107.94	2.30	1.82	
06.05.2024 04:49	CR2400948112.89	3.82	2.02	44.17	0.83	0.38	0.13	0.16	104.40	2.19	1.94	
06.05.2024 04:54	CR2400948313.07	3.88	2.02	44.18	0.82	0.39	0.11	0.16	104.02	2.21	1.92	
06.05.2024 05:24	CR2400948512.86	3.23	2.04	44.20	0.87	0.39	0.04	0.17	106.91	2.46	1.58	
06.05.2024 05:54	CR2400948712.93	3.77	2.07	44.28	0.87	0.37	0.13	0.16	105.45	2.22	1.82	
06.05.2024 06:24	CR2400948912.76	3.69	2.13	44.15	0.93	0.39	0.19	0.17	106.84	2.24	1.88	
06.05.2024 06:54	CR2400949313.77	3.65	2.11	44.36	0.90	0.39	0.41	0.15	105.31	2.22	1.73	
06.05.2024 07:24	CR2400949812.74	3.83	2.19	44.16	0.69	0.39	0.11	0.15	107.17	2.24	1.60	
06.05.2024 07:54	CR2400950013.01	3.94	2.16	44.12	0.84	0.39	0.07	0.16	105.00	2.28	1.83	
06.05.2024 08:00	CR2400950212.86	3.92	2.17	44.12	0.84	0.39	0.06	0.15	105.41	2.28	1.82	
06.05.2024 08:30	CR2400950412.66	3.39	2.16	44.11	0.86	0.39	0.16	0.14	107.35	2.28	1.57	
06.05.2024 09:00	CR2400950613.85	3.66	2.16	43.90	0.84	0.39	0.12	0.13	89.89	2.34	1.68	
06.05.2024 09:52	CR2400951013.73	3.49	2.07	43.90	0.88	0.39	0.05	0.11	89.69	2.48	1.60	
06.05.2024 09:59	CR2400951113.25	3.27	2.07	44.23	0.84	0.37	0.11	0.10	104.82	2.56	1.71	
06.05.2024 10:41	CR2400951313.68	3.42	2.09	44.25	0.95	0.37	0.11	0.15	105.62	2.34	1.71	
06.05.2024 11:17	CR2400951712.68	3.30	1.99	44.30	0.89	0.40	0.09	0.13	110.08	2.32	1.61	
06.05.2024 11:47	CR2400952113.05	3.72	2.07	44.18	0.95	0.39	0.19	0.15	104.66	2.26	1.80	
06.05.2024 12:17	CR2400952313.03	3.52	2.09	44.18	1.00	0.41	0.11	0.15	103.85	2.17	1.88	
06.05.2024 12:47	CR2400952512.82	3.68	2.10	44.29	0.99	0.43	0.06	0.16	106.23	2.22	1.75	
06.05.2024 13:17	CR2400952712.40	3.81	2.19	44.25	0.89	0.44	0.04	0.16	105.66	2.17	1.71	
06.05.2024 13:47	CR2400952912.50	3.08	2.13	44.23	1.02	0.41	0.02	0.16	107.32	2.01	1.92	
06.05.2024 14:17	CR2400953112.85	3.77	2.08	44.28	0.86	0.41	0.03	0.15	107.46	2.18	1.81	
06.05.2024 14:47	CR2400953312.47	3.40	1.98	44.50	0.84	0.40	0.03	0.10	110.05	2.32	1.72	
06.05.2024 15:17	CR2400953912.41	3.39	1.95	44.40	0.82	0.37	0.00	0.09	111.19	2.33	1.73	
06.05.2024 16:05	CR2400954112.78	3.42	2.03	44.32	0.82	0.41	0.11	0.11	107.74	2.35	1.69	
06.05.2024 16:10	CR2400954912.94	3.30	2.04	44.23	0.83	0.40	0.06	0.12	106.10	2.34	1.71	
06.05.2024 16:40	CR2400955112.82	3.42	2.00	44.18	0.86	0.41	0.04	0.14	106.38	2.38	1.71	
06.05.2024 17:10	CR2400955912.28	3.37	1.98	44.27	0.89	0.38	0.03	0.14	111.73	2.31	1.72	
06.05.2024 17:40	CR2400956412.68	3.54	2.02	44.23	0.94	0.41	0.05	0.15	107.89	2.29	1.76	
06.05.2024 18:10	CR2400956813.08	3.82	2.01	44.10	0.83	0.40	0.01	0.18	103.62	2.21	1.94	
06.05.2024 18:40	CR2400956812.85	3.82	1.95	44.20	0.86	0.39	0.01	0.17	107.30	2.20	1.96	

Date/Time	ID	SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O	LSF	SM	M
06.05.2024 23:44	CR2400948813.20	3.73	2.06	44.06	0.84	0.49	0.08	0.16	103.07	2.26	1.95	
06.05.2024 00:14	CR2400948913.24	3.82	1.89	43.89	0.93	0.47	0.01	0.18	89.91	2.39	2.02	
06.05.2024 00:44	CR2400948413.34	3.49	1.95	43.99	0.68	0.45	0.16	0.16	103.08	2.50	1.89	
06.05.2024 01:14	CR2400948613.40	3.80	1.90	44.12	0.92	0.43	0.04	0.15	102.05	2.35	2.00	
06.05.2024 01:44	CR2400947012.99	3.96	2.02	44.06	0.51	0.43	0.10	0.17	104.02	2.17	1.96	
06.05.2024 02:39	CR2400947212.51	3.56	1.96	44.40	1.01	0.42	0.10	0.13	109.89	2.28	1.83	
06.05.2024 02:44	CR2400947412.42	3.35	1.96	44.49	0.90	0.40	0.06	0.13	111.19	2.34	1.71	
06.05.2024 03:14	CR2400947812.34	3.37	2.01	44.44	0.95	0.40	0.07	0.13	111.81	2.30	1.67	
06.05.2024 03:44	CR2400947912.83	3.72	2.04	44.32	0.95	0.38	0.07	0.14	107.94	2.30	1.82	
06.05.2024 04:49	CR2400948112.89	3.82	2.02	44.17	0.83	0.38	0.13	0.16	104.40	2.19	1.94	
06.05.2024 04:54	CR2400948313.07	3.88	2.02	44.18	0.82	0.39	0.11	0.16	104.02	2.21	1.92	
06.05.2024 05:24	CR2400948512.86	3.23	2.04	44.20	0.87	0.39	0.04	0.17	106.91	2.46	1.58	
06.05.2024 05:54	CR2400948712.93	3.77	2.07	44.28	0.87	0.37	0.13	0.16	105.45	2.22	1.82	
06.05.2024 06:24	CR2400948912.76	3.69	2.13	44.15	0.93	0.39	0.19	0.17	106.84	2.24	1.88	
06.05.2024 06:54	CR2400949313.77	3.65	2.11	44.36	0.90	0.39	0.41	0.15	105.31	2.22	1.73	
06.05.2024 07:24	CR2400949812.74	3.83	2.19	44.16	0.69	0.39	0.11	0.15	107.17	2.24	1.60	
06.05.2024 07:54	CR2400950013.01	3.94	2.16	44.12	0.84	0.39	0.07	0.16	105.00	2.28	1.83	
06.05.2024 08:00	CR2400950212.86	3.92	2.17	44.12	0.84	0.39	0.06	0.15	105.41	2.28	1.82	
06.05.2024 08:30	CR2400950412.66	3.39	2.16	44.11	0.86	0.39	0.16	0.14	107.35	2.28	1.57	
06.05.2024 09:00	CR2400950613.85	3.66	2.16	43.90	0.84	0.39	0.12	0.13	89.89	2.34	1.68	
06.05.2024 09:52	CR2400951013.73	3.49	2.07	43.90	0.88	0.39	0.05	0.11	89.69	2.48	1.60	
06.05.2024 09:59	CR2400951113.25	3.27	2.07	44.23	0.84	0.37	0.11	0.10	104.82	2.56	1.71	
06.05.2024 10:41	CR2400951313.68	3.42	2.09	44.25	0.95	0.37	0.11	0.15	105.62	2.34	1.71	
06.05.2024 11:17	CR2400951712.68	3.30	1.99	44.30	0.89	0.40	0.09	0.13	110.08	2.32	1.61	
06.05.2024 11:47	CR2400952113.05	3.72	2.07	44.18	0.95	0.39	0.19	0.15	104.66	2.26	1.80	
06.05.2024 12:17	CR2400952313.03	3.52	2.09	44.18	1.00	0.41	0.11	0.15	103.85	2.17	1.88	
06.05.2024 12:47	CR2400952512.82	3.68	2.10	44.29	0.99	0.43	0.06	0.16	106.23	2.22	1.75	
06.05.2024 13:17	CR2400952712.40	3.81	2.19	44.25	0.89	0.44	0.04	0.16	105.66	2.17	1.71	
06.05.2024 13:47	CR2400952912.50	3.08	2.13	44.23	1.02	0.41	0.02	0.16	107.32	2.01	1.92	
06.05.2024 14:17	CR2400953112.85	3.77	2.08	44.28	0.86	0.41	0.03	0.15	107.46	2.18	1.81	
06.05.2024 14:47	CR2400953312.47	3.40	1.98	44.50	0.84	0.40	0.03	0.10	110.05	2.32	1.72	
06.05.2024 15:17	CR2400953912.41	3.39	1.95	44.40	0.82	0.37	0.00	0.09	111.19	2.33	1.73	
06.05.2024 16:05	CR2400954112.78	3.42	2.03	44.32	0.82	0.41	0.11	0.11	107.74	2.35	1.69	
06.05.2024 16:10	CR2400954912.94	3.30	2.04	44.23	0.83	0.40	0.06	0.12	106.10	2.34	1.71	
06.05.2024 16:40	CR2400955112.82	3.42	2.00	44.18	0.86	0.41	0.04	0.14	106.38	2.38	1.71	
06.05.2024 17:10	CR2400955912.28	3.37	1.98	44.27	0.89	0.38	0.03	0.14	111.73	2.31	1.72	
06.05.2024 17:40	CR2400956412.68	3.54	2.02	44.23	0.94	0.41	0.05	0.15	107.89	2.29	1.76	
06.05.2024 18:10	CR2400956813.08	3.82	2.01	44.10	0.83	0.40	0.01	0.18	103.62	2.21	1.94	
06.05.2024 18:40	CR2400956812.85	3.82	1.95	44.20	0.86	0.39	0.01	0.17	107.30	2.20	1.96	

Date/Time	ID	SOC	ALMO	Fe2O3	CaO	MgO	SO3	Ba2O	K2O	LSF	SM	IM
07.05.2024 19:00	CR24009801	12.72	0.80	3.94	44.17	1.80	0.40	0.00	0.00	109.64	2.18	1.80
07.05.2024 19:08	CR24009801	13.00	0.79	3.11	44.74	1.95	0.40	0.00	0.00	109.26	2.09	1.80
07.05.2024 19:30	CR24009801	13.30	0.95	3.19	44.07	0.93	0.38	0.00	0.00	107.95	2.09	1.80
07.05.2024 19:50	CR24009801	13.50	1.07	3.30	43.68	0.92	0.30	0.00	0.00	107.45	2.07	1.80
07.05.2024 20:06	CR24009801	14.20	0.75	3.21	44.02	0.90	0.37	0.00	0.00	106.50	2.10	1.77
07.05.2024 20:08	CR24009801	14.10	0.81	3.09	44.28	0.85	0.35	0.00	0.00	118.13	2.10	1.84
07.05.2024 21:10	CR24009801	12.54	1.60	3.42	44.33	0.94	0.34	0.00	0.00	111.57	2.06	1.80
07.05.2024 21:21	CR24009801	12.72	1.82	3.09	44.35	0.30	0.35	0.00	0.00	109.81	2.10	1.84
07.05.2024 22:22	CR24009801	12.80	2.61	2.95	44.41	0.78	0.30	0.00	0.00	107.35	2.23	1.73
07.05.2024 22:53	CR24009801	12.40	2.90	2.95	44.41	0.57	0.34	0.00	0.00	111.88	2.10	1.77
07.05.2024 23:22	CR24009801	12.90	2.00	2.95	44.40	0.30	0.32	0.00	0.00	108.88	2.09	1.80
07.05.2024 23:53	CR24009801	12.84	3.04	2.91	44.14	0.95	0.32	0.00	0.00	107.76	2.14	1.79
07.05.2024 23:59	CR24009801	12.90	3.06	2.95	44.19	0.85	0.34	0.00	0.00	108.98	2.08	1.80
07.05.2024 23:59	CR24009801	12.70	2.85	2.99	44.18	0.65	0.28	0.10	0.10	107.44	2.09	1.79
08.05.2024 00:00	CR24009801	12.80	2.10	2.99	44.08	0.90	0.30	0.00	0.00	104.00	2.05	1.77
08.05.2024 00:01	CR24009801	12.80	2.88	2.88	44.20	0.95	0.34	0.00	0.00	108.00	2.04	1.80
08.05.2024 00:02	CR24009801	12.80	2.42	2.94	44.30	0.82	0.34	0.00	0.00	108.00	2.04	1.80
08.05.2024 00:03	CR24009801	12.80	2.74	2.84	44.30	0.82	0.34	0.00	0.00	103.88	2.04	1.80
08.05.2024 00:04	CR24009801	12.72	2.21	3.51	43.90	0.62	0.34	0.00	0.00	108.76	2.00	1.80
08.05.2024 00:05	CR24009801	12.40	1.79	3.37	44.16	0.85	0.27	0.00	0.00	104.40	2.07	1.80
08.05.2024 00:06	CR24009801	12.40	1.50	3.34	44.20	0.87	0.30	0.00	0.00	104.70	2.07	1.80
08.05.2024 00:07	CR24009801	12.80	1.50	3.34	44.20	0.87	0.30	0.00	0.00	104.70	2.07	1.80
08.05.2024 00:08	CR24009801	12.80	3.62	2.97	44.40	0.80	0.28	0.00	0.00	114.70	2.01	1.80
08.05.2024 00:09	CR24009801	12.30	3.70	2.94	44.10	0.80	0.28	0.00	0.00	111.90	2.10	1.80
08.05.2024 00:10	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:11	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:12	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:13	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:14	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:15	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:16	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:17	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:18	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:19	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:20	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:21	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
08.05.2024 00:22	CR24009801	12.30	4.10	2.80	44.00	0.80	0.28	0.00	0.00	108.20	2.08	1.80
Avg		12.73	3.68	2.97	44.18	0.86	0.32	0.00	0.00	106.98	2.22	1.78
Std		0.38	0.25	0.08	0.17	0.09	0.00	0.00	0.00	3.43	0.12	0.11

09.05.2024 11:53	CR24009816	12.82	3.89	1.95	44.11	0.81	0.29	0.00	0.00	109.30	2.24	1.80
09.05.2024 12:23	CR24009816	12.82	3.32	1.94	44.11	0.74	0.26	0.00	0.00	105.61	2.29	1.80
09.05.2024 12:53	CR24009821	13.17	3.30	1.92	44.11	0.84	0.29	0.00	0.00	107.36	2.44	1.71
09.05.2024 13:23	CR24009823	13.03	3.69	1.94	44.06	0.75	0.28	0.00	0.00	104.88	2.21	2.05
09.05.2024 13:53	CR24009823	13.03	3.49	1.95	44.08	0.83	0.28	0.00	0.00	103.71	2.34	1.90
09.05.2024 14:23	CR24009824	12.85	3.71	1.96	44.11	0.77	0.27	0.00	0.00	105.44	2.42	1.78
09.05.2024 14:53	CR24009826	12.74	3.57	1.96	44.15	0.75	0.27	0.00	0.00	105.85	2.27	1.80
10.05.2024 02:09	CR24009858	12.52	3.38	2.09	44.59	0.80	0.24	0.00	0.00	107.26	2.31	1.83
10.05.2024 02:39	CR24009860	11.45	3.04	1.98	44.54	0.89	0.51	0.00	0.00	109.83	2.23	1.82
10.05.2024 03:27	CR24009861	12.23	3.01	2.02	44.25	1.08	0.83	0.07	0.14	120.65	2.19	1.64
10.05.2024 03:32	CR24009864	12.24	3.12	2.08	44.32	1.02	0.50	0.07	0.16	113.45	2.43	1.49
10.05.2024 04:15	CR24009865	13.20	3.88	2.13	43.74	1.06	0.50	0.03	0.26	112.79	2.35	1.50
10.05.2024 04:21	CR24009867	13.07	4.19	2.19	43.90	1.04	0.53	0.05	0.25	101.96	2.05	1.91
10.05.2024 04:59	CR24009869	11.99	3.51	2.04	44.28	0.95	0.53	0.04	0.20	113.43	2.46	1.72
10.05.2024 05:03	CR24009870	12.20	3.54	2.04	44.36	0.94	0.51	0.07	0.19	111.88	2.19	1.74
10.05.2024 05:14	CR24009872	12.67	3.57	2.09	44.23	0.98	0.52	0.09	0.20	107.73	2.24	1.71
10.05.2024 05:44	CR24009874	13.49	3.52	2.16	44.03	0.98	0.62	0.16	0.21	101.62	2.38	1.63
10.05.2024 06:14	CR24009876	12.77	3.76	2.05	44.11	0.95	0.50	0.05	0.20	106.20	2.20	1.82
10.05.2024 06:44	CR24009878	12.66	3.79	2.01	44.19	1.01	0.52	0.10	0.24	109.24	2.18	1.88
10.05.2024 07:14	CR24009882	12.81	4.11	2.09	44.16	0.97	0.51	0.08	0.24	104.96	2.07	1.87
10.05.2024 07:44	CR24009884	12.73	3.64	2.15	44.26	1.00	0.51	0.09	0.20	107.12	2.20	1.89
10.05.2024 08:14	CR24009886	12.64	3.78	2.22	44.29	0.99	0.51	0.08	0.20	107.31	2.11	1.82
10.05.2024 08:44	CR24009888	12.64	3.85	2.19	44.24	0.95	0.47	0.13	0.20	107.22	2.09	1.76
10.05.2024 09:14	CR24009890	12.95	3.42	2.11	44.35	1.05	0.51	0.12	0.20	106.44	2.34	1.62
10.05.2024 09:44	CR24009892	12.84	3.99	2.11	44.29	0.97	0.53	0.07	0.18	105.39	2.11	1.89
Avg		12.73	3.68	2.07	44.18	0.86	0.32	0.00	0.00	106.98	2.22	1.78
Std		0.38	0.25	0.08	0.17	0.09	0.00	0.00	0.00	3.43	0.12	0.11



LAMPIRAN 2 : KONVERSI HASIL KOMPOSISI SAMPEL

Tanggal	Waktu	SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O
05/05/2024	23:44:00	13,2	3,79	2,05	44,06	0,84	0,49	0,08	0,16
06/05/2024	00:14:00	13,64	3,82	1,89	43,89	0,93	0,47	0,01	0,18
06/05/2024	00:44:00	13,34	3,49	1,85	43,99	0,88	0,45	0,16	0,16
06/05/2024	01:14:00	13,4	3,8	1,9	44,12	0,92	0,43	0,04	0,15
06/05/2024	01:44:00	12,99	3,96	2,02	44,06	0,91	0,43	0,1	0,17
06/05/2024	02:39:00	12,51	3,55	1,95	44,4	1,01	0,42	0,1	0,13
06/05/2024	02:44:00	12,42	3,35	1,96	44,49	0,9	0,4	0,06	0,13
06/05/2024	03:14:00	12,34	3,37	2,01	44,4	0,95	0,4	0,07	0,13
06/05/2024	03:44:00	12,63	3,72	2,04	44,32	0,95	0,38	0,07	0,14
06/05/2024	04:49:00	12,99	3,92	2,02	44,17	0,89	0,38	0,13	0,16
06/05/2024	04:54:00	13,07	3,88	2,02	44,18	0,82	0,39	0,11	0,16
06/05/2024	05:24:00	12,98	3,23	2,04	44,2	0,87	0,39	0,04	0,17
06/05/2024	05:54:00	12,93	3,77	2,07	44,28	0,87	0,37	0,13	0,16
06/05/2024	06:24:00	12,78	3,59	2,13	44,15	0,93	0,39	0,15	0,17
06/05/2024	06:54:00	12,77	3,65	2,11	44,26	0,9	0,39	0,11	0,15
06/05/2024	07:24:00	12,74	3,49	2,19	44,15	0,89	0,39	0,11	0,15
06/05/2024	07:54:00	13,01	3,54	2,18	44,12	0,84	0,39	0,07	0,16
06/05/2024	08:00:00	12,96	3,52	2,17	44,12	0,94	0,39	0,06	0,15
06/05/2024	08:30:00	12,66	3,39	2,16	44,11	0,96	0,39	0,16	0,14
06/05/2024	09:00:00	13,65	3,66	2,18	4,39	0,94	0,39	0,12	0,13
06/05/2024	09:52:00	13,79	3,48	2,07	43,93	0,88	0,39	0,05	0,11
06/05/2024	09:58:00	13,25	3,27	1,91	44,23	0,89	0,37	0,11	0,1
06/05/2024	10:41:00	12,68	3,42	2	44,35	0,95	0,4	0,14	0,11
06/05/2024	11:17:00	12,58	3,2	1,99	44,36	0,89	0,4	0,08	0,13
06/05/2024	11:47:00	13,05	3,72	2,07	44,18	0,95	0,39	0,19	0,15
06/05/2024	12:17:00	13,03	3,92	2,09	44,13	1,01	0,41	0,11	0,16
06/05/2024	12:47:00	12,82	3,68	2,1	44,2	0,99	0,43	0,08	0,16
06/05/2024	13:17:00	12,4	3,61	2,11	44,25	0,99	0,44	0,04	0,16
06/05/2024	13:47:00	12,5	4,09	2,13	44,23	1,02	0,41	0,02	0,16
06/05/2024	14:17:00	12,65	3,77	2,08	44,29	0,9	0,41	0,03	0,15
06/05/2024	14:47:00	12,47	3,4	1,98	44,5	0,94	0,4	0,03	0,1
06/05/2024	15:17:00	12,41	3,38	1,95	44,48	0,92	0,37	0	0,09
06/05/2024	16:05:00	12,78	3,42	2,03	44,32	0,92	0,41	0,11	0,11
06/05/2024	16:10:00	12,94	3,5	2,04	44,23	0,93	0,4	0,06	0,12
06/05/2024	16:40:00	12,92	3,42	2	44,18	0,98	0,41	0,04	0,14
06/05/2024	17:10:00	12,28	3,37	1,96	44,27	0,88	0,38	0,03	0,14
06/05/2024	17:40:00	12,68	3,54	2,02	44,23	0,94	0,41	0,05	0,15
06/05/2024	18:10:00	13,08	3,92	2,01	44,1	0,93	0,4	-0,01	0,18
06/05/2024	18:40:00	12,65	3,82	1,95	44,2	0,96	0,39	0,01	0,17
06/05/2024	19:10:00	11,85	3,25	2,08	44,75	0,95	0,4	0,04	0,11
06/05/2024	19:40:00	12,51	4,15	2,37	44,15	0,93	0,42	0,1	0,17
06/05/2024	20:33:00	12,65	3,52	2,25	44,01	0,98	0,41	0,04	0,17

06/05/2024	20:39:00	12,68	3,57	2,15	44,24	0,93	0,4	0,05	0,14
06/05/2024	21:09:00	12,86	3,81	1,94	44,12	0,91	0,4	0,05	0,14
06/05/2024	21:39:00	13,08	3,46	1,88	44,08	0,91	0,39	0	0,13
06/05/2024	22:09:00	12,98	3,45	1,88	44,06	0,86	0,4	0,01	0,13
06/05/2024	22:39:00	12,86	3,5	2,02	44,1	0,9	0,4	0,02	0,14
06/05/2024	23:09:00	13,27	3,17	1,94	44,08	0,85	0,38	-0,01	0,13
07/05/2024	05:43:00	12,75	3,31	2,02	44,02	0,91	0,45	0	0,16
07/05/2024	07:08:00	13,01	3,39	2,33	43,77	0,8	0,43	-0,11	0,17
07/05/2024	07:39:00	12,6	3,94	2,13	44,09	0,91	0,41	-0,05	0,18
07/05/2024	08:20:00	13,17	3,36	1,9	44,33	0,98	0,41	0,01	0,17
07/05/2024	09:25:00	13,4	3,08	1,81	44,03	0,91	0,41	0	0,13
07/05/2024	09:31:00	13,06	3,45	1,79	44,39	0,92	0,43	-0,05	0,13
07/05/2024	10:01:00	12,4	3,43	1,94	44,41	0,96	0,49	0,08	0,17
07/05/2024	10:31:00	12,3	3,91	2,01	44,36	0,9	0,48	0,01	0,19
07/05/2024	11:20:00	12,87	3,19	2,02	44,21	0,94	0,5	0,09	0,18
07/05/2024	11:26:00	12,58	3,72	1,98	44,33	0,92	0,48	0,09	0,18
07/05/2024	12:01:00	12,5	3,68	1,96	44,33	0,92	0,48	0,09	0,16
07/05/2024	12:07:00	12,71	2,78	2,04	44,23	0,87	0,47	0	0,14
07/05/2024	12:36:00	13,11	3,43	2,09	44,07	0,87	0,47	0,05	0,15
07/05/2024	12:42:00	13,07	3,49	2,12	43,96	0,84	0,5	0,02	0,19
07/05/2024	13:12:00	12,75	3,34	2,02	44,15	0,81	0,51	-0,01	0,17
07/05/2024	13:42:00	12,41	3,62	1,93	44,35	0,86	0,51	0,06	0,15
07/05/2024	14:42:00	12,42	3,43	2,07	44,2	1,13	0,52	0,25	0,18
07/05/2024	15:14:00	12,12	3,25	1,89	44,54	0,97	0,53	0,12	0,13
07/05/2024	16:59:00	12,38	3,26	2,23	44,27	0,86	0,55	-0,05	0,17
07/05/2024	17:41:00	12,31	3,48	1,99	44,33	0,99	0,41	-0,1	0,18
07/05/2024	18:00:00	12,72	3,8	2,04	44,17	1	0,4	-0,03	0,2
07/05/2024	18:06:00	13,01	4,37	2,11	44,11	1,05	0,41	-0,03	0,2
07/05/2024	18:36:00	12,34	3,95	2,19	44,02	0,93	0,36	-0,06	0,21
07/05/2024	19:06:00	13,67	4,27	2,34	43,56	0,92	0,39	-0,05	0,27
07/05/2024	19:36:00	12,65	3,78	2,21	44,02	0,9	0,37	-0,02	0,18
07/05/2024	20:06:00	11,87	3,45	2,11	44,54	0,86	0,35	0,01	0,15
07/05/2024	20:36:00	12,15	3,82	2,09	44,5	0,84	0,34	0,03	0,16
07/05/2024	21:18:00	12,54	3,69	2,12	44,33	0,82	0,34	-0,03	0,17
07/05/2024	21:23:00	12,72	3,62	2,09	44,35	0,8	0,35	-0,04	0,18
07/05/2024	21:53:00	12,28	3,51	2,05	44,41	0,78	0,33	0	0,17
07/05/2024	22:23:00	12,06	3,09	2,05	44,4	0,83	0,33	0,04	0,17
07/05/2024	22:53:00	12,46	3,94	2,05	44,4	0,83	0,33	0,04	0,17
07/05/2024	23:23:00	12,6	3,79	2,11	44,3	0,86	0,32	-0,02	0,17
07/05/2024	23:53:00	12,63	3,98	2,11	44,14	0,85	0,33	-0,02	0,19
08/05/2024	00:23:00	12,53	3,99	2,05	44,19	0,85	0,34	0,06	0,18
08/05/2024	00:53:00	12,7	3,85	2,09	44,13	0,85	0,35	0,13	0,19
08/05/2024	01:23:00	13,08	3,7	2,09	44,06	0,9	0,32	0,05	0,2
08/05/2024	01:53:00	13,07	3,49	2,1	44,24	0,82	0,34	0,05	0,19
08/05/2024	02:23:00	13,22	3,42	2,04	43,93	0,91	0,34	0,01	0,17

08/05/2024	02:53:00	13,31	3,75	2,04	43,99	0,93	0,36	0,01	0,15
08/05/2024	03:23:00	13,72	3,31	1,91	43,8	0,82	0,34	0	0,18
08/05/2024	04:12:00	13,05	3,78	1,97	44,15	0,83	0,37	0,03	0,14
08/05/2024	04:18:00	12,46	3,53	1,95	44,27	0,84	0,36	-0,01	0,15
08/05/2024	04:48:00	12,01	3,26	1,94	44,46	0,82	0,31	0,04	0,17
08/05/2024	05:18:00	12,05	3,62	1,87	44,46	0,86	0,28	0,06	0,18
08/05/2024	16:28:00	12,39	3,7	2,01	44,1	0,66	0,5	-0,06	0,24
08/05/2024	16:33:00	12,84	4,18	2,08	44,03	0,92	0,45	-0,03	0,25
08/05/2024	17:15:00	12,97	3,68	2,02	44,21	0,9	0,38	-0,02	0,19
08/05/2024	17:29:00	12,65	3,75	2,05	44,26	0,82	0,38	-0,06	0,18
08/05/2024	17:51:00	12,67	3,5	2,1	44,24	0,81	0,36	-0,05	0,16
08/05/2024	17:57:00	12,7	3,72	2,06	44,15	0,97	0,35	-0,05	0,17
08/05/2024	18:27:00	12,52	3,77	2,19	44,22	0,81	0,36	-0,04	0,15
08/05/2024	19:27:00	12,48	3,82	2,15	44,33	0,86	0,33	0,01	0,16
08/05/2024	19:57:00	12,57	3,46	2,2	44,29	2,69	0,33	0,01	0,17
08/05/2024	20:27:00	13,05	3,74	2,09	44,16	0,81	0,33	-0,01	0,15
08/05/2024	20:57:00	13,07	3,76	2,08	44,14	0,8	0,33	-0,03	0,15
08/05/2024	21:27:00	12,42	3,6	2,06	44,22	0,88	0,31	-0,06	0,14
08/05/2024	21:57:00	13,05	3,6	2,08	44,2	0,84	0,3	-0,06	0,14
08/05/2024	22:27:00	12,89	3,83	2,18	44,11	0,74	0,32	0,01	0,13
08/05/2024	22:57:00	12,72	3,61	2,16	44,2	0,84	0,3	0,01	0,13
08/05/2024	23:27:00	12,85	3,97	2,16	44,23	0,76	0,32	-0,04	0,14
08/05/2024	23:57:00	12,64	3,89	2,2	44,17	0,84	0,31	-0,02	0,14
09/05/2024	00:27:00	12,51	3,6	2,18	44,22	0,78	0,33	-0,04	0,16
09/05/2024	00:57:00	12,58	4,01	2,21	44,18	0,81	0,35	-0,01	0,18
09/05/2024	01:27:00	12,55	4,04	2,15	44,15	0,81	0,38	-0,05	0,18
09/05/2024	01:57:00	12,81	3,52	2,12	44,1	0,82	0,35	-0,01	0,18
09/05/2024	02:27:00	12,63	3,36	2,11	44,05	0,83	0,35	-0,03	0,16
09/05/2024	02:57:00	12,98	3,72	2,17	44,07	0,75	0,34	-0,08	0,16
09/05/2024	03:27:00	13,01	3,84	2,14	44,03	0,83	0,36	-0,03	0,16
09/05/2024	03:57:00	13,05	3,74	2,11	43,99	0,72	0,33	-0,02	0,16
09/05/2024	04:27:00	12,96	3,86	2,07	44,09	0,8	0,33	-0,1	0,17
09/05/2024	05:47:00	12,77	3,72	2,08	44,12	0,78	0,33	-0,02	0,17
09/05/2024	06:10:00	12,87	3,61	2,05	44,14	0,86	0,32	-0,04	0,18
09/05/2024	06:17:00	12,54	3,58	2,07	44,07	0,77	0,31	0,01	0,18
09/05/2024	06:23:00	12,75	3,47	2,06	44,12	0,8	0,31	-0,04	0,16
09/05/2024	06:53:00	12,97	3,39	2,05	44,05	0,8	0,29	-0,06	0,16
09/05/2024	07:23:00	13,11	3,35	2,07	44,05	0,76	0,3	0,03	0,14
09/05/2024	07:53:00	12,82	3,375	2,03	44,06	0,77	0,3	-0,08	0,14
09/05/2024	08:23:00	13,4	3,31	2,03	44,12	0,83	0,32	-0,02	0,17
09/05/2024	08:53:00	12,87	3,71	2,02	44,1	0,75	0,28	0,01	0,16
09/05/2024	09:23:00	12,79	3,54	2	44,17	0,86	0,29	-0,01	0,16
09/05/2024	09:53:00	12,53	3,51	1,98	44,19	0,82	0,28	0	0,17
09/05/2024	10:23:00	12,54	3,39	1,93	44,22	0,71	0,3	-0,01	0,15
09/05/2024	10:53:00	12,91	3,79	1,96	44,2	0,83	0,3	-0,01	0,14

09/05/2024	11:23:00	12,91	3,69	1,95	44,11	0,81	0,29	-0,08	0,13
09/05/2024	11:53:00	12,82	3,32	1,94	44,11	0,74	0,28	0	0,13
09/05/2024	12:23:00	12,92	3,93	1,92	44,11	0,84	0,29	0,01	0,14
09/05/2024	12:53:00	13,17	3,69	1,94	44,06	0,75	0,28	-0,04	0,14
09/05/2024	13:23:00	13,03	3,43	1,95	44,08	0,83	0,28	0,03	0,15
09/05/2024	13:53:00	12,85	3,71	1,96	44,11	0,77	0,27	-0,03	0,15
09/05/2024	14:23:00	12,47	3,57	1,96	44,15	0,75	0,27	-0,04	0,17
10/05/2024	02:09:00	12,52	3,38	2,09	44,39	0,8	0,34	0,09	0,13
10/05/2024	02:39:00	11,45	3,24	1,98	44,84	0,89	0,51	0,1	0,07
10/05/2024	03:27:00	12,23	3,01	2,02	44,35	1,08	0,53	0,07	0,14
10/05/2024	03:32:00	12,24	3,12	2,08	44,32	1,02	0,5	0,07	0,16
10/05/2024	04:15:00	13,2	3,88	2,13	43,74	1,06	0,5	0,03	0,26
10/05/2024	04:21:00	13,07	4,19	2,19	43,8	1,04	0,53	0,05	0,25
10/05/2024	04:59:00	11,99	3,51	2,04	44,28	0,95	0,53	0,04	0,2
10/05/2024	05:08:00	12,2	3,54	2,04	44,36	0,94	0,051	0,07	0,19
10/05/2024	05:14:00	12,67	3,57	2,09	44,23	0,98	0,52	-0,03	0,2
10/05/2024	05:44:00	13,49	3,52	2,16	44,02	0,99	0,52	0,16	0,21
10/05/2024	06:14:00	12,77	3,76	2,06	44,11	0,95	0,5	0,05	0,2
10/05/2024	06:44:00	12,66	3,79	2,01	44,19	1,01	0,52	0,01	0,21
10/05/2024	07:14:00	12,81	4,11	2,09	44,16	0,97	0,51	0,09	0,21
10/05/2024	07:44:00	12,73	3,64	2,15	44,28	1	0,51	0,09	0,2
10/05/2024	08:14:00	12,64	3,76	2,22	44,29	0,99	0,51	0,08	0,2
10/05/2024	08:44:00	12,61	3,85	2,19	44,24	0,95	0,47	0,13	0,2
10/05/2024	09:14:00	12,95	3,42	2,11	44,35	1,05	0,51	0,12	0,2
10/05/2024	09:44:00	12,84	3,99	2,11	44,29	0,97	0,53	-0,07	0,18
10/05/2024	10:14:00	13,49	3,45	2,13	43,77	0,94	0,56	0,7	0,19
10/05/2024	10:44:00	13,04	3,39	2,08	44,18	1,09	0,56	0,13	0,18
10/05/2024	11:14:00	12,49	3,59	1,95	44,25	1,09	0,54	0,09	0,16
10/05/2024	11:44:00	12,95	3,63	1,94	44,21	1,02	0,52	0,08	0,16
10/05/2024	12:14:00	13,18	3,69	1,91	44,11	1,03	0,51	0	0,17
10/05/2024	12:44:00	12,74	3,4	1,91	44,05	0,95	0,51	0,05	0,16
10/05/2024	13:14:00	13,23	3,07	1,98	44,18	1,18	0,52	0,08	0,16
10/05/2024	13:44:00	12,78	3,5	2,06	44,14	1,14	0,5	0,1	0,16
10/05/2024	14:14:00	13,05	3,49	2,16	44,14	1,1	0,5	0,08	0,17
10/05/2024	14:44:00	12,94	3,47	2,17	44,04	1,11	0,5	0,07	0,21
10/05/2024	15:14:00	13,37	3,81	2,18	44,03	1,14	0,5	0,09	0,22
10/05/2024	15:44:00	13,56	3,66	2,14	44,03	1,05	0,49	0,11	0,21
10/05/2024	16:33:00	13,49	3,36	2,03	44,11	1,13	0,51	0,08	0,21
10/05/2024	16:39:00	12,72	3,5	2,01	44,16	1,07	0,51	0,08	0,21
10/05/2024	17:09:00	12,76	3,75	1,97	44,21	1,16	0,52	0,08	0,22
10/05/2024	17:39:00	12,58	3,8	2,01	44,13	1,12	0,55	0,12	0,23
10/05/2024	18:09:00	12,95	3,67	1,97	44,15	1,19	0,52	0,06	0,23
10/05/2024	18:39:00	13,22	3,62	2,09	44,1	1,05	0,54	0,06	0,23
10/05/2024	19:09:00	13,07	3,5	2,01	44,29	1,05	0,55	0,07	0,21
10/05/2024	19:39:00	12,11	3,86	2,05	44,34	1,05	0,58	0,07	0,21

10/05/2024	20:09:00	12,36	3,51	2,12	44,29	1,08	0,6	0,06	0,22
10/05/2024	20:39:00	13,11	3,82	2,31	44,01	1,13	0,6	0,08	0,25
10/05/2024	21:09:00	12,9	3,77	2,31	43,95	1,19	0,59	0,09	0,26
10/05/2024	21:39:00	12,7	3,71	2,18	44,11	1,08	0,58	0,07	0,24
10/05/2024	22:09:00	12,5	3,83	2,14	44,11	1,2	0,58	0,09	0,25
10/05/2024	22:39:00	12,27	3,79	2,12	44,11	1,16	0,57	0,06	0,25
10/05/2024	23:09:00	12,37	3,75	2,06	44,18	1,15	0,55	0,09	0,24
10/05/2024	23:38:00	12,51	3,65	2,04	44,24	1,1	0,55	0,08	0,23
10/05/2024	23:46:00	12,94	3,47	2,02	44,04	1,07	0,53	0,07	0,22
11/05/2024	00:16:00	12,48	3,71	2,07	44,13	1,18	0,54	0,09	0,22
11/05/2024	00:46:00	12,19	3,7	2,12	44,16	1,27	0,56	0,68	0,25
11/05/2024	01:16:00	12,57	3,96	2,17	44,02	1,21	0,57	0,09	0,26
11/05/2024	01:46:00	12,89	3,62	2,2	44,05	1,2	0,58	0,08	0,23
11/05/2024	02:16:00	13,24	3,38	2,09	43,9	1,12	0,57	0,12	0,24
11/05/2024	02:46:00	13,29	3,63	2,08	44,01	1,18	0,56	0,05	0,24
11/05/2024	03:16:00	12,65	3,66	2,02	44,04	1,17	0,58	0,08	0,23
11/05/2024	03:46:00	12,94	3,66	2,06	44,04	1,08	0,58	0,02	0,24
11/05/2024	04:16:00	12,81	3,61	2,08	44,02	1,08	0,59	0,08	0,25
11/05/2024	04:46:00	13,01	3,56	2,08	44	1,22	0,6	0,11	0,26
11/05/2024	05:16:00	12,65	3,63	2,05	44	1,09	0,58	0,09	0,26
11/05/2024	05:46:00	13,04	3,87	2,04	44,02	1,04	0,59	0,08	0,25
11/05/2024	06:16:00	13,16	3,88	2,04	43,49	1,14	0,59	0,09	0,25
11/05/2024	06:46:00	13,12	3,53	2,03	44,07	1,11	0,59	0,07	0,23
11/05/2024	07:16:00	12,58	3,57	2,06	44,11	1,1	0,59	0,09	0,22
11/05/2024	07:46:00	13,45	3,55	2,08	44,08	1,12	0,61	0,05	0,22
11/05/2024	08:16:00	12,66	3,81	2,03	44,01	1,13	0,59	0,07	0,22
11/05/2024	08:46:00	12,36	3,48	2	44,16	1,11	0,65	0,06	0,22
11/05/2024	09:16:00	12,34	3,64	1,99	44,18	1,04	0,61	0,08	0,22
11/05/2024	09:46:00	12,94	3,68	2,01	44,06	1,13	0,63	0,05	0,23
11/05/2024	10:16:00	12,52	3,88	2,01	44,07	1,11	0,6	0,09	0,23
11/05/2024	10:46:00	13,25	3,57	1,99	44,05	1,13	0,62	0,08	0,23
11/05/2024	11:16:00	12,87	3,53	2,02	44,04	1,08	0,59	0,09	0,25
11/05/2024	11:46:00	12,81	3,61	1,96	44,16	1,19	0,57	0,07	0,23
11/05/2024	12:16:00	13,1	3,59	1,97	44,12	1,09	0,58	0,09	0,23
11/05/2024	12:46:00	12,76	3,25	2,01	44,06	1,1	0,57	0,05	0,23
11/05/2024	13:16:00	12,64	3,5	1,95	44,2	1,1	0,59	0,1	0,22
11/05/2024	13:46:00	12,96	3,44	2,02	43,99	1,08	0,57	0,07	0,23
11/05/2024	14:16:00	13,3	3,62	2	43,98	1,13	0,58	0,08	0,23
11/05/2024	14:46:00	13,2	3,6	1,99	44,05	1,15	0,58	0,06	0,22
11/05/2024	15:16:00	13,06	3,34	1,96	44,14	1,04	0,57	0,1	0,21
11/05/2024	15:46:00	12,62	3,54	1,93	44,13	1,09	0,59	0,09	0,2
11/05/2024	16:16:00	12,96	3,46	1,98	44,08	1,11	0,57	0,05	0,2
11/05/2024	16:46:00	12,97	3,38	1,97	44,12	1,16	0,55	0,08	0,2
11/05/2024	17:16:00	12,9	3,43	1,91	44,15	1,08	0,55	0,08	0,2
11/05/2024	17:46:00	12,59	3,46	1,88	44,18	1,17	0,57	0,09	0,2

11/05/2024	18:16:00	12,65	3,59	1,9	44,17	1,2	0,56	0,05	0,2
11/05/2024	18:46:00	13,04	3,7	1,95	44,11	1,17	0,59	0,06	0,21
11/05/2024	19:16:00	12,71	3,32	1,99	44,08	1,11	0,58	0,06	0,21
11/05/2024	19:46:00	12,83	3,67	1,95	44,17	1,15	0,58	0,05	0,2
11/05/2024	20:16:00	12,01	3,31	1,86	44,56	1,18	0,5	0,08	0,17
11/05/2024	20:46:00	12,19	3,23	1,8	44,6	1,26	0,45	0,05	0,19
11/05/2024	21:15:00	11,52	3,34	1,69	44,64	1,28	0,41	0,06	0,19
11/05/2024	21:21:00	12,7	3,33	1,7	44,56	1,37	0,4	0,06	0,19
11/05/2024	21:51:00	12,6	3,46	1,85	44,34	1,23	0,41	0,06	0,2
11/05/2024	22:21:00	12,53	3,37	2,04	44,32	1,26	0,41	0,07	0,2
11/05/2024	22:51:00	12,67	3,45	2,12	44,09	1,3	0,44	0,06	0,22
11/05/2024	23:21:00	12,77	3,49	2,08	44,01	1,36	0,44	0,09	0,24
11/05/2024	23:51:00	12,69	3,49	2,08	44,1	1,3	0,44	0,09	0,25
12/05/2024	00:21:00	13,57	3,6	2,35	43,6	1,28	0,45	0,07	0,29
12/05/2024	00:51:00	12,88	3,52	2,16	43,92	1,28	0,42	0,07	0,28
12/05/2024	01:21:00	12,93	3,85	2,29	43,83	1,36	0,45	0,08	0,28
12/05/2024	01:51:00	12,77	3,64	2,22	43,89	1,35	0,46	0,08	0,29
12/05/2024	02:21:00	12,21	3,82	2,2	43,9	1,34	0,46	0,08	0,29
12/05/2024	02:51:00	12,65	3,85	2,16	43,88	1,37	0,45	0,07	0,28
12/05/2024	03:21:00	12,91	3,74	2,19	43,89	1,43	0,46	0,07	0,28
12/05/2024	03:51:00	12,44	3,7	2,18	43,99	1,37	0,45	0,07	0,26
12/05/2024	04:21:00	13,06	3,95	2,11	44,1	1,4	0,43	0,05	0,26
12/05/2024	04:51:00	12,24	3,9	2,1	44,01	1,28	0,45	0,07	0,27
12/05/2024	05:21:00	12,09	3,73	2	44,31	1,43	0,44	0,1	0,23
12/05/2024	05:51:00	12,79	3,58	2,05	44,15	1,45	0,43	0,06	0,25
12/05/2024	06:21:00	12,39	3,77	2,02	44,19	1,35	0,43	0,06	0,23
12/05/2024	06:51:00	12,1	3,62	1,99	44,29	1,41	0,42	0,03	0,21
12/05/2024	07:21:00	12,77	3,56	1,98	44,22	1,39	0,41	0,09	0,21
12/05/2024	07:51:00	12,77	3,62	2,01	44,08	1,2	0,43	0,09	0,22
12/05/2024	08:21:00	13,15	3,56	2,04	44,11	1,3	0,42	0,13	0,21
12/05/2024	08:51:00	12,67	3,65	2,06	44,12	1,36	0,41	0,09	0,21
12/05/2024	09:21:00	11,97	3,75	2,01	44,2	1,35	0,41	0,1	0,21
12/05/2024	10:09:00	12,64	3,48	2,01	44,2	1,31	0,43	0,07	0,22
12/05/2024	10:15:00	12,17	3,19	2,03	44,22	1,38	0,43	0,1	0,22
12/05/2024	11:09:00	12,07	3,22	2,08	44,37	1,38	0,44	0,07	0,22
12/05/2024	11:15:00	11,19	3,76	2,05	44,24	1,4	0,44	0,11	0,22
12/05/2024	12:05:00	13,42	3,86	2,08	43,77	1,38	0,42	0,08	0,29
12/05/2024	12:11:00	13,04	3,55	2,09	43,92	1,28	0,49	0,1	0,27
12/05/2024	12:59:00	12,58	3,37	1,94	44,2	1,31	0,42	0,12	0,24
12/05/2024	13:05:00	12,64	3,62	2,05	44,11	1,4	0,44	0,09	0,24
12/05/2024	13:35:00	12,78	3,49	2,05	44,03	1,22	0,42	0,09	0,24
12/05/2024	14:05:00	13,04	3,58	2,02	44,03	1,27	0,42	0,09	0,23
12/05/2024	14:35:00	12,96	3,51	2	44,02	1,39	0,43	0,1	0,22
12/05/2024	15:05:00	12,91	3,53	1,9	44,07	1,3	0,44	0,08	0,21
12/05/2024	15:35:00	12,61	3,62	1,97	45,08	1,28	0,44	0,11	0,22

12/05/2024	16:35:00	12,86	3,34	2,1	44,1	1,38	0,41	0,09	0,22
12/05/2024	17:05:00	12,82	3,34	2,11	44,06	1,34	0,42	0,06	0,22
12/05/2024	17:35:00	13,15	3,41	2,07	44,04	1,31	0,42	0,07	0,22
12/05/2024	18:05:00	12,91	3,48	2,02	44,16	1,31	0,42	0,06	0,22
12/05/2024	18:35:00	12,87	3,52	2,03	44,15	1,31	0,43	0,06	0,22
12/05/2024	19:05:00	12,69	3,67	2,02	44,28	1,35	0,41	0,1	0,24
12/05/2024	20:05:00	12,84	3,61	2,04	44,18	1,34	0,42	0,08	0,24
12/05/2024	20:35:00	12,76	3,7	2,08	44,21	1,32	0,43	0,11	0,23
12/05/2024	21:35:00	12,03	3,48	2,1	44,15	1,33	0,43	0,08	0,23
12/05/2024	22:05:00	12,82	3,27	2,14	44,17	1,35	0,41	0,07	0,23
12/05/2024	23:15:00	12,58	3,34	2,01	44,12	1,43	0,45	0,11	0,23
12/05/2024	23:51:00	13,06	3,72	2,04	44,02	1,4	0,43	0,06	0,24
13/05/2024	00:21:00	12,84	3,7	1,97	43,96	1,26	0,43	0,1	0,24
14/05/2024	02:21:00	12,38	3,69	2,06	44,08	1,3	0,43	0,11	0,26
13/05/2024	03:05:00	12,96	3,55	2,12	44,02	1,36	0,43	0,12	0,26
13/05/2024	03:35:00	12,36	3,6	2,11	44,04	1,34	0,44	0,09	0,27
13/05/2024	04:05:00	12,19	3,58	2,06	44,11	1,38	0,45	0,1	0,25
13/05/2024	04:35:00	12,58	3,38	2,02	44,07	1,32	0,43	0,09	0,28
13/05/2024	05:05:00	12,57	3,55	1,99	44,03	1,36	0,41	0,12	0,27
13/05/2024	05:35:00	12,66	3,66	2,03	43,95	1,36	0,41	0,12	0,27
13/05/2024	06:05:00	13,63	3,5	2	43,97	1,37	0,4	0,9	0,27
13/05/2024	06:35:00	12,69	3,72	2,03	43,93	1,27	0,4	0,11	0,28
13/05/2024	07:05:00	12,39	3,54	2	44,11	1,41	0,41	0,1	0,27
13/05/2024	07:35:00	12,29	3,56	2,07	43,98	1,33	0,47	0,09	0,28
13/05/2024	08:05:00	12,54	3,41	2,09	43,91	1,34	0,42	0,09	0,27
13/05/2024	08:35:00	12,14	3,58	1,92	44,01	1,28	0,43	0,11	0,25
13/05/2024	09:05:00	12,81	3,58	1,95	44,03	1,44	0,43	0,06	0,22
13/05/2024	09:35:00	12,74	3,39	1,9	43,9	1,26	0,41	0,07	0,2
13/05/2024	10:05:00	12,81	3,42	2	44,03	1,25	0,42	0,06	0,2
13/05/2024	10:35:00	12,82	3,63	2,12	43,95	1,33	0,44	0,09	0,23
13/05/2024	11:35:00	13,57	3,56	1,99	43,99	1,39	0,43	0,06	0,23
13/05/2024	12:05:00	13,4	3,56	2	43,96	1,32	0,44	0,1	0,21

LAMPIRAN 3 : BARIS KODE LSTM DAN ANN

3.1 BARIS KODE LSTM

```

% Membaca data dari file Excel
% data Training
Xtrain= xlsread('Data Input.xlsx',4, 'A2:I60');

Ytrain= xlsread('Data Input.xlsx',4, 'I70:I128');

% Membaca data dari file Excel
% data Testing
Xtest = xlsread('Data Input.xlsx',4, 'A70:I128'); % Data input untuk
testing

Ytest = xlsread('Data Input.xlsx',4, 'I129:I187'); % Data target untuk
testing

% mengubah format cell

XtrainCell = mat2cell(Xtrain, size(Xtrain, 1), ones(1, size(Xtrain, 2)));
YtrainCell = mat2cell(Ytrain, size(Ytrain, 1), ones(1, size(Ytrain, 2)));
XtestCell = mat2cell(Xtest, size(Xtest, 1), ones(1, size(Xtest, 2)));
YtestCell = mat2cell(Ytest, size(Ytest, 1), ones(1, size(Ytest, 2)));

% definisikan LSTM arc

inputSize = 9;

numResponses = 1;

numHiddenUnits = 400;

dropoutProb = 0.1;

layers = [ sequenceInputLayer(inputSize)

          lstmLayer(numHiddenUnits)

          dropoutLayer(0)

          fullyConnectedLayer(numResponses)

          regressionLayer];

opts = trainingOptions('adam',...
    'InitialLearnRate', 0.001, ...
    'MaxEpochs', 1000, ...
    'MiniBatchSize', 64, ...
    'Verbose', true, ...
    'ValidationData', {Xtest, Ytest}, ...
    'Plots', 'training-progress');

% Melatih Jaringan
net = trainNetwork(Xtrain, Ytrain, layers, opts);

```

```

% Prediksi
Ypred = predict(net, Xtest);

plotregression(Ytest, Ypred);

% Validasi RMSE
figure,
rmse = sqrt(mean((Ypred - Ytest).^2));

disp(['RMSE: ', num2str(rmse)]);

histogram(Ytest - Ypred)
title("RMSE = " + rmse)
ylabel("Frequency")
xlabel("Error")

% Validasi MAE
MAE = mean(abs(Ytest - Ypred));

% Menampilkan hasil
figure,
plot(Ypred, 'r-*, 'LineWidth',1),hold on
plot(Ytest, 'g-*, 'LineWidth',1) , hold all;
xlabel('Jumlah Sample')
ylabel('Kadar Kimia')
grid on
legend('Prediksi','Aktual');
disp(['MAE: ', num2str(MAE)]);
title("MAE = " + MAE)

% Memasukan hasil prediksi ke dalam file excel
Ypred = Ypred(:);
predictionsTabel = tabel(Ypred, 'VariableNames', {'Predictions'});
writetabel(predictionsTabel, 'K20.xlsx');

```

3.2 BARIS KODE ANN

```

Data = xlsread('Data Input.xlsx', 5, 'A2:G81');
Data2 = xlsread('Data Input.xlsx', 5, 'A82:G118');

X = Data(:, 1:3);
Y = Data(:, 7);
Xtest = Data2(:, 1:3);
Ytest = Data2(:, 7);

% Mengkalkulasi data X dan Xtest untuk rata-rata dan standar deviasi
X_mean = mean(X);
X_std = std(X);

Xtest_mean = mean(Xtest);
Xtest_std = std(Xtest);

% Menormalkan data X dan Xtest menggunakan rata-rata dan standar deviasi
dari X
X_norm = (X - X_mean) ./ X_std;
Xtest_norm = (Xtest - Xtest_mean) ./ Xtest_std;

```

```

% Mengkalkulasi data Y untuk rata-rata dan standar deviasi
Y_mean = mean(Y);
Y_std = std(Y);

Ytest_mean = mean(Ytest);
Ytest_std = std(Ytest);

% Menormalkan data Y
Y_norm = (Y - Y_mean) ./ Y_std;
Ytest_norm = (Ytest - Ytest_mean) ./ Ytest_std;

% Transposisi data untuk ANN
X_norm = X_norm'; % 3x80
Y_norm = Y_norm'; % 1x80
Xtest_norm = Xtest_norm'; % 3x37
Ytest_norm = Ytest_norm';

% membuat arsitektur jaringan
hiddenLayerSize = 10;

net = feedforwardnet([hiddenLayerSize, 1], 'trainbfg');

% Mengatur fungsi aktivasi untuk lapisan tersembunyi dan output
net.layers{1}.transferFcn = 'logsig'; % Lapisan tersembunyi
net.layers{2}.transferFcn = 'purelin'; % Lapisan output

% Mengonfigurasi jaringan
net = configure(net, X_norm, Y_norm);

% Menetapkan bobot dan bias secara manual
net.IW{1,1} = rand(hiddenLayerSize, size(X_norm, 1)) * 0.1; % Bobot
input-hidden
net.b{1} = rand(hiddenLayerSize, 1) * 0.1; % Bias untuk
lapisan tersembunyi
net.LW{2,1} = rand(1, hiddenLayerSize) * 0.1; % Bobot
hidden-output
net.b{2} = rand(1, 1) * 0.1;

% Mengatur parameter pelatihan
net.trainParam.epochs = 100; % Jumlah epoch
net.trainParam.lr = 0.01; % Learning rate
net.trainParam.goal = 0.2; % Error goal
net.trainParam.show = 25; % Interval untuk menampilkan hasil pelatihan
net.trainParam.max_fail = 500; % Jumlah maksimal epoch tanpa perbaikan
pada validasi
net.trainParam.min_grad = 0; % Gradient minimum

% Melatih jaringan
[net, tr] = train(net, X_norm, Y_norm);

% Menguji jaringan dengan data yang dinormalisasi
Y_pred_norm = net(Xtest_norm);

% Y_pred_norm = net(X_norm);

% Denormalisasi hasil prediksi (jika diperlukan)
Y_denorm = Y_pred_norm' * Ytest_std + Ytest_mean;

```

```

%Y_denorm = Y_pred_norm' * Y_std + Y_mean;

% Menampilkan hasil training
figure;
hold on;
plot(Ytest, 'o', 'MarkerFaceColor', 'w', 'MarkerEdgeColor', 'b');
plot(Y_denorm, '*', 'MarkerFaceColor', 'r', 'MarkerEdgeColor', 'r');
xlabel('Data ke-');
ylabel('Target/Output');
title('Hasil pengujian dengan data uji: Target (o), Output (*)');
legend({'Target', 'Output'}, 'Location', 'best');
hold off;

disp(Y_denorm);

% Menambahkan bobot akhir
final_input_weights = net.IW{1,1};
final_hidden_biases = net.b{1};
final_hidden_weights = net.LW{2,1};
final_output_biases = net.b{2};

% Menampilkan bobot dan bias akhir
disp('Bobot input-hidden akhir:');
disp(final_input_weights);

disp('Bias hidden layer akhir:');
disp(final_hidden_biases);

disp('Bobot hidden-output akhir:');
disp(final_hidden_weights);

disp('Bias output layer akhir:');
disp(final_output_biases);

%memasukan nilai prediksi ke dalam tabel excel
Y_denorm = Y_denorm(:);
predictionsTabel = tabel(Y_denorm, 'VariableNames', {'Predictions'});
writetabel(predictionsTabel, 'Iron2.xlsx');

```

LAMPIRAN 4 : HASIL PREDIKSI LSTM

Tanggal	Waktu	SiO2	Al2O3	Fe2O3	CaO	MgO	SO3	Na2O	K2O
07/05/2024	18:00:00	13,07	3,93	1,92	44,16	1,01	0,41	-0,02	0,19
07/05/2024	18:06:00	13,07	4,35	2,08	44,14	1,05	0,40	-0,02	0,18
07/05/2024	18:36:00	12,89	3,80	2,28	44,00	0,94	0,37	-0,07	0,21
07/05/2024	19:06:00	12,34	4,09	2,30	43,60	0,93	0,38	-0,03	0,23
07/05/2024	19:36:00	12,06	3,63	2,23	44,08	0,91	0,36	-0,02	0,17
07/05/2024	20:06:00	12,20	3,56	2,14	44,55	0,85	0,36	-0,01	0,16
07/05/2024	20:36:00	12,54	3,87	2,10	44,50	0,81	0,34	0,00	0,15
07/05/2024	21:18:00	12,92	3,61	2,10	44,31	0,78	0,35	0,00	0,16
07/05/2024	21:23:00	13,09	3,54	2,09	44,31	0,78	0,35	0,01	0,16
07/05/2024	21:53:00	12,87	3,24	2,06	44,43	0,83	0,34	0,02	0,15
07/05/2024	22:23:00	12,82	3,41	2,05	44,43	0,81	0,35	0,01	0,17
07/05/2024	22:53:00	12,84	3,94	2,06	44,35	0,81	0,36	0,02	0,18
07/05/2024	23:23:00	12,48	3,82	2,04	44,27	0,85	0,36	0,03	0,17
07/05/2024	23:53:00	12,18	3,97	2,07	44,20	0,87	0,35	0,04	0,16
08/05/2024	00:23:00	12,38	3,91	2,09	44,16	0,87	0,35	0,03	0,16
08/05/2024	00:53:00	12,59	3,83	2,06	44,17	0,85	0,33	0,04	0,16
08/05/2024	01:23:00	13,01	3,59	2,10	44,09	0,83	0,34	0,02	0,18
08/05/2024	01:53:00	13,28	3,45	2,10	44,02	0,86	0,35	0,03	0,18
08/05/2024	02:23:00	13,41	3,59	2,10	43,97	0,90	0,35	0,00	0,17
08/05/2024	02:53:00	13,34	3,67	2,09	43,97	0,88	0,35	0,00	0,17
08/05/2024	03:23:00	12,96	3,57	2,03	44,04	0,87	0,35	0,01	0,17
08/05/2024	04:12:00	12,41	3,58	2,01	44,17	0,87	0,36	0,00	0,16
08/05/2024	04:18:00	12,04	3,49	2,02	44,29	0,84	0,36	0,00	0,15
08/05/2024	04:48:00	11,91	3,46	1,99	44,32	0,83	0,34	0,01	0,15
08/05/2024	05:18:00	12,45	3,63	2,01	44,16	0,79	0,34	-0,01	0,16
08/05/2024	16:28:00	12,89	4,03	2,02	44,12	0,79	0,35	0,00	0,16
08/05/2024	16:33:00	13,03	3,85	2,06	44,22	0,85	0,35	-0,02	0,15
08/05/2024	17:15:00	13,01	3,65	2,07	44,32	0,87	0,34	-0,01	0,15
08/05/2024	17:29:00	13,09	3,57	2,10	44,21	0,82	0,34	-0,04	0,16
08/05/2024	17:51:00	13,05	3,80	2,11	44,11	0,82	0,35	-0,02	0,16
08/05/2024	17:57:00	12,74	3,80	2,12	44,19	0,87	0,35	-0,02	0,14
08/05/2024	18:27:00	12,60	3,75	2,15	44,28	0,80	0,32	-0,03	0,15
08/05/2024	19:27:00	12,79	3,53	2,14	44,20	0,79	0,34	-0,01	0,15
08/05/2024	19:57:00	12,91	3,71	2,13	44,15	0,81	0,34	-0,04	0,15
08/05/2024	20:27:00	12,96	3,82	2,13	44,18	0,81	0,34	-0,03	0,15
08/05/2024	20:57:00	12,99	3,68	2,13	44,21	0,82	0,35	-0,03	0,15
08/05/2024	21:27:00	12,90	3,67	2,13	44,24	0,82	0,35	-0,03	0,15
08/05/2024	21:57:00	12,79	3,79	2,14	44,20	0,80	0,34	-0,03	0,15
08/05/2024	22:27:00	12,73	3,83	2,13	44,15	0,78	0,35	-0,03	0,15
08/05/2024	22:57:00	12,64	3,95	2,08	44,14	0,80	0,35	-0,03	0,15

08/05/2024	23:27:00	12,76	3,91	2,12	44,13	0,75	0,34	-0,02	0,16
08/05/2024	23:57:00	12,75	3,86	2,12	44,19	0,76	0,33	-0,06	0,16
09/05/2024	00:27:00	12,60	3,76	2,06	44,19	0,81	0,33	-0,01	0,15
09/05/2024	00:57:00	12,52	3,69	2,05	44,12	0,83	0,33	-0,04	0,16
09/05/2024	01:27:00	12,69	3,69	2,09	44,08	0,80	0,33	-0,03	0,16
09/05/2024	01:57:00	12,73	3,61	2,07	44,14	0,81	0,31	-0,02	0,15
09/05/2024	02:27:00	13,03	3,52	2,14	44,09	0,77	0,31	-0,06	0,16
09/05/2024	02:57:00	13,08	3,44	2,07	44,05	0,79	0,30	0,00	0,15
09/05/2024	03:27:00	13,10	3,46	2,10	44,05	0,79	0,30	-0,06	0,16
09/05/2024	03:57:00	13,11	3,44	2,10	44,12	0,82	0,30	-0,01	0,16
09/05/2024	04:27:00	12,97	3,31	2,10	44,13	0,86	0,32	-0,03	0,15
09/05/2024	05:47:00	12,51	3,41	2,09	44,10	0,81	0,31	-0,03	0,15
09/05/2024	06:10:00	12,30	3,28	2,11	44,00	0,77	0,31	-0,03	0,16
09/05/2024	06:17:00	12,41	3,24	2,12	44,01	0,76	0,32	-0,04	0,15
09/05/2024	06:23:00	12,59	3,19	2,12	44,15	0,78	0,31	-0,04	0,15
09/05/2024	06:53:00	12,65	3,14	2,07	44,25	0,82	0,28	0,00	0,14
09/05/2024	07:23:00	13,03	3,25	2,12	44,10	0,85	0,30	-0,05	0,15
09/05/2024	07:53:00	13,39	3,58	2,19	43,95	0,83	0,31	-0,02	0,15
09/05/2024	08:23:00	13,42	3,55	2,21	44,00	0,80	0,33	-0,07	0,15
09/05/2024	08:53:00	13,10	3,79	2,03	44,16	1,00	0,39	-0,04	0,20
09/05/2024	09:23:00	13,00	4,36	2,19	44,13	1,05	0,39	-0,06	0,20
09/05/2024	09:53:00	13,16	3,96	2,41	44,00	0,94	0,37	-0,11	0,22
09/05/2024	10:23:00	13,04	4,30	2,40	43,56	0,90	0,39	-0,10	0,23
09/05/2024	10:53:00	12,66	3,71	2,31	44,01	0,91	0,39	-0,04	0,18
09/05/2024	11:23:00	12,31	3,47	2,22	44,56	0,88	0,38	0,00	0,15
09/05/2024	11:53:00	12,22	3,78	2,20	44,54	0,83	0,37	-0,02	0,14
09/05/2024	12:23:00	12,44	3,56	2,19	44,33	0,81	0,37	-0,02	0,15
09/05/2024	12:53:00	12,74	3,51	2,17	44,32	0,79	0,37	-0,02	0,15
09/05/2024	13:23:00	12,81	3,34	2,16	44,41	0,81	0,36	-0,01	0,14
09/05/2024	13:53:00	12,68	3,14	2,14	44,47	0,84	0,35	0,01	0,14
09/05/2024	14:23:00	12,73	3,90	2,15	44,48	0,83	0,33	-0,03	0,15
10/05/2024	02:39:00	12,85	3,86	2,15	44,42	0,84	0,34	0,01	0,16
10/05/2024	03:27:00	12,92	3,81	2,15	44,31	0,84	0,34	0,03	0,16
10/05/2024	03:32:00	12,81	3,59	2,12	44,21	0,85	0,34	0,10	0,16
10/05/2024	04:15:00	12,67	3,44	2,09	44,16	0,86	0,34	0,04	0,16
10/05/2024	04:21:00	12,79	3,44	2,10	44,11	0,85	0,35	0,02	0,17
10/05/2024	04:59:00	12,82	3,44	2,08	44,10	0,85	0,36	0,00	0,16
10/05/2024	05:08:00	12,84	3,49	2,09	44,03	0,84	0,36	0,00	0,17
10/05/2024	05:14:00	12,86	3,66	2,09	43,92	0,83	0,37	-0,03	0,17
10/05/2024	05:44:00	12,81	3,89	2,07	43,91	0,83	0,37	0,01	0,17
10/05/2024	06:14:00	12,55	3,93	2,00	44,07	0,84	0,38	-0,05	0,18
10/05/2024	06:44:00	12,39	3,69	2,02	44,36	0,85	0,38	0,02	0,17
10/05/2024	07:14:00	12,20	3,78	2,01	44,49	0,87	0,35	-0,03	0,16
10/05/2024	07:44:00	12,21	4,06	2,03	44,28	0,86	0,32	0,00	0,16
10/05/2024	08:14:00	12,81	3,74	2,11	44,05	0,83	0,30	-0,05	0,16

10/05/2024	08:44:00	13,16	3,56	2,09	44,11	0,81	0,29	-0,05	0,18
10/05/2024	09:14:00	13,13	3,65	2,07	44,19	0,83	0,31	-0,03	0,17
10/05/2024	09:44:00	12,99	3,85	2,10	44,23	0,83	0,32	-0,05	0,17
10/05/2024	10:14:00	12,66	3,73	2,10	44,20	0,83	0,33	-0,02	0,16
10/05/2024	10:44:00	12,49	3,38	2,10	44,16	0,82	0,34	-0,07	0,17
10/05/2024	11:14:00	12,40	3,48	2,11	44,16	0,82	0,35	-0,02	0,16
10/05/2024	11:44:00	12,39	3,81	2,10	44,20	0,82	0,35	-0,06	0,16
10/05/2024	12:14:00	12,72	4,07	2,06	44,25	0,82	0,35	0,00	0,15
10/05/2024	12:44:00	12,97	3,72	2,11	44,17	0,80	0,35	-0,07	0,16
10/05/2024	13:14:00	13,02	3,62	2,11	44,13	0,80	0,36	-0,02	0,17
10/05/2024	13:44:00	12,88	3,91	2,14	44,13	0,81	0,36	-0,07	0,16
10/05/2024	14:14:00	12,67	3,97	2,13	44,15	0,80	0,36	-0,02	0,16
10/05/2024	14:44:00	12,43	3,57	2,12	44,15	0,79	0,35	-0,06	0,16
10/05/2024	15:14:00	12,34	3,40	2,12	44,12	0,80	0,35	-0,02	0,16
10/05/2024	15:44:00	12,60	3,94	2,15	44,09	0,78	0,36	-0,08	0,16
10/05/2024	16:33:00	12,78	3,95	2,15	44,10	0,79	0,36	-0,03	0,16
10/05/2024	16:39:00	12,88	3,37	2,16	44,10	0,80	0,36	-0,07	0,15
10/05/2024	17:09:00	12,92	3,66	2,16	44,11	0,79	0,36	-0,04	0,16
10/05/2024	17:39:00	12,97	4,01	2,19	44,07	0,79	0,37	-0,09	0,16
10/05/2024	18:09:00	12,78	3,77	2,15	44,07	0,80	0,37	-0,02	0,15
10/05/2024	18:39:00	12,61	3,49	2,17	44,09	0,80	0,37	-0,06	0,15
10/05/2024	19:09:00	12,66	3,85	2,19	44,09	0,77	0,37	-0,04	0,16
10/05/2024	19:39:00	12,68	3,95	2,17	44,07	0,77	0,37	-0,07	0,16
10/05/2024	20:09:00	12,72	3,49	2,17	44,02	0,77	0,37	-0,03	0,16
10/05/2024	20:39:00	12,91	3,63	2,20	44,00	0,77	0,38	-0,09	0,16
10/05/2024	21:09:00	12,65	4,04	2,10	43,98	0,79	0,40	-0,03	0,16
10/05/2024	21:39:00	12,46	4,03	2,10	43,99	0,79	0,39	-0,07	0,17
10/05/2024	22:09:00	12,25	3,86	2,09	44,06	0,79	0,38	-0,02	0,16
10/05/2024	22:39:00	12,23	3,73	2,10	44,08	0,79	0,36	-0,06	0,16
10/05/2024	23:09:00	12,30	3,76	2,10	44,04	0,78	0,34	-0,01	0,17
10/05/2024	23:38:00	12,21	3,63	2,06	44,04	0,79	0,33	-0,05	0,16
10/05/2024	23:46:00	12,40	3,53	2,11	44,03	0,78	0,32	-0,02	0,17

LAMPIRAN 5 : PEMBOBOTAN WEIGHING FEEDER

LSF	SM	AM/IM	Limestone	Clay	Silica Sand	Iron Sand
106,64	2,18	1,86	95,1	1,6	1,6	1,7
102,66	2,01	2,07	95,1	1,6	1,6	1,7
108,3	2,01	1,08	94,54	1,73	1,82	1,91
97,15	2,07	1,82	95,81	0	2,32	1,9
109,69	2,28	1,83	94,7	0	3,41	1,89
115,15	2,13	1,64	97	0	1	1,68
111,57	2,06	1,82	95,7	0	2,62	1,68
111,57	2,06	1,82	95,81	0	2,54	1,65
107,55	2,23	1,73	95,74	0	2,56	1,7
111,44	2,21	1,71	95,4	0	2,9	1,7
111,89	2,03	1,91	95,08	0	3,22	1,7
108,68	2,08	1,93	94,59	0	3,66	1,75
107,7	2,14	1,79	94,49	0	3,65	1,86
106,59	2,08	1,89	94,43	0	3,92	1,65
107,44	2,08	1,95	94,45	0	3,9	1,65
106,42	2,14	1,84	94,42	0	3,83	1,65
104,02	2,26	1,77	94,34	0	4,01	1,65
105,13	2,34	1,66	94,65	0	3,85	1,5
103,68	2,42	1,68	94,85	0	3,6	1,55
102,27	2,3	1,84	94,88	0	3,57	1,55
100,54	2,62	1,73	95,93	0	2,61	1,46
104,42	2,27	1,92	95,95	0	2,6	1,46
109,78	2,27	1,81	95,84	0	2,58	1,58
114,74	2,31	1,68	95,47	0	2	1,45
113,32	2,19	1,93	95,1	0,7	3,74	1,7
109,26	2,17	1,84	95,1	0,7	3,74	1,7
104,21	2,05	2,01	95	0,7	2,6	1,7
105,36	2,27	1,82	95,3	0	0	1,7
107,55	2,18	1,83	93,91	0,64	3,71	1,68
107,98	2,26	1,67	93,96	0,64	3,71	1,68
106,93	2,2	1,81	93,96	0,64	3,71	1,68
108,06	2,1	1,72	93,96	0,64	3,71	1,68
108,53	2,09	1,78	93,96	0,64	3,71	1,68
108,82	2,22	1,57	93,96	0,64	3,71	1,68
104,38	2,24	1,79	94,95	0	4	1,6
104,13	2,24	1,81	94,6	0	3,84	1,56
109,65	2,21	1,79	94,69	0	3,7	1,66
104,91	2,3	1,73	94,05	0	4,15	1,7
104,99	2,15	1,75	94,55	0	3,84	1,61
107,06	2,21	1,67	94,52	0	3,72	1,7
105,15	2,09	1,84	94,28	0	3,92	1,7

106,69	2,07	1,77	94,45	0	3,81	1,74
108,65	2,17	1,81	94,26	0	3,94	1,63
106,72	2,02	1,81	94,12	0	4,26	1,6
106,89	2,03	1,88	94,14	0	4,26	1,6
106,5	2,27	1,66	94,08	0	4,28	1,6
108,24	2,31	1,59	94,06	0	4,49	1,54
104,57	2,2	1,71	93,82	0	4,58	1,6
103,94	2,18	1,79	94,01	0	4,53	1,6
103,98	2,23	1,77	94,24	0	4,25	1,5
104,51	2,19	1,86	94,47	0	4,03	1,5
106,34	2,2	1,79	94,43	0	4,03	1,5
106,02	2,27	1,76	94,43	0	4,03	1,5
108,35	2,22	1,73	94,43	0	4,03	1,5
107,23	2,31	1,68	94,25	0	4,25	1,5
105,8	2,38	1,65	94,13	0	4,37	1,5
104,91	2,42	1,62	94,21	0	4,31	1,48
105,77	2,22	1,85	94,27	0	4,26	1,47
103,18	2,51	1,63	94,37	0	4,22	1,41
105,7	2,25	1,84	94,58	0	4,04	1,38
106,98	2,28	1,77	94,59	0	3,96	1,45
109,05	2,28	1,77	94,39	0	4,12	1,49
109,58	2,36	1,76	94,33	0	4,17	1,5
105,5	2,24	1,93	93,89	0	4,61	1,5
105,61	2,29	1,89	94,12	0	4,38	1,5
107,36	2,44	1,71	94,22	0	4,28	1,5
104,88	2,21	2,05	93,83	0	4,67	1,5
103,71	2,34	1,9	94,03	0	4,47	1,5
105,44	2,42	1,76	94,28	0	4,22	1,5
105,95	2,27	1,89	0	0	0	0
107,26	2,31	1,83	92,22	0	0	1,7
120,65	2,19	1,62	95,3	0	0	1,7
113,45	2,43	1,49	93,51	0,9	3,89	1,7
112,79	2,35	1,5	93,03	1,19	4,07	1,71
101,9	2,2	1,82	95,16	0,64	2,6	1,6
101,96	2,05	1,91	93,06	0,9	4,34	1,7
113,43	2,16	1,72	93,06	0,9	4,34	1,7
111,86	2,19	1,74	95,22	0,62	2,56	1,6
107,73	2,24	1,71	95,22	0,62	1,56	2,6
101,62	2,38	1,63	93,25	0,85	4,2	1,7
106,2	2,2	1,82	94,61	0,6	3,19	1,6
107,21	2,18	1,88	94,51	0,68	3,13	1,68
104,95	2,07	1,97	94,35	0,71	3,23	1,71
107,12	2,2	1,69	94,23	0,26	3,81	1,7
107,31	2,11	1,69	94,33	0,26	3,71	1,7
107,22	2,09	1,76	94,16	0,42	3,72	1,7

106,44	2,34	1,62	94,14	0,1	4,06	1,7
105,39	2,11	1,89	94,19	0	4,03	1,78
101,24	2,42	1,62	94,21	0	3,91	1,88
105,57	2,38	1,63	94,18	0	4,05	1,77
109,31	2,25	1,84	94,46	0	3,82	1,72
105,77	2,32	1,87	94,49	0	3,75	1,76
103,81	2,35	1,93	94,05	0	4,15	1,8
107,65	2,40	1,78	94,29	0	3,91	1,8
105,29	2,62	1,55	94,43	0	3,66	1,91
107	2,30	1,70	94,24	0	3,76	2
104,97	2,31	1,62	94,02	0	3,98	2
105,5	2,29	1,60	94,12	0	2,99	2,89
101,58	2,23	1,75	93,94	0	3,01	3,05
100,82	2,34	1,72	94,28	0	2,94	2,78
102,47	2,50	1,67	94,95	1	2,46	1,59
107,57	2,31	1,75	95,21	1	2,27	1,52
106,7	2,23	1,91	95,31	1	2,16	1,53
107,62	2,17	1,90	94,88	0	2,31	2,81
105,43	2,30	1,87	94,99	0	2,17	2,84
103,43	2,32	1,74	94,62	1	2,29	2,09
105,38	2,37	1,75	94,92	1	2,14	1,94
111,43	2,05	1,89	94,99	1	2,05	1,96
110,4	2,20	1,67	95,1	1	1,98	1,92
103,04	2,14	1,66	94,54	1	2,34	2,12
104,47	2,12	1,64	94,09	1	2,47	2,44
106,65	2,16	1,71	94,8	1	2,24	1,96
107,86	2,09	1,79	94,7	1	2,26	2,04
109,72	2,08	1,79	94,67	1	2,32	2,01
109,35	2,13	1,82	94,78	0,6	2,9	1,72
108,79	2,20	1,79	94,84	0,57	2,86	1,73
105,77	2,36	1,72	94,56	0,6	3,09	1,75

