

## Forecasting Jumlah Penggunaan Obat *Digestive Enzymes* dengan Algoritma GRU

Abi Mahan Zaky<sup>1</sup>

<sup>1</sup>SMA Negeri 1 Mojotengah, Wonosobo, Jawa Tengah

### Article Info

#### Corresponding Author:

Abi Mahan Zaky,  
SMA Negeri 1 Mojotengah,  
Wonosobo, Jawa Tengah  
Indonesia.

Email: abimahan@gmail.com

### ABSTRACT

Obat-obatan banyak digunakan untuk mencegah atau menyembuhkan penyakit. Salah satu obat yang sering digunakan untuk meredakan sakit perut adalah obat yang mengandung *Digestive Enzymes*. Rumah sakit dan institusi kesehatan lainnya sangat membutuhkan obat jenis ini. Rumah Sakit dan institusi kesehatan lain harus memastikan ketersediaan obat untuk pasien. Situasi ini memaksa institusi kesehatan untuk menghadapi ketidakpastian penggunaan obat. Rumah sakit sebagai salah satu institusi kesehatan memiliki beberapa tantangan. Salah satu tantangan yang harus dihadapi adalah untuk menjamin ketersediaan obat bagi pasien. Kemampuan *forecasting* dapat membantu memastikan ketersediaan obat di rumah sakit. Di penelitian ini akan menyajikan model *forecasting* dengan menggunakan metode *Gated Recurrent Unit* (GRU) untuk memprediksi kebutuhan obat-obatan yang mengandung *Digestive Enzymes* di rumah sakit. Metode ini dipilih karena diketahui memiliki akurasi yang tinggi untuk memprediksi data stasioner. Salah satu metode yang digunakan dalam identifikasi input untuk metode GRU adalah dengan menggunakan *Autocorrelation Function* (ACF) dan *Partial Fungsi Autokorelasi* (PACF). Hasil penelitian ini menunjukkan bahwa penggunaan metode GRU cocok untuk *forecasting* data *timeseries* dalam kumpulan data historis, dengan nilai *Root Mean Square Error* (RMSE) 13,020446.

**Kata kunci:** GRU, *forecasting*, penggunaan obat.

Medicines are widely used to prevent or cure diseases. One of the drugs that are often used to relieve abdominal pain is a drug that contains *Digestive Enzymes*. Hospitals and other health institutions are in dire need of this type of medicine. Hospitals and other health institutions must ensure the availability of drugs for patients. This situation forces health institutions to face the uncertainty of the use of the drug. Hospitals as one of the health institutions have several challenges. One of the challenges that must be faced is to ensure the availability of drugs for patients. Forecasting capabilities can help ensure drug availability in hospitals. This study will present a *forecasting* model using the *Gated Recurrent Unit* (GRU) method to predict the need for drugs containing *Digestive Enzymes* in hospitals. This method was chosen because it is known to have a high accuracy for predicting stationary data. One of the methods used in input identification for the GRU method is to use the *Autocorrelation Function* (ACF) and the *Partial Autocorrelation Function* (PACF). The results of this study show that the use of the GRU method is suitable for *forecasting timeseries* data in historical data sets, with a *Root Mean Square Error* (RMSE) value of 13.020446.

**Keywords:** GRU, *forecasting*, medicine use

### 1. LATAR BELAKANG

Seperti yang kita ketahui, kesehatan merupakan hal yang sangat fundamental dalam kehidupan. Tidak hanya kehidupan manusia tetapi juga kehidupan semua makhluk hidup. Oleh karena itu, penting untuk melakukan upaya menciptakan kualitas kesehatan yang baik secara menyeluruh dan berkelanjutan. Salah satu cara yang dapat dilakukan adalah meningkatkan akses dan kualitas pelayanan kesehatan. Ketersediaan obat yang memadai merupakan elemen penting dalam pemeliharaan dan peningkatan kualitas pelayanan

kesehatan. Di antara berbagai pilihan yang tersedia, masalah terkait obat-obatan adalah yang paling banyak digunakan untuk mendapatkan pelayanan kesehatan yang berkualitas. Oleh karena itu, perlu untuk pengendalian ketersediaan obat oleh pihak terkait.

Ketidakpastian penggunaan obat dalam periode tertentu merupakan tantangan yang dimiliki oleh instansi terkait. Karenanya, institusi kesehatan harus melakukan manajemen sumber daya, khususnya sumber daya obat [1]. Selain meningkatkan kualitas pelayanan kesehatan juga dapat mempengaruhi peningkatan daya saing organisasi [2]. Oleh karena itu, *forecasting* dapat membantu pemangku kepentingan untuk mengidentifikasi langkah-langkah untuk mengelola sumber daya yang ada [3].

Berdasarkan informasi dari *World Health Organization* (WHO), membuat prediksi dan perhitungan pada permintaan obat berperan cukup signifikan. *Forecasting* dapat digunakan untuk mempertimbangkan dalam pembelian obat-obatan [4].

Ada beberapa penelitian sebelumnya yang terkait dengan *forecasting* pada konsumsi obat-obatan. Namun, dalam penelitian sebelumnya, banyak yang masih menggunakan cara tradisional. Diantaranya adalah *classification trees* [5], *regression* [6], dan *clustering algorithm* [7]. Seiring berjalannya waktu, metode untuk peramalan data *timeseries* semakin bertambah [8]. Hasilnya menunjukkan bahwa penggunaan *Deep Neural Network* lebih efektif daripada *Neural Network* biasa [9]. Dari penelitian yang menggunakan Metode *Neural Network* (NN) dan *Decision Tree*, menemukan bahwa *forecasting* penggunaan obat-obatan dapat membantu membuat keputusan untuk pemangku kepentingan untuk menentukan perencanaan produksi [10]. Satu dari metode *Recurrent Neural Network* (RNN) yang umum digunakan adalah *Gated Recurrent Unit* (GRU) [11]. Di dalam penelitian ini akan menyajikan model *forecasting* menggunakan metode GRU untuk memprediksi kebutuhan obat-obatan yang mengandung Digestive Enzymes di rumah sakit. Metode ini dipilih karena dikenal memiliki akurasi yang tinggi untuk memprediksi data stasioner [12]. Dalam proses peramalan menggunakan GRU, pada pemilihan lag yang signifikan akan menggunakan plotting *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk meningkatkan akurasi *forecasting* pada konsumsi obat-obatan.

Jurnal ini dibagi menjadi beberapa bagian. Bagian I adalah pengantar penelitian. Bagian II berisi landasan teori peramalan dan metode GRU. Kemudian Bagian III berisi tentang langkah penelitian, analisis, dan hasil dari penelitian. Selain itu, bagian terakhir, kesimpulan dari penelitian ini akan disajikan pada bagian IV.

## 2. METODOLOGI PENELITIAN

### 2.1. FORECASTING

*Forecasting* adalah masalah yang cukup menantang yang penelitiannya masih berkembang [13]. *Forecasting* data *timeseries* terdiri dari berbagai jenis. Jika dibagi dengan rentang waktu, *forecasting* dapat menjadi dibagi menjadi pendek (antara 1 hari sampai seperempat tahun), menengah (antara seperempat tahun untuk perkiraan dari tahun ke tahun), dan jangka panjang (antara satu tahun sampai lima tahun ke depan) [14].

Berdasarkan pola datanya, data *timeseries* dibagi menjadi empat macam karakteristik. Ada musim, siklus, horizontal, dan pola trend. Pola musiman hadir dalam kumpulan data deret waktu yang memiliki faktor musiman, yaitu, ada pengulangan pola selama satu periode. Sebuah siklus pola dapat terjadi jika dataset dipengaruhi oleh ekonomi fluktuasi. Sebuah pola horizontal terjadi ketika dataset memiliki fluktuasi yang konstan. Apalagi pola tren terjadi ketika dataset mengalami kenaikan atau penurunan nilai dalam waktu yang lama. Juga, ada juga kumpulan data deret waktu yang merupakan gabungan lebih dari satu pola [15].

Berdasarkan jumlah variabel yang dianalisis, maka *forecasting* data *time series* dibagi menjadi dua kelas. Yang pertama adalah *univariat* (satu variabel), contoh nya metode *forecasting* adalah *Gated Recurrent Unit* (GRU) dan *Autoregressive Integrated Moving Average* (ARIMA) metode [12]. Yang kedua adalah *multivariat* (beberapa variabel), contoh metode peramalannya adalah *Vector Autoregressive Integrated Moving Average* dan *Vector Autoregressive* (VAR) [16].

### 2.2. GRU

*Gated Recurrent Unit* (GRU) merupakan cabang dari RNN. GRU merupakan penerapan RNN untuk kasus *forecasting*. *Output* data berupa bilangan bulat atau diskrit, sedangkan untuk kasus regresi *output* data berupa bilangan riil atau kontinu. Dengan menggunakan konsep *insensitive loss function*, yang diperkenalkan oleh Vapnik, GRU bisa digeneralisasi untuk melakukan pendekatan fungsi (*function approximation*) atau regresi.

Misalkan kita punya set data training,  $(x_i, y_i)$ ,  $i = 1, \dots$ , dengan data *input*  $x = (x_1, x_2, \dots, x_n)$  dan *output* yang bersangkutan  $y = \{y_1, \dots, y_n\} \subseteq \mathcal{R}$ . Dengan GRU, kita ingin menemukan suatu fungsi  $f(x)$  yang mempunyai deviasi paling besar dari target aktual  $y_i$  untuk semua data training. Manakala nilai sama dengan 0 maka kita dapatkan suatu regresi yang sempurna. Misalkan kita mempunyai fungsi sebagai garis regresi pada persamaan (1) berikut:

$$f(x) = w^T \phi(x) + b$$

dimana  $(x)$  menunjukkan suatu titik di dalam feature space  $F$  hasil pemetaan  $x$  di dalam input space. Koefisien  $w$  dan  $b$  diestimasi dengan cara meminimalkan fungsi resiko (*risk function*) yang didefinisikan dalam persamaan (2) berikut:

$$\min \frac{1}{2} \|w\|^2 + C \frac{1}{l} \sum_{i=1}^l L_\epsilon(y_i, f(x_i))$$

Faktor  $w^2$  dinamakan regularisasi. Meminimalkan  $w^2$  akan membuat suatu fungsi setipis (*flat*) mungkin, sehingga bisa mengontrol kapasitas fungsi (*function capacity*). Faktor kedua dalam fungsi tujuan adalah kesalahan empirik (*empirical error*) yang diukur dengan *insensitive loss function*. Menggunakan ide *insensitive loss function*, kita harus meminimalkan *norm* dari  $w$  agar mendapatkan generalisasi yang baik untuk fungsi regresi  $f$ . Karena itu kita perlu menyelesaikan problem optimisasi pada persamaan (3) berikut:

$$y_i - w\phi(x_i) - b \leq \epsilon$$

$$w\phi(x_i) - y_i + b \leq \epsilon, i = 1, \dots, \ell,$$

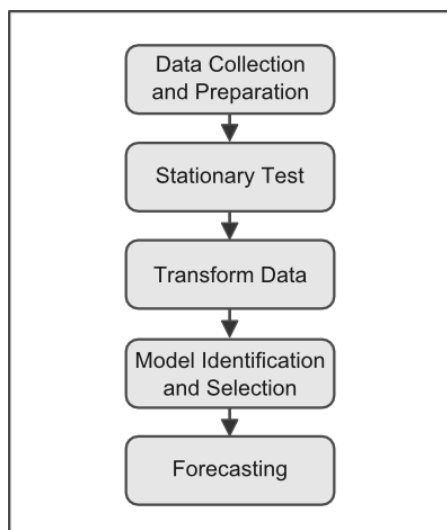
Dalam kasus ini kita asumsikan bahwa semua titik ada dalam rentang  $f \pm \epsilon$  (*feasible*). Dalam hal ketidaklayakan (*infeasibility*), dimana ada beberapa titik yang mungkin keluar dari rentang  $f$ , kita bisa menambahkan variable slack  $t_i$  untuk mengatasi masalah pembatas yang tidak layak (*infeasible constraints*) dalam problem optimisasi. Selanjutnya problem optimisasi di atas bisa diformulasikan sebagai persamaan (4) berikut :

$$L_\epsilon(y_i, f(x_i)) = \begin{cases} |y_i - f(x_i)| - \epsilon & \text{if } |y_i - f(x_i)| \geq \epsilon \\ 0 & \text{otherwise} \end{cases}$$

Konstanta  $C > 0$  menentukan tawar-menawar (*trade off*) antara ketipisan fungsi (*flatness of function*)  $f$  dan batas atas deviasi lebih dari masih ditoleransi. Semua deviasi lebih besar akan dikenakan penalti sebesar  $C$ . Dalam GRU, ekuivalen dengan akurasi dari aproksimasi kita terhadap data training. Nilai yang kecil terkait dengan nilai yang tinggi pada variabel slack  $t_i$  dan akurasi aproksimasi yang tinggi. Sebaliknya, nilai yang tinggi untuk berkaitan dengan nilai  $t_i$  yang kecil dan akurasi aproksimasi yang rendah. Menurut persamaan (4), nilai yang tinggi untuk variabel slack akan membuat kesalahan empirik mempunyai pengaruh yang besar terhadap faktor regularisasi. Dalam GRU, support vectors adalah data training yang terletak pada dan di luar batas dari fungsi keputusan. karena itu jumlah support vectors menurun dengan naiknya nilai  $C$ . Dalam formulasi dual, problem optimisasi dari GRU adalah persamaan (5) berikut:

$$\max \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_j)(\alpha_i - \alpha_j) K(x_i, x_j)$$

dimana  $C$  didefinisikan oleh user,  $K(x_i, x_j)$  adalah *dot-product kernel* yang didefinisikan sebagai  $K(x_i, x_j) = T(x_i) \cdot T(x_j)$ .




Gambar 1. Forecasting method

Gambar 1 merupakan diagram alir proses *forecasting*. Pada bagian Pengumpulan dan Persiapan Data, kami akan mengumpulkan dan menganalisis data yang ada. Setelah itu pada bagian *Stationary Test* dilakukan pengujian stasioneritas pada data dengan menggunakan ADF (*Augmented Dickey-Fuller*), salah satu contoh metode statistik untuk pengujian data stasioner. Setelah dilakukan pengujian data stasioner, selanjutnya akan ditransformasikan, sehingga selanjutnya dapat digunakan sebagai *input* untuk *forecasting*. Metode GRU digunakan pada tahap *forecasting*. Pada tahap identifikasi dan pemilihan model dilakukan pemilihan model GRU terbaik, kemudian digunakan dalam proses *forecasting*.

### 3. HASIL DAN ANALISIS

#### 3.1. PENGUMPULAN DATA DAN PERSIAPAN

Dataset untuk penelitian ini adalah penggunaan Enzyplex mingguan pada Rumah Sakit dari Januari 2015 hingga Desember 2015 (52 minggu). Enzyplex adalah suplemen *digestive enzyme* yang membantu proses pencernaan dan membantu penyerapan nutrisi secara optimal [20]. Dataset dipisahkan menjadi 80% data pelatihan (42 minggu) yang digunakan untuk model identifikasi dan seleksi, dan 20% data uji (10 minggu) yang digunakan untuk mengukur kesalahan model yang dihasilkan. Data pelatihan ditunjukkan pada Gambar 2. Sumbu y mewakili jumlah spesifik penggunaan Enzyplex (gram) sedangkan sumbu x mewakili minggu tertentu. Penggunaan obat tertinggi di minggu 26 dengan 94 gram.



Gambar 2. Training data

### 3.2. UJI STATIONARY

Pada bagian ini adalah untuk menguji apakah dataset stasioner atau tidak. Metode statistik yang digunakan untuk menguji apakah a data stasioner atau tidak adalah uji *Kwiatkowski-Phillips-SchmidtShin* (KPSS) dan uji *Augmented Dickey-Fuller* (ADF). Dalam penelitian ini, kami menggunakan uji ADF. Dalam uji ADF, jika *p-value* lebih kecil atau sama dengan 0,05 ( $p\text{-value} \leq 0,05$ ) maka datanya adalah stasioner. Sedangkan jika *p-value* lebih besar dari 0,05 ( $p\text{-value} > 0,05$ ) maka data tersebut tidak stasioner [21]. Nilai *p* atau probabilitas yang dihitung adalah probabilitas hasil ketika hipotesis nol ( $H_0$ ) dari pertanyaan penelitian adalah benar [22].

Proses pengujian menggunakan bahasa pemrograman Python. Kami telah menggunakan fungsi *adfuller* dalam paket *statsmodels*. Setelah dilakukan pengujian pada dataset, berikut hasil yang diperoleh

```
ADF Statistic : -4.891629
p-value       : 0.000036
Critical Values : 1% : -3.566
                5% : -2.920
                10% : -2.598
```

Dari data tersebut, *p-value* dari dataset adalah 0,000036, dan nilai Statistik ADF kurang dari 1% *Critical Values*. Maka dapat disimpulkan bahwa dataset adalah data stasioner dengan tingkat kepercayaan 99%. Oleh karena itu, tidak perlu untuk proses *differencing* ke dataset [23].


### 3.3. DATA TRANSFORM

Seperti yang digunakan dalam metode *neural network* lainnya, dataset di metode GRU harus pada skala aktivasi fungsi yang digunakan oleh jaringan [24]. Tangen hiperbolik (*tanh*) adalah fungsi aktivasi default yang digunakan dalam metode GRU. Nilai *output* berada di antara angka -1 dan 1. Oleh karena itu kita harus mengubah rentang dalam kumpulan data agar sesuai dengan nilai *output* yang diharapkan dari metode GRU. Dalam jurnal ini, proses transformasi data menggunakan *MinMaxScaler* fungsi dalam paket *scikit-learn* dengan bahasa pemrograman *python*.

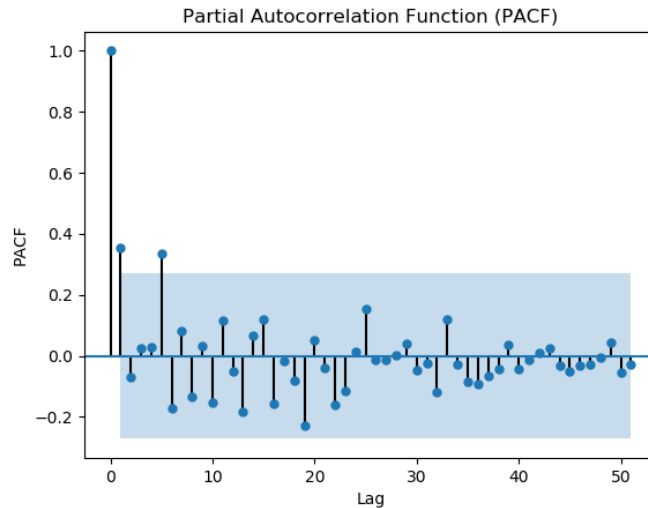
### 3.4. IDENTIFIKASI MODEL DAN PEMILIHAN

Bagian ini untuk mengidentifikasi dan memilih model yang akan digunakan untuk *forecasting*. Untuk pengembangan model, kami telah menggunakan *Keras package* pada *python*. Tahap awal adalah membuat *instance* dari kelas *Sequential*. Setelah itu, kita buat layer dan tambahkan itu untuk membuat mereka terhubung.

Dalam penelitian ini, kami menggunakan 1 ukuran *batch*. *Batch* ke 1 dipilih karena menggunakan *walk-forward validation* untuk melakukan *forecast* satu langkah [12]. Untuk memperbarui bobot jaringan, kami telah menggunakan *Adam Optimizer* [25]. Untuk menentukan *input* untuk Metode GRU, kami mencari lag yang signifikan pada dataset menggunakan plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).



Gambar 3. Autocorrelation Function (ACF)



Gambar 4. Partial Autocorrelation Function (PACF)

Pada Gambar 3 dan Gambar 4 menunjukkan bahwa lag yang paling signifikan dari dataset adalah lag 1 dan lag 5. Menurut Abolfazli [26], pemilihan lag di awal ACF dan Plot PACF lebih disukai. Oleh karena itu lag 1 digunakan sebagai input dari metode GRU. Jadi untuk melakukan *forecasting* pada waktu  $t$  maka masukan yang dipilih  $t-1$ .

### 3.5. FORECASTING

Metode GRU digunakan untuk memprediksi 10 minggu ke depan. Pada penelitian ini dilakukan percobaan *forecasting* pada metode GRU dengan 50 epoch, 100 epoch, dan 500 epoch digunakan. Selain itu, setiap epoch memiliki neuron 1, 2, 3, dan 4. Hasil ramalan dapat dilihat pada TABEL I

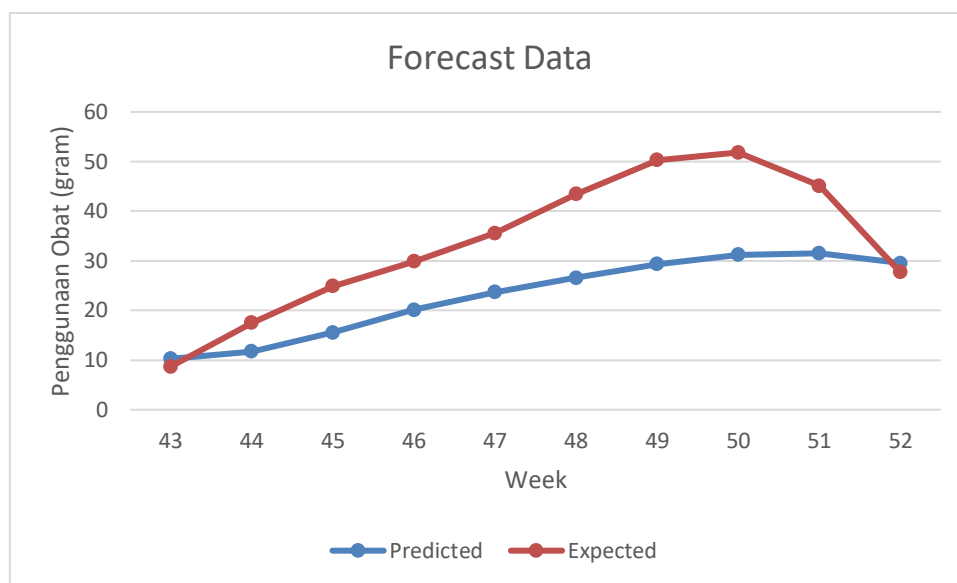
TABEL I  
FORECASTING RESULT

Epoch	Neuron	RMSE	MSE
50	1	21,287539	453,15933
50	2	21,59883	466,50947
50	3	28,481866	811,21668
50	4	13,020446	169,53201
100	1	18,778899	352,64704
100	2	15,37357	236,34667
100	3	26,548913	704,8448
100	4	22,805371	520,08497
500	1	21,685728	470,27081
500	2	14,610857	213,47714
500	3	20,66495	427,04015
500	4	14,005873	196,16448

Dari hasil Tabel 1 diketahui bahwa yang terbaik hasil peramalan adalah model GRU dengan 50 epoch dan 4 neuron dengan nilai Root Mean Square Error (RMSE) terkecil adalah 13,020446. Dari hasil tersebut dapat dianalisa bahwa untuk peramalan dataset yang ada, penggunaan model GRU dengan epoch yang lebih kecil dan jumlah neuron yang lebih banyak akan menghasilkan tingkat akurasi yang lebih tinggi. *Forecasting* selama 10 minggu ke depan dengan model terbaik GRU dapat terlihat pada Tabel 2 dan Gambar 5.

TABEL II  
FORECASTING RESULT (50 EPOCH, 4 NEURON)

Week	Predicted Value	Expected Value
43	10,267014	8,715306
44	11,717697	17,496825
45	15,597360	24,886069
46	20,131772	29,859432
47	23,686423	35,564931
48	26,594796	43,462110
49	29,343566	50,320050
50	31,239351	51,835794
51	31,518456	45,145199
52	29,505708	27,748791



Gambar 5. Forecast data

Gambar 5 adalah representasi grafis dari peramalan data dari minggu 43 hingga 52. Garis merah mewakili nilai sebenarnya dari data. Garis biru mewakili nilai *forecasting*. Dari grafik terlihat bahwa nilai *forecasting* memiliki pola yang hampir mirip dengan nilai sebenarnya dari data. Sehingga dapat disimpulkan bahwa hasil peramalan proses cukup berhasil.

#### 4. KESIMPULAN

Dalam penelitian ini, metode GRU telah diterapkan untuk memprediksi jumlah penggunaan obat yang mengandung *digestive enzyme* (Enzyplex) di rumah sakit berdasarkan data mingguan. Hasil penelitian menunjukkan bahwa metode GRU cocok untuk peramalan pada data historis *time series*. Hasilnya menunjukkan nilai RMSE terkecil adalah 13,020446 pada model GRU dengan 50 epoch dan 4 neuron.

*Forecasting* penggunaan obat dapat bermanfaat bagi pemangku kepentingan di rumah sakit atau institusi kesehatan lainnya untuk membuat keputusan tentang pengelolaan sumber daya obat. Untuk penelitian selanjutnya adalah masih perlu dibandingkan dengan model GRU lain dengan jumlah epoch dan neuron yang berbeda dan kemudian dilakukan evaluasi hasil.

## DAFTAR PUSTAKA

- [1] M. Jalalpour, Y. Gel, and S. Levin, "Forecasting demand for health services: Development of a publicly available toolbox," *Oper. Res. Heal. Care*, vol. 5, pp. 1–9, 2015.
- [2] C. Qingkui and R. Junhu, "Study on the Demand Forecasting of Hospital Stocks Based on Data Mining and BP Neural Networks," in *International Conference on Electronic Commerce and Business Intelligence Study*, 2009, pp. 284–289.
- [3] Á. Lublóy, "Factors affecting the uptake of new medicines: a systematic literature review," *BMC Health Serv. Res.*, pp. 1–25, 2014.
- [4] WHO, "Essential medicines and health products." [Online]. Available: <http://www.who.int/medicines/areas/access/supply/en/index2.html>. [Accessed: 10-Aug-2016].
- [5] Robinson, John W. "Regression tree boosting to adjust health care cost predictions for diagnostic mix." *Health services research* 43.2 (2008): 755-772.
- [6] Zhao, Y., A. S. Ash, R. P. Ellis, J. Z. Ayanian, G. C. Pope, B. Bowen, L. Weyuker. 2005. Predicting pharmacy costs and other medical costs using diagnoses and drug claims. *Med. Care* 43 34–43.
- [7] Bertsimas, Dimitris, et al. "Algorithmic prediction of healthcare costs." *Operations Research* 56.6 (2008): 1382-1392.
- [8] Gamboa, John Cristian Borges. "Deep Learning for TimeSeries Analysis." arXiv preprint arXiv:1701.01887 (2017).
- [9] Tesaro, Gerald. "Practical issues in temporal difference learning." *Advances in neural information processing systems*. 1992.
- [10] R. Ghousi, S. Mehrani, and M. Momeni, "Application of Data Mining Techniques in Drug Consumption Forecasting to Help Pharmaceutical Industry Production Planning," in *International Conference on Industrial Engineering and Operations Management*, 2012, pp. 1162–1167.
- [11] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget: Continual prediction with GRU," *Neural computation*, vol. 12, no. 10, pp. 2451–2471, 2000.
- [12] S. Kaushik, A. Choudhury, N. Dasgupta, S. Natarajan, L. A. Pickett, and V. Dutt, "Using GRUs for Predicting Patient's Expenditure on Medications", in *International Conference on Machine Learning and Data Science*, 2017, pp. 120-127.
- [13] L. B. Godfrey, M. S. Gashler, "Neural Decomposition of Time-Series Data", in *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2017, pp. 2796-2801.
- [14] I. N. Soyiri and D. D. Reidpath, "An overview of health forecasting," *Environ. Health Prev. Med.*, vol. 18, pp. 1–9, 2013.
- [15] S. Makridakis, S. C. Wheelwright, and V. E. McGee, *Forecasting: Methods and Applications*, 2nd ed. John Wiley & Sons Inc, 1983.
- [16] J. G. De Gooijer and R. J. Hyndman, "25 years of time series forecasting," *Int. J. Forecast.*, vol. 22, no. 44, pp. 443–473, 2006.
- [17] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [18] J. Zheng, C. Xu, Z. Zhang and X. Li, "Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network," *51st Annual Conference on Information Sciences and Systems (CISS)*, Baltimore, MD, pp 1-6, 2017.
- [19] J. Vermaak, E. C. Botha, "Recurrent Neural Networks for Short-Term Load Forecasting", *IEEE Transactions on Power Systems*, vol. 13, no. 1, pp. 126-132, February 1998.
- [20] "Enzyplex Product Details" [Online]. Available: <https://www.unilab.com.ph/products/enzyplex>. [Accessed 18-Mar-2018].
- [21] R. J. Hyndman and G. Athanasopoulos, "Stationarity and differencing." [Online]. Available: <https://www.otexts.org/fpp/8/1>. [Accessed: 23-Mar-2018].
- [22] "P Values (Calculated Probability) and Hypothesis Testing – StatsDirect" [Online]. Available: [https://www.statsdirect.com/help/basics/p\\_values.htm](https://www.statsdirect.com/help/basics/p_values.htm). [Accessed 18-Mar-2018].
- [23] "Complete guide to create a Time Series Forecast (with Codes in Python)" [Online]. Available: <https://www.analyticsvidhya.com/blog/2016/02/time-series-forecasting-codes-python>. [Accessed 18-Mar-2018].
- [24] "Time Series Forecasting with the Long Short-Term Memory Network in Python - Machine Learning Mastery" [Online]. Available: <https://machinelearningmastery.com/time-series-forecasting-long-short-term-memory-network-python>. [Accessed 18-Mar-2018].
- [25] Kingma, Diederik, and Jimmy Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980 (2014).
- [26] H. Abolfazli, S. M. Asadzadeh, and S. M. Asadzadeh, "Forecasting Rail Transport Petroleum Consumption Using an Integrated Model of Autocorrelation Function-Artificial Neural Network", vol. 11, no. 2, pp. 203-214, 2014.