



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - IS184853

**PERAMALAN PENJUALAN KEJU KRAFT KOTA SURABAYA
MENGUNAKAN METODE GATED RECURRENT UNIT (GRU)
(STUDI KASUS: PT MONDELÉZ INDONESIA)**

***FORECASTING SALES OF KRAFT CHEESE IN SURABAYA CITY
USING GATED RECURRENT UNIT (GRU) METHOD
(CASE STUDY: PT MONDELÉZ INDONESIA)***

**NAUFAL NEDIASA GHOZIAZMII
NRP. 05211640000108**

**Dosen Pembimbing
Edwin Riksakomara, S.Kom., MT.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020**



TUGAS AKHIR - IS184853

FORECASTING SALES OF KRAFT CHEESE IN SURABAYA CITY USING GATED RECURRENT UNIT (GRU) METHOD (CASE STUDY: PT MONDELÈZ INDONESIA)

**NAUFAL NEDIASA GHOZIAZMII
NRP. 05211640000108**

**Dosen Pembimbing
Edwin Riksakomara, S.Kom., MT.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020**

Halaman ini sengaja dikosongkan



UNDERGRADUATE THESIS - IS84853

***FORECASTING SALES OF KRAFT CHEESE IN
SURABAYA CITY USING GATED RECURRENT
UNIT (GRU) METHOD
(CASE STUDY: PT MONDELÉZ INDONESIA)***

NAUFAL NEDIASA GHOZIAZMII
NRP. 05211640000108

Dosen Pembimbing
Edwin Riksakomara, S.Kom., M.T

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN**PERAMALAN PENJUALAN KEJU KRAFT KOTA
SURABAYA MENGGUNAKAN METODE GATED
RECURRENT UNIT (GRU) (STUDI KASUS: PT
MONDELÉZ INDONESIA)****TUGAS AKHIR**

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer (S.Kom)

pada

Departemen Sistem Informasi

Fakultas Teknologi Elektro dan Informatika Cerdas (ELECTICS)

Institut Teknologi Sepuluh Nopember

Oleh

Naufal Nediassa Ghoziadmii

05211640000108

Surabaya, 24 Agustus 2020

Kepala Departemen Sistem Informasi

Dr. Mudjahidin, ST., MT.

NIP. 197010102003121001



Halaman ini sengaja dikosongkan

LEMBAR PERSETUJUAN

PERAMALAN PENJUALAN KEJU KRAFT KOTA SURABAYA MENGGUNAKAN METODE GATED RECURRENT UNIT (GRU) (STUDI KASUS: PT MONDELÉZ INDONESIA)

TUGAS AKHIR

Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember

Oleh :

NAUFAL NEDIASA GHOZIAZMII
NRP. 05211640000108

Disetujui Tim Penguji : Tanggal Ujian : 22 Juli 2020
Periode Wisuda : September 2020

Edwin Riksakomara, S.Kom., M.T.

(Pembimbing I)

Ahmad Muklason, S.Kom., M.Sc., Ph.D.

(Penguji I)

Faizal Mahananto, S.Kom., M.Eng.

(Penguji II)

Halaman ini sengaja dikosongkan

**PERAMALAN PENJUALAN KEJU KRAFT KOTA
SURABAYA MENGGUNAKAN METODE GATED
RECURRENT UNIT (GRU) (STUDI KASUS: PT
MONDELEZ INDONESIA)**

Nama : Naufal Nediasa Ghoziazmii
NRP : 05211640000108
Departemen : Sistem Informasi ITS
Pembimbing I : Edwin Riksakomara, S. Kom., M.T.

ABSTRAK

Keju merupakan makanan yang dapat dihasilkan dari proses koagulasi susu asli. Keju termasuk jenis makanan pelengkap yang sering digunakan dikarenakan rasanya yang asin dan manis. Penggunaan berbagai metode, enzim, dan jenis susu dapat mempengaruhi kematangan, rasa, pemeraman maupun kekerasan keju itu sendiri. Hampir setiap aneka makanan dapat ditambahkan keju sebagai bahan pelengkap yang disesuaikan dengan jenis kejunya. PT. Mondelez Internasional yang berasal dari Amerika Serikat merupakan perusahaan terbesar dalam bidang biskuit, coklat, permen, keju, dan minuman instan. Pada tahun 2013, PT. Mondelez Internasional memecah divisi penjualannya menjadi 2 divisi. Mondelez Internasional untuk penjualan divisi biskuit, coklat, permen, dan Mondelez Indonesia untuk penjualan divisi keju. Semakin tingginya harga bahan baku produksi keju dan ketidaksesuaian target penjualan tiap cabang distribusi menyebabkan perlunya tindakan perencanaan produksi. Oleh sebab itu, perlunya data peramalan penjualan sebagai dasar keputusan perusahaan bagian pabrik produksi dalam memproduksi produk keju Kraft, khususnya di Kota Surabaya.

Penelitian tugas akhir ini dilakukan untuk meramalkan jumlah penjualan produk Keju Kraft di Kota Surabaya dengan

menggunakan metode Gated Recurrent Unit (GRU) dan data yang digunakan merupakan data penjualan pada periode 1 Januari 2019 – 31 Desember 2019. Metode GRU merupakan salah satu variasi sederhana dari metode Long Short-Term Memory (LSTM). Kedua metode tersebut dapat memprediksi data yang bersifat time series dan sebagai solusi yang diusulkan dalam menyelesaikan permasalahan vanishing gradient dan exploding gradient dari metode Recurrent Neural Network (RNN).

Hasil analisis menunjukkan bahwa model terbaik dikonfigurasi dengan parameter units 200, epoch 300, dropout 0.0002, dan menggunakan fungsi lost function = mean squared logarithmic error serta optimizer Adam. Untuk fungsi optimasi pengaturan terbaik didapatkan dengan konfigurasi learning rate 0.00005 dan decay $1e-6$. Model ini dapat menghasilkan nilai MAPE terbaik sebesar 82%. Berdasarkan hasil yang didapatkan, dapat disimpulkan bahwa metode GRU tidak mampu melakukan peramalan dengan nilai error yang tinggi.

Kata Kunci: Peramalan, RNN, LSTM, GRU, Keju Kraft, Kota Surabaya.

FORECASTING SALES OF KRAFT CHEESE IN SURABAYA CITY USING GATED RECURRENT UNIT (GRU) METHOD (CASE STUDY: PT MONDELEZ INDONESIA)

Nama : Naufal Nediassa Ghoziadmii
NRP : 05211640000108
Departemen : Sistem Informasi ITS
Pembimbing I : Edwin Riksakomara, S. Kom., MT.

ABSTRACT

Cheese is a food that can be produced from the coagulation process from real milk. Cheese is also a type of complementary food that is often used because it tastes salty and sweet. The use of cheese in various methods, enzymes, and types of milk can be affected the maturity, flavor, ripening, and hardness of the cheese itself. Almost every food can be added with cheese as a supplementary ingredient that adjusted to the type of cheese. PT. Mondelez International from the United States is the largest company in the field of biscuits, chocolate, candy, cheese, and instant drinks. In 2013, PT. Mondelez International splits its sales division into 2 divisions. Mondelez International for the sale of the biscuits, chocolate, candy and Mondelez Indonesia divisions for the cheese division. The higher prices of raw materials for cheese production and the mismatch of sales targets for each distribution branch cause the need for production planning actions. Therefore, the need for sales forecasting data as the basis for the decision of the company in the production factory in producing Kraft cheese products, especially in the city of Surabaya.

This final project research is carried out to predict the number of sales of Kraft Cheese products in Surabaya using the Gated Recurrent Unit (GRU) method and the data used are sales data for January 1, 2019 – December 31, 2019. The GRU method is one of the simplest variations of the method Long Short-Term Memory (LSTM). Both methods can predict time series data and

as a proposed solution in solving the problem of vanishing gradient and gradient exploding from the Recurrent Neural Network (RNN) method.

The analysis shows that the best model is configured with the parameters of units 200, epoch 300, dropout 0.0002, and uses the lost function = mean squared logarithmic error and Adam optimizer. The best setting optimization function is obtained with a learning rate configuration of 0.00005 and decay $1e-6$. This model can produce the best MAPE value of 82%. Based on the results obtained, it can be concluded the GRU method is not capable of forecasting with high error values.

Keywords: Forecasting, RNN, LSTM, GRU, Kraft Cheese, Surabaya City

SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertandatangan dibawah ini:

Nama : Naufal Nediassa Ghoziazmii
NRP : 05211640000108
Tempat/Tanggal Lahir : Jakarta/12 Maret 1998
Fakultas/Departemen : FTEIC/Sistem Informasi
Nomor Telp/Hp/Email : 082214827183 /
nediasaopang03@gmail.com

Dengan ini menyatakan dengan sesungguhnya bahwa penelitian/makalah/tugas akhir saya yang berjudul


PERAMALAN PENJUALAN KEJU KRAFT KOTA SURABAYA MENGGUNAKAN METODE GATED RECURRENT UNIT (GRU) (STUDI KASUS: PT MONDELÉZ INDONESIA)

Bebas dari plagiarisme Dan Bukan Hasil Karya Orang Lain.

Apabila dikemudian hari ditemukan seluruh atau sebagian penelitian/makalah/tugas akhir tersebut terdapat indikasi plagiarisme, maka saya bersedia menerima sanksi sesuai peraturan dan ketentuan yang berlaku.

Demikian surat pernyataan ini saya buat dengan sesungguhnya dan untuk dipergunakan sebagaimana mestinya

Surabaya, 22 Juli 2020


Naufal Nediassa G.
NRP. 05211640000108

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur penulis panjatkan kepada kehadiran Allah SWT atas segala rahmat dan berkat yang telah memberikan anugerah dan tuntunan kepada penulis sehingga penulis dapat menyelesaikan tugas akhir dengan judul **“PERAMALAN PENJUALAN KEJU KRAFT KOTA SURABAYA MENGGUNAKAN METODE GATED RECURRENT UNIT (GRU) (STUDI KASUS: PT MONDELĒZ INDONESIA)”** yang merupakan salah satu syarat kelulusan pada Departemen Sistem Informasi, Fakultas Teknik Elektro dan Informatika Cerdas, Institut Teknologi Sepuluh Nopember Surabaya. Penyusunan penelitian tugas akhir ini selalu mendapatkan dukungan dari berbagai pihak baik dalam bentuk doa, semangat, motivasi, semangat, hiburan, kritik, saran dan berbagai bentuk bantuan lainnya. Untuk itu, secara khusus penulis akan menyampaikan ucapan terima kasih yang sedalam-dalamnya kepada:

1. Allah SWT yang telah memberikan rahmat dan hidayah serta atas ijin-Nya penulis mampu mengerjakan tugas akhir ini hingga selesai.
2. Segenap keluarga besar penulis, terutama kedua orang tua, Bapak Ir. Edison, M.PAf, IPM, ASEAN Eng. dan Ibu Prof. Ir. Neti Yuliana, M.Si, Ph.D. yang selalu senantiasa mendoakan, memberikan motivasi, dan seluruh kebutuhan materiil maupun non-materiil, sehingga penulis mampu menyelesaikan pendidikan S1 ini dengan baik.
3. Bapak Dr. Mudjahidin, S.T., M.T. selaku Ketua Departemen Sistem Informasi ITS, Bapak Ahmad Mukhlason, S.Kom., M.Sc., Ph.D. selaku Kalab RDIB S1 Sistem Informasi ITS serta seluruh dosen pengajar beserta staf dan karyawan di Jurusan Sistem Informasi, FTIF ITS Surabaya selama penulis menjalani kuliah.
4. Bapak Edwin Riksakomara, S.Kom, MT. selaku dosen pembimbing yang telah berkenan membantu penulis dengan meluangkan waktu untuk membimbing,

- memberi arahan, dan beserta ilmu selama pengerjaan penelitian tugas akhir ini.
5. Bapak Ahmad Mukhlason, S.Kom, M.Sc, Ph.D dan Ibu Dr. Retno Aulia Vinarti, S.Kom, M.Kom. selaku dosen penguji yang telah memberikan masukan dan saran kepada penulis dalam pengerjaan tugas akhir ini.
 6. Ibu Eko Wahyu Tyas Darmaningrat S.Kom., M.BA. selaku dosen wali yang selalu membantu dan memotivasi penulism dalam pengerjaan tugas akhir ini
 7. Teman-teman angkatan Artemis khususnya anggota lab RDIB yang telah memberikan motivasi, semangat, dan masukan kepada penulis selama proses pengerjaan tugas akhir ini.
 8. Sahabat terdekat Teristi penulis yaitu Tigor, Reza, Rama, Aldo, Arif, Rizal, Akram, Dimas beserta Faris yang senantiasa memberikan semangat, saran, hiburan, dan bantuan kepada penulis dalam menyusun dan mengerjakan tugas akhir ini.
 9. Meli Dyah Qoiru Mucharomah yang selalu berjuang, menyemangati, menghibur. dan memotivasi selama menyusun dan mengerjakan tugas akhir ini.
 10. Serta semua pihak yang telah membantu dalam pengerjaan tugas akhir ini yang tidak bisa disebutkan namanya.

Penyusunan laporan penelitian tugas akhir ini masih jauh dari kata sempurna, sehingga penulis menerima adanya kritik maupun saran yang dapat membangun untuk perbaikan di masa yang akan datang. Semoga tugas akhir ini dapat memberikan manfaat bagi pembaca.

Surabaya, 22 Juli 2020
Penulis

Naufal Nediassa Ghoziazmii

DAFTAR ISI

LEMBAR PENGESAHAN.....	VII
LEMBAR PERSETUJUAN.....	IX
ABSTRAK.....	XI
ABSTRACT.....	XIII
SURAT PERNYATAAN BEBAS PLAGIARISME ..	XV
KATA PENGANTAR.....	XVII
DAFTAR ISI.....	1
DAFTAR TABEL.....	5
DAFTAR SKRIP.....	7
BAB I PENDAHULUAN.....	9
1.1 Latar Belakang.....	9
1.2 Perumusan Masalah.....	11
1.3 Batasan Masalah.....	11
1.4 Tujuan Penelitian.....	11
1.5 Manfaat Penelitian.....	12
1.6 Relevansi.....	12
BAB II TINJAUAN PUSTAKA.....	15
2.1 Studi Sebelumnya.....	15
2.2 Dasar Teori.....	17
2.2.1 Keju.....	18
2.2.2 Data Praproses.....	18
2.2.3 Peramalan.....	18
2.2.4 Gated Recurrent Unit.....	19
2.2.5 Mean Absolute Percentage Error.....	22
BAB III METODOLOGI.....	29
3.1 Tahapan Pelaksanaan Tugas Akhir.....	29
3.2 Uraian Tahapan Pengerjaan.....	29
3.2.1 Identifikasi Masalah.....	30
3.2.2 Studi Literatur.....	30
3.2.3 Pengumpulan Data.....	30
3.2.4 Praproses Data.....	30
3.2.5 Pembuatan Model Peramalan.....	30
3.2.6 Training Model.....	31
3.2.7 Pengujian Model.....	31
3.2.8 Analisa Hasil dan Penarikan Kesimpulan.....	31

3.2.9	Penyusunan Laporan Tugas Akhir	31
BAB IV PERANCANGAN		35
4.1	Karakteristik Data	35
4.2	Praproses Data	37
4.2.1	Ekstraksi Data	37
4.2.2	Penghapusan Data Oulier	37
4.2.3	Menentukan Data Latih, Validasi dan Uji	38
4.3	Pemodelan Peramalan	38
4.3.1	Skenario	39
4.3.2	Fase Latih Model	40
4.3.3	Fase Uji Model	41
BAB V IMPLEMENTASI		43
5.1	Lingkungan Implementasi	43
5.2	Praproses Data	44
5.2.1	Menentukan Data Latih, Validasi dan Uji	44
5.3	Peramalan	46
5.3.1	Penyusunan Model	46
5.3.2	Fase Latih Model	48
5.3.3	Fase Uji Model	49
BAB VI HASIL DAN PEMBAHASAN		51
6.1	Hasil Praproses Data	51
6.1.1	Penghapusan Data Outlier	51
6.1.2	Menentukan Data Latih, Validasi dan Uji	52
6.2	Hasil Peramalan	53
6.2.1	Hasil Peramalan dengan Parameter Awal	53
6.2.2	Hasil Peramalan dengan Skenario Terbaik	56
6.3	Perbandingan Metode LSTM	58
6.4	Perbandingan Metode Regresi Linear	60
6.5	Hasil Peramalan Dengan Dataset Lainnya	61
6.6	Hasil Peramalan Tanpa Outlier	62
6.7	Performa Model	63
BAB VII KESIMPULAN DAN SARAN		69
7.1	Kesimpulan	69
7.2	Saran	70
DAFTAR PUSTAKA		71
BIODATA PENULIS		75
LAMPIRAN: DATA PENJUALAN KEJU		77

DAFTAR GAMBAR

Gambar 1.1. Roadmap Tugas Akhir Lab RDIB	13
Gambar 2.1. Arsitektur RNN.....	20
Gambar 2.2. Arsitektur LSTM	21
Gambar 2.3. Arsitektur GRU.....	21
Gambar 3.1. Tahap Pengerjaan Tugas Akhir.....	29
Gambar 4.1. Plot Data Penjualan Keju Kraft Cheddar	37
Gambar 6.1. Nilai MAPE Seluruh Skenario.....	55
Gambar 6.2. Plot Model Input2	55
Gambar 6.3. Nilai 10 MAPE Terbaik.....	57
Gambar 6.4. Ilustrasi Layer Model.....	57
Gambar 6.5. Plot Perbandingan Hasil Peramalan.....	58
Gambar 6.6. Plot Pelatihan Model.....	58
Gambar 6.7. Ilustrasi Layer Model LSTM	59
Gambar 6.8. Plot Perbandingan Hasil Peramalan Metode LSTM ...	59
Gambar 6.9. Plot Pelatihan Model LSTM	60
Gambar 6.10. Plot Perbandingan Hasil Peramalan Regresi Linier .	60
Gambar 6.11. Plot Perbandingan Hasil Peramalan Data Ethereum .	61
Gambar 6.12. Plot Perbandingan Hasil Peramalan Data Mentah	62
Gambar 6.13. Box Plot Data Penjualan Mentah.....	62
Gambar 6.14. Plot Perbandingan Hasil Peramalan Tanpa Outlier...	63
Gambar 6.15. Potongan Data Penjualan	64
Gambar 6.16. Hasil Peramalan dengan Model yang Overfitting	64
Gambar 6.17. Plot Perbandingan Hasil Peramalan Data Berbeda ...	65
Gambar 6.18. Plot Perbandingan Hasil Peramalan Tanpa Outlier...	66
Gambar 6.19. Plot Perbandingan Hasil Peramalan Metode LSTM .	66
Gambar 6.20. Plot Perbandingan Hasil Peramalan Regresi Linier .	67

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 2.1 Penelitian Sebelumnya	15
Tabel 4.1. Tabel Kolom Data	36
Tabel 4.2. Tabel Pivot Penjualan.....	36
Tabel 4.3. Rancangan Model Peramalan	39
Tabel 4.4. Deskripsi Parameter Model	39
Tabel 4.5. Penjelasan Jenis Parameter Model	40
Tabel 5.1. Lingkungan Hardware	43
Tabel 5.2. Lingkungan Software	43
Tabel 5.3. Lingkungan Library	43
Tabel 6.1. Tabel Data dengan Hasil Transformasi	51
Tabel 6.2. Periode Data Outlier	52
Tabel 6.3. Lagged Dataset	52
Tabel 6.4. Hasil Pengelompokkan Data	53
Tabel 6.6. Skenario yang Digunakan.....	54
Tabel 6.5. Parameter Awal yang Diujicobakan	54
Tabel 6.7. Pengaturan Parameter yang Digunakan.....	56
Tabel 6.8. Hasil Iterasi beserta nilai parameter	56

Halaman ini sengaja dikosongkan

DAFTAR SKRIP

Skrip 5.1. Membaca & Memeriksa Data	44
Skrip 5.2. Pembentukan Supervised Learning.....	45
Skrip 5.3. Pengelompokan Data Latih, Validasi dan Uji.....	45
Skrip 5.4. Menentukan variabel x dan y.....	46
Skrip 5.5. Membentuk Model Peramalan.....	47
Skrip 5.6. Model yang Dicompile	48
Skrip 5.7. Pelatihan Model	48
Skrip 5.8. Peramalan Data.....	49

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

Dalam bab ini akan dijelaskan mengenai latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, manfaat kegiatan tugas akhir serta relevansi. Berdasarkan uraian tersebut, diharapkan mampu memberi gambaran umum permasalahan dan solusi masalah yang ada pada tugas akhir ini.

1.1 Latar Belakang

PT Mondelez International resmi terbentuk pada 1 oktober 2012, merupakan perusahaan terbesar dalam bidang biskuit, coklat, permen, keju, dan minuman instan [1]. Pada tahun 2013, PT. Mondelez Internasional resmi memecah divisi penjualannya menjadi 2 divisi yang berfokuskan pada biskuit, coklat, dan permen dengan fokus produk keju. Produk biskuit, coklat, permen tetap menjadi Mondelez Internasional. Sedangkan produk keju menjadi Mondelez Indonesia [2].

Dalam melakukan penjualannya, pabrik pusat Mondelez Indonesia akan melakukan produksi sesuai permintaan distributor di kota cabang. Permintaan tersebut didasari distributor berdasarkan hasil penjualan di tiap outlet maupun permintaan konsumen terhadap seluruh jenis keju. Selain itu, tiap distributor memiliki target penjualan yang harus dipenuhi setiap bulannya. Dalam prosesnya, terdapat ketidaksesuaian antara target penjualan dengan produk keju yang diproduksi.

Setiap tahunnya, terjadi kenaikan harga untuk semua barang yang disebabkan inflasi dan kelangkaan barang. Tidak terkecuali susu yang dihasilkan dari peternakan sapi. Susu sebagai salah satu bahan utama pembuatan keju, menjadikannya sebagai bahan krusial dalam produksi keju sehingga perlu adanya perhitungan terencana dalam menyiapkan produksi produk [3].

Oleh karenanya agar produksi keju dapat direncanakan, diperlukan sebuah model peramalan penjualan yang dapat membantu distributor dalam menentukan target penjualan di tiap kota cabang. Model tersebut haruslah dapat mengolah data sekuensial berbentuk non-linear yang diperoleh dari data historis *time series* penjualan keju di kota cabang. Salah satu metode yang dapat dipakai ialah *Recurrent Neural Network* (RNN). RNN memiliki karakteristik *looping* pada arsitektur dirinya sendiri yang menyerupai sebuah ingatan sehingga dapat meningkatkan akurasi peramalan [4].

Walaupun RNN dapat memetakan pola non-linear dari suatu data, RNN tetapan memiliki kelemahan. Berdasarkan beberapa penelitian sebelumnya, ketika RNN digunakan untuk melatih data dalam jangka waktu yang lama, masalah *vanishing gradient* dan *exploding gradient* akan terjadi [5].

Vanishing gradient merupakan masalah dimana nilai gradien ketika proses pelatihan cenderung selalu mengecil lalu menghilang. Sedangkan *exploding gradient* merupakan masalah dimana nilai gradien ketika proses pelatihan cenderung selalu membesar dan lalu meninggi hingga tak ternilai. Hal tersebut dapat menyebabkan model tidak dapat mempelajari data yang disediakan [6].

Untuk mengatasi masalah tersebut, maka diusulkanlah model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua metode tersebut menggunakan konsep gerbang sehingga permasalahan *vanishing gradient* dan *exploding gradient* dapat dihindari. GRU merupakan model baru yang lebih sederhana dari LSTM dimana GRU hanya menggunakan dua gerbang, sedangkan LSTM menggunakan tiga gerbang [7].

Dari hasil beberapa penelitian sebelumnya, dapat disimpulkan bahwa nilai akurasi GRU dapat melebihi LSTM dan waktu pelatihannya jauh lebih cepat [8]. Dengan demikian maka tugas

akhir ini bertujuan melakukan peramalan menggunakan metode GRU dengan dasar data historis non-linear penjualan keju Kraft. Diharapkan penggunaan metode GRU dapat menghasilkan tingkat akurasi yang tinggi dalam meramalkan penjualan keju Kraft di Kota Surabaya.

1.2 Perumusan Masalah

Berdasarkan penjelasan latar belakang sebelumnya, rumusan masalah yang diangkat pada penelitian tugas akhir ini adalah:

1. Bagaimanakah model peramalan terbaik penjualan produk keju Kraft di Kota Surabaya menggunakan model GRU?
2. Bagaimana tingkat akurasi peramalan penjualan produk keju Kraft di Kota Surabaya menggunakan model GRU?

1.3 Batasan Masalah

Batasan permasalahan dalam penelitian tugas akhir ini ialah:

1. Penelitian hanya dilakukan untuk meramalkan penjualan produk keju Kraft di Kota Surabaya.
2. Penelitian ini menggunakan data harian penjualan keju pada periode 1 Januari 2019 – 31 Desember 2019.
3. Data yang digunakan berasal dari PT. Mondelez Indonesia.
4. Peramalan yang dilakukan menggunakan aplikasi RStudio *library* Keras atau MXNetR dengan metode GRU.

1.4 Tujuan Penelitian

Tujuan dari pengerjaan penelitian tugas akhir ini adalah:

1. Membangun model terbaik peramalan penjualan produk keju Kraft di Kota Surabaya menggunakan model GRU.

2. Mengetahui tingkat akurasi hasil peramalan penjualan produk keju Kraft di Kota Surabaya menggunakan model GRU.

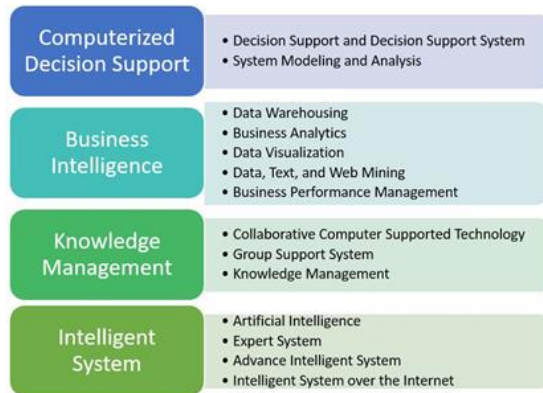
1.5 Manfaat Penelitian

Manfaat yang diberikan dari penelitian tugas akhir ini adalah untuk membantu PT Mondelez Indonesia dalam mengatur jumlah produksi produk keju Kraft untuk daerah Kota Surabaya. Manfaat lainnya dapat dijadikan dasar acuan distributor kota Surabaya untuk mengatur target penjualan dan permintaan produksi produk keju Kraft. Manfaat bagi mahasiswa ialah menambah wawasan peramalan metode GRU dan mengimplementasikan ilmu pengetahuan yang didapat dari perkuliahan.

1.6 Relevansi

Penelitian tugas akhir ini dibuat untuk mengimplementasikan ilmu yang didapatkan pada perkuliahan di Departemen Sistem Informasi ITS dan menjadi salah satu syarat kelulusan pada tahap sarjana. Relevansi dari penelitian tugas akhir ini sebagai tindakan perencanaan produksi keju Kraft agar dapat menyesuaikan target penjualan di Kota Surabaya pada rentang waktu tertentu.

Peramalan penjualan produk keju Kraft di Kota ini berkaitan dengan *roadmap* laboratorium Rekayasa Data dan Intelegensi Bisnis (RDIB) bidang keilmuan *Intelligent System*, *Business Intelligence*, dan *Computerized Decision Support* pada masing – masing bagian *Artificial Intelligence*, *Business Analytics*, dan *Decision Support System*. *Roadmap* RDIB ditunjukkan dalam gambar 1.1.



Gambar 1.1. Roadmap Tugas Akhir Lab RDIB

Mata kuliah laboratorium yang diterapkan untuk tugas akhir ini adalah mata kuliah Teknik Peramalan, Penggalan Data, dan Analisa Bisnis. Metode GRU masih relevan untuk digunakan karena metode ini terbilang relatif masih baru diperkenalkan dan dapat menghasilkan tingkat akurasi yang tinggi.

Halaman ini sengaja dikosongkan

BAB II

TINJAUAN PUSTAKA

Dalam melakukan penelitian tugas akhir, terlebih dahulu dilakukan tinjauan pustaka yang akan digunakan sebagai dasar acuan selama pengerjaan tugas akhir berlangsung.

2.1 Studi Sebelumnya

Berikut merupakan beberapa studi penelitian sebelumnya yang dijadikan acuan dalam pengerjaan penelitian tugas akhir. Seluruh studi tersebut akan dijelaskan lebih dalam pada tabel 2.1.

Tabel 2.1. Penelitian Sebelumnya

Penelitian 1	
Judul Paper	Forecasting the Sales of An Innovative Agro-Industrial Product with Limited Information: A Case of Feta Cheese from Buffalo Milk in Thailand [9].
Penulis; Tahun	Orakanya Kanjanatarakul dan Komsan Suriya; 2013.
Deskripsi Umum	<p>Penelitian ini membahas teknik peramalan penjualan dengan informasi yang didapatkan secara terbatas. Data yang digunakan berasal dari produk agroindustri yang inovatif, yaitu keju feta yang terbuat dari susu kerbau oleh Royal Project Foundation di Thailand. Teknik peramalan yang dibandingkan akurasi antara metode <i>Bass Model</i> dan <i>Logistic Function</i>.</p> <p>Perbandingan metodenya didasarkan nilai akurasi dari perhitungan nilai <i>Mean Absolute Percentage Error</i> (MAPE) yang didapatkan. Harapan para penulis penelitian ini dapat dilanjutkan studinya baik secara empiris, maupun secara teoritis.</p>

Relevansi	Objek dari penelitian ini memiliki keterkaitan besar dengan penelitian tugas akhir ini walaupun menggunakan metode berbeda. Pengukuran tingkat akurasinya menggunakan MAPE. Sehingga penelitian ini dapat dijadikan dasar pengerjaan tugas akhir.
Penelitian 2	
Judul Paper	Ether Price Prediction Using Gated Recurrent Unit [10].
Penulis, Tahun	Gopinath Balu dan I. Sathik Ali; 2018.
Deskripsi Umum	<p>Ether merupakan mata uang kripto kedua terbanyak digunakan dengan kapitalisasi pasar \$ ± 60 miliar pada 2018. Peramalan Ether telah dilakukan menggunakan metode <i>Long Short-Term Memory</i> (LSTM), tetapi modelnya sulit untuk dilatih sehingga penelitian ini dibuat dengan menggunakan metode <i>Gated Recurrent Unit</i> (GRU).</p> <p>Penelitian ini memiliki empat tahapan, yaitu Ekstraksi data, <i>Preprocessing</i> data, Prediksi model dan Visualisasi data. Hasil dari penelitian ini menunjukkan bahwa metode GRU memiliki tingkat akurasi yang tinggi serta dapat mengingat informasi dan <i>depedency</i> jangka panjang. Akan tetapi penelitian ini juga menunjukkan bahwa metode GRU tidak memiliki struktur tetap untuk membangun arsitekturnya.</p>
Relevansi	Metode pada penelitian ini menggunakan metode yang sama dengan metode yang tugas akhir ini, yakni metode GRU. Selain itu penelitian ini juga dapat dijadikan dasar pembuatan metodologi, arsitektur, dan model peramalan GRU.
Penelitian 3	
Judul Paper	Deep Learning with Gated Recurrent Unit Networks for Financial Sequence Predictions [11].

Penulis, Tahun	G. Shen, Q. Tan, H. Zhang, P. Zeng, J. Xu; 2018.
Deskripsi Umum	Walaupun metode GRU dapat digunakan pada data finansial <i>time-series</i> , metode ini jarang digunakan pada kasus nyata. Untuk itu dilakukan peramalan menggunakan data saham <i>Hang Seng Indexes</i> (HSI), <i>the Deutscher Aktienindex</i> (DAX), dan <i>S&P 500 Index</i> dari tahun 1991 sampai dengan 2017. Metode <i>Support Vector Machine</i> (SVM) juga digunakan sebagai perbandingan model. Kedua model menggunakan 25 <i>hidden layer</i> dengan <i>dropout rate</i> -nya 0,9. Setiap <i>training</i> dilakukan sampai 10000 <i>epoch</i> . Validasi dilakukan setiap 5 <i>epoch</i> dengan perbandingan <i>data training</i> dan <i>data validation</i> sebanyak 4:1. Hasil eksperimen dari penelitian menunjukkan bahwa kedua model GRU memiliki akurasi yang cukup tinggi dan versi GRU-SVM efektif meningkatkan kemampuan <i>training</i> model.
Relevansi	Penelitian ini digunakan sebagai referensi dan acuan pengerjaan penelitian tugas akhir terkait peramalan menggunakan metode GRU dengan data <i>time-series</i> . Penelitian ini juga membandingkan tingkat akurasi GRU dengan metode gabungan GRU-SVM.

Hasil dari studi literatur sebelumnya memperkuat penulis bahwa penelitian sebelumnya dapat digunakan penulis sebagai acuan dan referensi karena memiliki keterkaitan pada kasus dan metode yang digunakan.

2.2 Dasar Teori

Bagian ini akan menjelaskan dasar teori yang digunakan dalam melaksanakan penelitian tugas akhir ini.

2.2.1 Keju

Keju merupakan salah satu produk olahan susu yang dihasilkan dari proses penggumpalan (koagulasi) protein susu (kasein) beserta komponen lainnya. Komponen lainnya berupa lemak, mineral dan vitamin yang dapat larut ke dalam kasein. Sedangkan komponen – komponen susu yang tidak bisa larut dalam kasein disebut dengan *whey*. Tergantung dari jenis susu, metodenya maupun enzimnya dapat mempengaruhi kekerasan, pemeraman ataupun kematangan keju itu sendiri [12].

2.2.2 Data Praproses

Data praproses atau disebut juga *data preparation* merupakan serangkaian proses yang diterapkan pada data asli sebelum data itu dipakai dalam proses selanjutnya. Pada dasarnya data asli masih bersifat “kotor” untuk diolah. Kata kotor dapat diartikan data asli memiliki sifat yang tidak lengkap, tidak konsisten, *noise*, dan *null value*.

Oleh karena itu dilakukanlah data praproses yang bertujuan untuk mengolah data asli menjadi data yang siap olah. Penggunaan data yang siap olah pada proses pemeraman maupun penggalian data akan mendapatkan hasil yang lebih terpercaya [13]. Berbagai metode yang dapat digunakan dalam praproses, diantaranya menggunakan metode *data discretization*, *data normalization*, *outlier detection*, *instance selection*, *handling missing feature values*, dan *feature selection* [14].

2.2.3 Peramalan

Peramalan merupakan suatu proses memperkirakan secara kuantitatif apa yang akan terjadi pada masa depan dalam rentang waktu tertentu yang didasarkan data relevan masa lalu. Peramalan dapat digunakan dalam mengadakan pendekatan analisis terhadap pola dari data pada masa lalu, sehingga dapat memberikan *insight* mengenai pemecahan, ide pokok, dan pengerjaan yang sistematis dan praktis [15]. *Insight* yang didapat dari peramalan sangatlah penting sebagai dasar

perencanaan dan kontrol operasi dalam berbagai bidang perusahaan. Sebagai contohnya, dalam bidang manajemen produksi, sistem inventori, kontrol kualitas, perencanaan keuangan, dan analisis investasi [16].


Metode peramalan itu sendiri dapat dibagi menjadi dua, yaitu metode kualitatif dan metode kuantitatif. Metode kualitatif bersifat intuitif dan objektif karena didasarkan pendapat dari para ahli dan hasilnya sangatlah bergantung dari penyusunan pendapat dari para ahli bersangkutan. Sedangkan metode kuantitatif bersifat objektif dan didasarkan dari data – data masa lalu yang dapat dikuantitatifkan. Berdasarkan waktunya, peramalan juga dapat dibagi menjadi peramalan jangka pendek, peramalan jangka menengah, dan terakhir peramalan jangka panjang. Peramalan jangka pendek berguna bagi perusahaan modern untuk mengambil keputusan yang sifatnya mendesak seperti penjadwalan, produksi, ketenagakerjaan, dan perencanaan keuangan [17].

Yang dimaksud dengan data – data masa lalu atau data *time series* adalah rangkaian pengamatan data secara berurutan yang dikumpulkan dari waktu ke waktu. Contohnya yaitu data curah hujan bulanan, harga harian saham IBM, dan produksi bir Australia triwulan [18]. Data *time series* sendiri biasanya bersifat tidak stasioner. Sifat dari non-stasioner ditunjukkan dari pengamatan dalam selang rentang waktu tertentu, seseorang tidak dapat menemukan suatu pola maupun kecenderungan yang jelas yang menunjukkan bahwa data tersebut bernilai tetap [19].

2.2.4 Gated Recurrent Unit

Terdapat perbedaan besar antara arsitektur *Recurrent Neural Network* (RNN) dengan *Back-Propagation Neural Network* (BPNN) dan *Convolution Neural Network* (CNN). Dimana selain *input layer*, *hidden layer* dan *output layer*, arsitektur RNN memiliki perhitungan berulang pada *hidden layer*-nya.

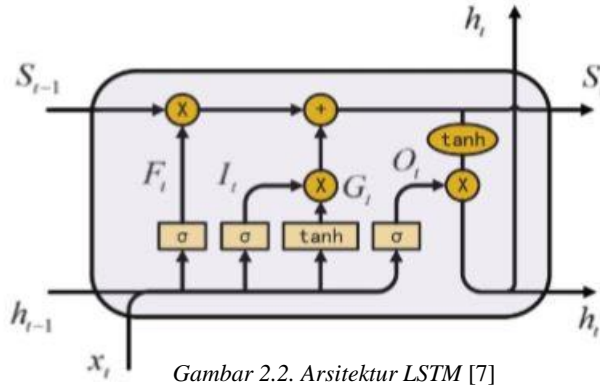
Yang dimaksud dengan *looping* dikarenakan adanya *input gate* dan *output gate* yang berada diantara *hidden layer* dalam 1 lapisan yang sama dan pada waktu yang sama. Bentuk arsitektur RNN dapat dilihat pada gambar 2.1. dimana arsitektur RNN secara efektif meningkatkan akurasi prediksi dengan menggunakan kekuatan data historis secara berulang seperti ingatan pada manusia.



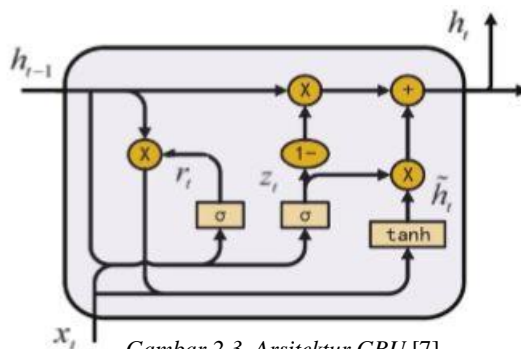
Gambar 2.1. Arsitektur RNN [7]

Tetapi, sejumlah besar penelitian menunjukkan bahwa RNN menghadapi masalah ketika mempelajari model secara jangka panjang. Masalah yang paling umum terjadi adalah *vanishing gradient* dan *exploding gradient* [4].

Untuk menyelesaikan masalah tersebut, pada tahun 1997 oleh Reiter dan Schmidhuber mengusulkan metode *Long Short-Term Memory* (LSTM). LSTM menambahkan sebuah proses gerbang seleksi pada arsitektur RNN. Penambahan *forget gate* tersebut dapat mengendalikan informasi mana yang layak diteruskan dan menggunakan fungsi yang berbeda untuk memperbarui keadaan tersembunyi pada *hidden layer*. Sehingga masalah umum RNN dapat teratasi. Lebih rinci arsitektur LSTM dapat dilihat pada gambar 2.2 [7].



Hingga kini, model LSTM merupakan salah satu variasi arsitektur RNN yang paling populer dan dapat mencapai akurasi yang cukup tinggi daripada algoritma lainnya. Meskipun begitu, pelatihan model LSTM memakan waktu lebih lama daripada algoritma lainnya. Pada tahun 2014, Cho et al mengusulkan metode *Gated Recurrent Unit* (GRU) yang merupakan variasi ekstensi dari model LSTM [11]. GRU menggabungkan fungsi *input gate* dan *forget gate* menjadi sebuah *update gate*, serta menggantikan *output gate* menjadi *reset gate*. Model akhirnya menjadi lebih sederhana daripada LSTM dan dapat mencapai akurasi yang setara. Selain itu waktu pelatihan GRU lebih cepat jika dibandingkan dengan LSTM. Detail dari arsitektur GRU dapat dilihat pada gambar 2.3 [8].



Secara matematis, permodelan GRU dapat didefinisikan menggunakan persamaan berikut:

$$r_t = \sigma(W_r h_{t-1} + U_r x_t) \quad 2.1$$

$$z_t = \sigma(W_z h_{t-1} + U_z x_t) \quad 2.2$$

$$\hat{h}_t = \tanh(W(r_t * h_{t-1}) + U x_t) \quad 2.3$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t \quad 2.4$$

Di mana r_t dan z_t menunjukkan *reset* dan *update gate*, h_t dan \hat{h}_t menunjukkan keadaan tersembunyi pada t waktu serta W dan U merupakan matrik pemberat. Fungsi aktivasi yang digunakan adalah aktivasi *sigmoid* (σ) dan aktivasi *tanh*. Aktivasi (σ) berfungsi mengubah nilai informasi menjadi 0 sampai 1. Sedangkan aktivasi *tanh* dapat mengubah nilai informasi menjadi -1 sampai 1. *Reset gate* menentukan seberapa banyak informasi yang dilupakan ketika nilainya mendekati 0 dan menggunakan *input* kandidat keadaan tersembunyi. *Update gate* mengontrol seberapa banyak informasi yang akan digunakan kembali dimana jika nilainya mendekati 0, maka informasi sebelumnya akan diingat dan berlaku sebaliknya [7].

2.2.5 Mean Absolute Percentage Error

Setelah model peramalan didapatkan, hasil peramalan akan dilakukan uji akurasi. Pada dasarnya, semakin kecil nilai *error*-nya pada hasil peramalan, maka model peramalan tersebut semakin baik. Terdapat beberapa indikator yang dapat digunakan adalah *Mean Absolute Percentage Error* (MAPE), *Mean Square Error* (MSE), dan *Mean Absolute Deviation* (MAD). Pengujian akurasi pada penelitian tugas akhir ini akan menggunakan MAPE untuk mengetahui persentase *error* hasil peramalan. Cara mengukurnya dengan terlebih dahulu menghitung nilai *error* dari selisih data aktual (y_t) dengan hasil peramalan ($\hat{y}_t(t-1)$). Setelahnya barulah dicari persentase

error-nya dengan menggunakan rumus MAPE. Secara matematis MAPE dapat dirumuskan sebagai persamaan 2.5.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left(\left| \frac{y_t - \hat{y}_t(t-1)}{y_t} \times 100\% \right| \right) \quad 2.5$$

Pengukuran MAPE mempunyai syarat yang penting, yakni MAPE hanya bisa diukur jika data sebelum peramalan sudah tidak memiliki nilai 0 [20]. Selain itu MAPE juga termasuk pengukuran *error* relatif. Maksudnya apabila rasio *error* dan nilai pembagiya tidak masuk akal, maka nilai MAPE bisa saja lebih besar dari 100% atau bahkan negatif [21].

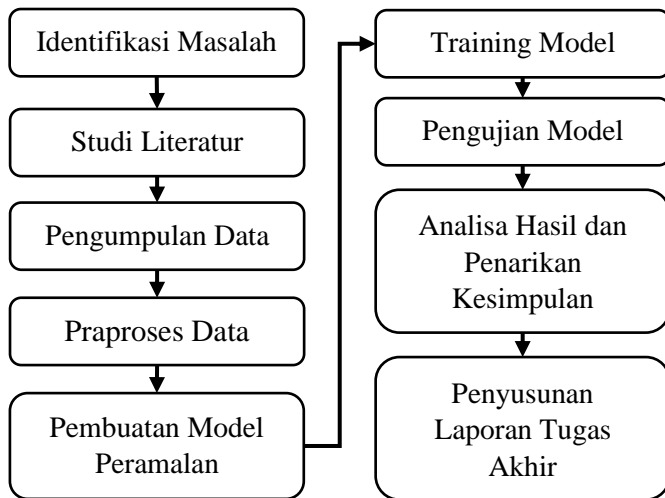
Halaman ini sengaja dikosongkan

BAB III METODOLOGI

Bab ini akan menjelaskan langkah-langkah sistematis mengenai tahapan pengerjaan penelitian tugas akhir ini. Penjelasan tersebut diperlukan agar setiap tahapan dapat berjalan secara terarah dan sistematis. Rincian tersebut akan diterangkan lebih lanjut pada bab berikut.

3.1 Tahapan Pelaksanaan Tugas Akhir

Pada sub bab ini akan diuraikan alur pengerjaan yang akan dipakai pada tugas akhir ini. Alur tersebut diterangkan pada gambar 3.1.



Gambar 3.1. Tahap Pengerjaan Tugas Akhir

3.2 Uraian Tahapan Pengerjaan

Alur pengerjaan peneliti tugas akhir yang sudah ditetapkan akan dijelaskan lebih lanjut pada sub bab berikut.

3.2.1 Identifikasi Masalah

Tahapan ini dilakukan dalam rangka mengetahui permasalahan yang ada pada studi kasus yang ingin diteliti. Masalah tersebut dikarenakan adanya ketidaksesuaian target penjualan Kota Surabaya dengan jumlah produksi keju Kraft pada perusahaan PT. Mondelez Indonesia.

3.2.2 Studi Literatur

Studi literatur merupakan proses pengumpulan informasi dari berbagai referensi seperti paper, artikel ilmiah, buku, dan studi penelitian sebelumnya. Tahapan ini dilakukan untuk menambah wawasan terkait dasar teori, konsep, proses perancangan, dan struktur algoritma *Gated Recurrent Unit* (GRU) yang akan digunakan di tugas akhir ini. Berdasarkan hasil dari studi literatur tersebut, diusulkan penggunaan metode peramalan menggunakan algoritma GRU pada penjualan keju Kraft di Kota Surabaya.

3.2.3 Pengumpulan Data

Tahapan ini dilakukan untuk mendapatkan data penunjang menjalankan tugas akhir ini. Data didapatkan melalui *manager sales* PT. Mondelez Indonesia terkait penjualan seluruh produk keju di Kota Surabaya yang berbentuk pivot *Microsoft Excel*. Jenis data yang akan digunakan merupakan penjualan keju Kraft Cheddar di Kota Surabaya dengan periode waktu harian dari 1 Januari 2019 hingga 31 Desember 2019.

3.2.4 Praproses Data

Data yang akan diramalkan terlebih dahulu akan dilakukan praproses data. Data akan ditransformasikan lalu dibersihkan dari *outlier*. Hasil dari praproses data nantinya dapat diolah dan dimasukkan ke dalam model peramalan.

3.2.5 Pembuatan Model Peramalan

Data yang sudah diolah akan dilakukan proses pemodelan peramalan dengan metode GRU. Secara garis besar proses

pemodelan tersebut dapat dibagi menjadi tiga tahapan, fase pembuatan, fase pelatihan model, dan fase uji model. Tiga tahapan tersebut akan dijelaskan lebih lanjut pada bagian berikutnya. Metode GRU akan dibuat dengan menggunakan *library* Keras atau MXNetR yang disediakan RStudio.

3.2.6 Training Model

Setelah model selesai dibuat, maka tahapan selanjutnya adalah melakukan pelatihan model. Pelatihan model tersebut akan menggunakan data training yang divalidasi menggunakan data validation. Untuk itu, data yang tersedia akan dibagi menjadi tiga bagian yaitu *data training*, *data validation*, dan *data testing* dengan proporsi 70:10:20.

3.2.7 Pengujian Model

Setelah model selesai dilatih, selanjutnya model akan dilakukan pengujian. Pada tahapan ini, model akan menggunakan data testing. Hasilnya akan diukur tingkat keakuratannya dengan cara mengukur persentase tingkat *error*-nya. Rumus yang digunakan disebut *Mean Absolute Error Percentage* (MAPE). Model terbaik didapatkan dari model dengan pengukuran nilai MAPE terkecil. Model tersebut akan dilakukan peramalan dan dianalisis hasilnya pada tahapan selanjutnya.

3.2.8 Analisa Hasil dan Penarikan Kesimpulan

Berikutnya hasil peramalan akan dianalisa berdasarkan tingkat akurasi. Setelahnya, hasil analisa tersebut akan ditarik kesimpulan untuk menjawab rumusan masalah tugas akhir. Selain itu kesimpulan tersebut dapat dijadikan rekomendasi bagi perusahaan, distributor cabang, bagian *sales* atau produksi, maupun peneliti yang ingin mengembangkan tugas akhir ini.

3.2.9 Penyusunan Laporan Tugas Akhir

Terakhir, dokumentasi terlaksananya tugas akhir akan disusun dalam laporan tugas akhir dengan format yang sudah ditetapkan oleh Laboratorium Rekayasa Data dan Intelejensi Bisnis

(RDIB) dan Departemen Sistem Informasi ITS. Laporan tugas akhir ini mencakup:

- a) Bab I Pendahuluan
Bagian pertama menjelaskan latar belakang, rumusan masalah, batasan masalah, tujuan, manfaat penelitian dan relevansi dari pengerjaan tugas akhir ini.
- b) Bab II Tinjauan Pustaka
Bab ini menjelaskan berbagai studi penelitian sebelumnya sebagai referensi, dan dasar acuan tugas akhir ini. Dasar – dasar teori yang dapat menunjang permasalahan dari tugas akhir ini juga dijelaskan dalam bab ini.
- c) Bab III Metodologi Penelitian
Bagian ini akan menjelaskan seluruh tahapan – tahapan sistematis pengerjaan tugas akhir ini. Setiap tahapan akan diberikan penjelasan lebih terperinci.
- d) Bab IV Perancangan
Bagian ini akan menjelaskan perancangan model peramalan yang digunakan dalam bagian ini. Model peramalan yang dibuat disesuaikan dengan metodologi yang sudah dijelaskan. Bagian ini juga berisi proses pengumpulan data dan praproses data.
- e) Bab V Implementasi
Bab ini menjelaskan proses peramalan yang dilakukan sesuai dengan rancangan pengerjaan tugas akhir. Peramalan tersebut akan digunakan pada data yang akan diramalkan.
- f) Bab VI Analisis Hasil dan Pembahasan
Bagian ini menjelaskan hasil peramalan yang didapat serta analisis dari hasil peramalan tersebut. Hasil peramalan tersebut dapat digunakan untuk peramalan penjualan untuk periode yang akan datang. Terdapat perbandingan hasil peramalan dengan metode maupun hasil peramalan lainnya

g) Bab VII Kesimpulan dan Saran

Bab terakhir akan menjelaskan kesimpulan yang didapat dari hasil peramalan. Saran untuk melanjutkan tugas akhir akan dimasukkan sebagai dasar pengembangan model peramalan selanjutnya dengan hasil yang sudah dihasilkan.

Halaman ini sengaja dikosongkan

BAB IV PERANCANGAN

Bab ini menjelaskan perancangan yang digunakan dalam proses pembuatan penelitian tugas akhir ini. Perancangan diperlukan sebagai dasar implementasi yang sesuai dengan metodologi yang dipakai.

4.1 Karakteristik Data

Data yang akan diramalkan merupakan data historis seluruh produk penjualan harian Keju Kraft 1 periode dari tanggal 1 Januari 2019 hingga 31 Desember 2019. Data yang dicatat merupakan penjualan yang terjadi pada hari kerja perusahaan yaitu dari hari senin sampai sabtu. Produk keju Kraft yang terjual yang digunakan terdiri dari produk Kraft Cheddar 165 Gram 48'S, Kraft Cheddar Free Mini 30+165 Gram 48'S, Kraft Cheddar Midi 70 Gram 48'S, Kraft Cheddar Midi 75 Gram 48'S, Kraft Cheddar Mini 30 Gram 18x8'S, Kraft Cheddar Mini 35 Gram 18x8'S BNS, Kraft Cheddar Q4 Bundle 4X36X35Gram, dan Kraft Cheddar Value Pack 2X165 Gram 24'S yang semuanya termasuk sub-produk 'Cheddar'. Dataset berbentuk pivot tabel dengan berbagai kolom yang dapat menunjukkan data yang diinginkan. Beberapa kolom yang menampilkan data digunakan dalam peramalan akan dijelaskan pada tabel 4.1. Untuk setiap produk terjual akan dihitung sebagai 1 potong yang merupakan jumlah kuantitas terkecil dari sebuah produk. Data produk terjual akan ditunjukkan sebagai variabel integer angka. Representasi data dengan 1 produk juga akan ditunjukkan pada tabel 4.2.

Tabel 4.1. Tabel Kolom Data

No.	Nama Kolom	Deskripsi
1	Cabang	Region tempat penjualan Keju Kraft
2	Barang	Jenis produk keju Kraft yang dijual
3	Bulan	Bulan terjadinya pejualan produk keju
4	Jenis Faktur	Jenis faktur pejualan
5	Tgl Faktur	Tanggal resmi terjadinya penjualan produk
6	Grand Total	Total jumlah produk yang terjual

Tabel 4.2. Tabel Pivot Penjualan

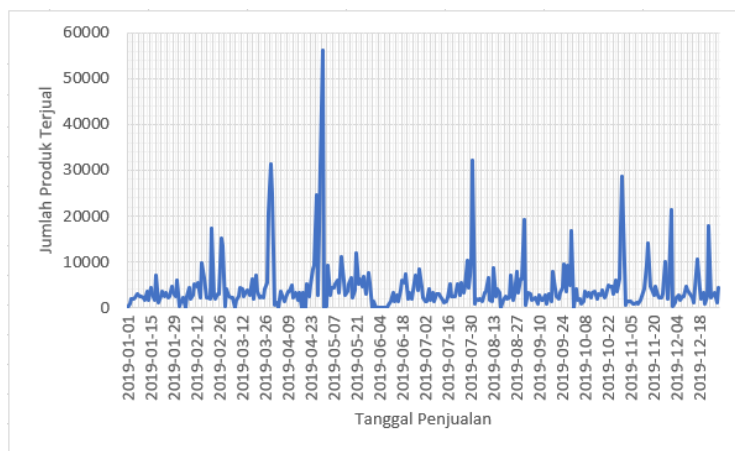
Jenis Faktur		FAKTUR						
Sum of Qty Terkecil			Bulan				Grand Total	
Cabang	Barang	Tgl faktur	1	2	...	12		
SURAB - AYA II Rungkut	KRAFT CHEDDAR 165GR 48'S	2019-01-02	39				39	
		2019-01-03	209				209	
		2019-01-04	397				397	
		...						
		2019-02-01		132			132	
		2019-02-02		431			431	
		2019-02-04		267			267	
		...						
		2019-12-28					507	507
		2019-12-30					93	93
2019-12-31					798	798		
KRAFT CHEDDAR 165GR 48'S Total			16.171	36.750		39.889	585.557	

4.2 Praproses Data

Setelah mengetahui karakteristik data yang akan digunakan, selanjutnya dilakukan praproses data. Terdapat 3 hal yang perlu dilakukan pada tahapan praproses data yaitu ekstraksi data, penghapusan data outlier, dan pemisahan data latih, data validasi dan data uji.

4.2.1 Ekstraksi Data

Data historis penjualan yang ada pada pivot data akan digabungkan menjadi 1 dataset penjualan sub-produk 'Cheddar'. Khusus produk berjenis Kraft Cheddar Mini dan Kraft Cheddar Midi akan dijadikan 1 jenis subset data. Plot data penjualan dapat dilihat pada gambar 4.1 dimana jenis plotnya termasuk plot data non-linear.



Gambar 4.1. Plot Data Penjualan Keju Kraft Cheddar

4.2.2 Penghapusan Data Oulier

Tahapan ini dilakukan untuk menghapus dataset penjualan dengan periode waktu yang dianggap sebagai *outlier*. Periode waktu yang dihapus sebanyak 1 periode, dari tanggal 3 Juni – 8 Juni. Dimana periode waktu tersebut menunjukkan penjualan

yang terjadi sangatlah sedikit dikarenakan adanya libur cuti bersama.

4.2.3 Menentukan Data Latih, Validasi dan Uji

Sebelum dikelompokkan, dataset akan diubah menjadi *lagged dataset* dulu, dimana dilakukan penambahan target variabel y ($x-n$) dan prediktor x . Nilai n disini menentukan jumlah waktu yang akan digeser. Hal ini dilakukan untuk mengubah data menjadi bentuk *supervised learning* dan menentukan seberapa banyak target variabel y yang digunakan sebagai *input* model. Selanjutnya barulah dataset yang ada akan dikelompokkan menjadi 3 kelompok data yaitu data latih, data validasi dan data uji dengan proporsi 70:10:20. Data latih yang digunakan sebanyak 213 data, dari 3 Januari – 13 September. Untuk data validasi yang digunakan sebanyak 30 data, dari 14 September – 18 Oktober, sedangkan data uji terdapat 61 data, dari 19 Oktober – 31 Desember.

4.3 Pemodelan Peramalan

Proses pemodelan ini dilakukan untuk membentuk model peramalan yang akan disusun. Model yang digunakan didasarkan variasi arsitektur *Recurrent Neural Network*, yaitu *Gated Recurrent Unit*. Model tersebut terdiri dari *input layer*, *hidden layer* dan *output layer*. Pada *input layer* akan dimasukkan nilai penjualan dan menghasilkan ramalan nilai penjualan pada *output layer*-nya. Sedangkan pada *hidden layer* memiliki 1 lapisan yang dapat menerima nilai *input* dari *input* sebelumnya. Lapisan ini memiliki keadan tersembunyi yang ditentukan dan 2 fungsi aktivasi yang menentukan fungsi dari *reset gate* dan *update gate*. Selain itu, terdapat *optimizer* yang digunakan untuk menekan nilai *error* pada iterasi model serta fungsi. Terakhir model akan ditambahkan *lost function* untuk mengukur efektivitas model dalam melakukan prediksi. Rincian dari rancangan model peramalan dapat dilihat pada tabel 4.3.

Tabel 4.3. Rancangan Model Peramalan

Parameter	Deskripsi
<i>Input layer</i>	1 lapisan, jumlah penjualan pada tanggal tertentu
<i>Hidden layer</i>	1 lapisan, dengan keadaan tersembunyi yang ditentukan
<i>Output layer</i>	Ramalan jumlah penjualan pada tanggal tertentu

4.3.1 Skenario

Percobaan mencari model terbaik dilakukan dengan 2 tahapan, yaitu fase latih model dan uji model. Untuk menentukan nilai MAPE terbaik, maka model menggunakan cara *trial & error*. Model akan diiterasi berdasarkan jumlah input dengan parameter *epoch*, *learning rate*, *decay*, *units* dan *dropout* yang sama. Penjelasan dari tiap parameter model akan dijelaskan pada tabel 4.4.

Tabel 4.4. Deskripsi Parameter Model

No	Parameter	Deskripsi
1	<i>Epoch</i>	Jumlah iterasi yang dilakukan model untuk memproses data latih.
2	<i>Learning rate</i>	Mengontrol banyaknya model merubah pembelajaran dalam menanggapi estimasi kesalahan model.
3	<i>Decay</i>	Konstanta yang mengatur peluruhan dari perubahan <i>learning rate</i> sebelumnya.
4	<i>Dropout</i>	Meregulasi pelatihan model untuk menghindari resiko model menjadi <i>overfit</i> atau <i>underfit</i> .
5	<i>Units</i>	Menentukan jumlah keadaan tersembunyi yang diolah dalam 1 waktu pada <i>hidden layer</i> .

Nantinya *input* yang menghasilkan nilai MAPE terbaik akan diterasi lebih lanjut agar dapat menghasilkan nilai lebih baik lagi MAPE. Evaluasi MAPE dilakukan setiap iterasi untuk melihat apakah nilai MAPE meningkat atau tidak. Tiap iterasi akan mengubah nilai parameter yang telah ditentukan sebelumnya. Percobaan dihentikan apabila model menghasilkan nilai MAPE yang sesuai.

4.3.2 Fase Latih Model

Setelah struktur model peramalan telah disusun, maka model akan dilatih dengan menggunakan data latih yang telah disiapkan. Model yang terpilih akan diatur lebih lanjut dengan banyaknya *epoch* serta *tuning* parameter. Tabel 4.5 akan menjelaskan seluruh pengaturan parameter yang digunakan. Untuk menghindari *overfitting* dan *undeffitting* model, maka data latih akan divalidasi dengan data validasi. Model juga dapat dilihat dengan plot yang menampilkan *training lost* dan *validation lost* untuk menentukan apakah model dilatih menjadi *overfitting* atau *undeffitting*. Efektivitas model dapat ditingkatkan dengan menggunakan *lost function*.

Tabel 4.5. Penjelasan Jenis Parameter Model

Parameter	Deskripsi	Jenis Parameter
<i>Activation</i>	Fungsi matematis yang menentukan nilai <i>output</i> dari keadaan tersembunyi.	<i>Tanh, Sigmoid, Null</i>
<i>Optimizer</i>	Fungsi untuk membentuk model agar semakain akurat dengan mengatur matrik pemberat didasarkan fungsi <i>lost function</i> .	<i>Adam, Rmsprop; (learning rate, decay)</i>
<i>Lost Function</i>	Fungsi yang mengevaluasi seberapa baik algoritma dalam memodelkan dataset berdasarkan nilai <i>lost</i> saat pelatihan model	<i>mean_squared_logarithmic_error, mean_squared_error, mean_absolute_percentage_error</i>

4.3.3 Fase Uji Model

Setelah model selesai dilatih, fase berikutnya yang dilakukan adalah menguji model. Pertama model akan melakukan prediksi data, hasil prediksi akan dibandingkan dengan data uji untuk mengukur akurasi model. Akurasi model dihitung dengan mencari nilai *error* peramalan. Setelahnya, Nilai *error* tersebut dihitung dengan menggunakan *Mean Absolute Percentage Error* (MAPE).

Halaman ini sengaja dikosongkan

BAB V IMPLEMENTASI

Bab ini menjelaskan bagaimana proses pelaksanaan penelitian tugas akhir ini. Proses akan meliputi pembuatan model berdasarkan rancangan yang sudah dijelaskan pada bab sebelumnya.

5.1 Lingkungan Implementasi

Lingkungan merupakan seluruh perangkat-perangkat yang dibutuhkan dalam melaksanakan proses implementasi penelitian tugas akhir ini. Lingkungan yang digunakan terdiri atas *hardware*, *software*, dan *library* proses implementasi. Penjelasan lebih lanjut lingkungan implementasi akan dijelaskan dalam tabel 5.1, 5.2, dan 5.3.

Tabel 5.1. Lingkungan Hardware

No	Hardware	Spesifikasi
1	Laptop	Asus X456UQ
2	Processor	Intel Core i5-62200U Quad Core
3	Memory	DDR3 4 GB
4	Hardisk	Samsung SSD 860 EVO 500GB
5	GPU	NVIDIA GeForce 940MX

Tabel 5.2. Lingkungan Software

No	Software	Spesifikasi
1	Windows 10	Sistem Operasi
2	R	Bahasa pemograman
3	Rtools 3.5	R <i>Environment packages</i>
4	Rstudio 1.3.959	R IDE & Code editor
5	Microsoft Excel	<i>Data spreadsheet</i>

Tabel 5.3. Lingkungan Library

No	Library	Penggunaan
1	readr	Membaca file csv
2	tidyverse	<i>Core</i> untuk manipulasi data
3	ggplot2	Memvisualisasikan data
4	keras	Membangun model peramalan

5.2 Praproses Data

Tahap ini dilakukan untuk menyiapkan dataset agar data dapat digunakan pada tahapan pemodelan berikutnya. Pertama, data akan diekstrak dari pivot data dan diatur agar menghasilkan *output* data menjadi bentuk file *.csv*. Seluruh proses ekstraksi dan penggabungan dilakukan dalam aplikasi Microsoft Excel. Penggabungan dilakukan dengan menggunakan fungsi *sum* untuk menyatukan seluruh data penjualan menjadi 1 dataset penjualan. Untuk penghapusan *oulier*, data akan diplotkan terlebih dahulu baru ditentukan dan dihapus data *outlier*-nya. Selanjutnya dataset akan dimasukkan ke dalam *workspace* RStudio menggunakan *library readr*. Dataset yang telah tersimpan dapat divisualisasikan dan diperiksa karakteristiknya dengan *library ggplot2 dan tidyverse*. Selanjutnya dilakukan penghapusan kolom yang tidak digunakan untuk menyiapkan tahapan praproses data selanjutnya. Langkah terkait penggunaan RStudio akan diperlihatkan dalam skrip 5.1.

```
#load librarby
library(readr)
library(tidyverse)
library(ggplot2)

#read & examine data
data <- read_csv("data penjualan.csv")
glimpse(data)
#visualize data
ggplot(data, aes(x = Date, y = Data)) + geom_line()
#drop column
data <- data.matrix(data[, -1])
```

Skrip 5.1. Membaca & Memeriksa Data

5.2.1 Menentukan Data Latih, Validasi dan Uji

Langkah selanjutnya dataset akan diubah menjadi *supervised learning*. Caranya dengan mengubah dataset menjadi *lagged dataset*, dengan menggunakan fungsi *lag*. Hasilnya dataset akan

terbagi 2 menjadi target variabel $y(x-n)$ dan prediktor x , dimana n menunjukkan jumlah waktunya. Skrip 5.2 akan menunjukkan proses pembuatan *supervised learning*.

```
##lagged data set
data_lag1 <- lag(data, 1)
data_lag2 <- lag(data, 2)
supervised <- cbind( data_lag2, data_lag1, data)
supervised <- supervised[-(1:2),]
rownames(supervised) =1:nrow(supervised)
head(supervised)
```

Skrip 5.2. Pembentukan Supervised Learning

Setelah menjadi *supervised learning*, barulah dataset dikelompokkan menjadi 3 kelompok, yaitu data latih, data validasi dan data uji dengan proporsi yang sudah ditentukan. Penentuan kelompok data akan dilakukan 2 kali, pertama untuk mengelompokkan data latih dan uji. Kedua untuk membagi data uji menjadi data uji dan data validasi. Data latih akan dipanggil variabel *train*, data validasi dengan variabel *valid*, dan data uji sebagai variabel *test*. Proses pengelompokan data ini akan diproses dengan menggunakan skrip 5.3.

```
##split dataset 1
N = nrow(data)
n = round(N *0.7, digits = 0)
train = data[1:n, ]
tes = data[(n+1):N, ]

##split dataset 2
tes <-as.data.frame(tes)
N = nrow(tes)
n = round(N *0.33, digits = 0)
valid = tes[1:n, ]
test = tes[(n+1):N, ]
```

Skrip 5.3. Pengelompokan Data Latih, Validasi dan Uji

Skrip 5.4 melanjutkan proses yang ada pada skrip 5.3. Dimana dataset yang telah dikelompokkan akan dikelompokkan kembali menjadi variabel x dan y untuk tiap kelompok data.

```
##determined x & y
y_train = data.matrix(train[,1:2])
x_train = data.matrix(train[,3])

y_val = data.matrix(valid[,1:2])
x_val = data.matrix(valid[,3])

y_tes = data.matrix(test[,1:2])
x_tes = data.matrix(test[,3])
```

Skrip 5.4. Menentukan variabel x dan y

5.3 Peramalan

Proses ini dilakukan untuk membangun model peramalan dengan variasi *metode Recurrent Neural Network*, yaitu model *Gated Recurrent Unit*. Data yang digunakan merupakan data yang telah dipraproses sebelumnya.

5.3.1 Penyusunan Model

Pertama, model akan dibentuk arsitekturnya. Model akan terdiri dari 1 *hidden layer* dengan berbagai parameter yang ditentukan. Penyusunan parameter tersebut akan didefinisikan pada skrip 5.5. Pertama-tama, dilakukan *reshape input* data latih dan validasi agar dapat dimasukkan ke dalam model. *Units* dan *epoch* akan mengatur banyaknya pelatihan yang dilakukan model beserta jumlah keadaan tersembunyi yang diolah.

Argumen *stateful = True* membuat model akan menggunakan *input* data berikutnya menggunakan *input* data sebelumnya. Karena itu, model harus menerima 3 dimensi inputan (*samples, timesteps, feature*) dari argumen *batch_input_shape*.

```

##create model
#parameter
dim(x_train) <- c(length(x_train), 1, 1)
dim(x_val) <- c(length(x_val), 1, 1)
X_shape2 = dim(x_train)[2]
X_shape3 = dim(x_train)[3]
batch_size = 1
units = 200
#model
modelG <- keras_model_sequential() %%
layer_gru(name = "hidden", units, stateful = TRUE,
          dropout = 0.0002, activation = NULL,
          recurrent_activation = "sigmoid",
          batch_input_shape = c(batch_size,
                                X_shape2, X_shape3),
          recurrent_initializer =
            initializer_random_uniform(minval = -0.05,
                                       maxval = 0.05, seed = 2),
          kernel_initializer =
            initializer_random_uniform(minval = -0.05,
                                       maxval = 0.05, seed = 2) )%%
layer_dense(name = "output", units = 1 )

```

Skrip 5.5. Membentuk Model Peramalan

Dimana *sample* merupakan jumlah observasi tiap *batch*, *timesteps* merupakan jumlah waktu dalam 1 pengamatan, dan *feature* adalah banyaknya jenis variabel dataset yang dilatih. Nilai *batch size* ditentukan dari nilai faktor persekutuan terbesar (FPB) antar data latih dan data uji. Fungsi aktivasi yang digunakan antara fungsi aktivasi *tanh* dan *sigmoid* atau *null*. Argumen *dropout* digunakan untuk mengurangi *overfitting* model. Terakhir argumen *reccurent_initializer* dan *kernel initializer* berfungsi agar hasil latih model cenderung tetap dengan membatasi nilai matrik pemberatnya.

Setelahnya model dibentuk, model dapat di-*compile*. Model akan menggunakan *optimizer adam* dengan nilai *learning rate* dan *decay* yang ditentukan. Untuk mengukur performa model,

model akan menggunakan *lost function* = *'mean_squared_logarithmic_error'*. Skrip 5.6 akan mendefinisikan fungsi *compile* model tersebut.

```
#compile model
modelG %>% compile(
  loss = 'mean_squared_logarithmic_error',
  optimizer = optimizer_adam
  (lr= 0.00005, decay = 1e-6) )
summary(modelG)
```

Skrip 5.6. Model yang Dicompile

5.3.2 Fase Latih Model

Model terpilih selanjutnya akan masuk ke proses pelatihan. Proses pelatihan model menggunakan fungsi *fit*. Model akan didefinisikan data latih, data validasi beserta iterasi *epoch* yang ditentukan. Argumen *verbose* berfungsi sebagai tampilan dalam proses latih model. Argumen *shuffle = False* digunakan untuk menghindari data latih tercampur dan menjaga depedensi antara variabel *y* dan prediktor *x*. Plot pelatihan dapat dilihat dengan fungsi *plot*, yang menampilkan *training lost* dan *validation lost*. Terakhir *initial_epoch* menentukan nilai awal matrik pemberatnya. Proses pelatihan model akan dijelaskan pada skrip 5.7.

```
##train model
history <- modelG %>% fit(x_train, y_train,
  epochs= 300, batch_size=batch_size, verbose=1,
  shuffle=FALSE, initial_epoch = 0,
  validation_data = list(x_val, y_val) )

plot(history)
```

Skrip 5.7. Pelatihan Model

5.3.3 Fase Uji Model

Model yang telah dilatih selanjutnya akan diuji dengan melakukan peramalan. Skrip 5.8 menunjukkan fase peramalan model. Hasil dari prediksi model akan dibentuk pada variabel *predictions*. Dimana struktur pada variabel tersebut memiliki plot yang sesuai dengan data uji. Untuk menghitung akurasi peramalan, maka digunakanlah fungsi MAPE. Data pada variabel *predictions* dipindahkan, dibandingkan, dan diplot dengan data uji pada *Microsoft Excel*.

```
##prediction
L = length(x_tes)
predictions = numeric(L)

for(i in 1:L){
  X = x_tes[i] dim(X) = c(1,1,1)
  yhat = modelG %>% predict(X, batch_size=batch_size)

# store
predictions[i] <- yhat }
```

Skrip 5.8. Peramalan Data

Halaman ini sengaja dikosongkan

BAB VI HASIL DAN PEMBAHASAN

Bab ini akan menjelaskan hasil dari proses penelitian tugas akhir ini beserta pembahasannya. Hasil dari setiap proses maupun luaran dari penelitian tugas akhir ini akan dibahas lebih lanjut.

6.1 Hasil Praproses Data

Praproses data dilakukan untuk mempersiapkan data agar dapat diproses di dalam model peramalan. Data pivot yang ada akan langsung diekstrak ke dalam bentuk tabel *excel*. Seluruh data penjualan produk akan dijumlahkan menjadi 1 kolom Total Penjualan nantinya akan diproses dalam model peramalan. Tabel 6.1 berikut menunjukkan potongan data yang telah diubah ke dalam 1 tabel.

Tabel 6.1. Tabel Data dengan Hasil Transformasi

Region	Sub-Produk	PENJUALAN								Total Penjualan
East Java	Grand Total	CHEDDAR								
Surabaya	Tanggal	KRAFT CHEDDAR 165GR 48'S	KRAFT CHEDDAR FREE MINI 30*165GR 48'S	KRAFT CHEDDAR MIDI 70/75GR 48'S	KRAFT CHEDDAR MINI 30/35G 18X8'S	KRAFT CHEDDAR MINI 35G 18X8'S BNS	KRAFT CHEDDAR Q4 BUNDLE 4X36X35GR	KRAFT CHEDDAR VALUE PACK 2X165GR 24'S		
Il Rungkut		Total	Total	Total	Total	Total	Total	Total		
	2019-01-01	0	0	0	0	0	0	0	0	0
	2019-01-02	39	0	57	152	0	476	0	0	724
	2019-01-03	209	0	164	928	0	488	0	0	1789
	2019-01-04	397	0	300	1160	0	152	0	0	2009
	2019-01-05	124	0	477	1288	0	384	0	0	2273
	2019-01-07	128	0	437	1984	0	520	0	0	3069
	2019-01-08	37	0	480	1208	0	812	0	0	2537
	2019-01-09	9	0	404	1264	0	696	0	0	2373
	2019-01-10	30	0	318	760	0	1012	0	0	2120
	2019-01-11	2	0	373	856	0	472	0	0	1703
	2019-01-12	481	0	691	1296	0	1032	0	0	3500
	2019-12-24	14162	0	465	3328	0	0	0	0	17955
	2019-12-26	815	0	140	1176	0	0	0	0	2131
	2019-12-27	248	0	640	1984	0	0	0	0	2872
	2019-12-28	507	0	554	2184	0	0	0	0	3245
	2019-12-30	93	0	224	888	0	0	0	0	1205
	2019-12-31	798	0	502	3088	0	0	0	0	4388
	Total	585557	8016	134169	598727	616	13016	10648		1350749

6.1.1 Penghapusan Data Outlier

Selanjutnya dilakukan penghapusan data yang dianggap sebagai *outlier*. 1 Periode yang dihapus ditunjukkan pada tabel 6.2 berikut.

Tabel 6.2. Periode Data Outlier

	A	B	C	D	E	F	G	H	I	J
1	Region	PENJUALAN								
2	East Java	Sub-Produk	CHEDDAR							
3		Grand Total	1350749							
4	Surabaya Il Rungkut	Tanggal	KRAFT CHEDDAR 165GR 48'S	KRAFT CHEDDAR FREE MINI 30+165GR 48'S	KRAFT CHEDDAR MIDI 70/75GR 48'S	KRAFT CHEDDAR MINI 30/35G 18X8'S	KRAFT CHEDDAR MINI 35G 18X8'S BNS	KRAFT CHEDDAR Q4 BUNDLE 4X36X35GR	KRAFT CHEDDAR VALUE PACK 2X165GR 24'S	Total Penjualan
5		Total	Total	Total	Total	Total	Total	Total	Total	
131		2019-05-27	516	156	563	1624	0	0	192	3051
132		2019-05-28	3097	46	525	3744	0	0	240	7652
133		2019-05-29	1390	47	767	3024	0	0	96	5324
134		2019-05-30	0	0	0	0	0	0	0	0
135		2019-05-31	145	0	91	1160	0	0	96	1492
136		2019-06-01	0	0	0	0	0	0	0	0
137		2019-06-03	3	0	10	24	0	0	0	37
138		2019-06-04	0	0	0	64	0	0	0	64
139		2019-06-05	0	0	0	0	0	0	0	0
140		2019-06-06	0	0	0	0	0	0	0	0
141		2019-06-07	0	0	3	24	0	0	0	27
142		2019-06-08	0	0	0	0	0	0	0	0
143		2019-06-10	185	0	59	288	0	0	0	532
144		2019-06-11	126	144	148	520	0	0	336	1274
145		2019-06-12	1268	189	381	1408	0	0	96	3342
146		2019-06-13	420	54	282	624	0	0	0	1380
147		2019-06-14	1283	54	335	1096	0	0	0	2768
148		2019-06-15	364	48	204	624	0	0	48	1288
317		Total	58557	8016	134169	598727	616	13016	10648	1350749

6.1.2 Menentukan Data Latih, Validasi dan Uji

Langkah berikutnya dilakukan dengan memasukkan data ada ke dalam *workspace project* RStudio. Data yang telah dimasukkan akan diubah menjadi *data lag*, dimana *data lag* tersebut akan menentukan jumlah *input* yang akan digunakan berdasarkan waktu yang ditentukan. Tiap skenario memiliki perbedaan waktu *data lag*. Tabel 6.3 menunjukkan potongan ilustrasi *lagged dataset* dengan 1 lag.

Tabel 6.3. Lagged Dataset

Variabel (y) (x-1)	Predictor (x) (stationer)
724	1789
1789	2009
2009	2273
2273	3069
3069	2537
2537	2373
2373	2120

Setelah data telah menjadi *supervised learning*, langkah selanjutnya mengelompokkan data menjadi data latih, validasi, dan uji. Kelompok data yang telah ditentukan akan

dikelompokkan kembali menjadi variabel x dan y untuk tiap masing - masing kelompok data. Berikut ilustrasi data latih, validasi, dan uji akan ditunjukkan pada tabel 6.4.

Tabel 6.4. Hasil Pengelompokkan Data

x_train	y_train	x_val	y_val	x_test	y_test
724	1789	2819	898	3772	2233
1789	2009	898	3102	2233	2752
2009	2273	3102	1395	2752	4941
2273	3069	1395	7959	4941	4628
3069	2537	7959	4134	4628	4559
2537	2373	4134	2422	4559	2994
2373	2120	2422	2039	2994	5960

6.2 Hasil Peramalan

Hasil dari peramalan akan ditampilkan berdasarkan parameter yang diuji. Pertama model akan dilatih dengan skenario yang berbeda. Tiap skenario memiliki parameter yang sama dengan jumlah *input* yang berbeda. Model terbaik merupakan model yang menghasilkan nilai MAPE terendah berdasarkan *input* yang ditentukan. Selanjutnya model akan diatur lebih lanjut parameternya agar dapat menghasilkan nilai MAPE terbaik.

6.2.1 Hasil Peramalan dengan Parameter Awal

Untuk menentukan skenario terbaik, percobaan dilakukan dengan menggunakan *input* berbeda dengan parameter yang sama. *Input* yang digunakan akan dibedakan menjadi 9 skenario, dimana 1 skenario memiliki jumlah *input* yang diatur *lag* data. Tabel 6.5 menunjukkan parameter awal yang diujicobakan, sedangkan tabel 6.6 menjelaskan skenario yang digunakan.

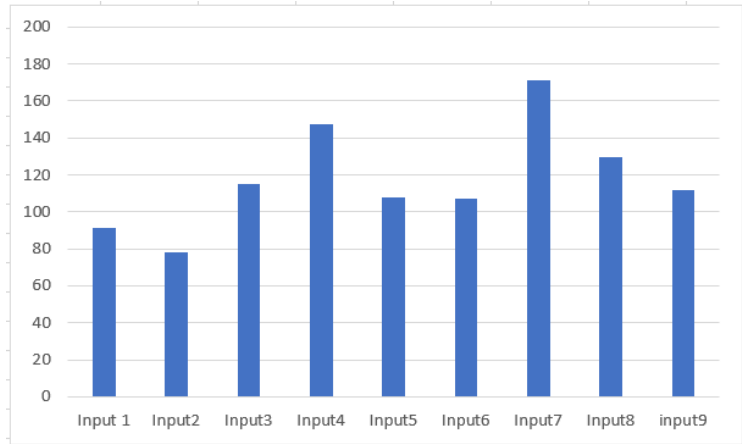
Tabel 6.6. Parameter Awal yang Diujicobakan

Parameter	Pengaturan
<i>Units</i>	20
<i>Epoch</i>	100
<i>Dropout</i>	0,002
<i>Learning Rate</i>	0,0001
<i>Lost Function</i>	'mean_squared_logarithmic_error'
<i>Optimizer</i>	<i>Adam</i>
<i>Decay</i>	<i>1e-6</i>


Tabel 6.5. Skenario yang Digunakan

Skenario	Jumlah Lag Dataset
<i>Input1</i>	x; x-1
<i>Input2</i>	x; x-1, x-2
<i>Input3</i>	x; x-1, x-2, x-3
<i>Input4</i>	x; x-1, x-2, x-3, x-4
<i>Input5</i>	x; x-1, x-2, x-3, x-4, x-5
<i>Input6</i>	x; x-1, x-2, x-3 x-4, x-5, x-6
<i>Input7</i>	x; x-1, x-2, x-3 x-4, x-5, x-6, x-7
<i>Input8</i>	x; x-1, x-2, x-3 x-4, x-5, x-6, x-7, x-8
<i>Input9</i>	x; x-1, x-2, x-3 x-4, x-5, x-6, x-7, x-8, x-9

Performa model terbaik didapatkan dengan membandingkan data tes dan data hasil prediksi yang dihasilkan. Hasil perbandingan direpresentasikan dengan perhitungan nilai MAPE. Nilai MAPE hasil peramalan dapat dilihat pada gambar 6.1. Terlihat nilai MAPE 78.09% merupakan nilai terbaik didapatkan pada skenario dengan menggunakan *Input2*. Plot modelnya juga dapat dilihat pada gambar 6.2.



Gambar 6.1. Nilai MAPE Seluruh Skenario



Gambar 6.2. Plot Model Input2

6.2.2 Hasil Peramalan dengan Skenario Terbaik

Setelah input model terbaik ditentukan, maka selanjutnya dilakukan percobaan dengan pengaturan parameter yang berbeda agar dapat menghasilkan nilai MAPE terbaik. Seluruh pengaturan parameter yang digunakan akan dijelaskan pada tabel 6.7.

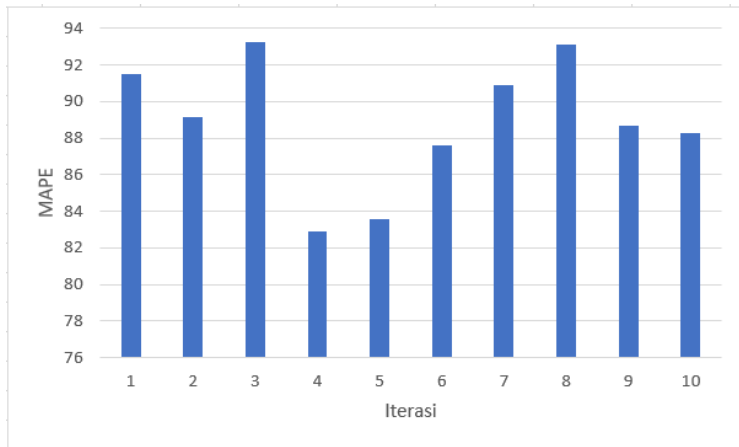
Tabel 6.7. Pengaturan Parameter yang Digunakan

Parameter	Pengaturan
<i>Units</i>	100, 200, 300, 500
<i>Epoch</i>	50, 100, 200, 300, 500
<i>Dropout</i>	0.2, 0.02, 0.005 0.002, 0.0005, 0.0002, 0.00005, 0.00002
<i>Lost Function</i>	'mean_squared_logarithmic_error'
<i>Optimizer</i>	Adam
<i>Learning Rate</i>	0.002, 0.001, 0.0005, 0.0002, 0.0001, 0.00005, 0.00002, 0.00001
<i>Decay</i>	1e-6

Dari kombinasi parameter diatas, terdapat 1280 iterasi dengan parameter yang berbeda. Hasil iterasi dengan nilai-nilai konfigurasi parameter dapat dilihat pada tabel 6.8. Hasil iterasi akan dikelompokkan berdasarkan nilai MAPE terbaik berdasarkan iterasi yang ditampilkan. Model terbaik berdasarkan nilai MAPE dapat dilihat pada gambar 6.3.

Tabel 6.8. Hasil Iterasi beserta nilai parameter

Iterasi	Units	Epoch	Dropout	Learning Rate	MAPE
1	100	50	0.2	0.00001	91.52
2	100	50	0.002	0.0005	89.12
3	100	50	0.0001	0.00002	93.22
4	200	300	0.0002	0.00005	82.89
5	200	300	0.0002	0.00002	83.55
6	200	300	0.0002	0.00001	87.63
7	300	50	0.2	0.0005	90.88
8	300	50	0.02	0.0005	93.11
9	300	50	0.0005	0.0005	88.66
10	300	100	0.2	0.0005	88.29




Gambar 6.3. Nilai 10 MAPE Terbaik

Hasil terbaik didapatkan dengan nilai MAPE sebesar 82.89%. Parameter yang dapat menghasilkan MAPE terbaik sebagai berikut, *units 200, epoch 300, dropout 0.0002*, dan menggunakan fungsi *lost function = mean squared logarithmic error* serta *optimizer Adam*. Untuk fungsi optimasi, konfigurasi terbaik didapatkan dengan konfigurasi *learning rate 0.00005* dan *decay 1e-6*. Waktu latih yang dibutuhkan selama ± 7 menit. Ilustrasi *layer* model dan plot pelatihan modelnya akan diperlihatkan pada gambar 6.4 dan 6.5.


Layer (type)	Output Shape	Param #
hidden (GRU)	(1, 275)	228525
output (Dense)	(1, 1)	276
Total params: 228,801		
Trainable params: 228,801		
Non-trainable params: 0		

Gambar 6.4. Ilustrasi Layer Model



Gambar 6.5. Plot Perbandingan Hasil Peramalan

Sedangkan gambar 6.6 menunjukkan plot perbandingan hasil peramalan. Sumbu x menunjukkan *time step* peramalan dan sumbu y menunjukkan jumlah penjualan.



Gambar 6.6. Plot Pelatihan Model


6.3 Perbandingan Metode LSTM

Sebagai perbandingan, model peramalan akan dibandingkan dengan variasi arsitektur *Recurrent Neural Network* lainnya,


yaitu *Long Short-Term Memory*. *Input* yang digunakan merupakan *Input2* dari data model sebelumnya. Parameter yang digunakan sebagai berikut, *units 200*, *epoch 300*, *dropout 0.0002*, dan menggunakan fungsi *lost function = mean squared logarithmic error* serta *optimizer Adam*. Konfigurasi *optimizer* dengan *learning rate 0.0005* dan *decay 1e-6*. Waktu latihan yang dibutuhkan selama ± 8 menit dan menghasilkan nilai MAPE sebesar 204.9%. Gambar 6.7 dan 6.8 akan memperlihatkan ilustrasi *layer* model dan plot perbandingan hasil peramalan. Sedangkan plot modelnya dapat dilihat pada gambar 6.9. Terlihat awalnya LSTM tidak dapat mengikuti pola data, namun mulai dari *time step* ke 19, LSTM dapat mengikuti pola data yang diproses.

Layer (type)	Output Shape	Param #
hidden (LSTM)	(1, 275)	304700
output (Dense)	(1, 1)	276
Total params: 304,976		
Trainable params: 304,976		
Non-trainable params: 0		

Gambar 6.7. Ilustrasi Layer Model LSTM




Gambar 6.8. Plot Perbandingan Hasil Peramalan Metode LSTM



Gambar 6.9. Plot Pelatihan Model LSTM

6.4 Perbandingan Metode Regresi Linear

Untuk perbandingan berikutnya, model akan dibandingkan dengan metode peramalan Regresi Linear. Dengan menggunakan data yang sama, hasilnya menunjukkan bahwa metode ini dapat menghasilkan nilai MAPE sebesar 14775%. Plot hasil perbandingan peramalannya dapat dilihat pada gambar 6.10.




Gambar 6.10. Plot Perbandingan Hasil Peramalan Regresi Lienar


6.5 Hasil Peramalan Dengan Dataset Lainnya

Selain menggunakan metode yang berbeda, model juga akan diproses menggunakan dataset yang berbeda. Dataset yang digunakan merupakan data historis harga terbuka *cryptocurrency Blockchain Ethereum* dari tanggal 1 Januari 2017 hingga 31 Desember 2019. Model juga akan diproses dengan data mentah penjualan Keju Kraft. Parameter model yang digunakan sama dengan parameter model dengan skenario terbaik.

Hasil peramalan dengan menggunakan data *Etherium* menghasilkan nilai MAPE sebesar 5.68%, sedangkan hasil peramalan dengan data mentah menghasilkan MAPE 146.3%. Plot hasil perbandingan peramalannya dapat dilihat pada gambar 6.11 dan 6.12. Terlihat model dapat mengikuti pola data ketika menggunakan dataset lainnya.




Gambar 6.11. Plot Perbandingan Hasil Peramalan Data



Gambar 6.12. Plot Perbandingan Hasil Peramalan Data Mentah


6.6 Hasil Peramalan Tanpa Outlier

Terakhir model juga akan diproses dengan penghapusan data *outlier*. Nilai *outlier* ditentukan dengan melihat box plot data pada gambar 6.13.



Gambar 6.13. Box Plot Data Penjualan Mentah

Pemrosesan dilakukan dengan penghapusan data penjualan yang memiliki nilai di atas 7500 dan di bawah 200. Tujuannya agar model dapat memproses dengan data yang tidak memiliki perbedaan nilai secara signifikan. Hasilnya model dapat menghasilkan nilai MAPE sebesar 55.48%. Gambar 6.14 menunjukkan plot hasil perbandingan peramalan.



Gambar 6.14. Plot Perbandingan Hasil Peramalan Tanpa Outlier

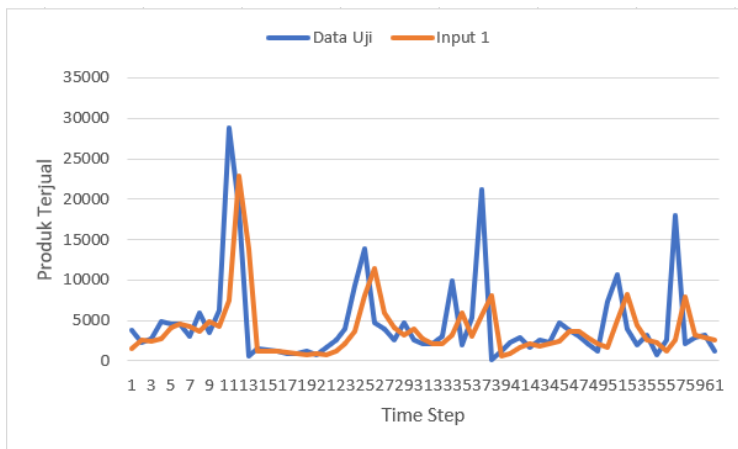
6.7 Performa Model

Berdasarkan MAPE yang diperoleh dari skenario terbaik, dapat disimpulkan bahwa hasil peramalan tidak terlalu baik. Model tersebut terbukti tidak dapat memproses data dengan nilai *error* yang sangat tinggi. Hal ini sangat dipengaruhi dari data penjualan yang didasarkan faktor penjualan. Data yang tercatat sangat tinggi pada 1 hari dan turun drastis pada hari berikutnya. Selisih antar 2 data tersebut menyebabkan model peramalan sulit menangkap data. Contohnya dapat dilihat pada gambar 6.15.

	Time Step	Data Uji	Prediksi	Error	MAPE
3	1	2233	2021.4781	9.472544	84.11553
4	2	2752	2517.324	8.527471	
5	3	4941	3232.3813	34.58042	
39	37	175	4825.1421	2657.224	
40	38	1159	637.9121	44.96013	
41	39	2213	2377.5957	7.437673	

Gambar 6.15. Potongan Data Penjualan


Apabila *learning rate* model ditingkatkan dan *decay* dikurangi, model peramalan dapat menangkap data. Tetapi hal tersebut sangatlah beresiko membuat model *overfitting* dan berlaku sebaliknya. Gambar 6.16 memperlihatkan *overfitting* model. Peningkatan *epoch* dan *units* juga dapat meningkatkan performa model sampai pada titik tertentu. Peningkatan berlebih dapat mengurangi performa model, membuat *underfitting* model dan menambah waktu proses.



Gambar 6.16. Hasil Peramalan dengan Model yang Overfitting

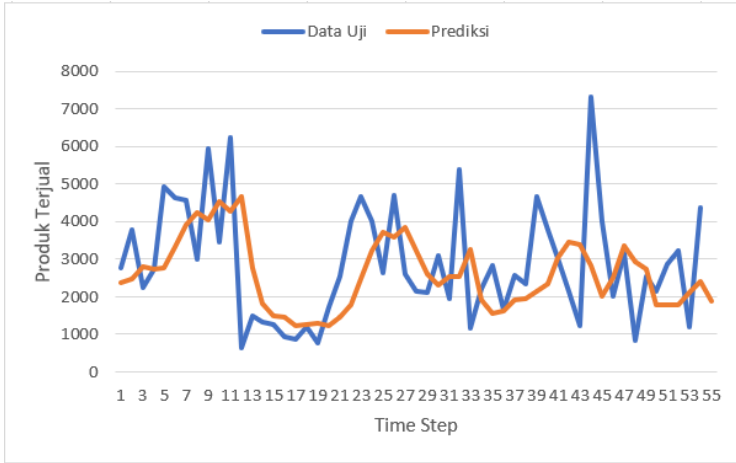
Secara keseluruhan model sebenarnya sudah cukup baik dengan waktu *epoch* yang tidak menyebabkan *underfitting* model. Hal itu dapat dibuktikan dengan percobaan menggunakan dataset

berbeda dan dataset tanpa adanya nilai *outlier*. Kedua percobaan tersebut dilakukan tanpa melakukan *tuning* parameter. Untuk dataset berbeda, model dapat menghasilkan nilai MAPE yang sangat kecil sebesar 5.68%. Model juga dapat menangkap pola data yang ditunjukkan pada gambar 6.17.




Gambar 6.17. Plot Perbandingan Hasil Peramalan Data Berbeda

Sedangkan untuk percobaan dengan data tanpa nilai *outlier*, model dapat menurunkan nilai MAPE secara signifikan. Penurunan nilai MAPE dapat mencapai nilai sebesar 55.48% dari nilai MAPE model terbaik, sebesar 82.89%. Perbandingan plot hasil peramalannya dapat dilihat Kembali pada gambar 6.18.




Gambar 6.18. Plot Perbandingan Hasil Peramalan Tanpa Outlier

Model juga dapat menyamai waktu latih dengan metode LSTM dengan selisih ± 1 menit dan lebih baik dalam mengikuti pola data. Selain itu, model juga dapat melampaui akurasi peramalan LSTM. Dimana nilai MAPE yang dihasilkan dengan model LSTM sebesar 204.9%. Gambar 6.19 menunjukkan kembali plot perbandingan hasil peramalan dengan menggunakan metode LSTM.



Gambar 6.19. Plot Perbandingan Hasil Peramalan Metode LSTM

Terakhir model terbukti dapat menghasilkan nilai MAPE jauh lebih baik dibandingkan dengan metode Regresi Linear. Dimana metode regresi menghasilkan nilai MAPE yang sangat tinggi, yakni sebesar 14775%. Gambar 6.20 menunjukkan kembali plot perbandingan hasil peramalan dengan menggunakan metode Regresi Linear.



Gambar 6.20. Plot Perbandingan Hasil Peramalan Regresi Lienar

Halaman ini sengaja dikosongkan

BAB VII

KESIMPULAN DAN SARAN

Kesimpulan yang didapat dari proses pengerjaan tugas akhir beserta saran perbaikan akan dijelaskan pada bab berikut. Harapannya dapat digunakan untuk mengembangkan tugas akhir ini untuk penelitian berikutnya.

7.1 Kesimpulan

Setelah proses pengerjaan penelitian tugas akhir selesai dilakukan, model yang terbaik untuk melakukan peramalan penjualan Keju Kraft dipilih berdasarkan model yang menghasilkan nilai MAPE terkecil.

Model yang terpilih merupakan model yang menggunakan scenario *input data lag 2*, dengan parameter sebagai berikut: *units 200, epoch 300, dropout 0.0002*, dan menggunakan *lost function = mean squared logarithmic error, optimizer Adam*. Konfigurasi fungsi aktivasinya *learning rate 0.00005* dan *decay 1e-6*. Model ini menghasilkan MAPE sebesar 82.89%.

Berdasarkan MAPE yang diperoleh, dapat disimpulkan bahwa model peramalan tidak baik untuk dijadikan sebagai metode peramalan penjualan Keju Kraft dikarenakan nilai MAPE yang didapat dari hasil peramalan sangatlah tinggi. Model terbukti tidak dapat memproses data dengan nilai *error* yang sangat tinggi. *Error* tersebut dikarenakan data yang tercatat sangat tinggi pada 1 hari dan turun drastis pada hari berikutnya. Selisih antar 2 data tersebut menyebabkan model peramalan sulit menangkap data.

Secara keseluruhan, model sudah cukup baik dalam mengolah data. Terbukti nilai MAPE model jauh lebih baik dibandingkan dengan metode Regresi Linear dengan nilai MAPE sebesar 14775% maupun metode LSTM dengan nilai MAPE 204.9%. Dengan menggunakan dataset *Etherium*, model juga dapat menghasilkan nilai MAPE sebesar 5.68%. Selain itu, nilai MAPE akan turun secara signifikan ketika model mengolah

dataset penjualan tanpa adanya nilai *outlier*. Penurunan tersebut mencapai nilai sebesar 55.48%.

7.2 Saran

Berdasarkan hasil penelitian pada tugas akhir ini, saran yang dapat diberikan untuk penelitian selanjutnya, yaitu:

- 1) Data yang digunakan haruslah lebih banyak, minimal lebih dari periode 1 tahun.
- 2) Melakukan praproses data agar data terhindar dari *outlier* dan selisih besar antar data.
- 3) Menambahkan parameter lainnya, seperti *recurrent dropout*, *return sequence*, dll. Bisa juga menggunakan fungsi *lost function* dan *optimizer* lainnya.
- 4) Menambah *layer* dalam proses pembuatan model ataupun mencoba skenario *lag* data lainnya agar dapat meningkatkan akurasi peramalan.
- 5) Melakukan peramalan dengan metode ANN lainnya, seperti BPNN ataupun RNN tradisional.

DAFTAR PUSTAKA

- [1] M. J. D. L. Merced, "Kraft, 'Mondelez' and the Art of Corporate Rebranding," *The New York Times*, 2012.
- [2] S. Strom, "For Oreo, Cadbury and Ritz, a New Parent Company," *The New York Times*, 2012.
- [3] M. Triraharjo, "Peternak Sapi Perah di Wonosalam Bersyukur Harga Susu Naik," *Radar Jombang*, 2018.
- [4] V. Athira, P. Geetha, R. Vinayakumar and K. P. Soman, "Prediction, DeepAirNet: Applying Recurrent Networks for Air Quality," *Procedia Computer Science*, vol. 132, pp. 1394-1403, 2018.
- [5] Y. Wang, M. Liu, Z. Bao and S. Zhang, "Short-Term Load Forecasting with Multi-Source Data Using Gated Recurrent Unit Neural Networks," *Energies*, vol. 11, no. 5, 2018.
- [6] R. Pascanu, T. Mikolov and Y. Bengio, "On the difficulty of training Recurrent Neural Networks," *ICML*, vol. 28, pp. 1310-1318, 2012.
- [7] C. Jinglong, J. Hongjie, C. Yuanhong and L. Qian, "Gated Recurrent Unit Based Recurrent Neural Network for Remaining Useful Life Prediction of Nonlinear Deterioration Process," *Reliability Engineering & System Safety*, vol. 185, pp. 372-382, 2019.

- [8] Y. Wang, W. Liao and Y. Chang, "Gated Recurrent Unit Network-Based Short-Term Photovoltaic Forecasting," *Energies*, vol. 11, no. 8, 2018.
- [9] O. Kannjanatarakul and K. Suriya, "Forecasting The Sales of An Innovative Agro-Industrial Product With Limited Information: A Case of Feta Cheese From Buffalo Milk in Thailand," *EcoMod2013*, 2013.
- [10] G. Balu and S. I. Ali, "Ether Price Prediction Using Gated Recurrent Unit," *Procedia Computer Science*, vol. 132, pp. 1394-1403, 2018.
- [11] G. Shen, Q. Tan, H. Zhang, P. Zeng and J. Xu, "Deep Learning with Gated Recurrent Unit Networks for Financial Sequence Predictions," *ICICT-2018*, vol. 131, pp. 895-903, 2018.
- [12] Mutakim, R. F. Muarifah and K. U. Al Awwaly, "Pembuatan Keju dengan Menggunakan Enzim Renin Mucor Pusillus Amobil," *Jurnal Ilmu Ilmu Peternakan*, vol. 19, no. 2, pp. 137-149, 2009.
- [13] A. Famili, W.-M. Shen, R. Weber and E. Simoudis, "Data preprocessing and intelligent data analysis," *Intelligent Data Analysis*, vol. 1, no. 1-4, pp. 3-23, 1997.
- [14] S. Kotsiantis, D. Kanellopoulos and P. E. Pintelas, "Data Preprocessing for Supervised Learning,"

International Journal of Computer Science, vol. 1, pp. 111-115, 2006.

- [15] F. Pakaja, A. Naba and Purwanto, "Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor," *EECCIS*, vol. 6, no. 1, pp. 22-28, 2012.
- [16] W. W. S. Wei, *Time Series Analysis : Univariate and Multivariate Methods (2nd Edition)*, Boston: Pearson, 2005.
- [17] M. S, *Metode dan Aplikasi Peramalan*, Jakarta : Erlangga, 1998.
- [18] Hyndman, R. J., Athanasopoulos, G., *Forecasting: principles and practice*, OTexts, 2018.
- [19] Popoola, A., Ahmad, S. dan Ahmad, K, "A Fuzzy-Wavelet Method for Analyzing Non-Stationary Time Series," in *Proc. of the 5th International Conference on Recent Advances in Soft Computing RASC2004*, Nottingham, United Kingdom, 231-236, 2004.
- [20] R. T. M. I. Sungkawa., "Penerapan Ukuran Ketepatan Nilai Ramalan Data Deret Waktu Dalam Seleksi Model Peramalan Volume Penjualan PT Satriamandiri Citramulia," *ComTect*, vol. 2, no. 2, pp. 636-645, 2011.
- [21] S. R. P. Nur Hidayatika and S. N. W.P, "Usulan Penggunaan Metode Forecasting untuk Permintaan

Kopi Robusta pada PT. Xyz," *Industrial Engineering Online Journal*, 2015.

BIODATA PENULIS



Penulis bernama Naufal Nediasa Ghoziazmi, lahir di Jakarta pada tanggal 12 Maret 1998, merupakan anak kedua dari tiga bersaudara. Penulis telah menempuh jenjang Pendidikan formal di beberapa sekolah yaitu; SD Al-Kautsar Bandar Lampung (2004-2010), SMP Negeri 2 Bandar Lampung (2010-2013), dan SMAIT As-Syifa *Boarding School* Subang (2013-2016). Penulis melanjutkan Pendidikan sarjana di Departemen Sistem Informasi Fakultas Teknik Elektro dan Informatika Cerdas (FTEIC) Institut Teknologi Sepuluh Nopember (ITS) pada tahun 2016 yang terdaftar sebagai mahasiswa dengan nrp 05211640000108.

Selama menjadi mahasiswa, penulis aktif mengikuti organisasi Himpunan Mahasiswa Sistem Informasi (HMSI) selama 1 periode kepengurusan. Penulis juga mengikuti berbagai pelatihan seperti Latihan Keterampilan Manajemen Wirausaha Tingkat Lanjut (LKMW TL) 2017 dan Latihan Keterampilan Manajemen Mahasiswa Tingkat Dasar (LKMM TD) 2018.

Untuk mendapatkan gelar S.Kom. (Sarjana Komputer), penulis mengambil topik penelitian tugas akhir peramalan pada laboratorium Rekayasa Data dan Intelegensi Bisnis (RDIB). Untuk kepentingan penelitian, Penulis dapat dihubungi melalui email nediasaopang03@gmail.com

Halaman ini sengaja dikosongkan

LAMPIRAN: DATA PENJUALAN KEJU

Sub-Produk	CHEDDAR							Total Penjualan
Tanggal	KRAFT CHEDDAR 165GR 48'S	KRAFT CHEDDAR FREE MINI 30+165GR 48'S	KRAFT CHEDDAR MIDI 70/75GR 48'S	KRAFT CHEDDAR MINI 30/35G 18X8'S	KRAFT CHEDDAR MINI 35G 18X8'S BNS	KRAFT CHEDDAR Q4 BUNDLE 4X36X35 GR	KRAFT CHEDDAR VALUE PACK 2X165GR 24'S	
	Total	Total	Total	Total	Total	Total	Total	
2019-01-01	0	0	0	0	0	0	0	0
2019-01-02	39	0	57	152	0	476	0	724
2019-01-03	209	0	164	928	0	488	0	1789

2019-01-04	397	0	300	1160	0	152	0	2009
2019-01-05	124	0	477	1288	0	384	0	2273
2019-01-07	128	0	437	1984	0	520	0	3069
2019-01-08	37	0	480	1208	0	812	0	2537
2019-01-09	9	0	404	1264	0	696	0	2373
2019-01-10	30	0	318	760	0	1012	0	2120
2019-01-11	2	0	373	856	0	472	0	1703
2019-01-12	481	0	691	1296	0	1032	0	3500
2019-01-14	480	0	232	456	0	368	0	1536
2019-01-15	1,209	0	309	1960	0	916	0	4394

2019-01-16	609	0	570	1344	0	508	0	3031
2019-01-17	349	0	179	768	0	416	0	1712
2019-01-18	3,580	0	849	2480	0	168	0	7077
2019-01-19	220	0	229	393	0	296	0	1138
2019-01-21	428	0	362	408	0	1280	0	2478
2019-01-22	671	0	848	1536	0	464	0	3519
2019-01-23	274	0	446	1632	0	92	0	2444
2019-01-24	1,323	0	317	1448	0	88	0	3176
2019-01-25	656	0	345	1256	0	44	0	2301
2019-01-26	1,176	0	535	744	0	44	0	2499

2019-01-28	1,602	0	1047	1944	0	0	0	4593
2019-01-29	805	0	327	2192	0	40	0	3364
2019-01-30	305	0	366	1768	0	24	0	2463
2019-01-31	1,028	0	935	3688	0	296	0	5947
2019-02-01	132	0	92	96	0	0	0	320
2019-02-02	431	0	122	664	0	16	0	1233
2019-02-04	267	0	383	1416	0	20	0	2086
2019-02-05	0	0	0	0	0	0	0	0
2019-02-06	254	0	392	1680	0	16	0	2342
2019-02-07	396	0	394	3656	0	28	0	4474

2019-02-08	619	0	414	880	0	16	0	1929
2019-02-09	775	0	424	1392	0	80	0	2671
2019-02-11	1991	0	554	2552	0	88	0	5185
2019-02-12	424	0	609	3440	0	32	0	4505
2019-02-13	767	0	957	3480	0	128	0	5332
2019-02-14	295	0	319	1424	0	144	0	2182
2019-02-15	5899	0	752	2896	0	172	0	9719
2019-02-16	1613	0	448	4056	0	288	0	6405
2019-02-18	509	0	286	1264	0	56	0	2115
2019-02-19	171	0	368	1568	0	144	0	2251

2019-02-20	265	0	323	1240	0	48	0	1876
2019-02-21	269	0	673	16312	0	40	0	17294
2019-02-22	996	0	418	1056	0	0	0	2470
2019-02-23	206	0	617	1208	0	16	0	2047
2019-02-25	604	0	422	1848	0	0	0	2874
2019-02-26	695	0	508	1664	0	152	0	3019
2019-02-27	11069	0	585	3264	0	144	0	15062
2019-02-28	8103	0	580	4784	0	160	0	13627
2019-03-01	215	0	81	128	0	0	0	424
2019-03-02	543	0	700	2704	0	0	0	3947

2019-03-04	518	0	395	1600	0	0	0	2513
2019-03-05	500	0	246	1288	0	32	0	2066
2019-03-06	430	0	383	1280	0	96	0	2189
2019-03-07	0	0	0	0	0	0	0	0
2019-03-08	161	0	362	1136	0	0	0	1659
2019-03-09	362	0	304	1880	0	8	0	2554
2019-03-11	1839	0	379	2168	0	0	0	4386
2019-03-12	837	0	950	2312	0	0	0	4099
2019-03-13	319	0	402	1816	0	0	0	2537
2019-03-14	461	0	231	2896	0	0	0	3588

2019-03-15	535	0	475	2824	0	0	0	3834
2019-03-16	820	0	274	1680	0	0	0	2774
2019-03-18	4074	0	379	1912	0	0	0	6365
2019-03-19	558	0	241	1000	0	0	0	1799
2019-03-20	2107	0	581	4456	0	4	0	7148
2019-03-21	915	0	592	1920	0	0	0	3427
2019-03-22	317	0	215	1584	0	0	0	2116
2019-03-23	287	0	333	1720	0	0	0	2340
2019-03-25	235	0	272	1744	0	0	0	2251
2019-03-26	1913	0	332	1952	0	0	0	4197

2019-03-27	1887	0	1005	2592	0	0	0	5484
2019-03-28	18011	0	557	1992	0	0	0	20560
2019-03-29	27592	0	866	2752	0	0	0	31210
2019-03-30	16439	4992	1309	2128	0	0	0	24868
2019-04-01	194	0	81	352	0	0	0	627
2019-04-02	132	0	247	776	0	0	0	1155
2019-04-03	0	0	0	0	0	0	0	0
2019-04-04	141	0	286	2984	0	0	0	3411
2019-04-05	179	0	469	2032	0	0	0	2680
2019-04-06	170	0	227	856	0	0	0	1253

2019-04-08	109	0	425	1600	0	0	0	2134
2019-04-09	370	240	275	2760	0	0	0	3645
2019-04-10	1270	0	487	1848	0	0	0	3605
2019-04-11	378	0	760	3808	0	0	0	4946
2019-04-12	697	0	292	1152	0	0	0	2141
2019-04-13	622	0	401	2208	0	0	0	3231
2019-04-15	329	0	319	1008	0	0	0	1656
2019-04-16	596	0	693	1976	0	0	0	3265
2019-04-17	0	0	0	0	0	0	0	0
2019-04-18	1165	0	466	1568	0	0	0	3199

2019-04-19	0	0	0	0	0	0	0	0
2019-04-20	945	0	295	2672	0	0	1200	5112
2019-04-22	359	0	504	1672	0	0	0	2535
2019-04-23	895	240	787	1944	0	0	960	4826
2019-04-24	5226	0	1224	1832	0	0	0	8282
2019-04-25	1307	0	723	6584	0	0	492	9106
2019-04-26	16840	0	634	7014	0	0	0	24488
2019-04-27	818	0	257	1528	0	0	24	2627
2019-04-29	17225	0	478	12984	0	0	0	30687
2019-04-30	49694	0	1294	4984	0	0	72	56044

2019-05-01	0	0	0	0	0	0	0	0
2019-05-02	114	0	39	224	0	0	0	377
2019-05-03	1162	0	1128	5888	0	0	960	9138
2019-05-04	487	0	448	1704	0	0	0	2639
2019-05-06	1300	0	453	2472	0	0	24	4249
2019-05-07	608	0	592	2920	0	0	156	4276
2019-05-08	798	0	743	3584	0	0	160	5285
2019-05-09	2947	0	525	2504	0	0	6	5982
2019-05-10	931	132	294	1616	0	0	246	3219
2019-05-11	9730	108	177	1000	0	0	84	11099

2019-05-13	824	0	905	3120	0	0	1016	5865
2019-05-14	583	240	553	1328	0	0	22	2726
2019-05-15	409	12	659	2280	0	0	42	3402
2019-05-16	1256	492	626	2264	0	0	516	5154
2019-05-17	3777	12	324	2472	0	0	24	6609
2019-05-18	236	9	404	1560	0	0	48	2257
2019-05-20	442	48	924	1808	0	0	686	3908
2019-05-21	8033	10	804	2784	0	0	200	11831
2019-05-22	1771	0	463	3016	0	0	28	5278
2019-05-23	2395	194	549	2520	0	0	480	6138

2019-05-24	1912	171	431	1864	0	0	288	4666
2019-05-25	4945	48	432	1240	0	0	48	6713
2019-05-27	516	156	563	1624	0	0	192	3051
2019-05-28	3097	46	525	3744	0	0	240	7652
2019-05-29	1390	47	767	3024	0	0	96	5324
2019-05-30	0	0	0	0	0	0	0	0
2019-05-31	145	0	91	1160	0	0	96	1492
2019-06-01	0	0	0	0	0	0	0	0
2019-06-03	3	0	10	24	0	0	0	37
2019-06-04	0	0	0	64	0	0	0	64

2019-06-05	0	0	0	0	0	0	0	0
2019-06-06	0	0	0	0	0	0	0	0
2019-06-07	0	0	3	24	0	0	0	27
2019-06-08	0	0	0	0	0	0	0	0
2019-06-10	185	0	59	288	0	0	0	532
2019-06-11	126	144	148	520	0	0	336	1274
2019-06-12	1268	189	381	1408	0	0	96	3342
2019-06-13	420	54	282	624	0	0	0	1380
2019-06-14	1283	54	335	1096	0	0	0	2768
2019-06-15	364	48	204	624	0	0	48	1288

2019-06-17	776	86	541	2392	0	0	0	3795
2019-06-18	930	0	208	4824	0	0	0	5962
2019-06-19	442	147	508	3784	0	0	528	5409
2019-06-20	5033	3	205	1864	0	0	96	7201
2019-06-21	265	48	175	1296	0	0	0	1784
2019-06-22	798	12	687	1816	0	0	12	3325
2019-06-24	199	13	388	1424	0	0	0	2024
2019-06-25	435	21	520	4384	0	0	24	5384
2019-06-26	5013	0	221	1896	0	0	0	7130
2019-06-27	434	0	546	2784	0	0	0	3764

2019-06-28	4022	0	1240	3032	0	0	0	8294
2019-06-29	961	0	611	3032	0	0	48	4652
2019-07-01	302	0	173	1696	0	0	0	2171
2019-07-02	209	0	142	1128	0	0	0	1479
2019-07-03	168	0	270	944	0	0	42	1424
2019-07-04	450	0	1584	1856	0	0	144	4034
2019-07-05	292	0	714	656	0	0	0	1662
2019-07-06	362	0	1749	1112	0	0	48	3271
2019-07-08	197	0	249	800	0	0	0	1246
2019-07-09	375	0	407	2112	0	0	0	2894

2019-07-10	421	0	477	1976	0	0	0	2874
2019-07-11	409	0	263	1808	0	0	0	2480
2019-07-12	203	0	146	1224	0	0	0	1573
2019-07-13	287	0	299	600	0	0	0	1186
2019-07-15	184	0	133	1088	0	0	0	1405
2019-07-16	456	0	353	1320	0	0	0	2129
2019-07-17	426	0	279	4472	0	0	0	5177
2019-07-18	150	0	598	1616	0	0	12	2376
2019-07-19	317	0	536	1568	0	0	0	2421
2019-07-20	765	0	434	1264	0	0	0	2463

2019-07-22	537	0	855	3632	0	0	0	5024
2019-07-23	1223	0	410	1040	0	0	0	2673
2019-07-24	3327	0	773	1320	0	0	0	5420
2019-07-25	780	0	407	1968	0	0	12	3167
2019-07-26	2238	0	378	1832	0	0	48	4496
2019-07-27	530	0	231	9608	0	0	0	10369
2019-07-29	2539	0	136	1648	0	0	0	4323
2019-07-30	5988	0	748	2752	0	0	0	9488
2019-07-31	26258	0	1051	4744	0	0	4	32057
2019-08-01	78	0	58	728	0	0	0	864

2019-08-02	124	0	295	1440	0	0	0	1859
2019-08-03	101	0	141	1520	0	0	0	1762
2019-08-05	164	0	275	1360	0	0	0	1799
2019-08-06	275	0	153	992	0	0	4	1424
2019-08-07	875	0	473	1992	0	0	0	3340
2019-08-08	706	0	507	2200	0	0	0	3413
2019-08-09	2711	0	314	3488	0	0	0	6513
2019-08-10	462	0	372	712	0	0	0	1546
2019-08-12	103	0	156	984	0	0	0	1243
2019-08-13	627	0	427	7592	0	0	0	8646

2019-08-14	151	0	525	1800	0	0	0	2476
2019-08-15	628	0	704	2832	0	0	4	4168
2019-08-16	298	0	734	2184	0	0	0	3216
2019-08-17	0	0	0	0	0	0	0	0
2019-08-19	472	0	193	1000	0	0	0	1665
2019-08-20	297	0	562	1480	0	0	4	2343
2019-08-21	370	0	293	1144	0	0	8	1815
2019-08-22	931	0	369	848	0	0	0	2148
2019-08-23	3464	0	1034	2664	0	0	0	7162
2019-08-24	281	0	230	1216	0	0	0	1727

2019-08-26	768	0	261	1816	0	0	0	2845
2019-08-27	3877	0	566	3464	0	0	2	7909
2019-08-28	1362	0	354	1632	0	0	8	3356
2019-08-29	1653	0	915	3608	0	0	12	6188
2019-08-30	1885	0	318	4088	0	0	12	6303
2019-08-31	12069	0	831	6168	0	0	0	19068
2019-09-02	31	0	52	480	0	0	0	563
2019-09-03	373	0	449	2480	0	0	4	3306
2019-09-04	328	0	397	2168	0	0	0	2893
2019-09-05	405	0	407	792	0	0	8	1612

2019-09-06	71	0	337	1488	0	0	0	1896
2019-09-07	552	0	335	1232	0	0	0	2119
2019-09-09	97	0	154	592	0	0	0	843
2019-09-10	1070	0	552	1224	0	0	0	2846
2019-09-11	115	0	274	1240	0	0	0	1629
2019-09-12	176	0	74	1520	0	0	0	1770
2019-09-13	322	0	417	2080	0	0	0	2819
2019-09-14	303	0	227	368	0	0	0	898
2019-09-16	1058	0	576	1456	0	0	12	3102
2019-09-17	156	0	303	936	0	0	0	1395

2019-09-18	5688	0	237	2034	0	0	0	7959
2019-09-19	2132	0	530	1424	0	0	48	4134
2019-09-20	1055	0	207	1160	0	0	0	2422
2019-09-21	1040	0	409	590	0	0	0	2039
2019-09-23	131	0	417	2616	0	0	0	3164
2019-09-24	2356	0	391	1640	0	0	0	4387
2019-09-25	5061	0	310	4232	0	0	0	9603
2019-09-26	345	0	593	2568	0	0	0	3506
2019-09-27	3999	0	952	4368	0	0	0	9319
2019-09-28	3914	0	138	864	0	0	0	4916

2019-09-30	12835	0	851	2472	0	0	586	16744
2019-10-01	0	0	0	0	0	0	0	0
2019-10-02	481	0	355	3344	0	0	0	4180
2019-10-03	430	0	357	864	0	0	0	1651
2019-10-04	196	0	271	1536	0	0	0	2003
2019-10-05	111	0	34	624	0	0	0	769
2019-10-07	291	0	161	896	0	0	0	1348
2019-10-08	249	0	255	2952	0	0	0	3456
2019-10-09	134	0	544	1800	0	0	0	2478
2019-10-10	792	0	460	1936	0	0	0	3188

2019-10-11	189	0	550	1368	0	0	0	2107
2019-10-12	399	0	2020	840	0	0	0	3259
2019-10-14	317	0	590	2552	32	0	0	3491
2019-10-15	154	0	337	1336	0	0	0	1827
2019-10-16	258	0	891	1800	0	0	0	2949
2019-10-17	247	0	448	2064	8	0	0	2767
2019-10-18	1023	0	245	2432	72	0	0	3772
2019-10-19	575	0	530	1120	8	0	0	2233
2019-10-21	288	0	224	2160	80	0	0	2752
2019-10-22	2068	0	865	2000	8	0	0	4941

2019-10-23	847	0	421	3200	160	0	0	4628
2019-10-24	2668	0	211	1616	64	0	0	4559
2019-10-25	1842	0	280	872	0	0	0	2994
2019-10-26	3915	0	557	1448	8	0	32	5960
2019-10-28	1061	0	755	1616	32	0	0	3464
2019-10-29	2054	0	745	3344	96	0	0	6239
2019-10-30	25767	0	372	2584	48	0	0	28771
2019-10-31	11229	0	375	7360	0	0	0	18964
2019-11-01	219	0	142	264	0	0	0	625
2019-11-02	479	0	26	976	0	0	0	1481

2019-11-04	418	0	86	832	0	0	0	1336
2019-11-05	722	0	456	96	0	0	0	1274
2019-11-06	292	0	196	432	0	0	0	920
2019-11-07	541	0	52	272	0	0	0	865
2019-11-08	355	0	24	816	0	0	0	1195
2019-11-11	102	0	22	648	0	0	0	772
2019-11-12	1368	0	118	224	0	0	0	1710
2019-11-13	244	0	551	1760	0	0	0	2555
2019-11-14	576	0	1470	1976	0	0	0	4022
2019-11-15	3336	0	623	5272	0	0	0	9231

2019-11-16	11054	0	626	2256	0	0	0	13936
2019-11-18	2349	0	726	1608	0	0	0	4683
2019-11-19	1092	0	550	2384	0	0	0	4026
2019-11-20	285	0	475	1880	0	0	0	2640
2019-11-21	2370	0	292	2032	0	0	0	4694
2019-11-22	1262	0	324	1008	0	0	0	2594
2019-11-23	225	0	564	1344	0	0	0	2133
2019-11-25	435	0	248	1440	0	0	0	2123
2019-11-26	907	0	482	1712	0	0	0	3101
2019-11-27	3342	0	936	5608	0	0	0	9886

2019-11-28	137	0	309	1512	0	0	0	1958
2019-11-29	1527	0	1007	2848	0	0	0	5382
2019-11-30	19486	0	369	1400	0	0	0	21255
2019-12-02	29	0	58	88	0	0	0	175
2019-12-03	555	0	228	376	0	0	0	1159
2019-12-04	709	0	416	1088	0	0	0	2213
2019-12-05	388	0	512	1936	0	0	0	2836
2019-12-06	405	0	282	984	0	0	0	1671
2019-12-07	1156	0	50	1360	0	0	0	2566
2019-12-09	426	0	172	1760	0	0	0	2358

2019-12-10	517	0	736	3416	0	0	0	4669
2019-12-11	592	0	724	2456	0	0	0	3772
2019-12-12	892	0	646	1496	0	0	0	3034
2019-12-13	421	0	501	1216	0	0	0	2138
2019-12-14	159	0	259	800	0	0	0	1218
2019-12-16	5931	0	258	1144	0	0	0	7333
2019-12-17	5877	0	627	4104	0	0	0	10608
2019-12-18	2589	0	491	928	0	0	0	4008
2019-12-19	509	0	349	1144	0	0	0	2002
2019-12-20	1438	0	445	1288	0	0	0	3171

2019-12-21	228	0	113	480	0	0	0	821
2019-12-23	445	0	390	1712	0	0	0	2547
2019-12-24	14162	0	465	3328	0	0	0	17955
2019-12-26	815	0	140	1176	0	0	0	2131
2019-12-27	248	0	640	1984	0	0	0	2872
2019-12-28	507	0	554	2184	0	0	0	3245
2019-12-30	93	0	224	888	0	0	0	1205
2019-12-31	798	0	502	3088	0	0	0	4388
Total	585557	8016	134169	598727	616	13016	10648	1350749