

Implementasi Jaringan Syaraf Tiruan untuk Memprediksi Inflasi Bulanan di Kota Malang

Mohamad As'ad dan Eni Farida

STMIK Pradnya Paramita Malang

Jl. LA Sucipto No. 249A Malang

E-mail:asad@stimata.ac.id, enistimata@gmail.com

Abstrak

Pertumbuhan ekonomi di kota Malang semakin baik, hal ini terlihat dari aktifitas perekonomian di kota Malang yang semakin ramai, apalagi akan ada akses jalan tol dari Surabaya langsung Malang. Peningkatan perekonomian ini perlu dilakukan perencanaan yang baik untuk periode kedepan. Perekonomian yang baik biasanya di ikuti oleh inflasi yang stabil. Secara teori, terjadinya deflasi (inflasi yang menurun hingga minus) akan menekan pertumbuhan ekonomi dan inflasi yang terlalu tinggi juga berakibat daya beli masyarakat menurun. Itu berarti ekonomi dalam keadaan tidak bagus, untuk itu perlu diteliti bagaimana tingkat inflasi bulanan untuk periode yang akan datang di kota Malang. Penelitian ini dilakukan di kota Malang (kampus STMIK Pradnya Paramita) dan mempunyai tujuan untuk melakukan peramalan nilai inflasi bulanan beberapa periode kedepan, dengan model yang berbeda dilakukan oleh BPS. Data inflasi sekunder diperoleh dari BPS kota Malang dan peramalan menggunakan model Jaringan Syaraf Tiruan (JST). Penelitian ini menggunakan model JST neural network autoregressive (NNAR) dengan hasil akhir model NNAR(2,6). Pengolahan data pada penelitian ini menggunakan R package statistics yang merupakan open source program. NNAR(2,6) mempunyai arti model JST ini mempunyai input data inflasi lag-1 dan lag-2 dengan 6 neuron single hidden layer. Hasil penelitian ini menunjukkan bahwa inflasi untuk sebelas bulan (Februari 2019-Desember 2019) yang akan datang relatif stabil, tidak ada kenaikan atau penurunan yang sangat tajam.

Kata Kunci : Inflasi kota Malang, BPS Kota Malang, Jaringan Syaraf Tiruan

Pendahuluan

Perencanaan merupakan hal penting yang perlu dilakukan untuk merencanakan tindakan di masa yang akan datang. Perencanaan membutuhkan data perkiraan (prediksi data) untuk menentukan rencana apa yang akan dilakukan atau persiapan apa yang harus dilakukan supaya kita lebih siap menghadapi yang akan terjadi.

Kota Malang merupakan kota besar kedua di Jawa Timur setelah kota Surabaya. Aktifitas kota pelajar ini sangat sibuk sekali ketika bukan hari libur panjang dan ini merupakan pasar yang potensial bagi banyak sektor ekonomi di kota Malang. Sektor-sektor yang mendukung diantaranya adalah sektor ritel (perdagangan kecil (toko-toko) dan besar (mall-mall)), akomodasi (kost-kostan), hotel atau home stay, transportasi, kuliner, wisata dan lain-lainnya. Dengan banyaknya sektor yang terlibat, artinya uang yang beredar di kota Malang semakin besar. Sektor-sektor yang mendukung ini akan meningkatkan pertumbuhan ekonomi kota Malang. Pertumbuhan ekonomi ini juga dipengaruhi oleh tingkat inflasi baik global (Indonesia) maupun regional (kota Malang). Tingkat inflasi ini perlu juga diprediksi sebagai indikator perekon-

mian yang akan datang apakah mengalami kenaikan atau penurunan.

Secara teori ekonomi, terjadinya deflasi (inflasi yang menurun hingga minus) akan menekan pertumbuhan ekonomi dan inflasi yang terlalu tinggi juga berakibat daya beli masyarakat menurun yang berakibat roda ekonomi tidak berjalan. Prediksi inflasi selalu di kalkulasi oleh Badan Pusat Statistik secara global maupun regional. BPS kota Malang juga melakukan kalkulasi inflasi untuk kota Malang (lokal) secara periodik, kalkulasi yang dilakukan dengan menggunakan rumusan yang telah ditetapkan oleh BPS.

Perhitungan inflasi secara umum dilakukan dengan membandingkan perubahan index harga konsumen (IHK periode sekarang dengan yang lalu) dibanding dengan IHK periode yang lalu. Cara lain untuk menghitung inflasi adalah dengan Product Domestic Bruto (PDB) atau Pendapatan Asli Daerah (PAD) dengan cara membandingkan perubahan PDB Deflator (PDB Deflator sekarang dikurangi PDB Deflator yang lalu) dengan PDB Deflator periode yang lalu [1].

Naiknya harga barang dan jasa tersebut menyebabkan turunnya nilai uang. Dengan demikian, inflasi dapat juga diartikan sebagai penurunan ni-

lai uang terhadap nilai barang dan jasa secara umum [2]. Hasil perhitungan dengan metode di atas hanya bisa digunakan untuk mengetahui inflasi periode sekarang [3]. Bagaimana caranya untuk memprediksi inflasi periode-periode yang akan datang dapat dilakukan dengan metode statistika melalui model-model time series.

Secara Umum metode statistika dengan model-model time series dapat digunakan untuk memprediksi inflasi untuk periode mendatang, hal ini bisa digunakan untuk prediksi, perencanaan manajerial atau hal-hal lain yang membutuhkan prediksi inflasi yang akan datang. Model time series yang digunakan dalam memprediksi inflasi yang akan datang dipilih model yang paling sederhana dan yang mudah serta mempunyai ketepatan atau presisi yang tinggi. Selanjutnya model time series yang mana akan digunakan untuk meramalkan inflasi yang akan datang di kota Malang yaitu model Jaringan Syaraf Tiruan (JST). Pemilihan model JST ini dilakukan atas dasar tidak adanya asumsi normalitas sisaan dan white noise seperti pada model-model autoregressive, hal ini berarti prediksi inflasi untuk periode yang akan datang dapat dilakukan dengan Jaringan Syaraf Tiruan.

Metode Penelitian

Kerangka Konsep Penelitian

Kerangka konsep penelitian dapat digambarkan pada Gambar 1.



Gambar 1: Kerangka Konsep Penelitian

Berdasarkan kerangka konsep penelitian pada Gambar 1, dapat dijelaskan sebagai berikut : Input berupa data inflasi bulanan kota Malang, kotak proses berupa black box jaringan syaraf tiruan untuk proses time series dan output berupa hasil peramalan inflasi bulanan kota Malang untuk periode yang akan datang.

Data Inflasi

Penelitian ini menggunakan data sekunder berupa data inflasi bulanan yang di dapat dari Badan Pusat Statistik (BPS) kota Malang. Data yang diolah yaitu data sekunder inflasi bulanan kota Malang dari bulan Januari 2011 sampai dengan Januari 2019 yang berarti terdapat 97 data.

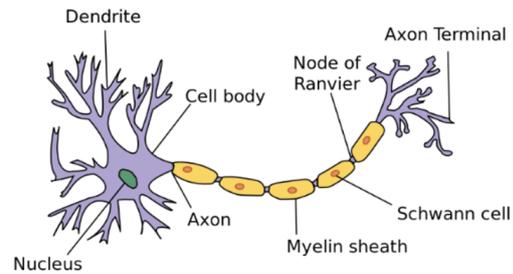
Tahap Penelitian

Setelah kerangka konsep penelitian di buat dan data inflasi sebagai input juga sudah siap, berikutnya

langkah untuk melakukan prediksi dengan menggunakan jaringan syaraf tiruan dilakukan. Prediksi inflasi yang akan terjadi menggunakan jaringan syaraf tiruan dengan bantuan software **R** package statistics.

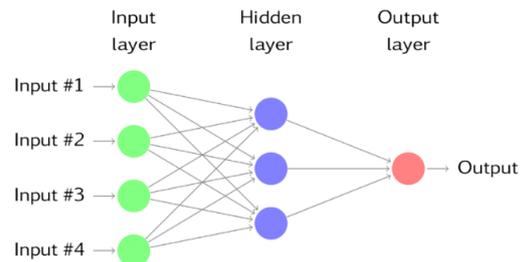
Arsitektur Jaringan Syaraf Tiruan

Pada penelitian ini menggunakan arsitektur jaringan syaraf tiruan. Jaringan syaraf yang sesungguhnya pada manusia dapat dilihat pada Gambar 2.



Gambar 2: Struktur dasar jaringan syaraf manusia[4]

Pada model JST yang digunakan meniru struktur dasar jaringan syaraf manusia seperti pada Gambar 2. Model arsitektur JST ada dua model yang cukup terkenal yaitu JST single layer (layar tunggal) dan JST multi layer (layar jamak). Pada penelitian ini menggunakan JST single layer (Model Neural Network Autoregression atau NNAR). Model NNAR single layer digunakan dalam penelitian ini dikarenakan data inflasi bulanan ini merupakan model ekonometrik linier. Untuk model ekonometrik non-linier bisa digunakan model Multilayer Feed Forward Neural Network (MLFFNN) [5]. Struktur JST dapat dilihat pada Gambar 3.



Gambar 3: JST dengan 4 input 1 hiden layer dan 3 neuron[6].

Gambar 3 merupakan single layer feed-forward network, dimana setiap titik pada layer menerima input dari layer sebelumnya [6].

Model Backpropogation

Merupakan metode pembelajaran (pelatihan) terawasi (supervised learning) yang paling banyak di 102

gunakan dalam membangun sistem jaringan syaraf tiruan. Model backpropogation ini merupakan model yang cukup baik karena kemampuannya mengenali pola yang cukup kompleks. Pelatihan menggunakan backpropagation meliputi tiga tahap yaitu umpan maju (feedforward) dari pola input, penghitungan error dan penyesuaian bobot-bobot. Pada model ini, input setiap note merupakan kombinasi linier terboboti. Hasil kombinasi linear terboboti tersebut dimodifikasi oleh fungsi nonlinier menjadi output dari JST. Fungsi kombinasi linier dapat ditulis sebagai :

$$z_j = b_j + \sum_{i=1}^4 w_{i,j} x_i \tag{1}$$

dimana, z_j adalah fungsi penjumlahan pada unit bias ke_j pada hidden layer, b_j adalah bobot pada unit bias ke j , $w_{i,j}$ adalah bobot pada lapisan ke i bias ke j , x_i adalah input jaringan ke i . Fungsi aktifasinya merupakan fungsi nonlinier berupa fungsi sigmoid biner dan ditulis sebagai :

$$s(z) = \frac{1}{1+e^{-z}} \tag{2}$$

Persamaan 2 ini merupakan fungsi dari z diatas, dimana fungsi sigmoid ini merupakan bagian dari fungsi aktivasi backpropogation pada model jaringan single layer [6].

Neural Network Autoregression (NNAR)

NNAR yang perkenalkan oleh Hyndman dan Athanasopoulos di tahun 2018 dengan program aplikasinya R package program statistics pada package “forecast” dengan function nnetar. Model NNAR ini merupakan model JST spesial untuk peramalan data time series. Model ini hanya diperuntukkan untuk jaringan feed-forward pada single hidden-layer dan dinotasikan dengan NNAR(p,k), dimana p menunjukkan lag- p sebagai input dan k sebagai notes pada hidden layer. NNAR ini menggunakan single hidden layer seperti pada gambar 3 diatas dan menggunakan fungsi nonlinier seperti pada persamaan 1 untuk memboboti dan menghasilkan output dari JST. Fungsi aktifasinya menggunakan fungsi aktivasi sigmoid seperti pada persamaan 2 diatas. Penelitian ini menggunakan model ini dengan function nnetar pada R package statistics [6].

Akurasi Peramalan

Untuk mengetahui model mana yang baik dan akan digunakan dalam peramalan akan diukur dengan mean absolute square error (MASE), mean absolute percentage error (MAPE) dan root mean square error (RMSE). Perhitungan dari ketiga akurasi tersebut seperti berikut [7,8]:

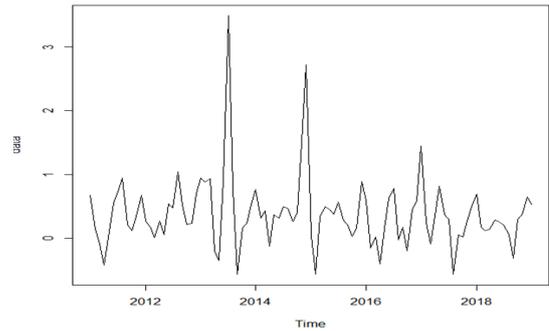
$$MASE = \frac{\sum_{i=1}^n |e_i|^2}{n} \tag{3}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{y_i} \right| \tag{4}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \tag{5}$$

Hasil dan Pembahasan

Plot time series data inflasi bulanan diberikan dalam Gambar 4.

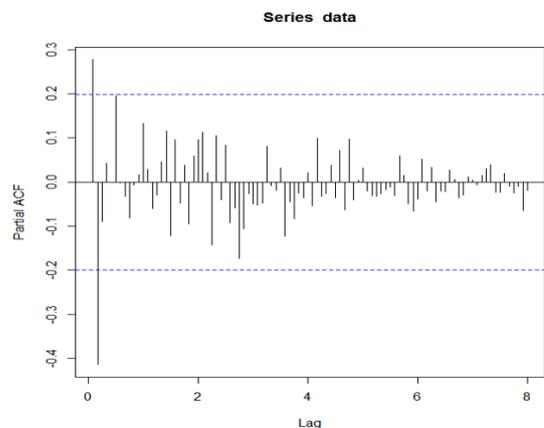


Gambar 4: Plot time series data inflasi bulanan di kota Malang (Jan 2011-Jan 2019).

Membangun JST berdasarkan gambar plot time series diatas nampaknya ada pola autoregressive atau lag data, sesuai dengan prosedur model NNAR dilakukan hal sebagai berikut :

a. Penentuan input jaringan

Untuk menentukan input jaringan dengan melakukan plot partial autocorelation (PACF) terhadap data inflasi bulanan di kota Malang, apakah data memang mengandung lag-lag (berautokorelasi) dengan data sebelumnya[8]. Hasilnya disajikan pada Gambar 5.



Gambar 5: Plot PACF data inflasi bulanan di kota Malang.

Tampak bahwa terdapat proses autoregressive pada lag 1 dan 2. Selanjutnya sebagai input yaitu data inflasi bulanan pada lag 1 dan lag 2.

b. Data Training

Untuk memodelkan JST yang baik dilakukan training atau pelatihan untuk mendapatkan model yang baik [9]. Ada beberapa kreteria yang diamati untuk mendapatkan model training yang baik berdasarkan model supervised backpropogation diantaranya adalah nilai error (kesalahan peramalan) yang kecil. Sebagai sampel data training (diambil secara acak) digunakan data sebanyak 48 data dari 97 data inflasi bulanan kota Malang. Hasil perhitungannya disajikan dalam Tabel 1.

c. Data Testing

Data testing yang digunakan (diambil secara acak) sebanyak 48 dari 97 data inflasi bulanan kota Malang, hal ini dilakukan karena data yang tersedia hanya 97 data dan antara data training dan data testing sebaiknya seimbang jumlahnya karena merupakan sampel yang diambil untuk membangun model dan sekaligus memvalidasi model tersebut[10]. Kreteria yang dipakai untuk menentukan model yang di test sama dengan kreteria pada model training adalah error yang terkecil yaitu root mean square error (RMSE), hal ini dilakukan karena RMSE atau MSE (Mean Square Error) pada umumnya digunakan sebagai kreteria perbandingan untuk mendapatkan model yang tentatif (sementara). Selain itu RMSE atau MSE ini merupakan default banyak software (termasuk R package staistics) sebagai kreteria perbandingan dalam memilih model (tentatif) yang didapat. Berikut hasil seleksi model pada training model dan testing model disajikan padaTabel 1.

Tabel 1: Nilai MSE pada Model Training dan Testing.

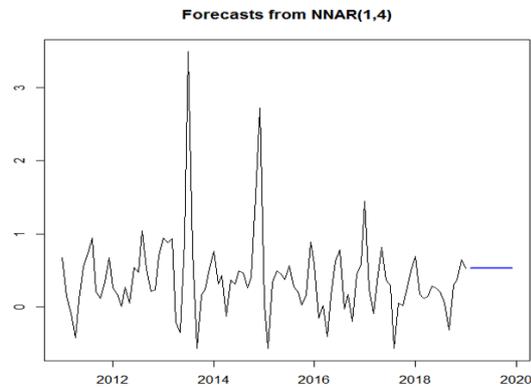
| Model | Neuron | RMSE | |
|-----------|--------|-----------|-----------|
| | | Training | Testing |
| NNAR(1,2) | 2 | 0.6559133 | 0.3372085 |
| NNAR(1,3) | 3 | 0.5441751 | 0.4493841 |
| NNAR(1,4) | 4 | 0.3070252 | 0.3563636 |
| NNAR(1,5) | 5 | 0.3964338 | 0.4256627 |
| NNAR(1,6) | 6 | 0.4334276 | 0.5128435 |
| NNAR(2,2) | 2 | 0.3223032 | 0.5311221 |
| NNAR(2,3) | 3 | 0.3066832 | 0.3071025 |
| NNAR(2,4) | 4 | 0.2906806 | 0.2496885 |
| NNAR(2,5) | 5 | 0.2559133 | 0.2056445 |
| NNAR(2,6) | 6 | 0.2296885 | 0.2513572 |
| NNAR(2,7) | 7 | 0.3410938 | 0.2259551 |

Dari Tabel 1, pada model NNAR(1,4) mempunyai nilai RMSE terkecil untuk training (0.3070252) dan testing (0.3563636) pada lag-1, sedang pada lag-2 untuk training (0.2296885) nilai terkecil

pada model NNAR(2,6) sedang untuk testing (0.2056445) terkecil pada model NNAR(2,5). Dari nilai RMSE terkecil untuk training dan testing serta untuk kedua lag-1 dan lag-2, maka model yang dipakai untuk peramalan sebelas bulan kedepan (Februari 2019- Desember 2019) dari bulan Januari 2019 adalah model : NNAR(1,4), NNAR(2,5) dan NNAR(2,6). Dari ketiga model tersebut dipakai untuk peramalan dan yang akan digunakan adalah model yang mempunyai RMSE, MAPE dan MASE terkecil.

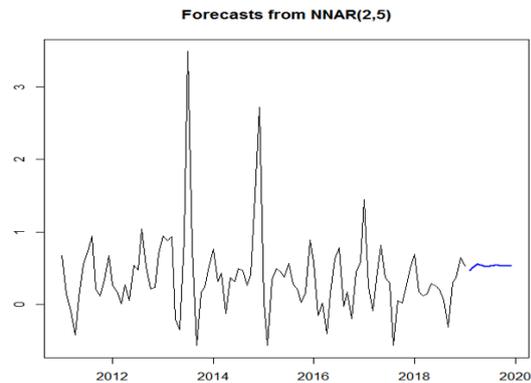
d. Model Peramalan

Peramalan nilai inflasi untuk bulan Februari 2019 – Desember 2019 akan dilakukan terhadap ketiga model yaitu NNAR(1,4), NNAR(2,5), dan NNAR(2,6). Hasil peramalannya pada gambar 6, gambar 7 dan gambar 8 dan nilai akurasi akan ditampilkan dalam Tabel 2.



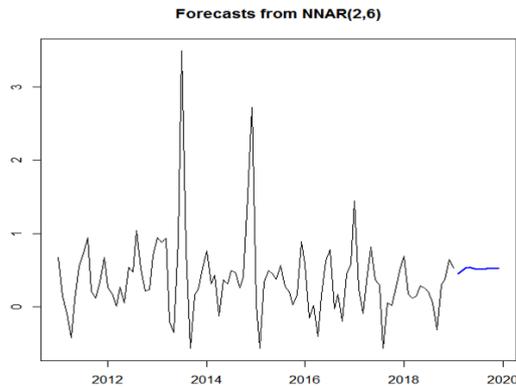
Gambar 6: Model NNAR(1,4)

Pada Gambar 6, hasil peramalan sebelas periode kedepan (Februari-Desember) tampak garis lurus datar yang berarti inflasi yang akan datang bersifat konstan. Hasil tersebut menurut peneliti kurang masuk akal karena inflasi sebelumnya tidak pernah konstan dan juga pada bulan Mei-Juni merupakan bulan puasa dan lebaran yang selalu terjadi fluktuasi inflasi.



Gambar 7: Model NNAR(2,5)

Pada Gambar 7, peramalan sebelas bulan kedepan tampak ada fluktuasi kecil, tetapi agak stabil karena tidak ada nilai ramalan yang naik atau turun drastis.



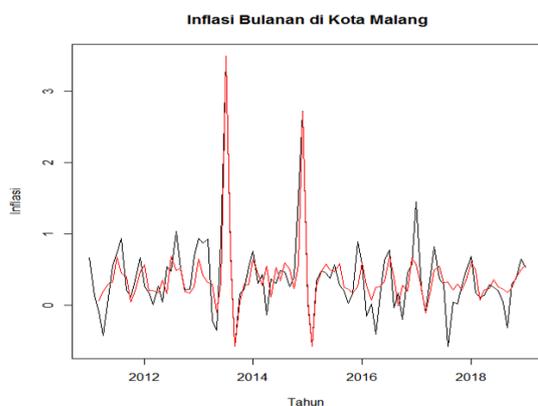
Gambar 8: Model NNAR(2,6)

Pada Gambar 8 hampir mirip seperti Gambar 7 yaitu berfluktuasi kecil dan stabil karena tidak ada nilai ramalan yang naik atau turun drastis. Untuk mengetahui model mana yang baik dapat dilakukan perbandingan nilai kriteria akurasi peramalan. Akurasi peramalan (MAPE, MASE dan RMSE) nilainya akan di sajikan dalam Tabel 2.

Tabel 2: Nilai akurasi peramalan untuk ketiga model

| Model | MAPE | MASE | RMSE |
|-----------|----------|-----------|-----------|
| NNAR(1,4) | 147.61 | 0.6358751 | 0.4581456 |
| NNAR(2,5) | 132.2376 | 0.4808339 | 0.3095238 |
| NNAR(2,6) | 130.6615 | 0.4697471 | 0.3066760 |

Tampak pada Tabel 2 nilai akurasi terkecil ada pada model NNAR(2,6), sehingga model ini nanti yang akan dipakai untuk meramalkan nilai inflasi bulanan kota Malang.



Gambar 9: Plot Inflasi dan hasil peramalan dari Model NNAR(2,6)

e. Hasil Peramalan

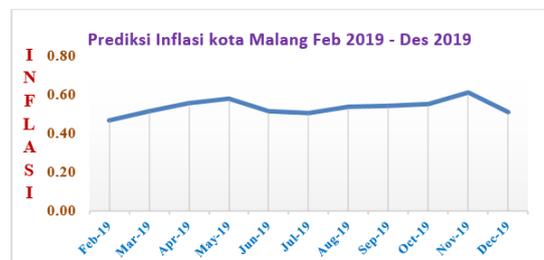
Model peramalan yang terpilih selanjutnya dibuat untuk peramalan. Hasil peramalan akan ditampilkan dalam bentuk gambar 9 dan nilai peramalan sebelas bulan kedepan akan disajikan pada tabel 3 berikut :

Gambar 9 menunjukkan nilai inflasi data BPS kota Malang dari bulan Januari 2011 sampai dengan Januari 2019 dan juga hasil peramalan dengan model NNAR(2,6).

Tabel 3: Nilai peramalan inflasi bulanan kota Malang sebelas bulan kedepan tahun 2019.

| | | | |
|---------|----------|-----------|---------|
| Bulan | Februari | Maret | April |
| Inflasi | 0.4529 | 0.4828 | 0.5310 |
| Bulan | Mei | Juni | Juli |
| Inflasi | 0.5392 | 0.5200 | 0.5096 |
| Bulan | Agustus | September | Oktober |
| Inflasi | 0.5146 | 0.5212 | 0.5215 |
| Bulan | November | Desember | |
| Inflasi | 0.5185 | 0.5173 | |

Tabel 3 menunjukkan prediksi nilai inflasi bulanan untuk sembilan bulan mendatang yaitu bulan Februari 2019 sampai dengan Desember 2019. Hasil ramalan untuk tabel 3 diatas jika disajikan dalam grafik ada pada Gambar 10.



Gambar 10: Grafik prediksi inflasi bulanan kota Malang

Data tersebut menunjukkan bahwa inflasi berfluktuasi seperti yang disajikan dalam grafik pada Gambar 9 dan dapat diartikan perekonomian di kota Malang untuk sebelas bulan kedepan di prediksi cukup baik karena inflasinya tidak cukup tinggi dan juga sebaliknya deflasi yang terjadi tidak cukup tinggi hingga minus yang menyebabkan perekonomian tertekan ke bawah.

Penutup

Dari penelitian ini dapat diambil kesimpulan bahwa analisis jaringan syaraf tiruan (JST) mampu meramalkan inflasi kota malang dengan baik, yang berarti inflasi kota Malang dapat dengan mudah di

ramalkan dengan JST model sederhana yaitu single layer dengan model backpropagation dan fungsi aktifasi sigmoid biner. Model JST ini mempunyai arsitektur jaringan data input berupa inflasi dengan lag-1 dan lag-2 dengan 6 neuron single layer, menggunakan fungsi aktifasi sigmoid biner. Hasil peramalan mempunyai akurasi peramalan RMSE sebesar 0.3066760, MASE sebesar 0.4697471 dan MAPE sebesar 130.6615.

Dalam penelitian ini setelah disimpulkan, yang dapat disarankan untuk penelitian tentang prediksi inflasi bulanan di kota Malang adalah membandingkan metode JST single layer ini dengan model JST multilayer yang cocok untuk data yang linier (selain model Multilayer Feed Forward Neural Network atau MLFFNN). Selain itu dapat juga dibandingkan dengan metode time series yang lain seperti Exponensial Smoothing (ES) atau model autoregresi regressive integrated moving average (ARIMA), sehingga diperoleh model yang mempunyai ketepatan peramalan yang tinggi.

Daftar Pustaka

- [1] Boediono, "Ekonomi Makro", BPFE, Yogyakarta, 2001.
- [2] S. Suseno & Astiya, "Inflasi : Seri Kebanksentralan no. 22", Pusat Pendidikan dan Studi Kebanksentralan (PPSK) Bank Indonesia, 2009.
- [3] Anonim, "Inflasi", diakses daring pada 10 Februari 2019 di <https://www.bps.go.id/subject/3/inflasi.html>.
- [4] M.Y. Habibi & E. Riksakomara, "Peramalan Harga garam Konsumsi Menggunakan Artificial Neural Network Feedforward-Backpropagation (Studi Kasus : PT. Garam Mas, Rembang, Jawa Tengah)", JURNAL TEKNIK ITS Vol.6(2), p.2337-3520, 2017.
- [5] T D. Chaudhuri & I. Ghosh, "Artificial Neural Network and Time Series Modeling Based Approach to Forecasting the Exchange Rate in a Multivariate Framework", Journal of Insurance and Financial Management, Vol. 1, No 5, p. 92-123, 2016.
- [6] R.J. Hyndman & G. Athanasopoulos, "Forecasting: principles and practice", 2nd edition, OTexts: Melbourne, Australia, 2019.
- [7] S. Makridakis, S.C. Wheelwright & R.J. Hyndman, "Forecasting: Methods and Applications", John Wiley & Sons, Inc., 1998.
- [8] M. As'ad, S. Wibowo & E. Sophia, "Peramalan Jumlah Mahasiswa Baru Dengan Model Autoregressive Integrated Moving Average (Arima)", JIMP - Jurnal Informatika Merdeka Pasuruan, Vol 2, No 3, 2017.
- [9] D. Sena & N.K. Nagwani, "A Neural Network Autoregression Model To Forecast Per Capita Disposable Income", Rpn Journal Of Engineering And Applied Sciences, Vol. 11, No. 22, 2016.
- [10] L. Safitri, S. Mardiyati & H. Rahim, "Forecasting the mortality rates of Indonesian population by using neural network", Journal of Physics: Conference Series, IOP Publishing, 974 (2018) 012030, 2018.