Terakreditasi SINTA Peringkat 4

Surat Keputusan Dirjen Penguatan Riset dan Pengembangan Ristek Dikti No. 28/E/KPT/2019 masa berlaku mulai Vol.3 No. 1 tahun 2018 s.d Vol. 7 No. 1 tahun 2022

Terbit online pada laman web jurnal: http://publishing-widyagama.ac.id/ejournal-v2/index.php/jointecs



JOINTECS

(Journal of Information Technology and Computer Science)

Vol. 6 No. 1 (2021) 21 - 28

e-ISSN:2541-6448 p-ISSN:2541-3619

Prediksi Indeks Harga Konsumen Komoditas Makanan Berbasis Cloud Computing Menggunakan Multilayer Perceptron

Soffa Zahara¹, Sugianto² Program Studi Teknik Informatika, Fakultas Teknik, Universitas Islam Majapahit ¹soffa.zahara@unim.ac.id, ²sugianto@unim.ac.id

Abstract

Prediction technique is one of the areas in data mining where it finds patterns from a set of data lead to predictions in the future. Prediction in the economic field is a predominant prediction due to one of the parameters for the country development. The Consumer Price Index describes the level of consumption of goods and services in society that used as a reference for the inflation rate. Previously the majority of research that predicts the Consumer Index value only predicts the value of the Consumer Price Index itself as an input and output value. The study built a forecasting model by utilizing multi input variables, namely 28 types of daily staple food prices as input values to predict Consumer Price Index of Surabaya for the period 2014 to 2018 where the whole development predictions built the Amazon Cloud Services environment. The prediction system is built using Multilayer Perceptron algorithm with architectural variations of the number of neurons, epoch, and hidden layer. Based on the test results, the best accuracy with RMSE value 3,380 is generated by 2 hidden layers, the first and second hidden layers which have 10 of neurons respectively with 1000 epoch.

Keywords: consumer prediction index; multilayer perceptron; cloud computing; multivariable prediction.

Abstrak

Teknik prediksi merupakan salah satu area dalam *data mining* dimana menemukan pola dari sekumpulan data yang mengarah pada prediksi di masa depan. Prediksi dalam bidang ekonomi merupakan prediksi yang mendominasi karena merupakan salah satu parameter berkembangnya suatu negara. Indeks Harga Konsumen menggambarkan tingkat konsumsi barang dan jasa pada masyarakat yang dapat dijadikan acuan nilai inflasi. Mayoritas penelitian yang melakukan prediksi nilai Indeks Harga Konsumen sebelumnya hanya melakukan prediksi menggunakan nilai Indeks Harga Konsumen itu sendiri sebagai nilai input dan output. Penelitian ini membangun model peramalan dengan memanfaatkan multi variabel input yaitu 28 jenis harga bahan pokok harian sebagai nilai input untuk meramal nilai Indeks Harga Konsumen di kota Surabaya periode 2014 sampai 2018 dimana keseluruhan pembangunan model prediksi dilakukan di lingkungan Amazon Cloud Services. Sistem prediksi dibangun dengan algoritma Multilayer Perceptron dengan variasi arsitektur jumlah *neuron*, *epoch*, dan *hidden layer*. Berdasarkan hasil pengujian, akurasi terbaik dengan nilai RMSE 3.380 dihasilkan oleh konfigurasi 2 hidden layer, hidden layer pertama dan kedua mempunyai neuron masing-masing berjumlah 10 dengan epoch sebesar 1000.

Kata kunci: indeks harga konsumen; multilayer perceptron; cloud computing; prediksi multivariabel.

© 2021 Jurnal JOINTECS

1. Pendahuluan

Teknik prediksi merupakan salah satu area dalam *data mining* dimana menemukan pola dari sekumpulan data yang mengarah pada prediksi di masa depan. Prediksi

dalam bidang ekonomi merupakan prediksi yang mendominasi karena merupakan parameter berkembangnya suatu negara diantaranya prediksi saham, prediksi inflas/deflasi, prediksi pertumbuhan

Diterima Redaksi : 4-11-2020 | Selesai Revisi : 14-01-2020 | Diterbitkan Online : 31-01-2021

yang dikonsumsi masyarakat [1] yang berubah dari cepat, efektif, dan efisien. bulan ke bulan atau kuartal ke kuartal. IHK di Indonesia dikeluarkan oleh Badan Pusat Statistik (BPS) Salah satu penyedia layanan Cloud terbesar yaitu digunakan sebagai acuan perhitungan nilai IHK.

Beberapa penelitian terdahulu yang telah melakukan prediksi IHK menggunakan berbagai macam metode, diantaranya Neural Network (NN) [2], Autoregressive Integrated Moving Average (ARIMA) [3], Seasonal ARIMA (SARIMA) [4] [5], Support Vector Regression (SVR) [6]. Dari keseluruhan penelitian yang telah dilakukan tersebut mayoritas hanya menggunakan satu variabel sebagai input dari prediksi yaitu nilai IHK itu sendiri, sehingga nilai input dan output berupa nilai IHK. Sedangkan prediksi IHK yang bersumber dari data inputan lebih dari satu variabel terutama data harga makanan pokok masih jarang ditemukan.

Multilayer Perceptron (MLP) merupakan algoritma Deep Learning yang paling banyak digunakan untuk pengenalan pola, klasifikasi, serta peramalan berbasis masukan informasi [7][8] dimana sangat cocok untuk pemrosesan data multidimensi [9]. Pada beberapa penelitian prediksi menggunakan MLP [10] [11] [12] [13] [14]telah membuktikan mempunyai akurasi yang cukup tinggi. Sakar dkk membuktikan dalam penelitiannya akurasi algoritma MLP vaitu 87.24 % lebih besar dibandingkan dengan SVM yaitu 84,88 % dan Random Forest 82,34 % dalam memprediksi tingkah laku pembelian online. Selain itu, Oktavianti dkk [10] juga membuktikan algoritma MLP mempunyai akurasi yang lebih tinggi Metode penelitian dalam proses pembangunan system dari pada SVR dengan nilai RMSE yaitu 11,45 untuk model prediksi terbagi menjadi 4 tahap yaitu MLP dan 15,84 untuk SVR dalam prediksi berbasis time series dengan jumlah dataset besar. Zang dkk [13] melakukan prediksi hujan menggunakan MLP dengan Multilayer Perceptron di lingkungan Cloud Computing, hasil RMSE sebesar 2.73. Chen dkk [14] membangun prediksi saham dengan MLP menghasilkan nilai MSE sebesar 0.002882. Namun, dari beberapa penelitian mempermudah dan memahami setiap langkah proses tersebut belum ada yang melakukan eksplorasi penelitian yang sedang dilakukan. mengenai jumlah hidden layer yang digunakan.

Penggunaan Cloud Computing sangat disarankan untuk mengatasi mahalnya biaya pembelian dan pemeliharaan hardware dan software [15] [16], untuk mendukung sistem pengolahan data. Sistem prediksi tentunya sangat membutuhkan hardware dan software dengan performa tinggi terutama jika data yang diolah sangat besar dan model algoritma yang digunakan sangat kompleks. Selain itu pengembang juga dihadapkan masalah lain yaitu yaitu pembangunan model yang membutuhkan proses penginstalan framework dan library pendukung dimana sangat memakan waktu yang tidak sedikit dan tidak praktis. Virtual server yang berjalan di lingkungan Cloud Computing atau bisa

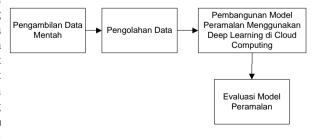
ekonomi dll. Indeks Harga Konsumen (IHK) adalah disebut serverless computing [17] dapat menjadi index yang menilai tingkat konsumsi barang dan jasa pilihan sebagai alternatif pembangunan sistem yang

setiap bulan nya berdasarkan Survei Biaya Hidup 2012 Amazon Web Service (AWS) [18] menawarkan solusi yang digolongkan menjadi 7 kelompok. Kelompok untuk para peneliti atau pengembang yang ingin bahan makanan merupakan salah satu kelompok yang membangun aplikasi berbasis Deep Learning, Solusi pembangunan sistem aplikasi yang ditawarkan AWS yaitu Deep Learning Amazon Machine Image (DLAMI) yang menyediakan seluruh komponen yang diperlukan untuk membangun sistem berbasis Deep Learning lengkap dengan berbagai jenis sistem operasi, framework, dan library pendukung seperti Tensorflow, Pytorch, Keras. DLAMI merupakan salah satu komponen dari Amazon Elastic Compute Cloud (EC2) dimana menyediakan layanan virtual mesin teroptimasi berbasis cloud yang berjalan layaknya komputer fisik [19] dengan sistem pembayaran berbasis durasi pemakaian per jam [20].

> Penelitian ini membangun sebuah sistem prediksi IHK berbasis multi variabel dimana data inputan terdiri dari 28 jenis harga bahan pokok harian di kota Surabaya tahun 2014 sampai 2018. Pembangunan sistem prediksi menggunakan algoritma Multilayer Perceptron (MLP) yang nantinya akan dibandingkan menggunakan variasi banyaknya hidden layer, neuron, dan epoch sehingga dapat dicapai hasil akurasi terbaik dengan peramalan IHK yang dibangun. Keseluruhan pembangunan sistem prediksi dibangun dalam lingkungan Cloud Computing yaitu pada provider AWS dengan menggunakan layanan DLAMI.

2. Metode Penelitian

pengambilan data mentah. pengolahan pembangunan model prediksi menggunakan algoritma dan evaluasi model peramalan yang telah dibangun. Adanya tahapan secara berurutan berfungsi untuk menggambarkan tahapan pembangunan sistem prediksi yang digunakan pada penelitian dimana terdiri dari 4 tahapan secara umum...



Gambar 1. Metode Penelitian

2.1. Pengambilan Data Mentah

Tahap pengambilan data mentah atar raw data bertujuan untuk mengumpulkan data yang dibutuhkan untuk pembangunan model prediksi. Data yang digunakan dalam peramalan IHK yaitu data harian 28 jenis harga bahan pokok harian kota Surabaya pada kurun waktu tahun 2014 sampai dengan 2018 yang diambil dari website Sistem Informasi Ketersediaan dan Perkembangan Bahan Pokok di Jawa Timur yaitu siskaperbapo.com yang dikelola oleh Perindustrian dan Perdagangan Jawa Timur. 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 bahan pokok yang dilakukan yaitu dengan mengimplementasikan teknik web crawling dengan memanfaatkan API (Application Programing Interface) yang tersedia pada website siskaperbapo.com. Hasil pengambilan data tersebut harian yang terdapat di kota Surabaya.

Tabel 1.Contoh Data Rerata Bulanan Harga Bahan Pokok

Jenis Bahan Pokok	Januari 2018	Februari 2018	Maret 2018
Gula Pasir Dalam Negeri	10.985	11.056	11.084
Bimoli botol 2 liter	81.200	81.181	80.226
Daging Sapi Daging Ayam	9.048	9.272	9.385
Broiler	26.400	26.400	26.400

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. Periode pengambilan data diseragamkan dengan data harga bahan pokok yaitu tahun 2014 sampai 2018. Tabel 2 menunjukkan contoh data IHK bulanan kota Surabaya yang diambil dari website BPS Jawa Timur. Pengambilan data IHK dilakukan dengan cara berbeda dengan data harga bahan pokok, yaitu secara langsung dengan cara mengunduh manual pada menu tabel dinamis pada website BPS dikarenakan BPS Jawa Timur tidak menyediakan layanan API untuk data IHK. Jika terdapat data yang tidak tersedia pada website BPS, maka dilakukan pengambilan data secara offline

vaitu observasi langsung ke perpustakaan BPS Jawa

Tabel 2.Data IHK Kota Surabaya

Bulan	2014	2015	2016	2017	2018
Januari	136,88	110,99	118,7 1	123,6 2	127,9 4
Maret	138,78	111,37	118,4 8	123,7 5	128,2 2
Mei	138,6	111,53	119,5	123,4 8	128,8 3
Juni	140,03	112,01	120,1 4	124,2 9	129,7 2
Agustus	146,25	113,58	121,7 3	125,1 3	129,9 1
Oktober	145,87	114,42	121,5 7	125,5 9	130,0 9
November	146,04	116,14	121,8 2	126,1 8	130,3 5
December	146,84	119	122,9 9	126,7 1	131,2 8

2.2. Pengolahan Data

kemudian disimpan dalam bentuk format CSV (Comma Tahap pengolahan data diperlukan untuk memastikan Separated Values) untuk diproses ke tahapan data yang akan masuk ke dalam sistem peramalan selanjutnya yaitu penggabungan dengan data IHK. sesuai format yang telah ditentukan. Dalam penelitian Tabel 1 menunjukkan contoh data harga bahan pokok ini keseluruhan data akan dikelompokkan dan yang akan diproses pada sistem prediksi yang dilabelkan ke dalam 29 variabel dimulai dari variabel dibangun. Data harga bahan pokok yang tercantum di X1 sampai dengan X29. Pada tiap variabel mewakili setiap bulannya merupakan hasil rata-rata dari harga nilai masukan dan keluaran dalam sistem peramalan. Tabel 3 merepresentasikan contoh detail variabel dan nilai yang diwakilinya. Label X1 merupakan data waktu diikuti dengan X2 yaitu data IHK, sedangkan untuk data harga pangan dimulai dari variabel X3 sampai dengan X29.

Tabel 3.Pelabelan Data Mentah

Variabel	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
X29	Buncis	7.214

Setelah melakukan pelabelan pada data mentah, langkah selanjutnya dalam proses pengolahan data yaitu melakukan teknik *minmaxscaler*. Teknik minmaxscaler [21] merupakan teknik yang digunakan untuk mengubah skala nilai menjadi lebih kecil tanpa melakukan modifikasi isi informasi di dalamnya dengan melakukan operasi perubahan skala dengan batas tepi atas 1 dan batas tepi bawah 0 (0,1). Alasan

dari digunakannya teknik minmaxscaler ini adalah Proses terakhir dalam tahap pengolahan data yaitu IHK sebagai nilai keluaran sistem peramalan.

Gambar 2 dan Gambar 3 menunjukkan contoh proses transformasi data IHK sebelum dan sesudah proses scaling(0,1). Terlihat data awal IHK nomor 1 yaitu 170.77 setelah proses scaling dengan teknik berubah menjadi 0.761. minmaxscaler Proses tranformasi keseluruhan data input dan output menggunakan teknik minmaxscaler otomatis dilakukan oleh sistem prediksi sebelum masuk ke model prediksi.

```
Using TensorFlow backend.
var35(t-1)
               var35(t)
170.779999
             175.880005
175.880005
            180.639999
180.639999
             178.300003
```

Gambar 2. Data IHK Sebelum Proses Scaling

```
Jsing TensorFlow backend
var35(t-1) var35(t)
  0.761491 0.832960
  0.832960 0.899664
  0.899664 0.866872
```

Gambar 3. Data IHK Setelah Proses Scaling

Data pada Tabel 4 merupakan dataset akhir setelah melalui berbagai proses pengolahan data yang tersimpan dalam format csv. Dataset dalam bentuk csv inilah yang akan diolah dalam sistem prediksi menggunakan algoritma MLP. Total jumlah data yang akan diolah ke dalam sistem prediksi berjumlah 60 data, sedangkan pada tiap data berisi 29 jenis variabel yang dipisahkan dengan pemisah tanda koma.

Tabel 4. Dataset Hasil Pengolahan Data

	<u> </u>
No Data	Keterangan
	2014-
	01,118.31,9823.87096774193,10775.48387096
	77,7905.8064516129,10497.4193548387,2493
	9.3548387097,11336.7741935484,91083.8709
	67742,27422.5806451613,48538.7096774194,
	17407.7419354839,28400,8274.1935483871,8
1	310.32258064516,27602.5806451613,30000,5
1	200,410000,3320,7169.03225806452,10914.83
	87096774,1800,26664.5161290323,24877.419
	3548387,19977.4193548387,9341.9354838709
	6,49058.064516129,16018.7096774194,16438.
	7096774193,3388.38709677419,5614.1935483
	871.9477.41935483871.8422.58064516129.77
	76.12903225806,7214.83870967742
	2018-
	12,141.69,12172.9032258065,12491.35483870
	97,9584.74193548387,10267.7419354839,272
	50.10193.5483870968.107429.774193548.344
	38.7096774194.70580.6451612903.25012.903
	2258065,29605.1612903226,9800,9900,40200,
	39000.7961.29032258064.1500.8000.8754.032
60	25806452,9020.16129032258,2300,25903.225
	8064516,26825.8064516129,26090.322580645
	2,19767.7419354839,72974.1935483871,1704
	5.1612903226,22793.5483870968,5264.51612
	903226,9767.74193548387,13061.2903225806
	.11316.1290322581.15696.7741935484.14529.
	0322580645
	U34430UU 1 3

sebagai solusi dari perbedaan nilai yang telalu jauh pembagian atau alokasi data menjadi 2 jenis yaitu data antara harga bahan pokok sebagai masukan dan nilai latih dan data uji. Data latih merupakan data yang dilatihkan kepada sistem untuk meningkatkan akurasi dalam melakukan proses peramalan. Sedangkan data uji merupakan data yang diujikan kepada sistem peramalan untuk mengukur akurasi yang telah dibangun. Komposisi pembagian data ini yaitu 21:39, dimana 21 data sebagai data latih, dan 39 data sebagai data uji yang dispesifikan pada Tabel 5.

Tabel 5.Pelabelan Data Mentah

No Data	Detail	Tipe Data
1-21	January 2014 – September 2015	Data Traning
22-39	October 2015 – December 2018	Data Testing

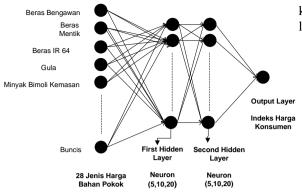
2.3. Pembangunan Model Peramalan Menggunakan Multilayer Perceptron

Algoritma yang digunakan dalam membangun sistem peramalan IHK vaitu Multilayer Perceptron yang dibandingkan dan dievaluasi berdasarkan hasil akurasi. Skenario evaluasi yang dibandingkan yaitu variasi hidden layer, neuron, dan epoch. Multilayer Perceptron 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 model yang dibangun [10]. Kunci dari algoritma Multilayer Perceptron yaitu adanya lebih dari beberapa neuron yang disebut perceptron yang terkoneksi satu sama lain kemudian setiap neuron menerima input dan melakukan operasi perkalian / dot product dengan memperhitungkan bobot dan bias di setiap layer yang dilewati. Setiap nilai neuron pada MLP dihitung berdasarkan rumus 1.

$$x_{ij} = f(W_i X_{i-1} + b_{i-1})$$
 (1)

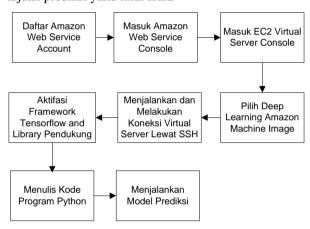
Penjelasan dari rumus 1 yaitu X_{ij} merupakan nilai setiap neuron j pada layer i, sedangkan W_i merepresentasikan bobot vektor setiap neuron j dari *layer i-1* sampai dengan *layer i*. Variabel X_{i-1} adalah nilai vektor dari keseluruhan neuron pada layer i-1. Sedangkan variabel b_{i-1} merupakan nilai bias pada layer i-1 [13]. Ketika bobot dan vektor telah dihitung maka akan dikalikan dengan variabel f. Variabel f merupakan nilai dari fungsi aktifasi sigmoid non linier yang dihitung dengan rumus 2 dimana e^x adalah fungsi MLP umumnya menggunakan ekponensial [13]. perhitungan fungsi aktifasi sigmoid non linier di hidden layer, sedangkan fungsi aktifasi linier digunakan pada perhitungan output layer sebagai tujuan hasil prediksi.

$$f(x) = sigmod(x) = \frac{1}{1+e^x}$$
 (2)



Gambar 4. Arsitektur Model Sistem Prediksi

Gambar 4 mengilustrasikan arsitektur dari algoritma yang dibangun dalam sistem prediksi IHK. Arsitektur MLP yang digunakan yang terdiri dari input layer, hidden layer, dan output layer. Input layer berisi Tabel 6 menjelaskan rincian kebutuhan hardware dan tujuan prediksi yaitu nilai IHK.



Gambar 5. Tahapan Pembangunan Model Pada DLAMI AWS Cloud

Gambar 5 menjelaskan langkah demi langkah tahapan pembangunan model prediksi dalam lingkungan AWS Sebelum menggunakan layanan AWS, pengguna diharuskan mendaftar dan masuk ke dalam sistem layanan AWS. Setelah masuk ke dalam AWS console, pengguna memilih layanan pembangunan virtual server EC2 dengan menggunakan pilihan image DLAMI. Ketika virtual server telah dibuat dan berjalan, pengguna mengakses virtual server tersebut menggunakan aplikasi remote server putty atau aplikasi remote yang telah disediakan oleh AWS. Setelah berhasil masuk ke dalam sistem virtual server, pengguna diharuskan mengaktifasi framework dan library yang dibutuhkan untuk menjalankan program prediksi yaitu Tensorflow dan Keras. Setelah

kebutuhan framework dan library telah terinstal lengkap, program berbahasa python dapat berjalan.

Tabel 6.Tabel Spesifikasi Software dan Hardware

Kebutuhan	Server	Spesifikasi
Hardware	vCPU	1
	Memoty (GiB)	1
	Processor	Intel Xeon clock speeds up to 3.3 GHz
Software	Sistem Operasi	Ubuntu Server 18.0
	Bahasa Pemrograman	Python
	Framework	Tensorflow
	Machine Learning API	Keras
	Library	Mathplotlib,
	Pendukung	Scikit-learn,
		Numpy, Pandas

28 jenis harga bahan pokok, hidden layer dengan software yang digunakan dalam pembangunan sistem variasi 1 sampai 2 dimana masing-masing layer terdiri prediksi IHK ini. Keseluruhan kebutuhan tersebut dari beberapa neuron dengan variasi berjumlah 5, 10, tersedia secara gratis jika memilih skema free tier dan 20. Layer terakhir yaitu output layer merupakan dalam layanan Cloud AWS. Layanan skema free tier adalah salah satu layanan AWS secara gratis dalam jangka waktu tertentu dengan batasan waktu yang digunakan.

2.4. Evaluasi

Tabel 7 menggambarkan skenario evaluasi algoritma Multilaver Perceptron yang telah dibangun. Konfigurasi input layer, output layer, jenis algoritma optimizer dan loss function yang digunakan adalah sama untuk setiap model, tetapi untuk jumlah hidden layer, jumlah neuron dan jumlah epoch dibedakan dan bervariasi. Skenario evaluasi digunakan untuk mencari kombinasi paling optimal dalam mendapatkan akurasi prediksi IHK.

Tabel 7.Skenario Evaluasi

Jenis Konfigurasi	Detail			
Input Layer	28 jenis harga bahan pokok			
Variasi Hidden Layer	1,2			
Output Layer	IHK			
Variasi Jumlah Epoch	1000, 2000, 3000			
Optimizer	Nadam (Nesterov Adam)			
Variasi Jumlah Neuron	5, 10, 20			

Pengukuran tingkat akurasi yang digunakan dalam bisa melalui remote server jalur SSH (Secure Shell) penelitian ini yaitu RMSE (Root Mean Square Error) dimana mencari nilai kesalahan antara nilai aktual dan prediksi yang dihitung dengan rumus 3. Perhitungan RMSE yaitu operasi mengkuadratkan nilai error Yi - Ydimana Yi merupakan nilai aktual, sedangkan Y adalah nilai hasil prediksi [22]. Hasil Operasi tersebut kemudian dibagi dengan banyaknya data lalu diakarkan.

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(Yi - Y)^2}$$
 (3)

3. Hasil dan Pembahasan

Tabel 8 menginformasikan hasil pengujian yang telah dilakukan sesuai dengan rancangan skenario pengujian. Terdapat 39 hasil nilai RMSE yang didapatkan yang mewakili setiap skenario pengujian. Pada kolom Konfigurasi Jumlah Neuron, 3 data pertama berisi jumlah neuron dalam satu hidden layer. Sedangkan pada data keempat dan seterusnya, konfigurasi kombinasi 2 angka dipisahkan dengan tanda strip seperti 5-5 menunjukkan bahwa terdapat jumlah 5 neuron pada hidden layer pertama dan 5 neuron pada mempengaruhi akurasi model yang dibangun yang hidden laver kedua.

Tabel 8. Nilai RMSE

Jumlah Hidden	Konfigurasi Jumlah	1000 Enoch	2000 Enoch	3000 Enoch
Layer	Neuron	Epoch	Epoch	Epoch
	5	3.754	7.399	6.451
1	10	7.933	5.685	7.024
	20	7.024	5.471	6.002
	5-5	4.416	4.376	4.574
	5-10	3.736	4.733	4.722
	5-20	5.790	4.683	5.290
	10-5	5.158	5.166	5.265
2	10-10	3.380	6.964	4.880
	10-20	5,657	7.908	10.995
	20-5	3.526	4.030	5.385
	20-10	5.190	5.216	3.913
	20-20	8.670	5.719	4.988

Dari hasil pengujian pada Tabel 8 didapatkan hasil rentang nilai RMSE, dimana semakin kecil nilai RMSE maka hasil prediksi akan semakin akurat. Berdasarkan hasil pengujian, didapatkan RMSE terkecil dengan nilai 3.380 dihasilkan oleh konfigurasi 2 hidden layer, dimana hidden layer pertama dan kedua mempunyai neuron masing-masing berjumlah 10 dengan epoch sebesar 1000. Sedangkan nilai RMSE terbesar yaitu dengan nilai 10.995 dihasilkan oleh konfigurasi 2 hidden layer, neuron pada hidden layer pertama berjumlah 10 dan neuron pada hidden layer kedua berjumlah 20 dengan epoch sebesar 3000.

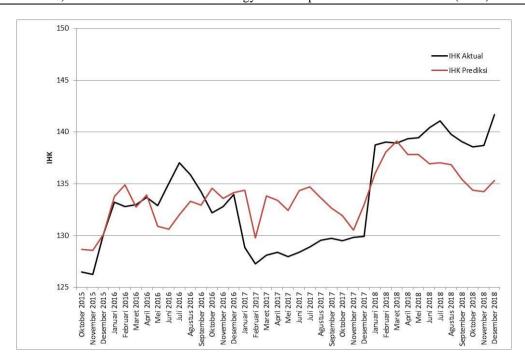
dibuktikan dengan semakin bertambahnya nilai RMSE seiring dengan bertambahnya nilai epoch.

pengaruh bertambahnya jumlah bertambahnya jumlah hidden layer juga menjadi perhatian peneliti. Pada konfigurasi yang memiliki 1 hidden layer, nilai RMSE terbaik yang dihasilkan yaitu 3.754. Sedangkan pada konfigurasi 2 hidden layer nilai RMSE terbaik yaitu 3.380 sehingga membuktikan banyak hidden laver kemungkinan meningkatnya akurasi juga semakin tinggi.

pada Berdasarkan hasil pengujian Tabel bertambahnya jumlah hidden layer dan neuron tidak dibuktikan dengan nilai RMSE yang dihasilkan. Ketika jumlah hidden layer atau neuron ditambah akurasi bisa menjadi lebih tinggi, namun ketika jumlah neuron atau hidden layer semakin banyak akurasi belum tentu semakin baik lagi. Salah satu kekurangan dari algoritma Multilayer Perceptron yang penulis temukan dalam penelitian ini yaitu nilai RMSE yang dihasilkan berubah-ubah setiap menjalankan program prediksi pada konfigurasi yang sama. Hal ini dikarenakan nilai optimasi RMSE pada Multilayer Perceptron hanya maksimal pada nilai local optimum yang menyebabkan nilai RMSE belum stabil dan tidak bisa mencapai titik global optimum seperti algoritma lain yaitu SVR. Oleh karena itu, perlu dilakukan beberapa pengujian ulang untuk menentukan nilai RMSE terbaik untuk setiap skenario yang membuat pengujian menjadi tidak efektif dan efisien karena pengujian yang berulang-ulang untuk setiap skenario.

Gambar 6 mengilustrasikan plot perbandingan nilai aktual IHK dan hasil prediksi sistem menggunakan algoritma Multilayer Perceptron dengan konfigurasi yang menghasilkan nilai RMSE terkecil yaitu 3.380. Sumbu x merupakan data bulan, sedangkan sumbu y merupakan nilai IHK. Garis plot berwarna merah adalah data prediksi, sedangkan plot berwarna hitam adalah grafik IHK aktual. Terlihat beberapa nilai prediksi telah berhasil meprediksi nilai aktual yaitu pada bulan Desember 2015, Januari 2016, dan April 2016.

Pada beberapa konfigurasi pengujian, banyaknya nilai Pada bulan Januari 2017 - September 2017 dan Mei epoch mempengaruhi tingkat akurasi yang dihasilkan. 2018 - Desember 2018 hasil prediksi berbeda jauh Pada skema 2 hidden layer dengan jumlah neuron pada dengan nilai aktual yang bisa disebabkan oleh nilai hidden layer pertama 5 dan jumlah neuron di hidden IHK aktual pada bulan Desember 2016 ke Januari 2017 layer kedua 10, serta skema 2 hidden layer dengan mengalami penurunan secara drastis yaitu dari 133 ke jumlah neuron pada hidden layer pertama 20 dan 128. Sistem prediksi yang dibangun masih belum hidden layer kedua 20, akurasi yang dihasilkan mampu mengikuti perubahan nilai data secara semakin baik yaitu nilai RMSE yang semakin menurun signifikan pada data aktual. Begitu juga dengan nilai seiring dengan bertambahnya jumlah epoch. Sedangkan prediksi IHK pada bulan Mei 2018 – Desember 2018, skema 2 hidden layer dengan jumlah neuron pada terjadi perubahan secara signifikan pada IHK aktual hidden layer pertama 10 dan hidden layer kedua 20, pada bulan Desember 2017 ke Januari 2018 yaitu serta skema 2 hidden layer dengan jumlah neuron pada terjadi kenaikan IHK yaitu dari 129. ke 138. Faktor hidden layer pertama 20 dan hidden layer kedua 5, lain yang dapat mempengaruhi kurang optimalnya akurasi yang dihasilkan semakin tidak bagus yang prediksi yaitu terbatasnya data sumber menyebabkan.



Gambar 6. Plot Perbandingan Nilai Aktual dan Prediksi IHK

[1]

jumlah data training dan testing yang diolah ke dalam Daftar Pustaka sistem menjadi tidak optimal

4. Kesimpulan

Peramalan berbasis *multivariabel* memungkinkan peneliti melakukan prediksi dengan mempertimbangkan seluruh variabel yang berpengaruh pada variabel tujuan sehingga diharapkan tingkat [2] akurasi akan semakin tinggi. Pembangunan model prediksi IHK ini mengimplementasikan konsep Deep Learning dimana menekankan pada eksplorasi banyaknya layer, neuron dan epoch. Dari hasil pengujian, akurasi terbaik dengan nilai RMSE 3.380 dihasilkan oleh konfigurasi 2 hidden layer, hidden layer pertama dan kedua mempunyai masing-masing berjumlah 10 dengan *epoch* sebesar 1000. Penelitian ini [3] juga menyimpulkan bahwa banyaknya jumlah hidden layer, epoch dan neuron tidak menjamin meningkatnya tingkat akurasi. Untuk pengembangan penelitian kedepan, diharapkan jumlah data yang diolah menjadi lebih banyak dan dilakukan evaluasi yang lebih [4] mendalam dari segi nilai batch size, jenis optimasi, algoritma Dep Learning lain maupun kombinasi hybrid antar metode.

Ucapan Terimakasih

Penelitian ini didukung dan didanai oleh Direktorat [5] Riset dan Pengabdian Masyarakat, Direktorat Jenderal Penguatan Riset dan Pengembangan Kementerian Riset, Teknologi, dan Pendidikan Tinggi Republik Indonesia.

- 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]. http://fe.budiluhur.ac.id/wp-Available: content/uploads/2017/08/b.-berlian.pdf.
- A. Wanto and A. P. Windarto, "Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation," J. Penelit. Tek. Inform. Sink., vol. 2, no. 2, pp. 37-43, 2017, [Online]. Available: https://zenodo.org/record/1009223#.Wd7norlT bhO.
- A. S. Ahmar et al., "Implementation of the ARIMA(p,d,q) method to forecasting CPI Data using forecast package in R Software," J. Phys. Conf. Ser., vol. 1028, no. 1, 2018, doi: 10.1088/1742-6596/1028/1/012189.
- D. A. Lubis, M. B. Johra, and G. Darmawan, "Peramalan Indeks Harga Konsumen dengan Metode Singular Spectral Analysis (SSA) dan Seasonal Autoregressive Integrated Moving Average (SARIMA)," J. Mat. "MANTIK," vol. no. 2, pp. 74–82, 2017, 10.15642/mantik.2017.3.2.74-82.
- A. Wibowo, "Model Peramalan Indeks Harga Konsumen Kota Palangka Raya Menggunakan Seasonal ARIMA (SARIMA)," J. Mat., vol. 17, 2. 17-24,pp. 2018, doi: no. 10.29313/jmtm.v17i2.3981.
- [6] K. Dewi, P. P. Adikara, and S. Adinugroho,

- "Prediksi Indeks Harga Konsumen (IHK) Kelompok Perumahan, Air, Listrik, Gas Dan Bahan Bakar Menggunakan Metode Support Vector Regression," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 10, pp. 3856– [15] 3862, 2018.
- [7] H. Ramchoun, M. Amine, J. Idrissi, Y. Ghanou, and M. Ettaouil, "Multilayer Perceptron: Architecture Optimization and Training," *Int. J. Interact. Multimed. Artif. Intell.*, vol. 4, no. 1, p. [16] 26, 2016, doi: 10.9781/ijimai.2016.415.
- [8] F. R. Lima-Junior and L. C. R. Carpinetti, "Predicting supply chain performance based on SCOR ® metrics and multilayer perceptron neural networks," *Int. J. Prod. Econ.*, vol. 212, [17] no. February, pp. 19–38, 2019, doi: 10.1016/j.ijpe.2019.02.001.
- [9] K. Halawa, M. Bazan, P. Ciskowski, T. Janiczek, P. Kozaczewski, and A. Rusiecki, "Road traffic predictions across major city [18] intersections using multilayer perceptrons and data from multiple intersections located in various places," *IET Intell. Transp. Syst.*, vol. 10, no. 7, pp. 469–475, 2016, doi: 10.1049/ietits.2015.0088.
- [10] I. Oktavianti, "Analisis Pola Prediksi Data [19] Time Series menggunakan Support Vector Regression, Multilayer Perceptron, dan Regresi Linear Sederhana," *J. Resti*, vol. 1, no. 10, pp. 282–287, 2019.
- [11] S. Sen, D. Sugiarto, and A. Rochman, [20] "Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras," *J. Ultim.*, vol. XII, no. 1, pp. 35–41, 2020.
- [12] C. O. Sakar, S. O. Polat, M. Katircioglu, and Y. [21] Kastro, "Real-time prediction of online shoppers' purchasing intention using multilayer perceptron and LSTM recurrent neural networks," *Neural Comput. Appl.*, vol. 31, no. 10, pp. 6893–6908, 2019, doi: 10.1007/s00521-018-3523-0.
- [13] P. Zhang, Y. Jia, J. Gao, W. Song, and H. [22] Leung, "Short-Term Rainfall Forecasting Using Multi-Layer Perceptron," *IEEE Trans. Big Data*, vol. 6, no. 1, pp. 93–106, 2018, doi: 10.1109/tbdata.2018.2871151.
- [14] Q. Chen, W. Zhang, and Y. Lou, "Forecasting Stock Prices Using a Hybrid Deep Learning Model Integrating Attention Mechanism,

- Multi-Layer Perceptron, and Bidirectional Long-Short Term Memory Neural Network," *IEEE Access*, vol. 8, pp. 117365–117376, 2020, doi: 10.1109/ACCESS.2020.3004284.
- I. A. T. Hashem, I. Yaqoob, N. B. Anuar, S. Mokhtar, A. Gani, and S. Ullah Khan, "The rise of 'big data' on cloud computing: Review and open research issues," *Inf. Syst.*, vol. 47, pp. 98–115, 2015, doi: 10.1016/j.is.2014.07.006.
- C. Yang, Q. Huang, Z. Li, K. Liu, and F. Hu, "Big Data and cloud computing: innovation opportunities and challenges," *Int. J. Digit. Earth*, vol. 10, no. 1, pp. 13–53, 2017, doi: 10.1080/17538947.2016.1239771.
- B. Varghese and R. Buyya, "Next generation cloud computing: New trends and research directions," *Futur. Gener. Comput. Syst.*, vol. 79, pp. 849–861, 2018, doi: 10.1016/j.future.2017.09.020.
- P. Pierleoni, R. Concetti, A. Belli, and L. Palma, "Amazon, Google and Microsoft Solutions for IoT: Architectures and a Performance Comparison," *IEEE Access*, vol. 8, pp. 5455–5470, 2020, doi: 10.1109/ACCESS.2019.2961511.
- T. M. Madhyastha *et al.*, "Running neuroimaging applications on Amazon Web Services: How, when, and at what cost?," *Front. Neuroinform.*, vol. 11, no. November, pp. 1–15, 2017, doi: 10.3389/fninf.2017.00063. G. Portella, G. N. Rodrigues, E. Nakano, and A. C. M. A. Melo, "Statistical analysis of Amazon EC2 cloud pricing models," *Concurr. Comput.*, vol. 31, no. 18, pp. 1–15, 2019, doi: 10.1002/cpe.4451.
- S. Mezzatesta, C. Torino, P. De Meo, G. Fiumara, and A. Vilasi, "A machine learning-based approach for predicting the outbreak of cardiovascular diseases in patients on dialysis," *Comput. Methods Programs Biomed.*, vol. 177, pp. 9–15, 2019, doi: 10.1016/j.cmpb.2019.05.005.
- H. Turabieh, "A Hybrid ANN-GWO Algorithm for Prediction of Heart Disease," *Am. J. Oper. Res.*, vol. 06, no. 02, pp. 136–146, 2016, doi: 10.4236/ajor.2016.62016.