

# Pemodelan *Time Series* untuk Peramalan *Web Traffic* Menggunakan Algoritma Arima, LSTM, dan GRU

Insyiraah Oxaichiko Arissinta<sup>a,\*</sup>, Indah Dwi Sulistiyawati<sup>b</sup>, Dedy Kurnianto<sup>c</sup>  
Iqbal Kharisudin<sup>d</sup>

<sup>a,b,c,d</sup> Jurusan Matematika, FMIPA, UNNES, Jl. Raya Sekaran Gunungpati, Semarang 50229, Indonesia

\* Alamat Surel: [insyiraahoxa@students.unnes.ac.id](mailto:insyiraahoxa@students.unnes.ac.id)

## Abstrak

Saat ini peramalan lalu lintas web merupakan masalah besar karena hal ini dapat menyebabkan kemunduran pada cara kerja utama situs web. Peramalan deret waktu telah menjadi topik hangat untuk penelitian. Meramalkan *Web Traffic* dataset dari Kaggle dan mengevaluasi keakuratan melalui hasil peramalan akan menjadi salah satu cara yang efisien untuk menyampaikan informasi. Kami mengusulkan menggunakan metode tradisional dan metode baru yaitu *Autoregressive Integrated Moving Average* (ARIMA), *Long-Short Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU). Penelitian ini bertujuan untuk membandingkan pemodelan *time series* pada peramalan web traffic dengan algoritma Arima, LSTM, dan GRU.

## Kata kunci:

*Web Traffic*, Arima, LSTM, GRU, *Time Series*.

© 2022 Dipublikasikan oleh Jurusan Matematika, Universitas Negeri Semarang

## 1. Pendahuluan

Dalam beberapa tahun terakhir peningkatan lalu lintas web tidak dapat dihindari karena semakin banyak orang yang mendapatkan kemudahan akses internet di seluruh dunia. Peningkatan lalu lintas situs web dapat menyebabkan banyak masalah jika perusahaan tidak mampu mengatasi perubahan secara efisien. Jika situs web mengalami kendala atau kerusakan server maka dapat menyebabkan ketidaknyamanan bagi pengguna dan sebagai akibatnya maka dapat menurunkan pengguna karena mereka memilih untuk menggunakan situs lain (Petluri & Al-Masri, 2019). Oleh karena itu diperlukan peramalan web traffic untuk mengatasi hal tersebut.

Sehingga peramalan web traffic meningkat secara signifikan dan mendorong kebutuhan untuk mengeksplorasi berbagai metode secara efektif untuk memperkirakan traffic sebuah situs web di masa depan. Dalam penelitian ini, kami menerapkan model peramalan untuk tujuan memprediksi lalu lintas web. Secara khusus, kami menggunakan kumpulan data Prakiraan Rangkaian Waktu Lalu Lintas Web yang ada oleh Google untuk memprediksi lalu lintas artikel Wikipedia di masa mendatang.

Lalu lintas web adalah jumlah data yang dikirim dan diterima oleh pengunjung suatu situs web yang ditentukan oleh jumlah pengunjung dan jumlah halaman yang mereka kunjungi. Memprediksi lalu lintas web dapat membantu pemilik situs web memperoleh informasi yang bermanfaat diantaranya untuk: (1) menentukan strategi yang efektif untuk penyeimbangan beban halaman web yang berada di cloud, (2) memperkirakan tren masa depan berdasarkan data historis, (3) memahami perilaku pengguna, (4) membantu menyusun konten situs web berdasarkan informasi lalu lintas situs web yang dikumpulkan (Petluri & Al-Masri, 2019). Telah banyak metode yang diusulkan untuk meramalkan lalu lintas web yang dapat diklasifikasikan menjadi 2 kelompok berdasarkan model yang dianalisis, yaitu prediksi nonlinier dan prediksi linier. Model yang paling banyak digunakan model peramalan linier adalah (1) Algoritma HoltWinters, (2) Model AR, (3) Model MA. Peramalan yang berfokus pada jaringan saraf berulang biasanya digunakan untuk prediksi nonlinier. Transformasi wavelet diskrit (DWT) membagi data menjadi komponen linier dan non-linier yang membantu meningkatkan akurasi peramalan (Madan, 2018).

## To cite this article:

Arissinta, I.O., Sulistiyawati, I.D., Kurniyanto, D., & Kharisudin, I. (2022). Pemodelan *Time Series* untuk Peramalan *Web Traffic* Menggunakan Algoritma Arima, LSTM, dan GRU. *PRISMA, Prosiding Seminar Nasional Matematika* 5, 693-700

Beberapa penelitian terdahulu terkait peramalan web traffic diantaranya penelitian Paun & Makwana (2019) yang mengusulkan penggunaan analisis pola wavelet dan jaringan saraf untuk memprediksi lalu lintas web. Namun penelitian tersebut cukup rumit dan memakan waktu terutama untuk analisis lalu lintas situs web secara real-time. Penelitian yang dilakukan oleh Shelatkar et al. (2020) memprediksi lalu lintas web dengan menggunakan Arima dan LSTM terbukti mampu meningkatkan kinerja dan efisiensi sistem. Usulan akan terus meningkat seiring dengan semakin banyaknya data pengguna yang dimasukkan.

### 1.1. Rumusan Masalah

Berdasarkan latar belakang penelitian peramalan lalu lintas web yang telah dijabarkan sebelumnya, maka rumusan masalah yang akan diteliti adalah bagaimana pemodelan peramalan web traffic dengan menggunakan algoritma Arima, LSTM, dan GRU serta bagaimana perbandingan model peramalan web traffic dengan menggunakan algoritma Arima, LSTM, dan GRU?

### 1.2. Tujuan Penelitian

Adapun tujuan penelitian ini adalah untuk membangun model time series untuk peramalan web traffic dengan menggunakan algoritma Arima, LSTM, dan GRU serta mengetahui perbandingan model peramalan web traffic dengan algoritma Arima, LSTM, dan GRU.

---

## 2. Metode

Metode yang akan digunakan pada penelitian kali ini berupa metode tradisional dan metode modern, dimana metode ARIMA sebagai metode tradisional serta LSTM dan GRU sebagai metode modern yang kemudian kedua jenis metode ini akan diperbandingkan hasilnya. Selain itu adapun package-package yang digunakan dalam melakukan proses analisis yaitu numpy, pandas, matplotlib, statsmodels arima, sklearn, keras LSTM, keras GRU.

### 2.1. Dataset

Pada penelitian ini kami mengambil dataset melalui *platform open source data* bernama Kaggle. Data tersebut berisi lalu lintas halaman web wikipedia dengan dataset pelatihan terdiri sekitar 145.000 time series dan masing-masing time series tersebut mewakili sejumlah tampilan harian dari artikel wikipedia yang berbeda, mulai dari 1 Juli 2015 hingga 31 Desember 2016. Selanjutnya kami melakukan *split* data menjadi data latih (*train*) dan data uji (*test*) yang kami pilih secara acak. Hal tersebut bertujuan untuk melihat seberapa besar keakuratan model time series untuk peramalan web traffic yang akan dibangun.

### 2.2 Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA (*Auto-Regressive Integrated Moving Average*) memiliki keuntungan besar dalam peramalan deret waktu univariat. Model ARIMA mencoba menggambarkan tren dan musiman dalam deret waktu sebagai fungsi dari nilai-nilai yang tertinggal (Parameter Auto Regressive) dan rata-rata berubah dalam interval waktu (*Moving Average*). Modelnya tersebut membedakan (Mengintegrasikan) data deret waktu asli. Membedakan deret waktu berarti membentuk waktu baru deret dengan mengurangi pengamatan sebelumnya dari waktu saat ini. Intinya adalah untuk menghilangkan tren tertentu, seperti musim, tren, atau varians yang tidak konsisten dalam data deret waktu (Mehrmolaei, n.d.) Persamaan ARIMA memiliki dua komponen hal penting yaitu bagian *Auto-Regressive (AR) part* dan *Moving Rata-rata (MA)*.

### 2.3 Long-Short Term Memory (LSTM)

Saat ini, kita sedang mengalami dunia data yang besar. Perusahaan telah mengumpulkan banyak data selama bertahun-tahun, yang menyimpan wawasan penting tentang bisnis mereka. Dalam hal ini model yang lebih canggih seperti *Neural Network* dibutuhkan (Chen et al., 2018) (Boone et al., 2019). Di bidang baru pertumbuhan minat ilmiah di *Neural Network* inilah *Recurrent Neural Network (RNN)* ikut berperan. Dengan jaringan saraf tipe baru ini khusus dalam masalah prediksi data *time series*, hasil yang belum pernah terlihat sebelumnya di bidang bahasa dan analisis deret waktu mulai tercapai (Madan, 2018). Namun, RNN memiliki masalah memori yang serius, yang diselesaikan dengan dimasukkannya

dalam dunia penelitian LSTM. Jenis RNN baru ini memiliki memori internal baru (keadaan sel) selain keadaan tersembunyi biasa dari RNN. Ini memudahkan pelatihan LSTM untuk menghindari masalah gradien menghilang atau meledak (Le & Zuidema, 2014).

Karena deret waktu memiliki komponen musiman, LSTM dapat digunakan dalam prediksi konteks. Misalnya, jika deret waktu bulanan tertentu memiliki musiman tahunan, prediksinya dari nilai untuk bulan depan langsung mendapat manfaat lebih dari nilai yang sama persis bulan dari tahun sebelumnya. Sulin dkk. melakukan pekerjaan yang luar biasa untuk tantangan Kaggle perkiraan lalu lintas web Wikipedia yang mencakup ide ini.

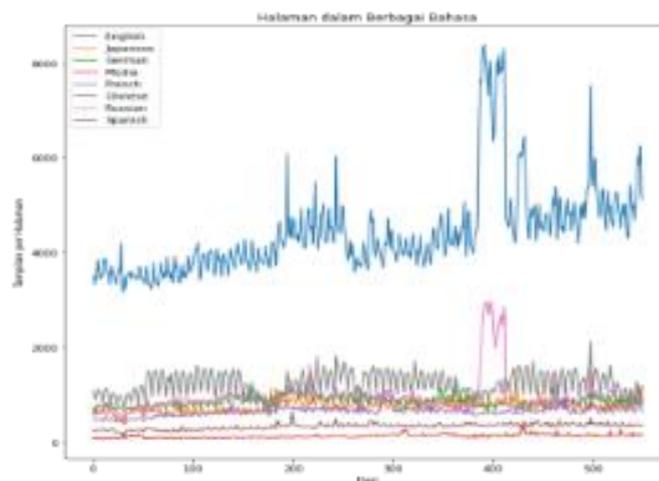
#### 2.4 Gated Recurrent Unit (GRU)

Salah satu ciri yang paling *popular* dari model GRU adalah memiliki jumlah gerbang yang lebih sedikit dibandingkan dengan LSTM dan telah ditemukan mengungguli LSTM ketika berhadapan dengan kumpulan data yang lebih kecil. Untuk mengatasi masalah gradien hilang dari RNN standar, GRU terdiri dari gerbang pembaruan dan reset, tetapi tidak seperti LSTM, ia tidak memiliki gerbang keluaran khusus. Gerbang pembaruan memutuskan berapa banyak memori sebelumnya yang akan disimpan, dan gerbang reset menentukan bagaimana menggabungkan memori sebelumnya dengan input baru. Karena gerbang yang lebih sedikit, mereka secara komputasi kurang menuntut dibandingkan dengan LSTM dan ideal ketika ada sumber daya komputasi yang terbatas (Cho et al, 2018).

### 3. Hasil dan Pembahasan

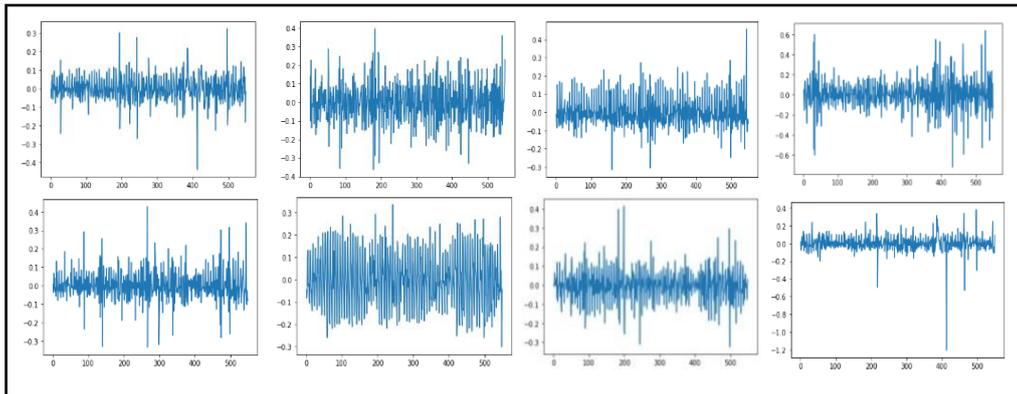
#### 3.1. Autoregresif Moving Avarage (ARIMA)

Model ARIMA mempunyai keuntungan untuk melakukan peramalan deret waktu univariat. Dimana dalam analisis ini menggunakan data dari bulan Juli 2015 sampai Desember 2016, dimana trend tersebut naik turun. Data tersebut sebelumnya perlu dilakukan proses stasioner data sebelum dilakukan pemodelan dan peramalan menggunakan ARIMA. Sebelum melakukan pemodelan menggunakan arima kita melakukan *scraping* data mana yang akan digunakan dengan mencari Bahasa di web Wikipedia. Kemudian data tersebut dilatih dengan mengambil beberapa Bahasa yaitu English (en), Japan (je), German (de), Media (na), French (fr), Chinese (zh), Russian (ru), Spanish (es). Setelah itu dilihat rata-rata jumlah penayangan untuk Bahasa yang telah diambil sebelumnya dengan menggunakan line plot. Hasil dari plot tersebut dapat dilihat sebagai berikut.



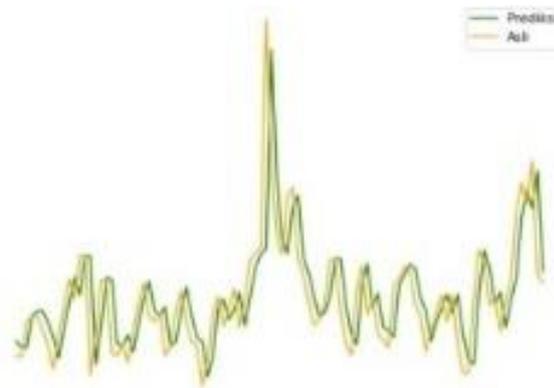
**Gambar 1.** Persebaran Total View dari beberapa Bahasa

Dari data diatas dapat dilihat trend dari masing-masing Bahasa, dalam melakukan peramalan perlu mengubah menjadi data stasioner untuk mengetahui model ARIMA mana yang akan digunakan. Hasil dari output stasioner dari masing-masing Bahasa dapat dilihat pada grafik dibawah ini.



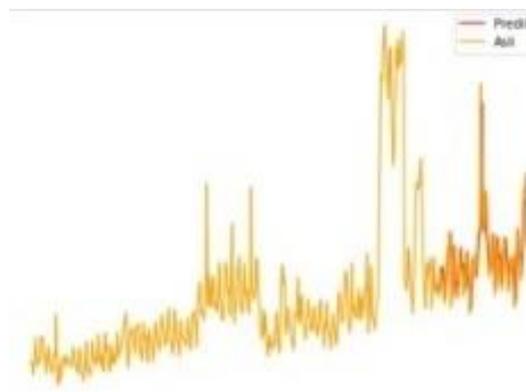
**Gambar 2.** Tampilan data stasioner dari masing-masing bahasa

Berikut ini hasil dari perbandingan hasil peramalan dengan data asli dapat dilihat pada gambar dibawah ini.



**Gambar 3.** Perbandingan data hasil forecasting dan data asli

Dari hasil gambar diatas dapat dilihat secara jelas peramalan menggunakan metode ARIMA seperti gambar dibawah ini



**Gambar 4.** Tampilan hasil forecast

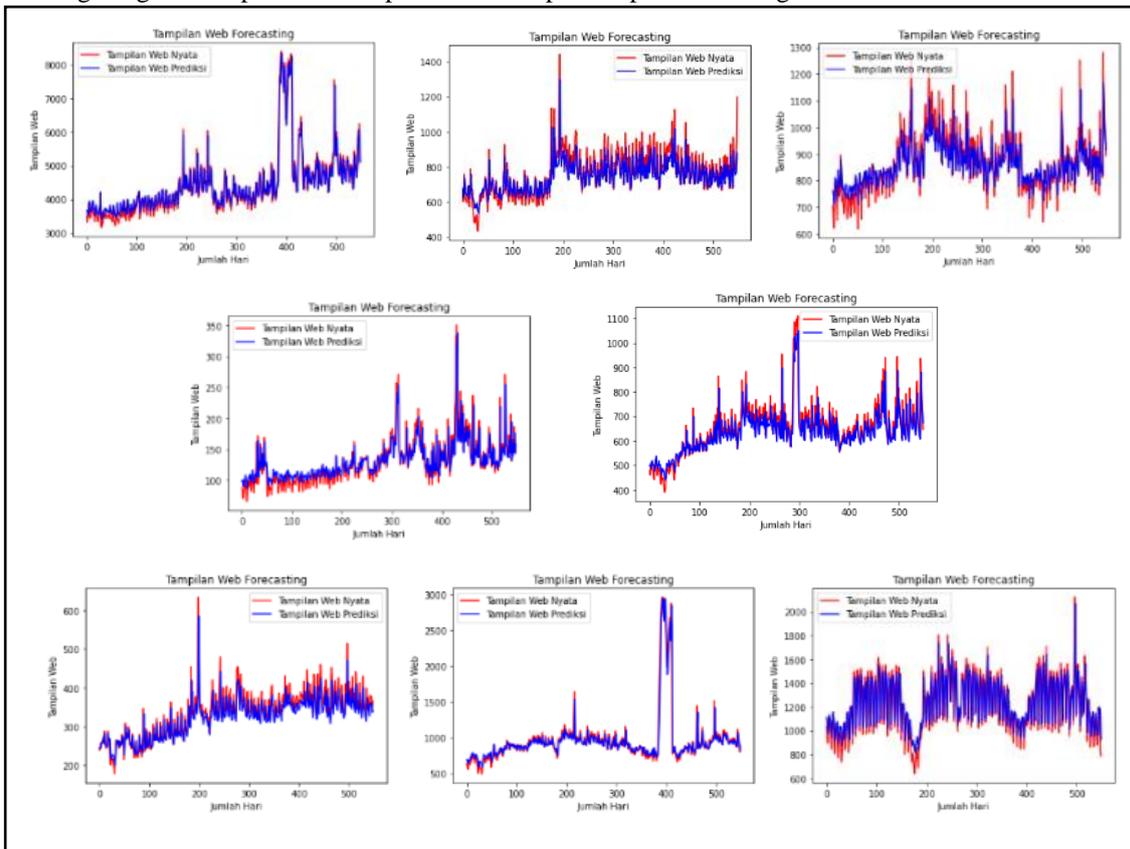
Dalam proses peramalan, kami menggunakan hasil dari rata-rata kesalahan dalam meramalkan kasus ini, sebagai berikut.

**Tabel 1.** Rata-rata kesalahan tiap bahasa

Language	Rata-rata Kesalahan
English	0.05420565
Japanese	0.07193860
German	0.06472334
Media	0.11594693
French	0.06991424
Chinese	0.06216769
Russian	0.06551725
Spanish	0.06551725

**3.2. Long-Short Term Memory (LSTM)**

Dataset dianalisis dan sampel data yang digunakan berisi lalu lintas halaman web wikipedia yang diperoleh dari Kaggle dengan dataset pelatihan terdiri sekitar 145.000 deret waktu dan masing-masing deret waktu tersebut mewakili sejumlah tampilan harian dari artikel wikipedia yang berbeda, mulai dari 1 Juli 2015 hingga 31 Desember 2016. Selanjutnya, dataset dibagi menjadi data training dan data testing dengan perbandingan 70% sebagai data training dan 30% sebagai data testing. Lalu selanjutnya membangun model sequential untuk peramalan time series dengan layer LSTM. Setelah dilakukan training dengan 100 epoch maka diperoleh model pada tiap bahasa sebagai berikut.



**Gambar 5.** Plot Tampilan Forecasting LSTM

Agar kita dapat membandingkan kinerja model yang telah dibangun dengan lebih jelas maka kami sajikan tabel perbandingan nilai *loss* MSE dan MAE dari tiap bahasa sebagai berikut.

**Tabel 2.** Perbandingan nilai *loss* MSE dan MAE

Language	Loss MSE	MAE
English	0.0046	0.0464
Japanese	0.0075	0.0646
German	0.0133	0.0852
Media	0.0070	0.0541
French	0.0068	0.0573
Chinese	0.0049	0.0498
Russian	0.0031	0.0268
Spanish	0.0096	0.0801

**3.3. Gated Recurrent Unit (GRU)**

Persamaan di bawah ini menjelaskan bagaimana sel-sel memori pada setiap lapisan tersembunyi (*hidden layer*) dari jaringan GRU diperbarui pada setiap langkah waktu. Persamaannya dituliskan sebagai berikut:

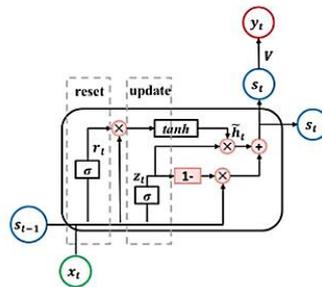
$$z_t = \sigma(W_z \cdot [S_{t-1}, x_t] + b_z)$$

$$r_t = \sigma(W_r \cdot [S_{t-1}, x_t] + b_r)$$

$$\tilde{S}_t = \tanh(W_s \cdot [r_t \cdot S_{t-1}, x_t] + b_s)$$

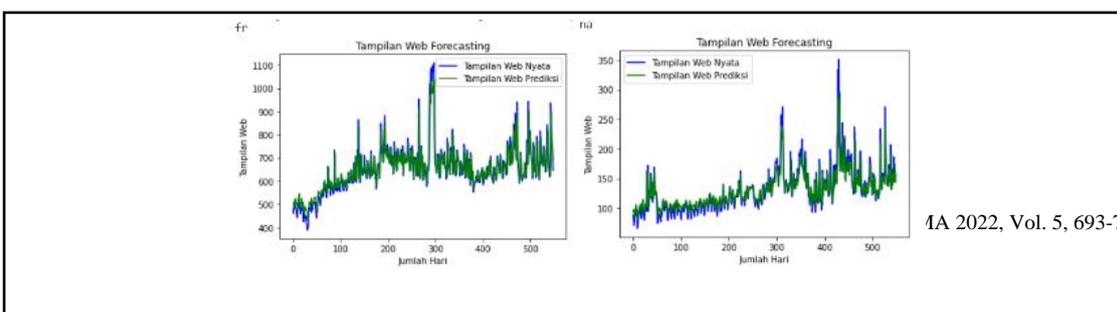
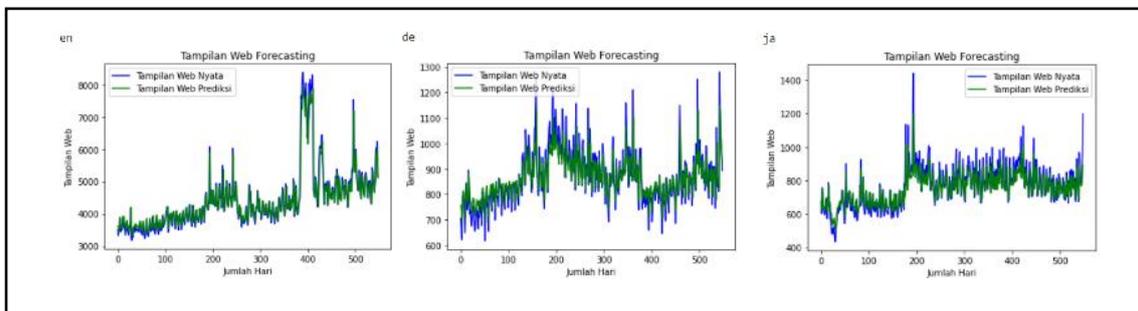
$$s_t = (1 - z_t) \cdot s_{t-1} + z_t \cdot \tilde{S}_t$$

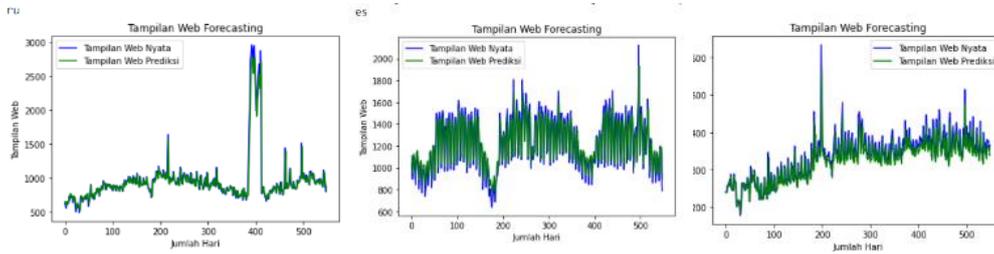
Dimana  $W_z$ ,  $W_r$ , dan  $W_s$  adalah matriks bobot serta  $b_z$ ,  $b_r$ , dan  $b_s$  adalah vektor bias.



**Gambar 6.** Diagram GRU RNN Unit

Dalam hal ini kami menetapkan jumlah periode pelatihan epochs dari sistem terdistribusi sebesar 100 untuk eksekusi dari simulasi sistem pelatihan terdistribusi model GRU kami. Hiperparameter lapisan diinisialisasi mengikuti distribusi normal (rata-rata = 0, standar deviasi = 0,1). Seperti yang ditunjukkan pada Gambar 3, hasil prediksi (garis hijau) dari tampilan halaman yang berbeda untuk setiap bahasa sangat cocok dengan waktu nyatanya (garis biru). Sungguh luar biasa bahwa model kami tidak dapat memprediksi puncak terbesar yang terjadi dalam data time series ini karena mereka mengasumsikan perilaku anomali time series. Ini adalah karena fakta bahwa pelanggan Wikipedia tidak dapat diprediksi.





**Gambar 7.** Tampilan web forecasting dengan GRU

Untuk menyimpulkan bagian hasil menggunakan model GRU, akan dibuat tabel perbandingan yang berisi fungsi loss MSE dan MAE untuk memperjelas hasil uji keakuratan model. Nilai grafis ditunjukkan pada Tabel 2 untuk peramalan GRU sebesar 100 epochs. Secara intuitif, orang dapat berpikir bahwa MAE dan loss MSE itu baik dikarenakan menurun pada tingkat yang baik dan akhirnya stabil pada tingkat nilai yang relatif rendah. Namun, hal tersebut tidak sepenuhnya benar, karena dalam beberapa kasus terjadi peningkatan indikator jauh dengan 200, 500 bahkan 1000 epochs. Meskipun model menghasilkan model yang dikatakan sangat memuaskan hanya dengan 100 epochs, mungkin lebih akurat jika dilakukan percobaan dengan menggunakan 500 epochs atau lebih..

**Tabel 3.** Perbandingan Hasil Uji Model GRU

Language	Loss MSE	MAE
English	0.0046	0.0464
Japanese	0.0075	0.0646
German	0.0133	0.0852
Media	0.0070	0.0541
French	0.0068	0.0573
Chinese	0.0049	0.0498
Russian	0.0030	0.0268
Spanish	0.0096	0.0801

#### 4. Simpulan

Berdasarkan hasil analisis peramalan yang dilakukan dengan menggunakan ketiga metode yaitu ARIMA, LSTM, dan GRU diperoleh hasil peramalan yang paling baik akurasi menggunakan LSTM dan GRU, sedangkan pada peramalan menggunakan metode ARIMA masih diperoleh nilai error yang cukup besar daripada hasil peramalan yang menggunakan LSTM dan GRU. Peramalan Web Traffic menggunakan metode LSTM dan GRU sebenarnya menghasilkan nilai loss MSE yang tidak jauh berbeda. Maka dari itu kedua metode tersebut cocok digunakan untuk peramalan Web Traffic. Sehingga diharapkan hasil dari peramalan Web Traffic yang menghasilkan nilai error paling kecil dapat diimplementasikan oleh perusahaan untuk menentukan keputusan dalam bisnisnya.

---

**Daftar Pustaka**

---

- Boone, T., Ganeshan, R., Jain, A., & Sanders, N. R. (2019). Forecasting sales in the supply chain: Consumer analytics in the big data era. *International Journal of Forecasting*, 35(1), 170–180. <https://doi.org/10.1016/j.ijforecast.2018.09.003>
- Casado-Vara, R., del Rey, A. M., Pérez-Palau, D., De-La-fuente-valentín, L., & Corchado, J. M. (2021). Article web traffic time series forecasting using LSTM neural networks with distributed asynchronous training. *Mathematics*, 9(4), 1–22. <https://doi.org/10.3390/math9040421>
- Chen, W. C., Chen, W. H., & Yang, S. Y. (2018). A big data and time series analysis technology-based multi-agent system for smart tourism. *Applied Sciences (Switzerland)*, 8(6). <https://doi.org/10.3390/app8060947>
- Le, P., & Zuidema, W. (2014). Quantifying the vanishing gradient and long distance dependency problem in recursive neural networks and recursive LSTMs. 2010.
- Madan, R. (2018). Predicting Computer Network Traffic : A Time Series Forecasting Approach using DWT , ARIMA and RNN. 1, 2–4.
- Mehrmolaei, S. (n.d.). Time series forecasting using improved ARIMA. 92–97.
- Paun, K. P., & Makwana, C. H. (2019). A Survey on Web Traffic Forecasting on Time Series Data. VI(3588), 3588–3594.
- Petluri, N., & Al-Masri, E. (2019). Web Traffic Prediction of Wikipedia Pages. Proceedings - 2018 IEEE International Conference on Big Data, Big Data 2018, 5427–5429. <https://doi.org/10.1109/BigData.2018.8622207>
- Shelatkar, T., Tondale, S., Yadav, S., & Ahir, S. (2020). Web Traffic Time Series Forecasting using ARIMA and LSTM RNN. ITM Web of Conferences, 32, 03017. <https://doi.org/10.1051/itmconf/20203203017>
- Shen, G., Tan, Q., Zhang, H., Zeng, P., & Xu, J. (2018). ScienceDirect ScienceDirect Deep Learning with Gated Recurrent Unit Networks for Financial Deep Learning with Gated Recurrent Unit Networks for Financial Sequence Predictions Sequence Predictions. *Procedia Computer Science*, 131, 895–903. <https://doi.org/10.1016/j.procs.2018.04.298>
- Zhao, H., Chen, Z., Jiang, H., Jing, W., & Sun, L. (2019). *Evaluation of Three Deep Learning Models for Early Crop Classification Using Sentinel-1A Imagery Time Series — A Case Study in Zhanjiang , China. November*. <https://doi.org/10.3390/rs11222673>