



## Prediksi Belanja Pemerintah Indonesia Menggunakan *Long Short-Term Memory (LSTM)*

Sabar Sautomo<sup>1</sup>, Hilman Ferdinandus Pardede<sup>1,2</sup>

<sup>1</sup>Program Studi Ilmu Komputer, STMIK Nusa Mandiri Jakarta

<sup>2</sup>Pusat Penelitian Informatika, Lembaga Ilmu Pengetahuan Indonesia

<sup>1</sup>14002304@nusamandiri.ac.id, <sup>2</sup>hilman@nusamandiri.ac.id

### Abstract

*Estimates of government expenditure for the next period are very important in the government, for instance for the Ministry of Finance of the Republic of Indonesia, because this can be taken into consideration in making policies regarding how much money the government should bear and whether there is sufficient availability of funds to finance it. As is the case in the health, education and social fields, modeling technology in machine learning is expected to be applied in the financial sector in government, namely in making modeling for spending predictions. In this study, it is proposed the application of Long Short-Term Memory (LSTM) Model for expenditure predictions. Experiments show that LSTM model using three hidden layers and the appropriate hyperparameters can produce Mean Square Error (MSE) performance of 0.2325, Root Mean Square Error (RMSE) of 0.4820, Mean Average Error (MAE) of 0.3292 and Mean Average Percentage Error (MAPE) of 0.4214. This is better than conventional modeling using the Auto Regressive Integrated Moving Average (ARIMA) as a comparison model.*

*Keywords: Government Expenditure, Machine Learning, LSTM, ARIMA*

### Abstrak

Perkiraan pengeluaran belanja pemerintah untuk periode kedepan merupakan hal yang sangat penting di pemerintah dalam hal ini pada Kementerian Keuangan Republik Indonesia, karena hal ini dapat dijadikan bahan pertimbangan dalam mengambil kebijakan terkait berapa nilai uang yang harus ditanggung pemerintah serta apakah ada ketersediaan dana yang cukup dalam membiayai belanja tersebut untuk periode yang akan datang. Seperti halnya pada bidang kesehatan, pendidikan dan sosial, teknologi pemodelan pada *Machine Learning* diharapkan dapat diterapkan di bidang keuangan pada pemerintahan, yaitu dalam membuat pemodelan untuk prediksi belanja. Pada penelitian ini, diusulkan penerapan model *Long Short-Term Memory (LSTM)* untuk prediksi belanja. Eksperimen menunjukkan model LSTM dengan menggunakan tiga *hidden layers* dan *hyperparameter* yang tepat dapat menghasilkan performa *Mean Square Error (MSE)* sebesar 0.2325, *Root Mean Square Error (RMSE)* sebesar 0.4820, *Mean Average Error (MAE)* sebesar 0.3292 dan *Mean Average Percentage Error (MAPE)* sebesar 0.4214. Ini lebih baik dibandingkan pemodelan konvensional menggunakan *Auto Regressive Integrated Moving Average (ARIMA)* sebagai model pembandingan.

Kata kunci: Belanja Pemerintah, *Machine Learning*, LSTM, ARIMA.

### 1. Pendahuluan

Adanya perkembangan teknologi Machine Learning dewasa ini telah banyak diterapkan diberbagai bidang, baik bidang kesehatan, pendidikan maupun keuangan. Teknologi tersebut merupakan *tools* yang patut di aplikasikan dalam melakukan analisis pengelolaan keuangan negara di pemerintahan pada Kementerian Keuangan Republik Indonesia, terutama dalam melakukan suatu prediksi belanja pemerintah.

Kemampuan pemerintah Indonesia dalam membiayai setiap belanja negara merupakan hal penting dalam

proses pelaksanaan anggaran negara, hal ini tidak lepas dalam memprediksi belanja atau uang tunai masa depan yang dibutuhkan untuk memenuhi tanggung jawab pemerintah dalam penyediaan layanan publik, serta Pada negara berkembang, khususnya Indonesia bahwa kebijakan pemerintah sangat berpengaruh terhadap besarnya tingkat pengeluaran belanjanya, sehingga *variable* kebijakan pemerintah merupakan salah satu faktor penyebab kenaikan proyeksi belanja [1].

Data *history* harian yang berbasis *time-series* dari belanja pemerintah selama beberapa periode

sebelumnya dapat dijadikan bahan dalam penelitian dalam mendapatkan prediksi kebutuhan belanja selama periode kedepan, dimana Metode prediksi *cash* terakurat pada belanja seluruhnya diperoleh dengan menggunakan data tiga tahun terakhir [2].

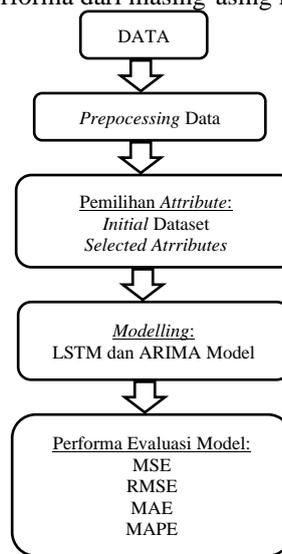
Studi menunjukkan bahwa ada banyak parameter yang dapat mempengaruhi belanja negara pada negara-negara Eropa Timur [3]. Penelitian ini menggunakan feed forward networks untuk prediksinya. Namun, Setiap negara memiliki parameter spesifik yang mungkin berbeda antara satu dengan yang lain, sehingga perlu adanya variable tambahan yang dijadikan data pendukung [3]. Ditambah lagi, feed forward network tidak memperhatikan relasi temporal yang merupakan karakteristik dasar data belanja keuangan negara.

Pada penelitian ini, diusulkan untuk penerapan *Long Short Term Memory (LSTM)* untuk prediksi belanja pemerintah pada data *history* belanja dari Kementerian Keuangan RI untuk 3 tahun terakhir. LSTM mempertimbangkan relasi temporal dan studi terdahulu menunjukkan rata-rata error prediksi menurun cukup signifikan dibanding model lain [4]. Penelitian data time-series untuk prediksi dalam bidang perekonomian dan keuangan yang membandingkan dua pemodelan LSTM dan ARIMA, dimana LSTM model dapat memberikan performa lebih baik dengan nilai penurunan error prediksi 84% sampai dengan 87% dibandingkan dengan ARIMA model [4]. Pada penelitian lain, prediksi konsumsi listrik dengan *deep learning CNN-LSTM* menghasilkan tingkat akurasi yang stabil dengan pilihan hyperparameter yang terbaik [5]. Pemodelan untuk prediksi arus lalu lintas kendaraan dengan menggunakan *Long Short Term Memory (LSTM)* dan *Gated Recurrent Units (GRU) neural network (NN) methods* dapat menghasilkan performa lebih baik dibandingkan pemodelan menggunakan *Auto Regressive Integrated Moving Average (ARIMA)* [6]. Pemodelan dengan menggunakan *single* dan *multi layer* pada *Long Short Term Memory (LSTM)* dapat menghasilkan performa akurasi lebih baik dan tingkat *error* kecil [7].

Kontribusi penelitian ini adalah penerapan LSTM untuk prediksi belanja keuangan dengan data dari Kementerian Keuangan Republik Indonesia yang belum pernah dilakukan. Penelitian ini tujuannya untuk melakukan analisis dalam membuat suatu pemodelan yang dapat digunakan dalam melakukan *prediksi* belanja pemerintah Indonesia untuk periode yang akan datang, dimana proses pemodelan tersebut dilakukan optimalisasi dengan pemilihan *hyperparameter* dan jumlah *hidden layer* yang sesuai dalam rangka untuk mendapatkan hasil performa prediksi yang lebih baik. Sebagai model pembanding, digunakan *Auto Regressive Integrated Moving Average (ARIMA)*.

## 2. Metode Penelitian

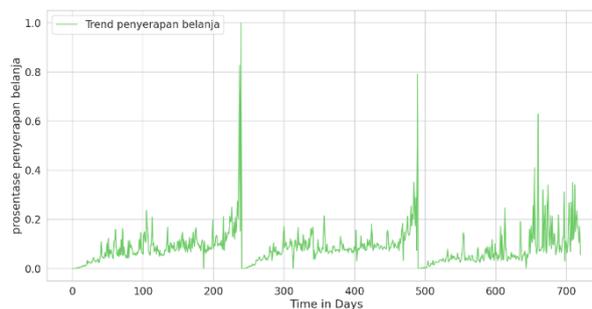
Rancangan atau desain metodologi yang digunakan pada Penelitian ini seperti terlihat pada Gambar 1. Data yang bersumber dari Kementerian Keuangan RI sebagai dataset, kemudian dilakukan *preprocessing* data dengan dilakukan *cleaning* dan *reduction* data sehingga dataset siap digunakan. Proses selanjutnya dengan pemilihan *attributes* data sebelum dilakukan proses pemodelan. Proses pemodelan dilakukan dengan dua *models* yaitu LSTM dan ARIMA. Setelah proses pemodelan dilakukan, selanjutnya proses evaluasi model untuk mengetahui performa dari masing-masing model tersebut.



Gambar 1 Rancangan Metodologi Penelitian

### 2.1. Data

Pada penelitian ini menggunakan data yang bersumber pada Kementerian Keuangan Republik Indonesia yaitu data *history* harian belanja pemerintah dengan basis data *time-series*, selama kurun waktu dari tahun 2018 hingga menjelang akhir tahun 2020 atau selama kurun waktu 721 hari.



Gambar 2. Grafik tingkat penyerapan belanja Pemerintah Indonesia berdasarkan *history* harian dari tahun 2018 hingga menjelang akhir tahun 2020

Pada Gambar 2 menunjukkan grafik *history* harian pada tingkat penyerapan belanja pemerintah yang selalu menunjukkan tren kenaikan pada setiap menjelang akhir tahun, baik itu di tahun 2018, tahun 2019 dan tahun 2020.

## 2.2. Data Preprocessing

Pada tahap ini kondisi data awal telah dikumpulkan, proses analisis setiap variable dilakukan pada data tersebut sehingga siap untuk digunakan dalam proses pemodelan.

Analisis data dilakukan karena untuk mengurangi kompleksitas data yang tidak penting, mendeteksi atau menghapus elemen yang tidak relevan dan menghindari adanya *noise* dari data [8]. Pada penelitian ini analisis tersebut dengan dilakukan proses *cleaning* dan *reduction* terhadap data.

### 2.2.1. Data Cleaning

Data dapat memiliki banyak bagian yang tidak relevan dan hilang, untuk menangani bagian ini dilakukan pembersihan data, pembersihan data dilakukan terkait dengan *missing data*, *noisy data* dan *data transformation*.

Untuk bagian data yang hilang (*missing data*) dilakukan *cleaning* guna menghindari anomali data. Pada penelitian ini, dilakukan cek terkait adanya nilai data yang *missing*, hal ini untuk menghindari adanya anomali data pada tahapan berikutnya. Dari jumlah *records* dataset yang di kelompokkan berdasarkan data harian berdasarkan tanggal berjumlah 721 *row data*, untuk *variable* dengan nilai yang *null*, yaitu jika hari libur *variable* realisasi belanja pada dataset bernilai null, pada tahapan ini nilai null tersebut akan di dirubah dengan angka 0.

*Noisy data* merupakan data tidak berarti yang tidak dapat diinterpretasikan oleh mesin, dan dapat dihasilkan karena kesalahan pengumpulan data, kesalahan entri data, dan lain-lain. *Noisy data* mengindikasikan adanya suatu intervensi ataupun outlier. Pada dataset *variable* realisasi belanja terdapat nilai negatif, seharusnya positif sehingga menyebabkan anomali data, pada proses ini data yang bernilai negatif tersebut akan di *drop*. Berdasarkan *plot density* pada Gambar 4 dan *trend* dataset pada Gambar 2 dapat disimpulkan bahwa sudah tidak ada data yang bersifat *noisy*.

*Data Transformation* diambil untuk mengubah data dalam bentuk yang sesuai untuk proses penambangan, hal ini dilakukan untuk menskalakan nilai data dalam rentang tertentu (-1.0 hingga 1.0 atau 0.0 hingga 1.0). Pada tahap ini dengan melakukan *normalization* dan *standardization* data. Proses *Transformation* dataset pada penelitian ini dengan menggunakan *library* python *scikit-learn MinMaxScaler* untuk *attribute* dengan tipe *Integer*, sedangkan yang bertipe *String* menggunakan *One-hot encoding*. Proses *transformation*-nya menggunakan *Library* pada python yaitu *MinmaxScaler* dan *Library One-hot encoder*.

### 2.2.2. Data Reduction

Karena data mining digunakan untuk menangani data dalam jumlah besar. Saat bekerja dengan volume data

yang besar, analisis menjadi lebih sulit dalam kasus seperti itu. Untuk menghilangkan ini, menggunakan teknik reduksi data. Ini bertujuan untuk meningkatkan efisiensi penyimpanan dan mengurangi biaya penyimpanan dan analisis data.

Tahapan pada teknik *data reduction* dilakukan dengan *Attribute subset selection*, yaitu atribut yang relevan harus digunakan, sisanya dapat dibuang. Untuk melakukan pemilihan atribut, dapat menggunakan tingkat signifikansi dari atribut tersebut.

### 2.3. Pemilihan Attribute (Variable)

Untuk mendapatkan *performance* pemodelan yang baik dari suatu prediksi yang digunakan pada penelitian dapat dilakukan dengan meningkatkan suatu proses pemilihan *variable* pada suatu dataset [9].

Tahapan pada proses pemilihan *Attribute (Variable)* pada penelitian ini terbagi menjadi dua, yaitu:

#### 2.3.1. Initial Dataset

Merupakan dataset awal pada penelitian ini yang menjelaskan semua *attribute* atau *variable* dari dataset.

Pada Tabel 1 merupakan semua *attribute* dari dataset yang terdiri dari sembilan *attribute*.

No	Variables	Keterangan
1	Tanggal	Tanggal realisasi belanja
2	Tahun	Tahun anggaran realisasi belanja
3	Bulan	Bulan realisasi belanja
4	Tgl	Tanggal realisasi belanja
5	Weeks	Minggu ke realisasi belanja
6	Jenbel	Jenis belanja pemerintah, dikelompokkan menjadi 4 belanja, yaitu belanja pegawai (B51), Belanja Barang (B52), Belanja Modal (B53) dan Belanja Bantuan Sosial (B57)
7	Policy_1	Kebijakan yang dikeluarkan secara internal oleh Kementerian Keuangan (1=adanya kebijakan internal yang dikeluarkan, 0= tidak ada kebijakan internal yang dikeluarkan)
8	Policy_2	Kebijakan yang dikeluarkan oleh pihak eksternal diluar Kementerian Keuangan (1=adanya kebijakan eksternal yang dikeluarkan, 0= tidak ada kebijakan eksternal yang dikeluarkan)
9	preal	nilai dari tingkat penyerapan dari realisasi belanja pemerintah

#### 2.3.2. Selected Attribute (Variable)

Pemilihan *attribute* pada dataset dapat di dilakukan dengan tiga metode, yaitu *Filter methods*, *Wrapper methods* dan *embedded methods* [10].

Metode yang akan digunakan pada penelitian ini yaitu Pada *Filter methods*, salah satu metode tersebut adalah *Correlation Coefficient*, metode kriteria pemeringkatan dari hubungan antar attribute terhadap target pada dataset.

### 2.4. Proses Pemodelan (Modelling)

Tahapan selanjutnya yaitu proses pemodelan dari dataset. Adapaun pada penelitian ini akan dilakukan eksperimen dengan dua pemodelan, yaitu *Long Short-Term Momory (LSTM)* dan *Auto Regressive Integrated Moving Average (ARIMA)*.

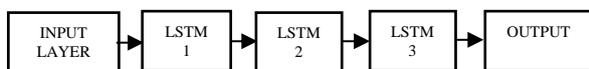
Kedua proses pemodelan pada penelitian ini menggunakan *Library Python* versi tiga dengan Google Colab sebagai *tools* nya.

#### 2.4.1. Long Short-Term Momory (LSTM)

Proses pemodelan ini menggunakan library Python Deep Learning Keras yaitu LSTM, yang merupakan bagian dari arsitektur *Recurrent Neural Networks (RNN)*.

Untuk menghasilkan pemodelan yang baik ada beberapa hal yang diperhatikan pada proses pemodelan LSTM, antara lain dengan penentuan jumlah *hidden layer* yang tepat dan penentuan input *hyperparameter* yang sesuai [11].

Secara umum, belum ada pedoman tentang cara menentukan jumlah lapisan atau jumlah *Hidden Layer* dalam LSTM. Jumlah lapisan yang diperlukan dalam LSTM tergantung pada kompleksitas dari dataset, jumlah fitur, jumlah titik data dan lain-lain dalam rangka untuk mendapatkan performa yang baik, pada gambar 3 merupakan contoh dari ilustrasi LSTM dengan tiga *hidden layer*.



Gambar 3 Ilustrasi Arsitektur LSTM dengan tiga *Hidden Layer* 2.4.2. *Auto Regressive Integrated Moving Average (ARIMA) Model*

Pada proses pemodelan ARIMA di penelitian ini, menggunakan *library python* ARIMA.

Proses pemodelannya dengan prakiraan model ARIMA (5, 1, 0) artinya bahwa nilai *lag* nya diatur ke 5 untuk autoregresi. Dan menggunakan urutan perbedaan 1 untuk membuat deret waktu tidak bergerak, serta tidak mempertimbangkan jendela rata-rata bergerak yaitu dengan ukuran nol.

#### 2.5. Model Evaluation

Pemodelan yang berhasil dibuat pada tahapan sebelumnya, kemudian akan dilakukan evaluasi guna mengukur performa sejauhmana tingkat efektivitas prediksi yang dihasilkan.

Pada penelitian ini evaluasi pemodelan yang digunakan dapat berupa:

##### 2.5.1. Mean Square Error (MSE)

MSE untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau sisa dikuadratkan. Kemudian dijumlahkan dan ditambahkan dengan jumlah observasi.

Pendekatan ini mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan. Metode itu menghasilkan kesalahan-kesalahan sedang yang kemungkinan lebih baik untuk kesalahan kecil, tetapi kadang menghasilkan perbedaan yang besar [12].

$$MSE = \frac{1}{n} \sum (y - \hat{y})^2 \quad (1)$$

$\hat{y}$  = nilai hasil forecast,  $y$  = nilai observasi ke -  $i$  dan  $n$  = banyaknya data

##### 2.5.2. Root Mean Square Error (RMSE)

RMSE digunakan sebagai pembeda antara suatu nilai yang akan diprediksi dengan nilai yang sebenarnya. Semakin tinggi sebuah nilai RMSE yang dihasilkan, tingkat keakuratan semakin rendah, dan semakin rendah nilai RMSE yang dihasilkan maka tingkat keakuratan semakin tinggi.

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

$\hat{y}_i$  = nilai hasil forecast,  $y_i$  = nilai observasi ke -  $i$  dan  $n$  = banyaknya data

##### 2.5.3. Mean Absolute Error (MAE)

Evaluasi MAE ini merupakan nilai rata-rata kesalahan (error) absolute antara hasil dari peramalan dengan nilai data sebenarnya

$$MAE = \frac{1}{n} \sum |f_i - y_i| \quad (3)$$

$f_i$  = nilai hasil forecast,  $y_i$  = nilai observasi ke -  $i$  dan  $n$  = banyaknya data

##### 2.5.4. Mean Everage Presentage Error (MAPE)

Evaluasi MAPE dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, merata-rata kesalahan persentase absolut tersebut. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan itu penting dalam mengevaluasi ketepatan ramalan.

MAPE mengindikasi seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai nyata [12].

$$MAPE = \frac{100\%}{n} \sum \left| \frac{y - \hat{y}}{y} \right| \quad (4)$$

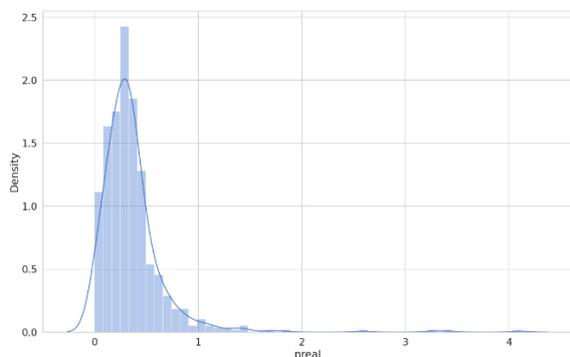
$\hat{y}$  = nilai hasil forecast,  $y$  = nilai observasi ke -  $i$  dan  $n$  = banyaknya data

### 3. Hasil dan Pembahasan

#### 3.1. Data

Berdasarkan semua *attribute* atau *variable* dari dataset seperti pada Tabel 1 di atas dapat digambarkan dalam

suatu histogram dan *density plot* untuk memvisualisasikan variabel numerik distribusi datasetnya. Adapun sebaran *density* pada dataset di atas dapat di lihat pada gambar 4 menunjukkan bahwa untuk sebaran nilai tertinggi dikisaran 0 dan 1.



Gambar 4. Grafik *Density dependent variable* dataset

### 3.2. Pemodelan *Long Short-Term Momory (LSTM)*

Selanjutnya pada tahap ini akan dilakukan proses pemodelan yaitu menggunakan library *Deep Learning Keras* pada python yaitu *Long Short-Term Momory (LSTM)*. Pada penelitian ini proses pemodelan pada dataset tersebut dilakukan dengan pemilihan *variable* pada dataset, yaitu semua *variable (Initial dataset)* dan *variable* terpilih (*selected attribute*).

Setelah dilakukan *preprocessing* data untuk selanjutnya pada penelitian ini untuk mendapatkan pemodelan dengan performa yang baik akan dilakukan regularisasi dengan inputan *hyperparameter* yang telah disesuaikan, seperti pada tabel 2.

Tabel 2 *Hyperparameter* pemodelan

No	Jenis	Nilai/Uraian
1	Units	150
2	Dropout	0,221
3	Activation	Relu
4	Optimizer	Adam
5	Epochs	150
6	Batch	50
7	Validation Split	0.4651

Proses pemodelan terhadap dataset dilakukan dengan melakukan split dataset menjadi dua bagian, yaitu 80% untuk data *training* dan 20 % untuk data *testing*. Data *training* dilatih dengan proses pemodelan LSTM, kemudian hasil pemodelan tersebut diterapkan untuk prediksi data *testing* dalam rangka evaluasi dari performa model.

Pada penelitian ini proses pemodelan LSTM dilakukan sampai dengan empat *hidden layer* dalam rangka untuk mendapatkan hasil pemodelan yang lebih baik.

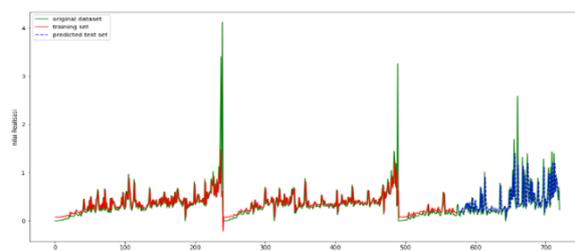
#### 3.2.1. *Initial Dataset*

Proses pemodelan LSTM yang pertama dengan *Initial Dataset*, di lakukan terhadap semua *variable* dataset.

Untuk optimalisasi hasil maka proses regularisasi dengan memasukkan *hyperparamter* sesuai pada tabel 2.

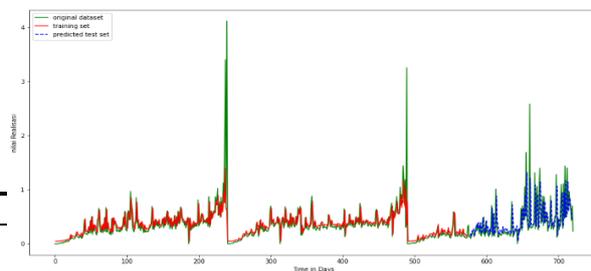
Evaluasi model terhadap prediksi dataset disetiap *hidden layer* dapat digambarkan dalam grafik seperti pada gambar 6-9 dengan penjelasan bahwa garis warna hijau pada grafik merupakan keseluruhan dataset, yang warna merah adalah garis prediksi data *training* dan warna biru adalah garis prediksi data *testing*, untuk sumbu vertikal adalah nilai prediksi realisasi belanja sedangkan garis horisontal menjelaskan jumlah *record* dataset.

Proses pemodelan terhadap satu *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4259, 0.2343, 0.4850 dan 0.3326.



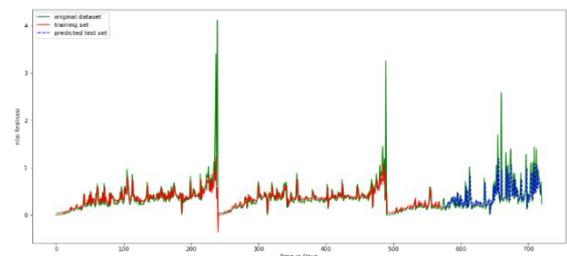
Gambar 6 Grafik hasil prediksi data *testing* pada pemodelan LSTM Initial dataset dengan satu *hidden layer*

Proses pemodelan terhadap dua *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4235, 0.2342, 0.4840 dan 0.3320.



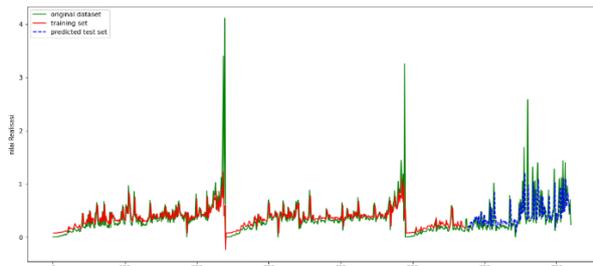
Gambar 7 Grafik hasil prediksi data *testing* pada pemodelan LSTM Initial dataset dengan dua *hidden layer*

Proses pemodelan terhadap tiga *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4232, 0.2335, 0.4830 dan 0.3310.



Gambar 8 Grafik hasil prediksi data *testing* pada pemodelan LSTM Initial dataset dengan tiga *hidden layer*

Proses pemodelan terhadap empat *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4255, 0.2340, 0.4847 dan 0.3323.



Gambar 9 Grafik hasil prediksi data *testing* pada pemodelan LSTM Initial dataset dengan empat *hidden layer*

3.2.2. Selected Attribute (Variable)

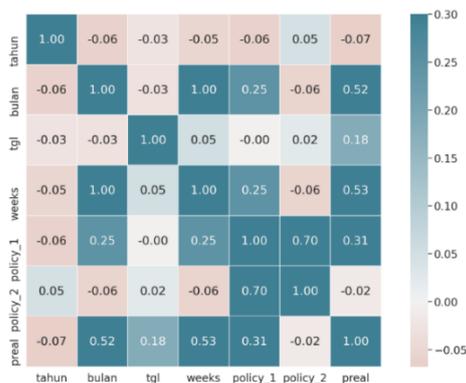
Proses pemodelan LSTM yang kedua dengan *Selected Attribute*, proses ini akan dilakukan dengan metode *filter* setiap *variable*, untuk menganalisis *variable* mana saja yang mempunyai pengaruh yang lebih baik terhadap target prediksinya metode ini dengan menggunakan *correlation coefficient*.

Berdasarkan *correlation coefficient* terhadap *variable* pada datasetnya dapat dihasilkan masing-masing nilainya seperti pada tabel 3.

Tabel.3 Nilai *correlation coefficient* setiap *variable* dataset

No	Variable	Nilai	Tanda
1	Tahun	0.067968	Negatif
2	Bulan	0.515588	Positif
3	Tgl	0.184405	Positif
4	Weeks	0.529580	Positif
5	Policy_1	0.309188	Positif
6	Policy_2	0.015148	Negatif

Pada nilai *correlation coefficient* masing-masing *variable* di atas dapat di gambarkan dalam matriks seperti pada gambar 10.



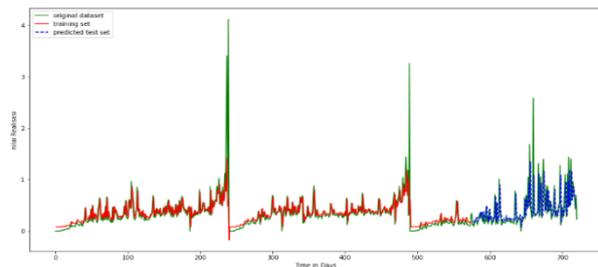
Gambar 10 Matriks *correlation coefficient* *variable* dataset

Dari nilai *correlation coefficient* pada tabel 3 didapatkan bahwa *variable* tahun dan *policy\_2* mendapatkan nilai negatif, hal ini bahwa *variable* tersebut mempunyai pengaruh terhadap target prediksi hampir tidak ada. Sedangkan pada *variable* weeks, bulan, *policy\_1* dan tgl berturut-turut mempunyai pengaruh besar dalam penentuan nilai target prediksi. Sehingga pada proses pemodelan selanjutnya akan dilakukan *filtering* atau

pemilihan *variable* dengan pengaruh yang lebih baik dan untuk *variables* yang bernilai negatif akan di kesampingkan.

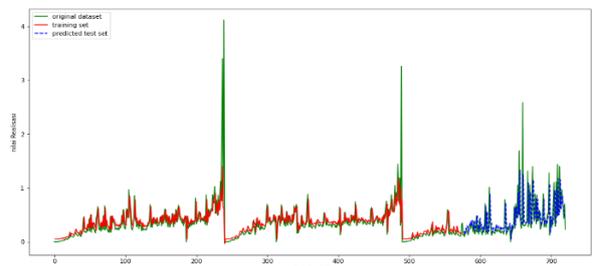
Pada gambar 11-14 merupakan hasil evaluasi model untuk prediksi dataset disetiap *hidden layer*, dengan penjelasan bahwa garis warna hijau grafik merupakan keseluruhan dataset, yang warna merah adalah garis prediksi data *training* dan warna biru adalah garis prediksi data *testing*, untuk sumbu vertikal adalah nilai prediksi realisasi belanja sedangkan garis horisontal menjelaskan jumlah *record* dataset.

Proses pemodelan terhadap satu *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4259, 0.2340, 0.4850 dan 0.3326.



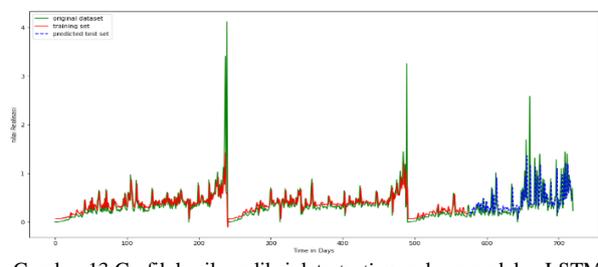
Gambar 11 Grafik hasil prediksi data *testing* pada pemodelan LSTM Selected Attribute dataset dengan satu *hidden layer*

Proses pemodelan terhadap dua *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4224, 0.2333, 0.4830 dan 0.3309.



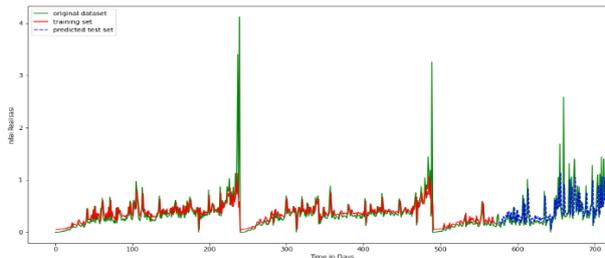
Gambar 12 Grafik hasil prediksi data *testing* pada pemodelan LSTM Selected Attribute dataset dengan dua *hidden layer*

Proses pemodelan terhadap tiga *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4214, 0.2335, 0.4820 dan 0.3292.



Gambar 13 Grafik hasil prediksi data *testing* pada pemodelan LSTM Selected Attribute dataset dengan tiga *hidden layer*

Proses pemodelan terhadap empat *hidden layer* menghasilkan nilai MAPE, MSE, RMSE dan MAE sebesar 0.4255, 0.2338, 0.4844 dan 0.3323.

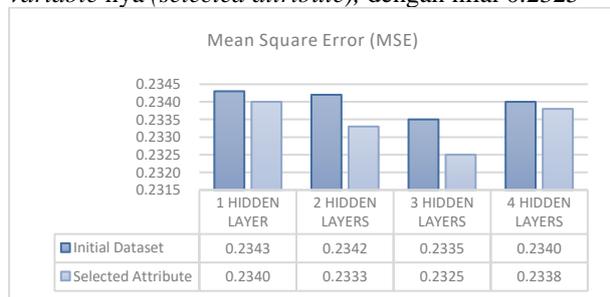


Gambar 14 Grafik hasil prediksi data *testing* pada pemodelan LSTM *Selected Attribute* dataset dengan empat *hidden layer*

### 3.3. Performance Evaluasi model

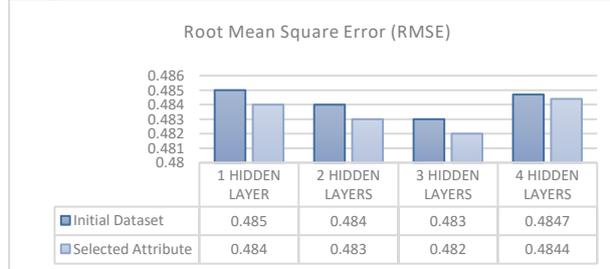
#### 3.3.1. Long Short-Term Memory (LSTM)

Pada gambar 15 menunjukkan bahwa nilai evaluasi pemodelan untuk *Mean Square Error (MSE)* terendah ada di *hidden layer* ketiga pada dataset yang difilter *variable* nya (*selected attribute*), dengan nilai 0.2325



Gambar 15 Grafik Evaluasi Model nilai MSE

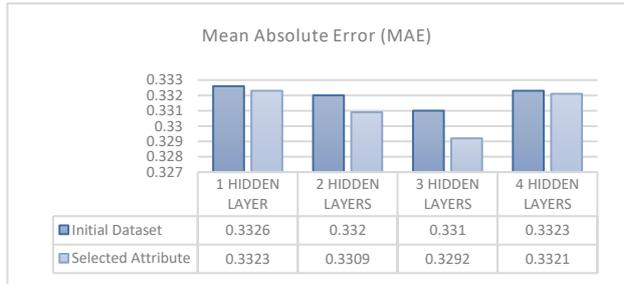
Pada gambar 16 menunjukkan bahwa nilai evaluasi pemodelan untuk *RM Root Mean Square Error (RMSE)* terendah ada di *hidden layer* ketiga pada dataset yang difilter *variable* nya (*selected attribute*), dengan nilai 0.4820



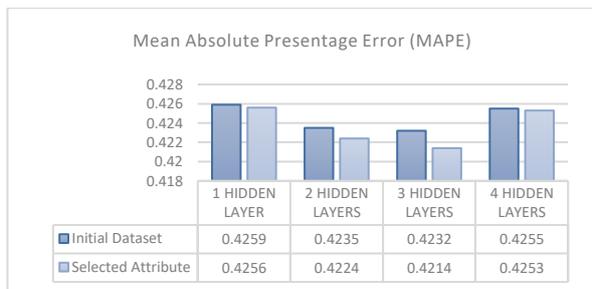
Gambar 16 Grafik Evaluasi Model nilai RMSE

Pada gambar 17 menunjukkan bahwa nilai evaluasi pemodelan untuk *Mean Absolute Error (MAE)* terendah ada di *hidden layer* ketiga pada dataset yang difilter *variable* nya (*selected attribute*), dengan nilai 0.3292.

Pada gambar 18 menunjukkan bahwa nilai evaluasi pemodelan untuk *Mean Absolute Percentage Error (MAPE)* terendah ada di *hidden layer* ketiga pada dataset yang difilter *variable* nya (*selected attribute*), dengan nilai 0.4214



Gambar 17 Grafik Evaluasi Model nilai MAE



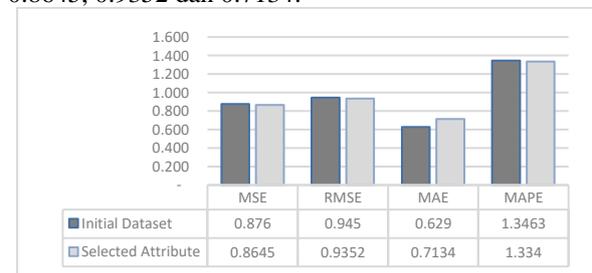
Gambar 18 Grafik Evaluasi Model nilai MAPE

#### 3.3.2. Auto Regressive Integrated Moving Average (ARIMA)

Bahwa untuk proses pemodelan *ARIMA* pada penelitian ini dengan proses pemilihan *variable* dataset terdiri dari *Initial Dataset* dan *selected Attribute* dengan hasil evaluasi pemodelannya dapat digambarkan dalam bentuk grafik seperti pada gambar 19.

Untuk proses *Initial Dataset* seluruh *variable* dataset digunakan dalam eksperimen penelitian, dan pada pemodelan *ARIMA* ini menghasilkan performa MAPE, MSE, RMSE dan MAE 1.3463, 0.8760, 0.9450 dan 0.6290.

Dan Proses *Selected Dataset* ini ditentukan berdasarkan nilai *correlation coefficient* antar *attribute* seperti halnya di pada Tabel 3, dimana untuk *attribute* yang bernilai negatif tidak digunakan dalam eksperimen penelitian, dan pada pemodelan *ARIMA* ini menghasilkan performa MAPE, MSE, RMSE dan MAE 1.3340, 0.8645, 0.9352 dan 0.7134.



Gambar 19 Grafik Evaluasi Model ARIMA

## 4. Kesimpulan

Penelitian ini bertujuan untuk membuat suatu pemodelan dalam memprediksi jumlah realisasi belanja yang akan ditanggung pemerintah Indonesia untuk

periode yang akan datang. Dataset yang digunakan berasal dari *history* harian belanja pemerintah Indonesia yang berbasis *time-series*.

Pemodelan yang digunakan pada penelitian ini adalah *Long Short-Term Memory (LSTM)*, Pemilihan *hyperparameter* yang tepat dengan menggunakan tiga *hidden layer* pada pemodelan *LSTM* dipenelitian ini dapat menghasilkan performa yang lebih baik dibandingkan dengan pemodelan *Auto Regressive Integrated Moving Average (ARIMA)*.

Hasil eksperimen penelitian menghasilkan pemodelan LSTM dengan performa *Mean Square Error (MSE)* sebesar 0.2325, *Root Mean Square Error (RMSE)* sebesar 0.4820, *Mean Average Error (MAE)* sebesar 0.3292 dan *Mean Everage Presentage Error (MAPE)* sebesar 0.4214.

### Daftar Rujukan

- [1] I. Iskandar, R. Willett, and S. Xu, "The development of a government cash forecasting model," *J. Public Budgeting, Account. Financ. Manag.*, vol. 30, no. 4, pp. 368–383, 2018, doi: 10.1108/JPBAFM-04-2018-0036.
- [2] E. Sumando, "Pengembangan Metode Cash Forecasting Pemerintah: Studi Kasus Saldo Kas Pemerintah 2009 – 2011," *Kaji. Ekon. dan Keuang.*, vol. 2, pp. 70–93, Sep. 2018, doi: 10.31685/kek.v2i1.284.
- [3] R. Magdalena, B. Logica, and T. Zamfiroiu, "Forecasting public expenditure by using feed-forward neural networks," *Econ. Res. Istraz.*, vol. 28, no. 1, pp. 668–686, 2015, doi: 10.1080/1331677X.2015.1081828.
- [4] S. Siami-Namini and A. S. Namin, "Forecasting Economics and Financial Time Series: ARIMA vs. LSTM," pp. 1–19, 2018, [Online]. Available: <http://arxiv.org/abs/1803.06386>.
- [5] X. Shao, C. S. Kim, and P. Sontakke, "Accurate deep model for electricity consumption forecasting using multi-channel and multi-scale feature fusion CNN-LSTM," *Energies*, vol. 13, no. 8, 2020, doi: 10.3390/en13081881.
- [6] R. Fu, Z. Zhang, and L. Li, "Using LSTM and GRU neural network methods for traffic flow prediction," 2017, doi: 10.1109/YAC.2016.7804912.
- [7] A. G. Salman, Y. Heryadi, E. Abdurahman, and W. Suparta, "Single Layer & Multi-layer Long Short-Term Memory (LSTM) Model with Intermediate Variables for Weather Forecasting," *Procedia Comput. Sci.*, vol. 135, pp. 89–98, 2018, doi: 10.1016/j.procs.2018.08.153.
- [8] S. García, J. Luengo, and F. Herrera, "Data Preprocessing in Data Mining," *Intell. Syst. Ref. Libr.*, 2015.
- [9] Z. Zeng, H. Zhang, R. Zhang, and C. Yin, "A novel feature selection method considering feature interaction," *Pattern Recognit.*, 2015, doi: 10.1016/j.patcog.2015.02.025.
- [10] A. M. De Silva and P. H. W. Leong, "Grammar-based feature generation for time-series prediction," *SpringerBriefs Appl. Sci. Technol.*, 2015, doi: 10.1007/978-981-287-411-5.
- [11] F. Chollet, "keras," *Github*, 2015. <https://github.com/fchollet/keras>.
- [12] O. B. Sezer, M. U. Gudelek, and A. M. Ozbayoglu, "Financial time series forecasting with deep learning: A systematic literature review: 2005–2019," *Appl. Soft Comput. J.*, 2020, doi: 10.1016/j.asoc.2020.106181.