

PERAMALAN PERTUMBUHAN JUMLAH OUTLET MENGGUNAKAN METODE GATED RECURRENT UNIT (STUDI KASUS: PT XYZ)

David Suluh¹, Dyah Erny Herwindiati², Janson Hendryli³

^{1,2,3} Program Studi Teknik Informatika Fakultas Teknologi Informasi Universitas Tarumanagara,
Jln. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia

E-mail: ¹david.535190026@stu.untar.ac.id, ²dyahh@fti.untar.ac.id, ³jansonh@fti.untar.ac.id

Abstrak

Sebagai perusahaan telekomunikasi, PT XYZ menggunakan outlet seluler sebagai mitra untuk melakukan pendistribusian komoditas mereka. Dalam memperluas jaringan outlet seluler merka, PT XYZ tentu perlu memikirkan strategi bisnis yang tepat agar pertumbuhan jumlah outlet dapat menjadi lebih maksimal. Peramalan dapat digunakan sebagai acuan dalam strategi bisnis dan meningkatkan efektivitas rencana penyebaran outlet. Penelitian ini membahas peramalan pertumbuhan jumlah outlet menggunakan metode Gated Recurrent Unit yang berfungsi untuk melakukan peramalan atau prediksi jumlah outlet yang dapat diraih oleh PT XYZ. Data yang digunakan merupakan data outlet yang ada di PT XYZ dimana data ini akan dikelompokkan berdasarkan minggu ketika outlet bergabung. Proses pelatihan data menggunakan 80% dari total dataset dan pengujian menggunakan 20% dari total dataset. Pada proses pengujian, model mendapatkan hasil evaluasi MAE sebesar 0.1230, RMSE sebesar 0.2103 dan MSE sebesar 0.0442.

Kata kunci—Peramalan, Jumlah Outlet, Gated Recurrent Unit

Abstract

As a telecommunications company, PT XYZ uses cellular outlets as partners to distribute their commodities. In expanding their network of cellular outlets, PT XYZ certainly needs to think about the right business strategy so that the growth in the number of outlets can be maximized. Forecasting can be used as a reference in business strategy and to increase the effectiveness of outlet deployment plans. This research discusses forecasting the growth of the number of outlets using the Gated Recurrent Unit method which serves to forecast or predict the number of outlets that can be achieved by PT XYZ. The data used is outlet data at PT XYZ where this data will be grouped based on the week when the outlet joins. The data training process uses 80% of the total dataset and testing uses 20% of the total dataset. In the testing process, the model obtains MAE evaluation results of 0.1230, RMSE of 0.2103 and MSE of 0.0442.

Keywords—Forecasting, Outlet Count, Gated Recurrent Unit

1. PENDAHULUAN

Industri telekomunikasi merupakan industri yang berada di dalam sektor teknologi komunikasi dan informasi, dimana industri ini menyediakan jasa untuk melakukan penyebaran komunikasi dan informasi melalui infrastruktur komunikasi, baik itu melalui telepon kabel, telepon genggam, fiber optic, satelit dan internet [1]. PT XYZ merupakan salah satu perusahaan telekomunikasi berbasis penyedia layanan operator seluler terbesar yang ada di Indonesia.

Perusahaan ini menawarkan saluran komunikasi untuk pengguna telepon genggam dengan melalui kartu perdana (sim card). Tentunya kartu perdana ini merupakan komoditas utama dan salah satu sumber penghasilan utama pada PT XYZ.

Untuk membantu menyebarluaskan penjualan kartu perdana, PT XYZ menggandeng banyak outlet seluler sebagai mitra mereka untuk menyebarluaskan distribusi kartu perdana milik mereka. PT XYZ biasa mengajak bekerja sama berbagai macam outlet seluler dari yang besar hingga yang kecil untuk menjadi mitra PT XYZ, tentunya kerja sama ini dapat menguntungkan kedua belah pihak dimana outlet seluler mendapatkan penghasilan lebih sebagai distributor kartu perdana PT XYZ, dan PT XYZ dapat memperbesar cakupan konsumen mereka tanpa perlu membuka banyak gerai.

Dalam memperluas jaringan outlet seluler merka, PT XYZ tentu perlu memikirkan strategi bisnis yang tepat agar pertumbuhan jumlah outlet dapat menjadi lebih maksimal. Peramalan dapat digunakan sebagai salah satu acuan dalam strategi bisnis dan meningkatkan efektivitas rencana penyebaran outlet. Oleh karena itu pada sistem ini akan dibuat suatu model peramalan pertumbuhan jumlah outlet dengan menggunakan metode *Gated Recurrent Unit*. Metode *Gated Recurrent Unit* merupakan salah satu metode yang dapat digunakan untuk meramalkan data *time series* dimana metode ini merupakan pengembangan dari Recurrent Neural Network. Metode inilah yang akan digunakan untuk melakukan peramalan atau prediksi jumlah outlet yang dapat diraih oleh PT XYZ di minggu-minggu yang akan datang.

2. METODE PENELITIAN

2.1 Tahap Rancangan

Sistem website yang dirancang adalah sistem peramalaan pertumbuhan outlet pada PT XYZ yang tersebar diseluruh Indonesia dengan menggunakan metode Gated Recurrent Unit. Sistem ini berfungsi untuk menampilkan visualisasi peramalan data outlet seluler yang ada di PT XYZ. Sistem ini memiliki fitur yang akan menampilkan visualisasi peramalan berdasarkan data jumlah outlet nasional atau seluruh wilayah, dan data jumlah outlet setiap region. Untuk visualisasi hasil peramalan dibagi menjadi 2 hasil peramalan yaitu peramalan pertumbuhan jumlah outlet nasional dan peramalan pertumbuhan jumlah outlet regional.

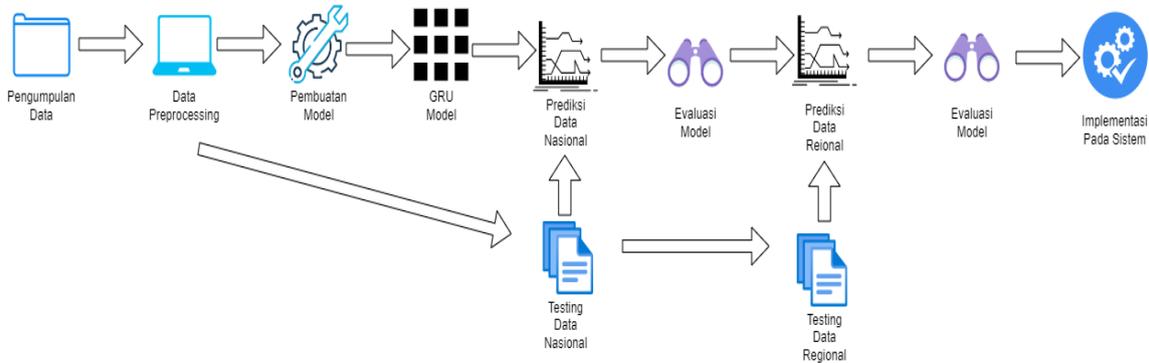
Input dari sistem ini menggunakan data historis mingguan pertumbuhan jumlah outlet dari tahun 2012 sampai dengan 2022 dengan total 545 minggu. Dataset pertumbuhan ini kemudian akan dipisah menjadi dua bagian dengan 80% dataset akan digunakan sebagai data training dan 20% lainnya akan digunakan untuk data testing. Kemudian akan dilakukan proses normalisasi data terlebih dahulu menggunakan min-max scaler agar tidak ada ketimpangan antara data dengan nilai yang besar dengan data yang memiliki nilai kecil.

Data yang sudah melalui normalisasi kemudian akan melalui tahap training dan testing menggunakan metode GRU dengan menggunakan data pertumbuhan outlet nasional. Sebelum tahap training, akan dilakukan *hyperparameter tuning* dan optimisasi model agar dapat menghasilkan model GRU dengan kemampuan peramalan yang baik. Oleh karena itu akan dilakukan percobaan pembuatan model GRU dengan *hyperparameter* yang berbeda dan *optimizer* yang berbeda. Untuk *optimizer* yang digunakan adalah *optimizer* ADAM dan *optimizer* SGD.

Setelah melalui proses training data dan testing data menggunakan data pertumbuhan outlet nasional, model GRU yang memiliki hasil evaluasi yang paling baik pada setiap optimizer akan dilakukan uji coba kedua dengan menggunakan data pertumbuhan outlet regional. Pada uji

David Suluh: Peramalan Pertumbuhan Jumlah Outlet Menggunakan Metode Gated Recurrent Unit (Studi Kasus: PT XYZ)

coba ini, masing-masing model akan melakukan prediksi menggunakan data outlet region dan kemudian akan dibandingkan data actual pertumbuhan outlet region dan data hasil prediksinya. Model dengan hasil evaluasi paling baik pada data region akan digunakan kedalam sistem untuk melakukan peramalan pertumbuhan outlet di minggu-minggu mendatang.



Gambar 1. Flowchart Pembuatan Model

2.2 Pengambilan Data

Data yang digunakan merupakan data pertumbuhan jumlah outlet atau data outlet baru PT XYZ dari minggu ke minggu, mulai dari tahun 2012 sampai dengan 2022. Data didapatkan dari website sistem informasi PT XYZ dalam format .xlsx. Data tersebut berisikan 160.000 data outlet beserta tanggal bergabung menjadi mitra PT XYZ. Dari data tersebut kemudian dilakukan pengolompokkan data berdasarkan waktu(mingguan), lalu didapat data pertumbuhan jumlah outlet PT XYZ dari minggu ke minggu. Contoh dataset pertumbuhan outlet nasional dapat dilihat pada tabel 1. Dataset pertumbuhan outlet nasional akan digunakan dalam proses training model GRU dan proses testing model GRU.

Tabel 1. Data pertumbuhan jumlah outlet nasional

Date	Jumlah Outlet
WK1	22
WK2	35
WK3	20
WK4	24
...	
WK544	487
WK545	562

Untuk contoh dataset pertumbuhan outlet regional dapat dilihat pada tabel 2. Dataset pertumbuhan outlet regional hanya akan digunakan dalam proses testing model GRU. Proses ini dilakukan untuk mengetahui kemampuan prediksi model terhadap data pertumbuhan outlet regional. Untuk data region sendiri terbagi menjadi 10 region, yaitu West Java, East Java, Central Java, South Sumatera, North Sumatera, Central Sumatera, Kalimantan, Sulawesi, JABODETABEK, dan Bali Nusra.

Tabel 2. Data pertumbuhan jumlah outlet regional

Week	WEST JAVA	BALI NUSRA	NORTH SUMATERA	CENTRAL SUMATERA	SOUTH SUMATERA	SULAWESI	KALIMANTAN	CENTRAL JAVA	EAST JAVA	JABODETABEK
WK1	0	0	0	0	1	0	10	2	3	6
WK2	0	0	1	0	0	1	10	7	13	3
WK3	1	1	0	0	0	1	6	4	5	2
...										
WK544	53	7	82	10	31	21	6	44	76	157
WK545	74	4	33	10	69	24	8	36	167	137

2.3 Normalisasi Data

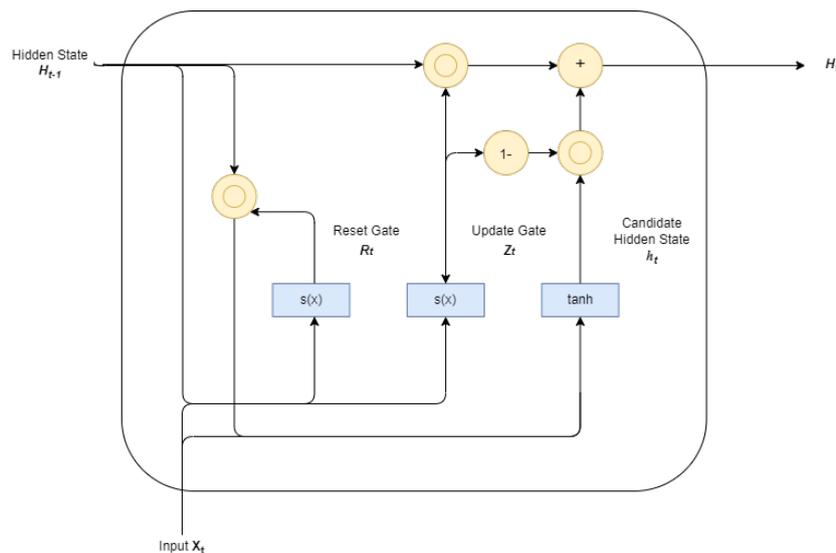
Terdapat beberapa normalisasi data, salah satunya adalah normalisasi min-max. Normalisasi min-max adalah salah satu normalisasi dimana teknik ini menghitung data sesuai dengan skala antara batas nilai terkecil dan terbesar serta tetap menjaga hubungan antara fitur yang berhubungan [2]. Persamaan dari normalisasi data min-max dapat dilihat pada persamaan (1).

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Dimana X adalah data asli, X_{min} merupakan data actual dengan nilai paling kecil, dan X_{max} merupakan data actual dengan nilai paling besar.

2.4 Gated Recurrent Unit

Metode Gated Recurrent Unit atau GRU adalah sebuah metode yang diusung oleh Kyunghun Cho Et Al dimana metode ini merupakan varian dari Recurrent Neural Network dimana setiap recurrent unit dapat menangkap dependencies dalam skala waktu yang berbeda-beda secara adaptif [3]. GRU sendiri memiliki arsitektur yang lebih sederhana jika dibandingkan dengan LSTM [4] dimana GRU hanya memiliki 2 pintu saja yaitu update gate dan reset gate [5]. Arsitektur dari GRU dapat dilihat pada gambar 2.



Gambar 2. Arsitektur GRU

Langkah pertama pada arsitektur GRU adalah menghitung reset gate dengan menggunakan persamaan (2) dimana langkah ini menentukan berapa banyak informasi dari time step terdahulu yang dapat dilupakan menggunakan aktivasi sigmoid [6].

$$r = \sigma(W_r \cdot X_t + U_r \cdot h_{(t-1)} + B_r) \quad (2)$$

Dimana W dan U adalah bobot, X adalah input, h adalah hidden state dan B adalah bias.

Langkah selanjutnya adalah perhitungan pada update gate dengan menggunakan persamaan (3). Pada update gate arsitektur menentukan berapa banyak informasi dari time step terdahulu yang akan disimpan pada perhitungan hidden state, dimana hasil perhitungan hidden state ini akan digunakan untuk input pada time step selanjutnya dan menentukan pengaruh informasi dari time step terdahulu untuk output di time step saat ini.

$$z = \sigma(W_z \cdot X_t + U_z \cdot h_{(t-1)} + B_z) \quad (3)$$

Tahap selanjutnya dalam arsitektur ini adalah melakukan perhitungan kandidat hidden state dengan menggunakan persamaan (4). Kandidat hidden state ini menjadi content memory pada time step yang sedang berlangsung.

$$\tilde{h} = \tanh(W_h \cdot X_t + r * U_h \cdot h_{(t-1)} + b_h) \quad (4)$$

Tahap terakhir pada arsitektur GRU adalah perhitungan output akhir dengan menggunakan persamaan (5). Perhitungan output terakhir ini dipengaruhi oleh nilai kandidat hidden state, nilai hidden state pada time step sebelumnya dan output dari update gate.

$$h = z * h_{(t-1)} + (1 - z) * \tilde{h} \quad (5)$$

2.4 Evaluasi Peramalan

Dilakukan perhitungan evaluasi untuk mengetahui keakuratan hasil peramalan data. Metode evaluasi yang digunakan adalah Mean Squared Error, Root Mean Squared Error dan Mean Absolute Error

2.4.1 Mean Squared Error

Mean Squared Error (MSE) merupakan salah satu metrik evaluasi yang digunakan dalam menghitung nilai error dimana semakin kecil nilai MSE maka peramalan akan menjadi semakin akurat [7]. Dalam mencari nilai MSE dapat menggunakan persamaan (6).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (6)$$

Dimana y_i adalah data actual, y'_i adalah data prediksi dan n adalah banyaknya data yang digunakan.

2.4.2 Root Mean Squared Error

Root Mean Squared Error (RMSE) digunakan untuk menghitung akurasi peramalan dengan mengukur tingkat dispersi kesalahan peramalan. Keakuratan RMSE dilihat dari semakin kecil RMSE maka hasil peramalan menjadi semakin akurat. Dalam mencari nilai RMSE dapat menggunakan persamaan (7).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (7)$$

2.4.3 Mean Absolut Error

Mean Absolute Error (MAE) digunakan untuk menghitung rata-rata selisih antar nilai hasil prediksi yang dihasilkan dengan penilaian pengguna yang sesungguhnya. Keakuratan MAE dilihat dari selisih nilai hasil peramalan dengan nilai sesungguhnya [8]. Jika MAE mendekati 0, maka hasil peramalan menjadi semakin akurat. Dalam mencari nilai MAE dapat menggunakan persamaan (5).

$$MAE = \frac{\sum_{i=1}^n |P_i - Q_i|}{N} \quad (8)$$

Dimana P_i adalah nilai rating hasil prediksi, Q_i adalah nilai rating sebenarnya dan N adalah jumlah dataset.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Hasil pada penelitian ini akan dibagi menjadi beberapa bagian yaitu tentang data yang digunakan pada pembuatan model, pengujian dataset nasional dan pengujian dataset regional.

3.1.1 Data

Pada penelitian ini data yang digunakan dalam pembuatan model adalah data pertumbuhan outlet nasional dengan jumlah data 545 minggu, dimana 80% atau 436 minggu akan digunakan sebagai proses *training* dan 20% atau 109 minggu akan digunakan sebagai proses pengujian. Sampel pembagian data training dan data pengujian dapat dilihat pada Tabel 3.

Tabel 3. Pembagian *training* dan *testing*

Training		Testing	
Week	ALL	Week	ALL
WK1	22	WK437	830
WK2	35	WK438	1049
WK3	20	WK439	949
...		...	
WK435	579	WK544	487
WK436	953	WK545	562

Data yang akan digunakan kemudian melalui proses normalisasi menggunakan normalisasi min-max sehingga nilai berubah menjadi antara 0 dan 1.

3.1.2 Pengujian Dataset Nasional

Dalam pembuatan model GRU akan dilakukan pelatihan data untuk melatih model agar dapat melakukan peramalan atau prediksi berdasarkan data historis pertumbuhan jumlah outlet PT XYZ. Pada tahap ini akan dibuat beberapa model dengan konfigurasi *hyperparameter* dan *optimizer* yang berbeda. Pengujian ini dilakukan agar bisa dilakukan perbandingan antara model satu dengan model lainnya sehingga dapat dipilih model dengan hasil evaluasi peramalan yang paling baik. Uji coba model dilakukan dengan menggunakan 2 optimizer yang berbeda yaitu ADAM dan SGD, dengan setiap uji coba model akan dilakukan perubahan parameter pada bagian unit dan *batch size*.

Hasil evaluasi dari setiap model yang dibuat dengan menggunakan optimizer ADAM dengan unit dan *batch size* yang berbeda dapat dilihat pada tabel 4. Berdasarkan tabel 4, model GRU dengan optimisasi ADAM yang memiliki kinerja terbaik adalah model dengan parameter unit sebesar 64 dan *batch size* 128 yang menghasilkan nilai MAE sebesar 0.1230, nilai RMSE sebesar 0.2103, dan nilai MSE sebesar 0.0442. Sedangkan nilai model GRU dengan optimizer ADAM yang memiliki kinerja terburuk adalah model dengan parameter unit sebesar 64 dan *batch size* 16 yang menghasilkan nilai MAE sebesar 0.5764, nilai RMSE 0.6768, dan nilai MSE 0.4580.

Tabel 4. Hasil Evaluasi Optimizer Adam

Parameter		ADAM Optimizer		
Unit	Batch Size	MAE	RMSE	MSE
64	16	0.5764	0.6768	0.4580
	32	0.1257	0.2113	0.0446
	64	0.1259	0.2126	0.0452
	128	0.1230	0.2103	0.0442
128	16	0.1333	0.2063	0.0426
	32	0.1262	0.2073	0.0430
	64	0.1250	0.2079	0.0432
	128	0.1249	0.2088	0.0436
256	16	0.1376	0.2102	0.0442
	32	0.1292	0.2070	0.0428
	64	0.1256	0.2051	0.0421
	128	0.1250	0.2050	0.0420

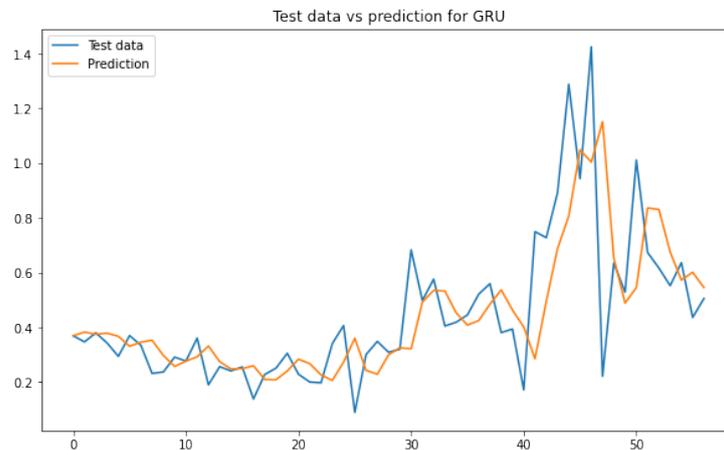
Hasil evaluasi dari setiap model yang dibuat dengan menggunakan optimizer SGD dengan unit dan *batch size* yang berbeda dapat dilihat pada tabel 5. Berdasarkan hasil evaluasi yang ada pada tabel 5, model GRU dengan optimisasi SGD yang menghasilkan hasil prediksi terbaik adalah model dengan parameter unit sebesar 64 dan *batch size* 128. Dimana model tersebut menghasilkan nilai MAE sebesar 0.1220, nilai RMSE sebesar 0.2050, dan nilai MSE sebesar 0.0421. Sedangkan model GRU dengan optimizer SGD yang memiliki nilai evaluasi yang kurang baik adalah model dengan parameter unit sebesar 256 dan *batch size* 32 yang menghasilkan nilai MAE sebesar 0.1256, nilai RMSE 0.2059, dan nilai MSE 0.0424.

Tabel 5. Hasil Evaluasi Optimizer SGD

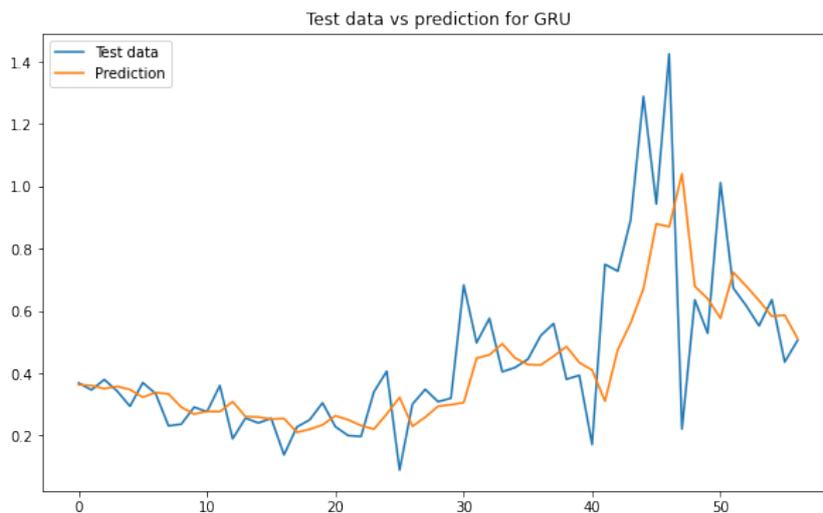
Parameter		SGD Optimizer		
Unit	Batch Size	MAE	RMSE	MSE
64	16	0.1242	0.2050	0.0420
	32	0.1244	0.2052	0.0421
	64	0.1226	0.2052	0.0421
	128	0.1220	0.2050	0.0420
128	16	0.1255	0.2053	0.0422
	32	0.1256	0.2056	0.0423

Parameter		SGD Optimizer		
Unit	Batch Size	MAE	RMSE	MSE
	64	0.1233	0.2061	0.0425
	128	0.1252	0.2054	0.0422
256	16	0.1255	0.2057	0.0423
	32	0.1256	0.2059	0.0424
	64	0.1250	0.2062	0.0425
	128	0.1252	0.2058	0.0423

Visualisasi dari hasil prediksi dan data actual model GRU yang menggunakan optimizer ADAM dengan hasil evaluasi terbaik dapat dilihat pada gambar 2. Hasil prediksi dan data actual model GRU yang menggunakan optimizer SGD dengan hasil evaluasi terbaik dapat dilihat pada gambar 3. Pada gambar 2 dan gambar 3 menunjukkan data actual dan hasil prediksi model.



Gambar 3. Hasil Prediksi Model dengan Optimizer ADAM



Gambar 4. Hasil Prediksi Model dengan Optimizer SGD

3.1.3 Pengujian *Dataset Regional*

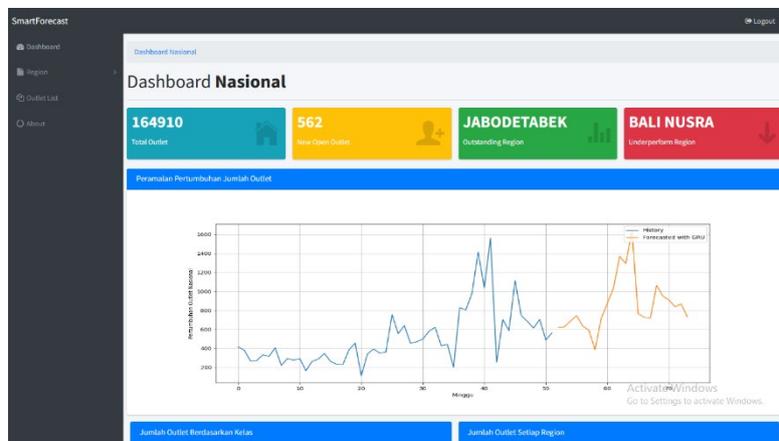
Setelah didapatkan model terbaik untuk masing-masing *optimizer*, akan dilakukan pengujian kedua menggunakan dataset region. Untuk hasil evaluasi kedua model dapat dilihat pada tabel 5. Dari hasil evaluasi pengujian, Model GRU dengan *optimizer* ADAM mempunyai hasil evaluasi yang lebih baik dibandingkan model GRU dengan *optimizer* SGD. Model GRU dengan *optimizer* ADAM memiliki nilai MAE yang lebih baik pada region JABODETABEK, Kalimantan, Sulawesi, North Sumatera, South Sumatera, Central Sumatera, West Java, East Java. Dan memiliki nilai RMSE dan MSE yang lebih baik pada region Kalimantan, Central Sumatera, West Java, dan East Java. Selain itu juga, model ini memiliki rata-rata nilai MAE, RMSE dan MSE yang sedikit lebih baik dibandingkan dengan model dengan *optimizer* SGD.

Tabel 6. Hasil Evaluasi Menggunakan Dataset Regional

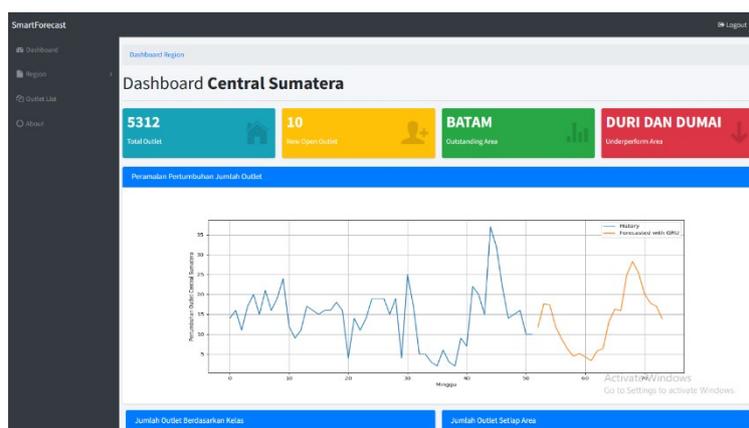
Region	Model GRU ADAM			Model GRU SGD		
	MAE	RMSE	MSE	MAE	RMSE	MSE
JABODETABEK	0.1679	0.3020	0.0912	0.1690	0.2895	0.0838
Bali Nusra	0.0737	0.1000	0.0100	0.0726	0.0986	0.0097
Kalimantan	0.0161	0.0197	0.0004	0.0204	0.0231	0.0005
Sulawesi	0.0794	0.1045	0.0109	0.0803	0.1033	0.0107
North Sumatera	0.3442	0.4548	0.2068	0.3452	0.4514	0.2038
South Sumatera	0.0523	0.0682	0.0047	0.0538	0.0679	0.0046
Central Sumatera	0.0711	0.0946	0.0090	0.0724	0.0958	0.0092
Central Java	0.0778	0.1090	0.0119	0.0759	0.1073	0.0115
West Java	0.1973	0.3314	0.1098	0.2008	0.3477	0.1209
East Java	0.0809	0.1264	0.0160	0.0814	0.1265	0.0160
Average	0.11607	0.17106	0.04707	0.11718	0.17111	0.04707

3.2 Pembahasan

Setelah melalui 2 buah pengujian, untuk model GRU dengan *Optimizer* ADAM yang menggunakan unit sebesar 64 dan *batch size* sebesar 128 dipilih untuk digunakan kedalam system peramalan pertumbuhan jumlah outlet, dikarenakan memiliki hasil evaluasi yang sedikit lebih baik dibandingkan model dengan *optimizer* SGD. Untuk contoh hasil penerapan model dalam melakukan peramalan pertumbuhan jumlah outlet minggu mendatang dapat dilihat pada gambar 5 dan gambar 6.



Gambar 5. Penerapan Model pada Peramalan Outlet Nasional



Gambar 6. Penerapan Model pada Peramalan Outlet Regional - Central Sumatera

4. KESIMPULAN

Berdasarkan hasil pengujian yang dilakukan menggunakan metode Gated Recurrent Unit dalam meramal data pertumbuhan jumlah outlet, hasil evaluasi peramalan pertumbuhan jumlah outlet menggunakan metode Gated Recurrent Unit yang didapatkan melalui evaluasi menggunakan MAE, RMSE dan MSE menunjukkan bahwa secara keseluruhan metode GRU dapat melakukan peramalan dengan cukup baik. Terutama pada model GRU dengan *optimizer* ADAM dengan unit sebesar 64 dan *batch size* sebesar 128.

Model GRU ini dapat menghasilkan nilai evaluasi yang cukup baik untuk dataset pertumbuhan outlet nasional dengan menghasilkan nilai MAE sebesar 0.1230, nilai RMSE sebesar 0.2103, dan nilai MSE sebesar 0.0442. Model ini juga mendapatkan hasil evaluasi yang cukup baik untuk dataset pertumbuhan outlet regional dengan nilai rata-rata MAE sebesar 0.11607, nilai rata-rata RMSE sebesar 0.17106, dan nilai rata-rata MSE sebesar 0,04707. Hal ini menunjukkan hasil model GRU dengan *optimizer* ADAM, unit sebesar 64, dan *batch size* sebesar 128 memiliki akurasi peramalan yang cukup baik untuk dataset pertumbuhan outlet nasional dan dataset pertumbuhan outlet regional. Walaupun memiliki nilai evaluasi yang kecil, berdasarkan gambar perbandingan prediksi dan data aktual yang ada di gambar 3 dan gambar 4, kedua model masih belum bisa menghasilkan nilai prediksi yang benar-benar mengikuti tren dari dataset.

Pengembangan yang dapat dilakukan selanjutnya adalah dengan menggunakan dataset dengan rentan waktu yang lebih panjang daripada 545 minggu agar dapat meningkatkan kemampuan belajar model sehingga hasil prediksi menjadi lebih baik.

UCAPAN TERIMA KASIH

Penulis berterima kasih kepada Tuhan Yang Maha Esa, keluarga dan pihak-pihak yang tidak dapat disebutkan satu per satu yang telah mendukung terlaksananya penulisan makalah ini. Jurnal Computatio berterima kasih kepada IJCCS sebagai landasan bentuk format makalah ini.

DAFTAR PUSTAKA

- [1] CFI Team, Telecommunications Industry – Overview, Origin, Current State, <https://corporatefinanceinstitute.com/resources/careers/companies/telecommunications-industry/>, diakses tanggal 9 September 2022.
- [2] Sugiartawan, P., Pulungan, R., dan Kartika, A., *Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network*, *International Journal of Advanced Computer Science and Applications*, Vol. 8, Nomor 2, hal. 326-332.
- [3] Chung, J., Gulcehre. C., Cho, K., dan Bengio., *Empirical evaluation of gated recurrent neural networks on sequence modelling*, *NIPS 2014 Workshop on Deep Learning*, 2014.
- [4] Tzeng, Y. R. Lai, M. L. Lin, Y. H. Lin, and Y. C. Shih, *Improve the LSTM and GRU model for small training data by wavelet transformation*, Proc. Int. Jt. Conf. Neural Networks, hal. 2–7.
- [5] Q. Tao, F. Liu, Y. Li, and D. Sidorov, *Air Pollution Forecasting Using A Deep Learning Model Based on 1D Convnets and Bidirectional GRU*, *IEEE Access*, vol. 7, hal. 76690–76698, <https://ieeexplore.ieee.org/abstract/document/8732985>.
- [6] Rochman Nugroho, W., PREDIKSI HARGA MATA UANG BITCOIN MENGGUNAKAN METODE OPTIMIZED GATED RECURRENT UNIT DENGAN OPTIMASI ADAPTIVE MOMENT ESTIMATION. <http://eprints.upnyk.ac.id/28377/>, diakses pada tanggal 19 September 2022.
- [7] Liu, H., dan Shen, L., *Forecasting carbon price using empirical wavelet transform and Gated Recurrent Unit neural network*, *Carbon Management Journal*, Vol. 11, Nomor 1, hal. 25-37, <https://www.tandfonline.com/doi/full/10.1080/17583004.2019.1686930>
- [8] Y Noh, Jiseong, Park, Hyun-Ji, dan Kim, Joong Soo, *Gated Recurrent Unit with genetic algorithm for product demand forecasting in supply chain management*, *MDPI Mathematics Journal*, Vol. 8, Issue 4, <https://www.mdpi.com/2227-7390/8/4/565/htm>.