

Aplikasi Metode Ensemble untuk Peramalan Inflasi di Indonesia

Mega Silfiani dan Suhartono

Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111

E-mail: suhartono@statistika.its.ac.id

Abstrak—Bank Indonesia melakukan kebijakan moneter berdasarkan kerangka kerja yang dinamakan ITF (*inflation targeting framework*) untuk memelihara kestabilan nilai rupiah. Oleh karena itu penelitian ini bertujuan untuk mengembangkan suatu model yang sesuai untuk peramalan inflasi di Indonesia berdasarkan metode ARIMA, ANN dan ensemble (gabungan). Metode ensemble yang digunakan dalam penelitian ini menggunakan perubahan input dan jumlah neuron untuk menciptakan anggota ensemble, sedangkan *averaging* dan *stacking* digunakan untuk menggabungkan. Data yang digunakan adalah inflasi nasional dan tujuh kota di Jawa Timur periode 2000-2012. Hasil penelitian menunjukkan bahwa untuk peramalan dua belas bulan ke depan metode *single ANN* menghasilkan RMSE yang terkecil sedangkan jika dilihat dari ensemble, RMSE terkecil dihasilkan oleh ANN ensemble.

Kata Kunci—ANN, ARIMA, Ensemble, Inflasi

I. PENDAHULUAN

BANK Indonesia mempunyai tujuan tunggal yaitu mencapai kestabilan nilai rupiah. Salah satu aspek kestabilan rupiah tercermin dalam inflasi yang rendah dan stabil. Oleh karena itu, Bank Indonesia melakukan kebijakan moneter berdasarkan ITF (*inflation targeting framework*). Dengan ITF, Bank Indonesia mengumumkan sasaran inflasi ke depan pada periode tertentu. Setiap periode, Bank Indonesia mengevaluasi apakah proyeksi inflasi ke depan masih sesuai dengan sasaran yang ditetapkan. Proyeksi ini dilakukan dengan sejumlah model dan sejumlah informasi yang dapat menggambarkan kondisi ke depan.

Proyeksi inflasi ke depan dapat menggunakan peramalan *time series*. Metode yang sering digunakan dalam peramalan *time series* adalah *autoregressive integrated moving average* (ARIMA) dan *artificial neural network* (ANN). Beberapa penelitian peramalan inflasi yang pernah dilakukan di luar negeri dengan menggunakan ANN dapat dilihat pada [1][2]. Sedangkan, penelitian peramalan inflasi di Indonesia juga pernah menggunakan ANN yang dapat dilihat pada [3][4] serta fungsi transfer [5].

Perkembangan pemodelan di bidang peramalan *time series* menunjukkan bahwa akurasi peramalan akan meningkat jika dihasilkan dari penggabungan beberapa model dengan kombinasi linier daripada memilih satu model yang terbaik [6]. Metode penggabungan multi-model tersebut sering disebut sebagai pendekatan ensemble. Dasar ide dari pendekatan ensemble multi-model digunakan karena masing-masing model memiliki kemampuan yang berbeda-beda dalam menangkap perbedaan pola pada data [7]. Penelitian ini bertujuan melakukan peramalan inflasi dengan menggunakan

metode *univariat* ARIMA dan ANN, serta ensemblenya kemudian dicari metode mana yang sesuai untuk meramalkan inflasi di Indonesia.

II. TINJAUAN PUSTAKA

A. Model *Autoregressive Integrated Moving Average* (ARIMA)

Pada model ARIMA (p,d,q), nilai yang akan datang dari suatu variabel diasumsikan sebagai fungsi linier dari beberapa pengamatan di masa lalu dan *random error* [8]. Model ARIMA(p,d,q) secara umum, yaitu [9]

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t, \quad (1)$$

dengan $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$, $\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ dan θ_0 adalah *intercept* pada model untuk *difference* ke-d.

Pembuatan model ARIMA dapat dilakukan dengan menggunakan tiga prosedur yaitu identifikasi model, estimasi model dan cek diagnosa [10]. Identifikasi model merupakan metodologi untuk mengidentifikasi perlunya suatu transformasi seperti transformasi untuk stasioner dalam varians, transformasi *differencing*, keputusan untuk memasukkan parameter θ_0 ketika $d > 0$ dan penentuan order p dan q pada ARIMA [9]. Estimasi parameter yang digunakan dalam penelitian ini menggunakan *conditional least square* kemudian dilanjutkan uji statistik untuk menentukan apakah parameter tersebut signifikan atau tidak.

Pada tahap cek diagnosa dilakukan pengecekan model didekati dengan analisis residual dari *fitted model* [11]. Pengecekan meliputi residual harus independen dan berdistribusi normal. Jika model ARIMA tidak memenuhi asumsi residual berdistribusi normal maka *outlier* perlu dimasukkan ke dalam model. Pada kasus *time series*, *outlier* dapat dibedakan menjadi *additive Outlier* (AO) dan *level Shift* (LS). Model ARIMA dengan *outlier* secara umum dituliskan sebagai berikut [9].

$$Z_t = \sum_{j=1}^k \sigma_j v_j(B) I_j^{(r)} + \frac{\theta(B)}{\phi(B)} a_t, \quad (2)$$

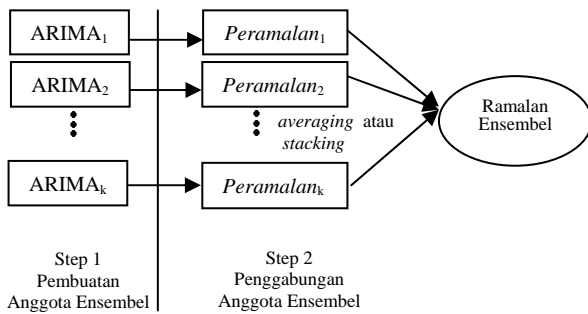
dimana $I_j^{(r)}$ = variabel yang menunjukkan adanya *outlier* pada waktu ke- T_j , dan $v_j(B) = 1$ untuk AO, $v_j(B) = \frac{1}{(1-B)}$ untuk LS.

Setelah model ARIMA memenuhi semua asumsi maka dapat dilakukan peramalan.

B. *Autoregressive Integrated Moving Average* Ensemble (ARIMA Ensemble)

ARIMA ensemble merupakan penggabungan hasil ramalan beberapa model ARIMA. Pembentukan ARIMA ensemble terdiri dari dua langkah. Pertama, menciptakan anggota ensemble dari beberapa model ARIMA selanjutnya menggabungkan hasil

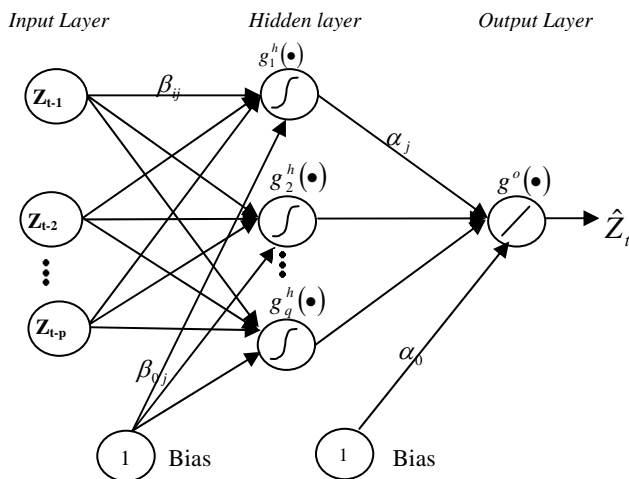
ramalan anggota ensemble dari ARIMA yang terbentuk dengan menggunakan *averaging* dan *stacking* sehingga didapatkan hasil ramalan ARIMA ensemble. Arsitektur model ARIMA ensemble dapat dilihat melalui Gambar 1.



Gambar .1. Arsitektur ARIMA Ensemble.

C. Single Artificial Neural Network (Single ANN)

Artificial neural networks (ANN) merupakan salah satu model yang dapat menangkap berbagai hubungan nonlinier. Arsitektur ANN yang sering digunakan untuk pemodelan *time series* adalah *feedforward multilayer network* yang juga diketahui sebagai *multilayer perceptrons* (MLPs). Arsitektur ANN MLPs dilihat berdasarkan Gambar 2.



Gambar . 2. Arsitektur MLP ANN.

Secara umum hubungan antara output (Z_t) dan input ($Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$) pada ANN mempunyai persamaan matematis seperti [7].

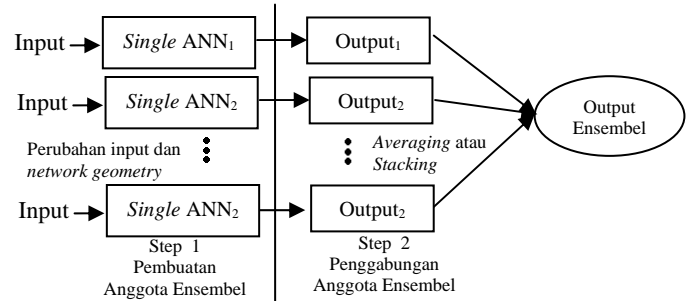
$$Z_t = g^o \left[\alpha_0 + \sum_{j=1}^q \alpha_j g_j^h \left(\beta_{0j} + \sum_{i=1}^p \beta_{ij} Z_{t-i} \right) \right] + \varepsilon_t \quad (3)$$

dimana $i = 0, 1, 2, \dots, p$; $j = 0, 1, 2, \dots, q$ adalah parameter model yang sering disebut sebagai bobot, p adalah banyaknya neuron pada input dan q adalah banyaknya neuron pada *hidden layer*. Fungsi logistik *sigmoid* sering digunakan sebagai fungsi aktivasi pada *hidden layer*. Estimasi bobot dan bias ANN menggunakan algoritma pembelajaran *Backpropagation* dengan *update* bobot-bobot pada tiap-tiap *layer* dapat menggunakan *gradient descent*.

D. Artificial Neural Network Ensemble (ANN Ensemble)

Penggabungan multi-model *artificial neural network* (ANN) disebut ANN ensemble [12]. Pembentukan ANN

ensemble terdiri dari dua langkah. Langkah pertama adalah menciptakan anggota ensemble secara individu dan langkah kedua adalah menggabungkan output dari anggota ensemble dengan kombinasi yang sesuai untuk menghasilkan output ensemble yang unik [13]. *Output* ensemble dari ANN ensemble didapatkan dari gabungan output dari beberapa *single ANN*. Untuk menciptakan beberapa model dari *single ANN* dapat menggunakan perubahan arsitektur dan banyaknya hidden unit dengan data training yang tetap [13]. Arsitektur ANN ensemble dapat dilihat berdasarkan Gambar 3.



Gambar. 3. Arsitektur ANN Ensemble.

E. Metode Penggabungan Ensemble

Ketika anggota ensemble (baik ANN maupun ARIMA) telah dibentuk maka langkah kedua yang harus dilakukan adalah menggabungkan output (hasil ramalan) yang berbeda dari masing-masing member dalam ensemble. Dua pendekatan yang paling sering digunakan adalah *averaging* dan *stacking*.

a. Averaging

Jika k adalah banyaknya anggota ensemble solusi dari pendekatan ensemble dengan *averaging* adalah

$$\hat{Z}_t = \frac{1}{k} \sum_{i=1}^k \hat{Z}_t^{(i)}, i = 1, \dots, k \quad (4)$$

dimana $\hat{Z}_t^{(i)}$ adalah nilai yang diprediksi ke- t dari anggota ensemble ke- i .

b. Stacking

Stacking merupakan metode untuk membentuk kombinasi linier dari prediktor untuk meningkatkan akurasi prediksi. *Stacking* didapatkan dari data *cross-validation* dan meminimumkan kuadrat terkecil dari fungsi G dengan syarat non-negatif untuk memperoleh koefisien dari kombinasi [14].

$$G = \sum_{i=1}^n \left[Z_t - \sum_{i=1}^k c_i \hat{Z}_t^i \right]^2, c_i > 0, \sum_{i=1}^n c_i = 1 \quad (5)$$

Koefisien $\hat{c}_1, \hat{c}_2, \dots, \hat{c}_k$ diestimasi untuk mendapatkan *final output* dari ensemble, yaitu

$$\hat{Z}_t = \sum_{i=1}^k \hat{c}_i \hat{Z}_t^{(i)} \quad (6)$$

2.6 Inflasi

Inflasi dapat diartikan sebagai meningkatnya harga-harga secara umum dan terus. Kenaikan harga dari satu atau dua barang saja tidak dapat disebut inflasi kecuali bila kenaikan itu meluas atau mengakibatkan kenaikan harga pada barang lainnya. Kebalikan dari inflasi disebut deflasi. Indikator yang sering digunakan untuk mengukur tingkat inflasi adalah indeks harga konsumen (IHK). Perubahan IHK dari waktu ke waktu menunjukkan pergerakan harga dari paket barang dan jasa yang dikonsumsi masyarakat. Perumusan inflasi berdasarkan inflasi dapat dilihat sebagai berikut.

$$Inflasi = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \times 100\% \quad (7)$$

III. METODOLOGI PENELITIAN

A. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data inflasi dari tahun 2000 sampai dengan tahun 2012 yang merupakan data sekunder yang diperoleh dari BPS. Sedangkan variabel penelitian yang digunakan dalam penelitian ini adalah data inflasi bulanan dari inflasi nasional (Z_1), Surabaya (Z_2), Malang (Z_3), Jember (Z_4), Kediri (Z_5), Probolinggo (Z_6), Madiun (Z_7) dan Sumenep (Z_8)

B. Langkah Analisis


Sebelum dilakukan analisis lebih lanjut data dibagi menjadi dua yaitu data *in sample* dan data *out of sample*. Data *in sample* digunakan untuk membentuk model dan data *out of sample* digunakan untuk mengecek ketepatan model. Tahap pertama dilakukan pemodelan dengan metode ARIMA, ANN, ARIMA ensemble, ANN ensemble kemudian gabungan dari ARIMA dan ANN ensemble. Setelah dilakukan analisis untuk kelima metode tersebut dilakukan perbandingan hasil pemodelan dan peramalan data *out of sample* berdasarkan kriteria kebaikan model data *out of sample*, yaitu RMSE. Model yang terbaik yang digunakan untuk peramalan inflasi nasional dan tujuh kota di Jawa Timur dipilih berdasarkan nilai RMSE terkecil dari hasil perbandingan kedua metode. Nilai RMSE dapat dirumuskan sebagai

$$RMSE = \left(\frac{1}{M} \sum_{i=1}^M e_i^2 \right)^{1/2} \quad (8)$$

IV. HASIL DAN PEMBAHASAN

A. Karakteristik Inflasi di Indonesia

Data inflasi yang dipakai dalam penelitian ini adalah inflasi yang diukur dari IHK (indek harga konsumen) berdasarkan tujuh kelompok pengeluaran yang meliputi kelompok bahan makanan, kelompok makanan jadi, minuman dan tembakau, kelompok perumahan, kelompok san-dang, kelompok kesehatan, kelompok pendidikan dan olah-raga dan kelompok transportasi dan komunikasi.



Gambar. 4. Box-Plot Inflasi Nasional dan Tujuh Kota di Jawa Timur pada Periode Tahun 2000-2012.

Gambar 4 menunjukkan bahwa inflasi nasional dan inflasi tujuh kota di Jawa Timur masih terdapat beberapa *outlier*. Hal ini diperkirakan karena ketidakstabilan ekonomi Indonesia yang menyebabkan nilai inflasi beragam seperti krisis ekonomi dunia, ketidakstabilan politik, penyesuaian harga bahan bakar minyak. Banyaknya *outlier* pada data diduga akan menyebabkan data inflasi nasional dan tujuh kota di Jawa Timur tidak mengikuti distribusi normal.

B. Peramalan Inflasi di Indonesia dengan ARIMA Ensemble

Inflasi Indonesia yang akan dimodelkan dalam ARIMA ensemble meliputi data inflasi nasional dan tujuh kota di Jawa Timur yang terdiri dari Kota Surabaya, Malang, Jember, Kediri, Probolinggo, Madiun dan Sumenep. Pe-modelan ARIMA ensemble didapatkan dari gabungan nilai peramalan beberapa model ARIMA yang sesuai. Oleh karena itu, untuk mendapatkan model ARIMA ensemble di-perlukan pemodelan ARIMA terlebih dahulu.

B.1 Peramalan Inflasi di Indonesia dengan ARIMA

Data akan dibagi menjadi dua yaitu data *in sample* dan data *out of sample*. Data *in sample* yang digunakan untuk pemodelan dari inflasi nasional, Surabaya, Malang, Jember dan Kediri mulai dari Januari 2000 sampai dengan Februari 2011 dan data inflasi Maret 2011 sampai dengan Februari 2012 dipakai untuk data *out of sample*. Sedangkan data *in sample* inflasi Probolinggo, Madiun dan Sumenep mulai dari Juni 2008 sampai dengan Oktober 2011 dan data inflasi November 2011 sampai dengan Februari 2012 dipakai untuk data *out of sample*. Data inflasi akan dimodelkan tiap variabel dengan beberapa model ARIMA yang sesuai.

Penentuan order dari ARIMA dapat dilakukan setelah data memenuhi asumsi stasioner dalam mean dan varian, dugaan order ARIMA dilihat berdasarkan pola dari ACF dan PACF kemudian dilanjutkan ke tahap estimasi parameter dan uji signifikansi parameter dan didapatkan model dugaan berdasarkan Tabel 1.

Tabel 1
Pendugaan Model ARIMA pada Inflasi Nasional dan 7 Kota di Jawa Timur

Kota	Model ARIMA	White noise	Kenormalan Residual
Inflasi Nasional	ARIMA(1,0,0)	ya	tidak
	ARIMA(0,0,1)	ya	tidak
Inflasi Surabaya	ARIMA([20],0,0)	ya	tidak
	ARIMA(0,0,[20])	ya	tidak
Inflasi Malang	ARIMA([3],0,0)	ya	tidak
	ARIMA(0,0,[20])	ya	tidak
Inflasi Jember	ARIMA([20],0,0)	ya	tidak
	ARIMA(0,0,[20])	ya	tidak
Inflasi Kediri	ARIMA([8],0,0)	ya	tidak
	ARIMA(0,0,[8])	ya	tidak
Inflasi Probolinggo	ARIMA(1,0,0)	ya	tidak
	ARIMA(0,0,1)	ya	tidak
Inflasi Madiun	$Z_t = \mu + a_t$	ya	tidak
	ARIMA([9],0,0)	ya	ya
Inflasi Sumenep	ARIMA(0,0,[9])	ya	ya

Tabel 1 menunjukkan bahwa ada satu *series* yang memiliki pola data *white noise* dimana pada plot ACF dan PACF tidak menunjukkan adanya satu pun lag yang keluar. Penyebab data

white noise ini diduga disebabkan oleh adanya outlier selain itu juga outlier dapat mengakibatkan data yang tidak memenuhi asumsi residual berdistribusi normal. Salah satu cara untuk menyelesaikan permasalahan residual tidak berdistribusi normal adalah dengan cara memodelkan outlier pada model ARIMA. Sebelum memodelkan outlier ke ARIMA maka outlier perlu dideteksi untuk mengetahui jenis outlier tersebut additive outlier atau level shift outlier. Outlier yang dideteksi kemudian dimodelkan dengan ARIMA dan dilakukan tahap estimasi dan uji signifikansi kemudian dilanjutkan dengan tahap cek diagnosa dan didapatkan model seperti pada Tabel 2.

Tabel 2
Model ARIMAX pada Inflasi Nasional dan 6 Kota di Jawa Timur

Kota	Model ARIMA	Jumlah Outlier	White noise	Kenormalan residual
Inflasi Nasional	ARIMAX(1,0,0)	1	ya	ya
Inflasi Surabaya	ARIMAX(0,0,1)	12	ya	ya
Inflasi Malang	ARIMAX([20],0,0)	5	ya	ya
Inflasi Jember	ARIMAX(0,0,[20])	5	ya	ya
Inflasi Kediri	ARIMAX([3],0,0)	1	ya	ya
Inflasi Probolinggo	ARIMAX(0,0,[20])	4	ya	ya
Inflasi Madiun	ARIMAX([20],0,0)	5	ya	ya
Inflasi Sumenep	ARIMAX(0,0,[20])	4	ya	ya
Inflasi Nasional	ARIMAX([8],0,0)	3	ya	ya
Inflasi Surabaya	ARIMAX(0,0,[8])	1	ya	ya
Inflasi Malang	ARIMAX(1,0,0)	1	ya	ya
Inflasi Jember	ARIMAX(0,0,1)	2	ya	ya
Inflasi Kediri	ARIMAX(0,0,0)	1	ya	ya
Inflasi Probolinggo	ARIMAX([9],0,0)	1	ya	ya
Inflasi Madiun	ARIMAX(0,0,[9])	1	ya	ya

Setelah mendapatkan beberapa model ARIMA dan ARIMAX untuk penanganan outlier maka untuk memilih model ARIMA atau ARIMAX yang paling sesuai pada pemodelan univariat ARIMA diperlukan suatu kriteria pemilihan model. Kriteria pemilihan model berdasarkan data out of sample dapat menggunakan nilai RMSE

Tabel 3
Kriteria Pemilihan Model Berdasarkan RMSE Inflasi Tujuh Kota di Jawa Timur

Variabel	Model	RMSE
Inflasi Nasional	ARIMAX(0,0,1)	0,442
Inflasi Surabaya	ARIMAX(0,0,[20])	0,423
Inflasi Malang	ARIMAX(0,0,[20])	0,466
Inflasi Jember	ARIMAX([20],0,0)	0,678
Inflasi Kediri	ARIMAX([8],0,0)	0,482
Inflasi Probolinggo	ARIMA(0,0,1)	0,098
Inflasi Madiun	$Z_t = \mu + a_t$	0,187
Inflasi Sumenep	ARIMA(0,0,[9])	0,417

Tabel 3 dapat diketahui bahwa model ARIMAX dengan penanganan outlier memberikan hasil peramalan yang lebih baik daripada ARIMA tanpa penanganan outlier. Meskipun demikian pada tiga kota memberikan hasil bahwa tanpa penanganan outlier model ARIMA menghasilkan peramalan yang lebih baik daripada model ARIMAX. Hal ini disebabkan karena pada tiga kota yaitu Probolinggo, Madiun dan Sumenep jumlah data inflasi relatif kecil sehingga dampak penanganan outlier tidak banyak berkontribusi terhadap hasil peramalan.

B.2 Perbandingan Akurasi Peramalan ARIMA dengan ARIMA Ensemble

Nilai peramalan yang didapatkan dari model ARIMA dan ARIMAX dari data inflasi nasional dan tujuh kota di Jawa

Timur kemudian digabungkan melalui averaging dan stacking. Penggabungan peramalan melalui averaging yaitu dengan merata-ratakan hasil ramalan setiap periode sedangkan penggabungan dengan stacking didapatkan dari meregresikan taksiran in sample, kemudian estimasi parameter stacking digunakan untuk menggabungkan output anggota ensemble. Pada inflasi nasional, Malang, Jember, Kediri, Probolinggo dan Madiun tidak menghasilkan ramalan ensemble stacking karena nilai pembobot \hat{c}_i konvergen ke nilai 0 dan 1 sehingga dapat dikatakan terdapat satu model univariat ARIMA yang mendominasi anggota ensemble lainnya. Pemodelan ARIMA ensemble yang paling sesuai berdasarkan RMSE terkecil dapat dilihat pada Tabel 4.

Model ARIMA ensemble dengan penanganan outlier (ARIMAX) memberikan hasil peramalan yang lebih baik daripada ARIMA ensemble tanpa penanganan outlier. Meskipun demikian pada tiga kota memberikan hasil bahwa tanpa penanganan outlier model ARIMA ensemble menghasilkan peramalan yang lebih baik daripada model ARIMAX ensemble. Hal ini disebabkan karena pada tiga kota yaitu Probolinggo, Madiun dan Sumenep jumlah data inflasi relatif kecil sehingga dampak penanganan outlier tidak banyak berkontribusi terhadap hasil peramalan.

Tabel 4
Kriteria Pemilihan Model Berdasarkan RMSE Inflasi Nasional Tujuh Kota di Jawa Timur

Variabel	Model	RMSE
Inflasi Nasional	ARIMAX averaging	0,464
Inflasi Surabaya	ARIMAX stacking	0,428
Inflasi Malang	ARIMA-ARIMAX averaging	0,468
Inflasi Jember	ARIMAX averaging	0,682
Inflasi Kediri	ARIMAX averaging	0,485
Inflasi Probolinggo	ARIMA stacking	0,098
Inflasi Madiun	ARIMA-ARIMAX averaging	0,288
Inflasi Sumenep	ARIMA stacking	0,419

C. Peramalan Inflasi di Indonesia dengan ANN Ensemble

Inflasi Indonesia yang akan dimodelkan dalam ANN ensemble meliputi data inflasi nasional dan tujuh kota di Jawa Timur yang terdiri dari Kota Surabaya, Malang, Jember, Kediri, Probolinggo, Madiun dan Sumenep. Pemodelan ANN ensemble didapatkan dari gabungan nilai peramalan beberapa model single ANN yang dengan perubahan input dan network geometry. Oleh karena itu, untuk mendapatkan model ANN ensemble diperlukan pemodelan single ANN terlebih dahulu.

C.1 Peramalan Inflasi di Indonesia dengan Single ANN

Sebelum melakukan pemodelan dengan single ANN, maka data inflasi nasional dan tujuh kota di Jawa Timur perlu dilakukan preprocessing. Preprocessing yang digunakan dalam data inflasi ini menggunakan preprocessing dengan normalized, sehingga transformasi data yang dihasilkan berada pada range 0 sampai dengan 1. Setelah melakukan preprocessing maka dapat dilakukan penentuan input dan batasan iterasi untuk mendapatkan parameter ANN melalui proses optimasi backpropagation.

Penentuan input didapatkan dari dua alternatif model yang paling sesuai dari regresi best subset dari lag 1 sampai dengan 12 dengan maksimal jumlah input 4 variabel. Batasan iterasi yang digunakan dalam pemodelan inflasi ini menggunakan batasan early stopping yaitu dilakukan penghentian sebelum

terjadi konvergen dalam parameter *single ANN*. *Early stopping* digunakan untuk mencegah *overfitting* pada model.

Tabel 5

Model *Single ANN* Tujuh Kota di Jawa Timur dengan Nilai RMSE Terkecil

Variabel	Input	Model	RMSE
Inflasi Nasional	Lag 1,8,11	NN(3,8,1)	0,458
Inflasi Surabaya	lag 1,7,8,12	NN(4,3,1)	0,401
Inflasi Malang	Lag 1,3,6,8	NN(4,2,1)	0,416
Inflasi Jember	Lag 1,8,11	NN(3,2,1)	0,654
Inflasi kediri	Lag 3,7,8,12	NN(4,8,1)	0,419
Inflasi Probolinggo	Lag 3	NN(1,1,1)	0,143
Inflasi Madiun	Lag 3	NN(1,4,1)	0,153
Inflasi Sumenep	Lag 3,6,10	NN(3,8,1)	0,290

Tabel 5 dapat diketahui bahwa jumlah input dan neuron dengan nilai RMSE terkecil pada tiap kota berbeda-beda. Jumlah input pada sebagian besar kota memiliki jumlah input sebanyak tiga dengan jumlah neuron yang bervariasi.

C.2 Perbandingan Akurasi Peramalan *Single ANN* dengan ANN Ensemble

Nilai peramalan yang didapatkan dari model *single ANN* dari data inflasi nasional dan tujuh kota di Jawa Timur kemudian digabungkan melalui *averaging* dan *stacking*. emilihan model ANN ensemble inflasi nasional dan tujuh kota di Jawa Timur yang paling sesuai berdasarkan kriteria pemilihan model RMSE dapat dilihat berdasarkan Tabel 6. Pada inflasi Surabaya, Kediri, Probolinggo dan Madiun tidak menghasilkan ramalan ensemble dari ANN *stacking* karena nilai pembobot \hat{c}_i konvergen ke nilai 0 dan 1 sehingga dapat dikatakan terdapat satu model *single ANN* yang mendominasi anggota ensemble lainnya. Pemodelan ANN ensemble yang paling sesuai berdasarkan RMSE terkecil dapat dilihat pada Tabel 6.

Tabel 6

Model ANN Ensemble Tujuh Kota di Jawa Timur dengan RMSE Terkecil

Variabel	Anggota Ensemble	Jenis Penggabungan	RMSE
Inflasi Nasional	5	<i>stacking</i>	0,451
Inflasi Surabaya	5	<i>averaging</i>	0,410
Inflasi Malang	5	<i>averaging</i>	0,443
Inflasi Jember	5	<i>averaging</i>	0,658
Inflasi kediri	5	<i>averaging</i>	0,431
Inflasi Probolinggo	3	<i>averaging</i>	0,132
Inflasi Madiun	3	<i>averaging</i>	0,154
Inflasi Sumenep	3	<i>stacking</i>	0,231

D. Peramalan Inflasi di Indonesia dengan ANN-ARIMA Ensemble

Inflasi Indonesia yang akan dimodelkan dalam ANN-ARIMA ensemble meliputi data inflasi nasional dan tujuh kota di Jawa Timur yang terdiri dari Kota Surabaya, Malang, Jember, Kediri, Probolinggo, Madiun dan Sumenep. Pemodelan ANN-ARIMA ensemble didapatkan dari gabungan nilai peramalan beberapa model *single ANN* yang dengan perubahan input dan *network geometry* dan ARIMA. Jumlah anggota ensemble yang dibangun dari ANN-ARIMA ensemble merupakan beberapa model dengan nilai RMSE terkecil pada model *single ANN* dan model ARIMA yang telah memenuhi semua asumsi.

Pada inflasi Nasional, Kediri, dan Madiun tidak menghasilkan ramalan ensemble dari ANN-ARIMA *stacking* karena nilai pembobot \hat{c}_i konvergen ke nilai 0 dan 1 sehingga dapat dikatakan terdapat satu model *single ANN* dan *univariat ARIMA* yang mendominasi anggota ensemble lainnya. Pemodelan ANN-ARIMA ensemble yang paling sesuai berdasarkan RMSE terkecil dapat dilihat pada Tabel 7. Model yang menghasilkan RMSE terkecil didominasi oleh model yang dihasilkan dari ANN-ARIMA dengan jenis penggabungan *averaging*.

Tabel 7

Model ANN-ARIMA Ensemble dengan Nilai RMSE Terkecil

Variabel	Jenis Penggabungan	RMSE
Inflasi Nasional	<i>averaging</i>	0,446
Inflasi Surabaya	<i>averaging</i>	0,414
Inflasi Malang	<i>averaging</i>	0,450
Inflasi Jember	<i>averaging</i>	0,657
Inflasi kediri	<i>averaging</i>	0,424
Inflasi Probolinggo	<i>averaging</i>	0,128
Inflasi Madiun	<i>averaging</i>	0,207
Inflasi Sumenep	<i>averaging</i>	0,259

E. Perbandingan Akurasi Peramalan Inflasi Indonesia dengan ARIMA, *Single ANN*, ARIMA Ensemble, ANN Ensemble dan ANN-ARIMA Ensemble

Model yang paling sesuai dari inflasi nasional dan tujuh kota di Jawa Timur berdasarkan kriteria RMSE yang terkecil dari model *univariat ARIMA*, *single ANN*, ARIMA ensemble, ANN ensemble dan ANN-ARIMA ensemble dapat dilihat seperti pada Tabel 8. RMSE terkecil dari pemodelan inflasi nasional dan tujuh kota di Jawa Timur dihasilkan oleh model *single ANN* karena *single ANN* menghasilkan RMSE terkecil dari lima kasus diantara delapan kasus. Sedangkan jika dilihat dari model ensemble, RMSE terkecil dihasilkan oleh ANN ensemble dimana jenis penggabungan *stacking* dan *averaging* memiliki kontribusi yang relatif sama dalam menghasilkan RMSE yang kecil.

Tabel 8

Model ARIMA, *Single ANN*, ARIMA Ensemble, ANN Ensemble dan ANN-ARIMA Ensemble dengan RMSE Terkecil

Variabel	Model	RMSE
Inflasi Nasional	ARIMAX	0,442
Inflasi Surabaya	<i>Single ANN</i>	0,401
Inflasi Malang	<i>Single ANN</i>	0,416
Inflasi Jember	<i>Single ANN</i>	0,654
Inflasi Kediri	<i>Single ANN</i>	0,419
Inflasi Probolinggo	ANN <i>averaging</i>	0,132
Inflasi Madiun	<i>Single ANN</i>	0,153
Inflasi Sumenep	ANN <i>averaging</i>	0,231

Hasil yang diperoleh pada penelitian ini berbeda dengan hasil yang diperoleh dari penelitian Zaier et al. [6] dimana pada penelitian tersebut metode ANN ensemble menghasilkan ketepatan ramalan yang lebih tinggi daripada *single ANN*. Namun hasil penelitian ini sama seperti salah satu hasil *M3 competition* [15] dimana metode yang lebih rumit tidak selalu meningkatkan akurasi peramalan pada data *out of sample* dibandingkan metode yang sederhana meskipun metode yang lebih rumit cocok dengan model statistik untuk data historis yang tersedia.

V. KESIMPULAN

Dari hasil dan analisis diperoleh bahwa metode *single* ANN menghasilkan RMSE yang kecil dibandingkan model lainnya pada pemodelan inflasi nasional dan tujuh kota di Jawa Timur. Sedangkan jika dilihat dari ensemble, metode ANN ensemble menghasilkan RMSE yang kecil dibandingkan model ensemble lainnya. Oleh karena itu dapat dikatakan metode yang lebih rumit tidak selalu meningkatkan akurasi peramalan pada data *out of sample* dibandingkan metode yang sederhana meskipun metode yang lebih rumit cocok dengan model statistik untuk data historis yang tersedia.

DAFTAR PUSTAKA

- [1] McAdam, P., McNelis, P. Forecasting Inflation With Thick Model and Neural Networks. *Economics Modelling*, 22, (2005) 848-867.
- [2] Nakamura, E. Inflation Forecasting Using a Neural Network. *Economics Letters*, 86, (2005) 373-378.
- [3] Muqtashidah, I. Jaringan Syaraf Tiruan Backpropagation dan Analisis Runtun Waktu Sebagai Metode Forecast Pada Penghitungan Laju Inflasi. (2009) Skripsi Jurusan Matematika Universitas Negeri Semarang (tidak dipublikasikan)
- [4] Purnama, A. Backpropagation Neural Network As Method For Forecasting on Calculation Inflation Rate In Jakarta and Surabaya. (2010) Skripsi Jurusan Ilmu Komputer Universitas Gunadarma (tidak dipublikasikan)
- [5] Septiorini, A. Peramalan Inflasi Nasional Yang Dipengaruhi Faktor Ekonomi Makro Dengan Metode Fungsi Transfer. (2009) Skripsi Jurusan Matematika Institut Teknologi Sepuluh Nopember Surabaya (tidak dipublikasikan).
- [6] Zaier, I., Shu, C., Ouarda, T.B.M.J., Seidou, O., Chebana, F. Estimation of Ice Thickness on Lakes Using Artificial Neural Network Ensembles. *Journal Of Hidrology*, 383, (2010) 330-340.
- [7] Zhang, G. P. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, (2003) 159-175.
- [8] Khashei, M., Bijari, M., Ardali, G.A.R. Improvement of Auto-Regressive Integrated *Moving average* Models Using Fuzzy Logic and Artificial Neural Networks (ANNs). *Neurocomputing*, 72, (2009) 956-967.
- [9] Wei, W.W.S. *Time series Analysis: Univariate and Multivariate Methods Second Edition*. USA: Pearson Education, Inc (2006).
- [10] Box, G.E.P., Jenkins, G.M. *Time series Analysis Forecasting and Control Revised Edition*. Oakland: Holden-Day, Inc (1976).
- [11] Cryer, J. D., Chan, Kung-Sik. *Time series Analysis With Applications in R Second Edition*. New York: Springer (2008).
- [12] Shu, C., Burn, D.H. Artificial Neural Network Ensembles and Their Application in Pooled Flood Frequency Analysis. *Water Resource Research*, Vol 40, 9 (2004).
- [13] Sharkey, A.J.C. *On Combining Artificial Neural Net: Ensemble and Modular Multi-Network System*. Springer Verlag (1999).
- [14] Breiman, L. Stacked Regression. *Machine Learning*, 24, (1996) 49-64.
- [15] Makridakis, S., Hibon, M. The M3-Competition : Result, Conclusions and Implications. *International Journal Of Forecasting*, 16, (2000) 451-476.