



Peramalan Data Indeks Harga Konsumen Berbasis Time Series Multivariate Menggunakan Deep Learning

Soffa Zahara¹, Sugianto²^{1,2} Teknik Informatika, Fakultas Teknik, Universitas Islam Majapahit¹soffa.zahara@unim.ac.id, ²sugianto@unim.ac.id

Abstract

Multivariate Time Series based forecasting is a type of forecasting that has more than one criterion changes from time to time that it can forecast based on historical patterns of data sequences. The Consumer Price Index (CPI) issued regularly every month by the Statistics Indonesia calculated based on data observations. This study is a development of previous research that only used on type of algorithm to predict CPI value resulting poor of accuracy due to lack of architecture variations testing. This study developed a CPI forecasting model with a new approach about using several types of deep learning algorithms, namely LSTM, Bidirectional LSTM, and Multilayer Perceptron with architectural variations of the number of neurons and epochs. Furthermore, this study adapt ADDIE model of Research and Development method. Based on the results, the best accuracy is obtained from the LSTM Bidirectional with 10 neurons and 2000 epoch resulting 3,519 of RMSE value. Meanwhile, based on the average RMSE value for the whole test, LSTM gets the smallest average of RMSE followed Bidirectional LSTM and Multilayer Perceptron with the RMSE value 4,334, 5,630, 6,304 respectively.

Keywords: consumer price index, time series forecasting, deep learning.

Abstrak

Peramalan berbasis *Multivariate Time Series* merupakan salah satu jenis peramalan yang mempunyai lebih dari satu kriteria yang berubah dari waktu ke waktu sehingga dapat melakukan peramalan berdasarkan pola riwayat urutan data. Indeks Harga Konsumen (IHK) yang dikeluarkan secara rutin tiap bulan oleh Badan Pusat Statistik merupakan salah satu indikator ekonomi yang berpengaruh pada tingkat inflasi. Penelitian ini merupakan pengembangan dari penelitian sebelumnya yang hanya menggunakan satu jenis algoritma deep learning dalam memprediksi nilai IHK dimana nilai akurasi prediksi yang dihasilkan masih belum optimal dikarenakan kurangnya variasi eksplorasi dari sisi jumlah *neuron* dan *epoch*. Beberapa penelitian prediksi IHK terdahulu juga hanya menggunakan satu jenis algoritma sehingga sulit mencari metode yang memberikan nilai akurasi terbaik. Penelitian ini membangun model peramalan IHK dengan pendekatan baru yaitu penggunaan beberapa jenis algoritma deep learning yaitu LSTM, LSTM Bidirectional, dan Multilayer Perceptron dengan variasi arsitektur jumlah *neuron* dan *epoch* yang diharapkan dapat meningkatkan hasil akurasi dari penelitian sebelumnya. Penelitian dibangun dengan metode Research and Development dengan model ADDIE (Analysis, Design, Development, Implementation, Evaluation). Sistem peramalan memanfaatkan 28 jenis harga bahan pokok harian sebagai nilai input untuk meramal nilai Indeks Harga Konsumen di kota Surabaya periode 2014 sampai 2018. Berdasarkan hasil pengujian, nilai akurasi terbaik dengan nilai RMSE 3,519 didapatkan dari algoritma Bidirectional LSTM dengan konfigurasi 10 *neuron* dan 2000 *epoch*. Sedangkan berdasarkan nilai rata-rata RMSE keseluruhan pengujian, LSTM mendapatkan RMSE terkecil yaitu 4,334 disusul dengan LSTM Bidirectional yaitu 5,630, kemudian Multilayer Perceptron yaitu 6,304.

Kata kunci: indeks harga konsumen, peramalan time series, deep learning.

1. Pendahuluan

Salah satu indikator penilaian dalam menentukan nilai diterbitkan secara setiap bulan atau triwulan, tersedia inflasi yaitu Indeks Harga Konsumen (IHK). IHK adalah dengan cepat sekitar dua minggu setelah akhir bulan, indeks yang bertujuan mengukur perubahan atas barang dan tidak ada revisi dalam setiap publikasinya. Badan dan jasa dari waktu ke waktu yang digunakan oleh Pusat Statistik (BPS) melakukan perhitungan IHK setiap konsumen [1]. Karakteristik umum dari nilai IHK yaitu bulan menggunakan rumus *Modified Laypeyres*

berdasarkan observasi data harga transaksi barang dan jasa di tingkat pedagang eceran yang dilakukan pada jangka waktu harian, mingguan, dua minggu dan bulanan [2]. Pemilihan barang dan jasa yang digunakan terdiri dari 225-462 jenis komoditas per kota yang diklasifikasikan menjadi 7 kelompok besar komoditas [2]. Salah satu kelompok komoditas yaitu bahan makanan merupakan komoditas yang paling sering dijadikan acuan IHK secara umum dikarenakan nilainya yang berubah-ubah hingga tingkat harian sehingga berkontribusi dan berpengaruh cukup besar dalam perubahan nilai IHK Umum [3].

Peramalan berbasis *Multivariate Time Series* merupakan salah satu jenis peramalan yang mempunyai lebih dari satu kriteria yang berubah dari waktu ke waktu sehingga dapat melakukan prediksi lebih akurat daripada peramalan berbasis *Univariate* [4]. Salah satu algoritma yang mendukung peramalan berbasis *Multivariate Time Series* adalah *deep learning*. Konsep *deep learning* berbeda dengan para pendahulunya yaitu *artificial intelligence* dan *machine learning* dengan menekankan pada pembelajaran *end-to-end* serta kedalaman pembelajaran [5]. *Deep learning* telah terbukti lebih akurat dan memiliki performansi yang lebih baik dibanding dengan algoritma lain dengan banyaknya layer atau lapisan pembelajaran yang digunakan [6] [7] [8].


Beberapa penelitian yang telah melakukan peramalan IHK menggunakan sumber harga bahan makanan pokok diantaranya yaitu Budiastuti dkk [9] membandingkan beberapa metode *machine learning* untuk memprediksi IHK harian yaitu Kernel Ridge Regression, Linear Regression, SVR (Support Vector Regression)-Linier, SVR-Polynomial, dan SVR-RBF (Radial Basis Function). Rohmah dkk [10] melakukan prediksi IHK di tiga kota di Jawa Timur yaitu Banyuwangi, Jember, Sumenep menggunakan metode SVR-RBF dan SVR-Polynomial. Beberapa penelitian diatas hanya fokus pada pemanfaatan 1 jenis model *machine learning* yaitu SVR (Support Vector Regression). Zahara [11] dkk membangun prediksi IHK bulanan menggunakan algoritma LSTM (Long Short Term Memory) dengan membandingkan beberapa algoritma optimasi, namun hasil akurasi yang dihasilkan belum optimal dimana nilai RMSE terbaik yang didapatkan yaitu 4.088. Nilai akurasi dikatakan semakin baik apabila semakin kecil mendekati nilai 0 [12], sehingga nilai RMSE pada penelitian sebelumnya termasuk belum optimal. Dari keseluruhan penelitian yang membangun model prediksi IHK sebelumnya belum ada penelitian yang menggunakan dan membandingkan lebih dari satu jenis model algoritma *deep learning* yang berbeda serta mengeksplorasi variasi jumlah *neuron* dan *epoch*.

Penelitian ini membangun sebuah sistem peramalan IHK berbasis *Multivariate Time Series* dimana data inputan terdiri dari 28 jenis harga bahan pokok harian di kota Surabaya tahun 2014 sampai 2018

menggunakan beberapa algoritma *deep learning*. Algoritma *deep learning* yang digunakan yaitu Multilayer Perceptron, LSTM, serta LSTM Bidirectional yang nantinya akan dibandingkan menggunakan variasi banyaknya *epoch* dan *neuron* sehingga dapat dicapai hasil akurasi terbaik dengan peramalan IHK.

2. Metode Penelitian

Metode penelitian yang digunakan dalam penelitian ini menggunakan metode Research and Development dengan pendekatan ADDIE Model [13]. Gambar 1 menjelaskan tentang keseluruhan tahapan yang digunakan dalam sistem peramalan IHK.



Gambar 1. Metode Penelitian [13]

2.1. Analyze

Tahap Analyze atau analisis merupakan tahapan awal dari keseluruhan penelitian dimana peneliti menentukan tujuan keseluruhan penelitian yaitu membangun sistem peramalan IHK. Langkah yang dilakukan yaitu melakukan analisa kelemahan dan kelebihan penelitian-penelitian yang telah melakukan prediksi IHK sebelumnya. Kemudian menentukan algoritma dan parameter evaluasi seperti *hidden layer*, *epoch*, algoritma optimasi, *loss function*, serta satuan akurasi yang akan digunakan untuk pembangunan peramalan.

Penentuan jumlah variabel data bahan pokok yang diambil dari penyedia sumber data merupakan salah satu tahapan penting yang termasuk dalam proses analisis. Selain itu jumlah dataset yang akan dianalisa serta dibagi menjadi data latih dan data uji juga ditentukan pada tahap ini sehingga diharapkan didapatkan kombinasi konfigurasi yang maksimal agar tujuan peramalan dengan akurasi tinggi dapat tercapai.


2.2. Design

Tahapan selanjutnya setelah analisis yaitu tahap design dimana proses-proses yang terlibat yaitu pembuatan perancangan sistem secara keseluruhan dimulai dari proses perancangan teknologi penarikan dataset dari 2 sumber data yaitu website siskaperbapo.com dan bps.go.id. Proses selanjutnya yaitu perancangan teknik *preprocessing* atau pengolahan data yang akan dilakukan diantaranya yaitu pembersihan data dan tranformasi data.

Perancangan pembangunan sistem diantaranya lingkungan sistem berjalan, termasuk proses instalasi sistem operasi, bahasa pemrograman, framework, *library* pendukung program, dan monitoring keberlanjutan sistem yang dibangun. Tahapan perencanaan paling akhir yaitu pembuatan skenario pengujian meliputi skenario evaluasi akurasi pada setiap konfigurasi perubahan *hidden layer*, *neuron* dan, *epoch*.

2.3. Develop

Tahap Develop merupakan tahap pembangunan sistem peramalan yang terdiri dari 3 langkah sub proses. Gambar 2 menggambarkan langkah-langkah dalam proses pembangunan sistem yaitu pengambilan data mentah, pengolahan data atau bisa disebut tahap *preprocessing*, dan terakhir yaitu pembangunan model peramalan menggunakan *deep learning* yang dibangun di lingkungan Cloud Computing.



Gambar 2. Pembangunan Sistem

Seluruh proses pembangunan sistem dalam tahap Develop dilaksanakan berdasarkan analisis dan perancangan yang telah dilakukan sebelumnya. Jika terdapat hambatan atau masalah yang ditemukan dalam proses pembangunan sistem maka akan dianalisis dan dilakukan peninjauan kembali sehingga dapat ditemukan solusi yang tepat untuk menyelesaikan hambatan tersebut.

2.3.1 Pengambilan Data Mentah

Tahap pengambilan data mentah atau *raw data* bertujuan untuk mengumpulkan data yang dibutuhkan untuk pembangunan model peramalan. Data yang digunakan dalam peramalan IHK yaitu data harian 28 jenis harga bahan pokok kota Surabaya pada kurun waktu tahun 2014 sampai dengan 2018. Data harian tersebut kemudian dilakukan operasi rerata per bulan sehingga didapatkan rerata harga bahan pokok bulanan. Data 28 jenis rerata harga bahan pokok bulanan ini yang menjadi data masukan untuk pembangunan model peramalan IHK. Proses pengambilan data yang dilakukan yaitu dengan mengimplementasikan teknik *web crawling* dengan memanfaatkan *API (Application Programming Interface)* yang tersedia pada website siskaperbapo.com. Data hasil kemudian disimpan dalam bentuk format csv (comma separated values).

Gambar 3 merupakan website Sistem Informasi Ketersediaan dan Perkembangan Bahan Pokok di Jawa Timur yang dikelola oleh Dinas Perindustrian dan Perdagangan Jawa Timur yang berisi harga harian 28 jenis komoditas bahan pokok di 38 kota / kabupaten di Jawa Timur.

NO	NAMA BAHAN POKOK	SATUAN	HARGA KEMARIN	HARGA SEKARANG	PERUBAHAN (Rp)	PERUBAHAN (%)
01	BERAS					
	- Bergawean	kg	11.364	11.363	-2	-0.02%
	- Mentik	kg	10.992	10.989	-4	-0.04%
	- IR 64	kg	9.699	9.704	5	0.05%
02	GULA PASIR					

Gambar 3. Website siskaperbapo.com

Tabel 1 menunjukkan contoh data bulanan yang akan diproses pada sistem peramalan yang dibangun. Nilai rerata merupakan hasil perhitungan manual peneliti yang bersumber dari data harian website siskaperbapo.com.

Tabel 1. Contoh Data Rerata Bulanan Harga Bahan Pokok

Jenis Bahan Pokok	Januari 2018	Februari 2018	Maret 2018
Daging Ayam Broiler	26.400	26.400	26.400
Daging Ayam Kampung	25.945	25.986	25.199
Telur Ayam Ras/Petelur	17.734	18.108	15.943

Data IHK bulanan kota Surabaya yang merupakan data keluaran dari sistem peramalan berasal dari BPS (Badan Pusat Statistik) Jawa Timur dalam subjek kelompok Ekonomi dan Perdagangan. Data IHK diambil dengan cara mengunduh manual pada website jatim.bps.go.id yang ditunjukkan pada Gambar 4. Periode pengambilan data diseragamkan dengan data harga bahan pokok yaitu tahun 2014 sampai 2018, mulai dari bulan Januari sampai dengan bulan Desember.

Gambar 4. Website jatim.bps.go.id

Tabel 2 menunjukkan contoh data IHK bulanan yang diambil dari website BPS Jawa Timur yaitu www.jatim.bps.go.id. Alasan pemilihan kota Surabaya menjadi subjek dalam pemilihan data bahan pokok dan

IHK yaitu pertimbangan kelengkapan data dibandingkan kota-kota lain di Jawa Timur sehingga dapat meminimalisir masalah hilang atau tidak lengkapnya data yang diambil.

Tabel 2. Data IHK Kota Surabaya

Bulan	2014	2015	2016	2017	2018
Januari	136,88	110,99	118,71	123,62	127,94
Februari	137,91	111,28	118,28	123,51	128,24
Maret	138,78	111,37	118,48	123,75	128,22

2.3.2. Pengolahan Data

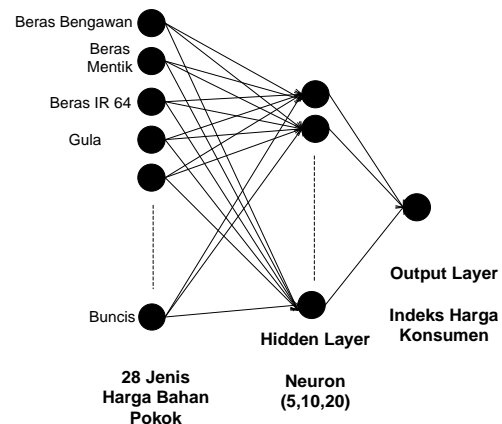
Tahap pengolahan data diperlukan untuk memastikan data yang akan masuk ke dalam sistem peramalan sesuai format yang telah ditentukan sehingga mempermudah proses peramalan data nantinya. Dalam penelitian ini keseluruhan data akan dikelompokkan dan dilabelkan ke dalam 35 variabel dimulai dari X1 sampai dengan X35. Pada tiap variabel mewakili nilai masukan dan keluaran dalam sistem peramalan. Tabel 3 merepresentasikan contoh detail variabel dan nilai yang diwakilinya.

Tabel 3. Pelabelan Data Mentah

No	Keterangan	Nilai
X1	Waktu	2014-01
X2	Indeks Harga Konsumen	118.31
X3	Beras Bengawan	9.823
X4	Beras Mentik	10.775
X5	Beras IR64	7.905
X6	Gula	10.497
X7	Daging Sapi	82.939
X8	Minyak Curah	11.336
X9	Minyak Bimoli Kemasan	29.108
....
X35	Buncis	7.214

2.3.3 Pembangunan Model Peramalan Menggunakan Deep Learning


Algoritma Deep Learning yang digunakan dalam membangun sistem peramalan IHK terbagi menjadi 3 jenis algoritma yaitu Multilayer Perceptron (MLP), LSTM, dan LSTM Bidirectional. Ketiga metode tersebut akan dibandingkan dan dievaluasi berdasarkan hasil akurasi. Gambar 5 mengilustrasikan arsitektur dari jaringan *deep learning* yang terdiri dari 3 layer. *Input layer* berisi 28 variabel jenis harga bahan pokok, 1 *hidden layer* yang terdiri dari beberapa variasi jumlah neuron yaitu 5, 10, dan 20. Layer terakhir yaitu *output layer* yang merupakan nilai tujuan prediksi yaitu nilai IHK. Arsitektur yang digunakan berlaku untuk setiap algoritma yang digunakan yaitu Multilayer Perceptron, LSTM, dan Bidirectional LSTM.



Gambar 5. Arsitektur Umum Sistem Peramalan IHK

Multilayer Perceptron merupakan jenis algoritma *deep learning* paling sederhana yang biasanya digunakan untuk pengenalan pola, klasifikasi, serta peramalan berbasis masukan informasi [14]. Kunci dari algoritma Multilayer Perceptron yaitu adanya lebih dari beberapa *neuron* yang disebut *perceptron* yang terkoneksi satu sama lain.

Multilayer Perceptron (MLP) terdiri dari 3 bagian atau lapisan dimana lapisan pertama disebut *input layer* yang menjadi gerbang masuknya data yang akan diolah, kemudian *output layer* sebagai tujuan pengolahan data akan tercapai, serta ditengah-tengah *input* dan *output layer* terdapat satu atau lebih *hidden layer* yang berfungsi meningkatkan nilai akurasi [14].




Gambar 6. Arsitektur MLP [8]

Gambar 6 mengilustrasikan arsitektur umum dari algoritma MLP yang merupakan versi paling sederhana dari model *deep learning*. Dalam setiap layer berisi satu atau lebih *neuron* yang memproses setiap informasi yang masuk dan melanjutkan pemrosesan data ke *neuron* di *layer* selanjutnya. Variabel x merupakan nilai *input* atau masukan, sedangkan variabel y adalah nilai *output* atau prediksi. Diantara *input* dan *output layer* terdapat satu atau beberapa *hidden layer* yang berisi satu atau lebih *neuron*. Salah satu kelebihan *hidden layer* yaitu dapat berfungsi meningkatkan hasil akurasi model algoritma yang dibangun.


Hochreiter dan Schmidhuber membangun algoritma Long Short-Term Memory (LSTM) pada tahun 1997

untuk memperbaiki permasalahan *vanishing gradient* pada algoritma RNN (Recurrent Neural Network) [15]. Poin utama LSTM adalah menyimpan informasi baru dan menjaga informasi lama agar tidak menghilang secara perlahan ketika proses pengolahan data. LSTM mempunyai kelebihan dapat menyimpan informasi jangka panjang dimana dalam setiap *cell* LSTM mempunyai 3 *gate*/gerbang pengatur yaitu *input gate*, *forget gate*, dan *output gate*. *Input gate* bertugas mengontrol titik masuk dan pemrosesan data dari luar, *forget gate* memutuskan data yang dihilangkan untuk proses setelahnya, *gate* terakhir yaitu *output gate* melakukan seluruh perhitungan masuk dan menghasilkan luaran atau output dalam tiap LSTM cell [14]. Gambar 7 menginformasikan arsitektur dari sebuah *cell* LSTM yang memproses 2 *states* dalam satu waktu. Variabel c adalah *state* cell, sedangkan variabel h merupakan *hidden state*. Simbol σ merupakan fungsi sigmoid.



Gambar 7. Arsitektur Cell LSTM [14]

Bidirectional LSTM [14] merupakan pengembangan dari LSTM tradisional dimana dapat meningkatkan kinerja algoritma dikarenakan mampu melatih 2 proses algoritma LSTM yaitu *forward* dan *backward* secara paralel. Bidirectional LSTM mampu menyimpan informasi masa depan menggunakan dua status yang tersembunyi. Selain itu, struktur Bidirectional LSTM memberikan sistem untuk mempertahankan urutan informasi mundur dan maju pada satu langkah waktu. LSTM Bidirectional menunjukkan hasil yang baik lebih baik daripada LSTM tradisional [14].



Gambar 8. Arsitektur Bidirectional LSTM [15]

Arsitektur algoritma LSTM Bidirectional digambarkan pada Gambar 8 dimana dalam proses pelatihan dalam jaringan menggunakan urutan data di masa lampau dan

masa depan. Dua koneksi yang terhubung dalam satu layer digunakan untuk memproses data yang masuk. Bidirectional LSTM menggunakan 2 layer pemrosesan dimana 1 layer berfungsi pemrosesan data searah dengan aliran data, sedangkan 1 layer lainnya berbalik arah dengan aliran data [15].

2.4. Implement

Tahap implementasi dilakukan dengan memindahkan seluruh sistem fisik ke dalam lingkungan *cloud computing* atau komputasi berbasis awan. Penyedia jasa *cloud computing* yang digunakan yaitu Amazon Web Service (AWS). Implementasi sistem pada lingkungan *cloud computing* ini bertujuan untuk meningkatkan performansi sistem peramalan. Tabel 4 menjelaskan rincian kebutuhan *hardware* dan *software* yang digunakan dalam implementasi pembangunan sistem prediksi IHK dalam lingkungan *cloud computing*.

Tabel 4. Tabel Spesifikasi Software dan Hardware

Kebutuhan	Server	Spesifikasi
Hardware	vCPU	1
	Memory (GiB)	1
	Processor	Intel Xeon clock speeds up to 3.3 GHz
Software	Sistem Operasi	Ubuntu Server
	Bahasa Pemrograman	Python
	Framework	Tensorflow
	Machine Learning API	Keras
	Library	Mathplotlib,
	Pendukung	Scikit-learn, Numpy, Pandas

2.5. Evaluasi

Tahap evaluasi yang dilakukan yaitu melakukan pengujian berdasarkan skenario yang telah dibuat. Konfigurasi *input layer*, *output layer*, *jenis optimizer* dan *loss function* yang digunakan adalah sama untuk setiap model, tetapi untuk *neuron* dan *epoch* dibedakan dan bervariasi. Jumlah neuron dibedakan dan ditingkatkan secara bertahap dari 5, 10, kemudian 20. Sedangkan jumlah epoch untuk setiap pengujian divariasikan sebanyak 1000, 2000, dan 3000. Selain itu, konfigurasi algoritma optimasi dan loss function yang digunakan di tiap model disamakan yaitu Nadam (Nesterov Adam) dan MAE (Mean Absolute Error).

Pengukuran akurasi yang digunakan dalam penelitian ini yaitu RMSE (Root Mean Square Error) dimana RMSE menghitung nilai selisih dan kesalahan yang ditemukan antara data aktual dan ramalan. Nilai RMSE menunjukkan tingkat akurasi model yang dibangun. Semakin kecil nilai RMSE, akurasi yang dihasilkan akan semakin tinggi.

3. Hasil dan Pembahasan

Tabel 5 menginformasikan hasil pengujian yang telah dilakukan pada masing-masing algoritma sesuai dengan

rancangan skenario pengujian. Terdapat 27 hasil nilai RMSE yang didapatkan yang mewakili setiap skenario pengujian.

Tabel 5. Nilai RMSE

Model	Konfigurasi Jumlah Neuron	1000 Epoch	2000 Epoch	3000 Epoch
MLP	5	3.754	7.399	6.451
	10	7.933	5.685	7.024
	20	7.024	5.471	6.002
LSTM	5	4.155	4.429	4.255
	10	4.252	4.341	4.819
	20	3.997	3.846	4.919
LSTM Bidirectional	5	9.602	6.966	4.809
	10	5.164	3.519	4.294
	20	6.373	5.784	4.161

Dari hasil pengujian didapatkan hasil bahwa RMSE terkecil dengan nilai 3.519 dihasilkan oleh model algoritma LSTM Bidirectional dengan konfigurasi *neuron* sejumlah 10 dan *epoch* sebesar 2000. Sedangkan nilai RMSE terbesar yaitu 9.602 merupakan LSTM Bidirectional dengan konfigurasi 2 *neuron* sebanyak 5 dan jumlah *epoch* yaitu 1000.

3.1. Pengaruh Jumlah *Epoch*

Beberapa hasil skenario pengujian membuktikan jumlah *epoch* yang digunakan membuat tingkat akurasi semakin tinggi. Pada konfigurasi model LSTM Bidirectional dengan konfigurasi jumlah *neuron* 5 dan 20, tingkat akurasi semakin meningkat dibuktikan dengan semakin menurunnya nilai RMSE. LSTM Bidirectional dengan jumlah *neuron* 5, nilai RMSE yang dihasilkan yaitu 9.602, 6.966, 4.809 secara berurutan seiring dengan bertambahnya *epoch*. Begitu juga dengan LSTM Bidirectional dengan jumlah *neuron* 20, nilai RMSE secara berurutan sesuai dengan bertambahnya jumlah *epoch* yaitu 6.373, 5.784, 4.161. Namun, dari 27 hasil skenario konfigurasi, hanya 6 skenario yang membuktikan bertambahnya jumlah *neuron* membuat nilai akurasi semakin tinggi, 21 skenario lainnya hanya membuat nilai RMSE menjadi fluktuatif dimana ketika nilai *epoch* ditambahkan awalnya nilai akurasi akan semakin kecil, tetapi ketika nilai *epoch* ditambahkan semakin besar, nilai akurasi berbalik menjadi lebih besar.

3.2. Pengaruh Jumlah *Neuron*

Dalam penelitian ini penulis juga mempelajari hubungan jumlah *neuron* dengan peningkatan akurasi peramalan. Pada skenario 2000 *epoch*, keseluruhan model algoritma yang diujikan yaitu MLP, LSTM, LSTM Bidirectional mengalami penurunan nilai RMSE sebanding dengan semakin banyaknya *neuron* yang diujikan. Begitu juga dengan konfigurasi LSTM Bidirectional dengan jumlah *epoch* 3000. Seperti pada model algoritma MLP 2000 *epoch*, pada awalnya RMSE yang dihasilkan ketika jumlah *neuron* 5 yaitu 7.399, kemudian ketika *neuron* bertambah menjadi 10 nilai RMSE berkurang menjadi

5.685, dan saat *neuron* pada MLP menjadi 20, nilai RMSE semakin turun menjadi 5.471. Selain mempengaruhi tingkat akurasi semakin tinggi, bertambahnya jumlah *neuron* juga dapat membuat akurasi semakin tidak bagus. Seperti pada konfigurasi LSTM dengan *epoch* 3000. Terjadi peningkatan nilai RMSE berurutan dari mulai 4.255, 4.819, 4.919 seiring dengan meningkatnya jumlah *neuron*.

Berdasarkan hasil pengujian rata-rata nilai RMSE yang dihasilkan pada model algoritma MLP yaitu 6.304. Sedangkan pada LSTM rata-rata RMSE yaitu 4.334, dan yang terakhir yaitu LSTM Bidirectional mempunyai rata-rata RMSE 5.630. Hal ini menunjukkan bahwa dilihat dari nilai rata-rata RMSE LSTM merupakan model akurasi terbaik disusul dengan LSTM Bidirectional, kemudian MLP. Sedangkan nilai akurasi tertinggi yang didapatkan penelitian ini yaitu 3.519 pada nilai RMSE lebih tinggi dibandingkan penelitian sebelumnya yaitu 4.088 pada nilai RMSE [11] sehingga penelitian ini lebih baik dari penelitian sebelumnya.

4. Kesimpulan

Peramalan berbasis *Multivariate Time Series* memungkinkan kita melakukan peramalan dengan mempertimbangkan seluruh variabel yang berpengaruh pada variabel tujuan peramalan sehingga diharapkan tingkat akurasi akan semakin tinggi. Pembangunan model peramalan IHK ini mengimplementasikan konsep *deep learning* dimana menekankan pada eksplorasi banyaknya jenis model algoritma yang digunakan dalam pembangunan model peramalan. Selain banyaknya model yang digunakan, eksplorasi banyaknya jumlah *neuron* dan *epoch* juga dipertimbangkan dalam proses implementasi. Dari hasil pengujian, akurasi terbaik dengan nilai 3.519 dihasilkan oleh model algoritma LSTM Bidirectional dengan konfigurasi *neuron* sejumlah 10 dan *epoch* sebesar 2000. Penelitian ini juga membuktikan bahwa banyaknya jumlah *epoch* dan *neuron* tidak menjamin meningkatnya tingkat akurasi.

Untuk pengembangan penelitian kedepan, diharapkan data sumber pengujian yang digunakan dapat ditingkatkan menjadi lebih banyak. Selain itu perlu dilakukan evaluasi arsitektur dan pengujian yang lebih mendalam dari segi nilai *batch size*, dan optimasi algoritma yang digunakan. Akan lebih baik jika ditambahkan lebih banyak perbandingan model *deep learning* lain seperti CNN (Convolutional Network) maupun kombinasi *hybrid* antar metode seperti algoritma CNN-LSTM.

Ucapan Terimakasih

Penelitian ini didukung dan didanai oleh Direktorat Riset dan Pengabdian Masyarakat, Direktorat Jenderal Penguatan Riset dan Pengembangan Kementerian Riset, Teknologi, dan Pendidikan Tinggi Republik Indonesia.

Daftar Rujukan

- [1] B. Karlina, "Pengaruh Tingkat Inflasi, Indeks Harga Konsumen Terhadap PDB di Indonesia Pada Tahun 2011-2015," *J. Ekon. dan Manaj.*, vol. 6, no. 1, pp. 2252–6226, 2017, [Online]. Available: <http://fe.budiluhur.ac.id/wp-content/uploads/2017/08/b.-berlian.pdf>.
- [2] Departemen Statistik, "Indeks Harga Konsumen," *Metadata*, no. March, pp. 3–6, 2016.
- [3] Listyowati and B. Sutidjo, "Pemodelan Indeks Harga Konsumen (IHK)," *J. Sains dan Seni Pomits*, vol. 2, no. 2, 2013.
- [4] Y. Yin and P. Shang, "Forecasting traffic time series with multivariate predicting method," *Appl. Math. Comput.*, vol. 291, pp. 266–278, 2016, doi: 10.1016/j.amc.2016.07.017.
- [5] A. Patterson, Josh and Gibson, *Deep learning : A Practitioners Approach*, vol. 29, no. 7553. CA: O'Reilly Media, 2017.
- [6] O. Al Qasem, M. Akour, and M. Alenezi, "The Influence of Deep Learning Algorithms Factors in Software Fault Prediction," *IEEE Access*, vol. 8, pp. 63945–63960, 2020, doi: 10.1109/ACCESS.2020.2985290.
- [7] M. Nabipour, P. Nayyeri, H. Jabani, S. Shahab, and A. Mosavi, "Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data : a comparative analysis on the Tehran stock exchange," vol. XX, 2020, doi: 10.1109/ACCESS.2020.3015966.
- [8] J. Gozalez, "A Comprehensive Evaluation of Deep Learning-Based Techniques for Traffic Prediction," vol. 8, 2020, doi: 10.1109/ACCESS.2020.2994415.
- [9] I. A. Budiastuti, S. M. S. Nugroho, and M. Hariadi, "Predicting daily consumer price index using support vector regression method," *QiR 2017 - 2017 15th Int. Conf. Qual. Res. Int. Symp. Electr. Comput. Eng.*, vol. 2017-Decem, pp. 23–28, 2017, doi: 10.1109/QIR.2017.8168445.
- [10] M. Rohmah, "Meramal Indeks Harga Konsumen Kabupaten di Jawa Timur dengan Metode Support Vector Regression Data Mining," no. x, pp. 30–36, 2019.
- [11] S. Zahara, Sugianto, and M. Bahril Ilmiddafiq, "Prediksi Indeks Harga Konsumen Menggunakan Metode Long Short Term Memory (LSTM) Berbasis Cloud Computing," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 3, pp. 357–363, 2019, doi: 10.29207/resti.v3i3.1086.
- [12] L. Qadrini, A. Asrirawan, N. Mahmudah, M. Fahmuddin, and I. F. Amri, "Forecasting Bank Indonesia Currency Inflow and Outflow Using ARIMA, Time Series Regression (TSR), ARIMAX, and NN Approaches in Lampung," *J. Mat. Stat. dan Komputasi*, vol. 17, no. 2, pp. 166–177, 2020, doi: 10.20956/jmsk.v17i2.11803.
- [13] A. Battou, O. Baz, and D. Mammass, "Learning Design approaches for designing Learning environments: A comparative study," *Int. Conf. Multimed. Comput. Syst. - Proceedings*, vol. 0, pp. 206–211, 2017, doi: 10.1109/ICMCS.2016.7905666.
- [14] H. Daoud and M. Bayoumi, "Efficient Epileptic Seizure Prediction based on Deep Learning," *IEEE Trans. Biomed. Circuits Syst.*, vol. PP, no. c, p. 1, 2019, doi: 10.1109/TBCAS.2019.2929053.
- [15] K. A. Althelaya and S. Mohammed, "Evaluation of Bidirectional LSTM for Short- and Long-Term Stock Market Prediction," pp. 151–156, 2018.