

APLIKASI METODE *BAYESIAN MODEL AVERAGING* (BMA) DENGAN PENDEKATAN *MARKOV CHAIN MONTE CARLO* (MCMC) UNTUK PERAMALAN CURAH HUJAN DI STASIUN METEOROLOGI KOTA MAKASSAR

Paramita¹, Suwardi Annas², Muhammad Kasim Aidid³

^{1,2,3}Prodi Statistika FMIPA UNM Makassar

e-mail: paramitamitha102@gmail.com

Abstrak

Curah hujan yang turun dapat mempengaruhi produksi dari beberapa jenis pekerjaan tertentu dan dapat mengganggu aktifitas manusia. Peramalan curah hujan dalam hal ini sangat penting untuk dilakukan. Metode peramalan yang sering dilakukan yaitu metode ensemble. Namun, metode ini cenderung mengalami *overdispersive* atau *underdispersive*. Maka dilakukan suatu proses kalibrasi yaitu *Bayesian Model Averaging* (BMA). Metode ini mampu menggeser nilai rata-rata dan variansi agar mendekati nilai observasi. Penaksiran parameter BMA dilakukan dengan pendekatan *Markov Chain Monte Carlo* (MCMC) yang mampu mengatasi variasi pada distribusi BMA dan memberikan hasil informasi penting mengenai bobot dan variansi. Metode ini diaplikasikan pada Curah Hujan Bulanan Kota Makassar. Hasil analisis memberikan kesimpulan bahwa metode *ensemble* tidak ada yang mampu yang menangkap nilai observasi sedangkan metode BMA dengan menggunakan *training window* 5 mampu menangkap nilai observasi curah hujan bulan Februari, Maret, Mei, Juni, Juli, dan Agustus 2018. Nilai observasi curah hujan bulan Juni yaitu 121 mm. Hasil peramalan dari metode *ensemble* untuk bulan Juni yaitu 130,6 mm, sedangkan pada metode BMA diperoleh interval ramalan untuk bulan Juni yaitu (-61,02-156,41) mm. Nilai *Continuous Ranked Probability Score* (CRPS) yang diperoleh untuk metode *ensemble* yaitu 62,07 dan metode BMA yaitu 25,24. Sehingga, metode BMA lebih baik dari metode *ensemble* karena nilai CRPS yang dihasilkan lebih kecil, sehingga interval yang dihasilkan dari peramalan BMA lebih banyak menangkap nilai observasi.

© 2019 Author(s). Published by Department of Statistics, Universitas Negeri Makassar. All rights reserved.

Keywords: Survival Analysis, Regression Cox Proportional Hazard, Thyroid Fever.

1. Latar Belakang

Peramalan merupakan bagian yang penting dari proses pengambilan keputusan sebab efektif atau tidaknya suatu keputusan umumnya bergantung pada beberapa faktor yang yang tidak dapat dilihat pada waktu keputusan itu diambil (Aswi dan Sukarna, 2006). Peramalan terbagi dalam dua jenis yaitu peramalan deterministik dan peramalan probabilistik. Peramalan deterministik memberikan hasil berupa suatu titik, sehingga kurang dapat digunakan sebagai acuan dalam membuat peramalan cuaca yang sifatnya memiliki variasi yang tinggi (Prayoga dkk, 2015). Sedangkan peramalan probabilistik merupakan suatu teknik peramalan yang bergantung pada metode yang berbeda dalam menetapkan peluang suatu kejadian dan peramalan ini dapat mengetahui ketidakpastian dari peramalan yang dilakukan (Doswell dan Brooks, 2001). Maka dari itu, penelitian ini menggunakan peramalan probabilistik.

Salah satu metode pendekatan yang sering digunakan dalam peramalan probabilistik adalah metode peramalan *ensemble*. Metode *ensemble* ini sangat baik digunakan dalam memberikan informasi penting tentang hasil peramalan. Namun bentuk peramalan *ensemble* cenderung *underdispersive* atau *overdispersive*. *Underdispersive* adalah hasil dari peramalan cenderung terpusat pada suatu titik tertentu dengan nilai variansi yang relatif rendah dan sebaliknya (*overdispersive*). Untuk mengatasi masalah tersebut, digunakan *Bayesian Model Averaging* (BMA). BMA dapat



memberikan kalibrasi dan ketepatan peramalan probabilistik yang lebih unggul daripada *ensemble* sederhana (Prayoga dkk, 2015). Kelebihan dari metode BMA yaitu dapat menggeser atau menyesuaikan nilai rata-rata dan variansi dari hasil peramalan sedemikian rupa sehingga dapat mendekati nilai observasi. Peramalan dengan metode BMA dapat dilakukan dengan pendekatan *Markov Chain Monte Carlo* (MCMC). Penggunaan metode BMA-MCMC juga mampu mengatasi variasi pada distribusi BMA dan dapat memberikan informasi penting mengenai perkiraan bobot dan variasi (Vrugt dkk, 2008). Peramalan dengan metode BMA dapat digunakan untuk meramalkan temperatur, tekanan udara, jumlah curah hujan, kecepatan angin, arah angin, vektor angin, dan parameter potensial yang lain (Prayoga dkk, 2015). Oleh karena itu, dalam penelitian ini akan menggunakan metode BMA-MCMC untuk meramalkan curah hujan bulanan di kota Makassar. Peramalan curah hujan merupakan hal yang sangat dibutuhkan dalam kehidupan manusia. Karena ada beberapa jenis pekerjaan tertentu, hujan yang turun dapat mempengaruhi hasil produksi. Peramalan curah hujan digunakan untuk mengetahui curah hujan yang akan turun pada suatu tempat sehingga tidak merugikan aktifitas manusia.

2. Kajian Pustaka

2.1 Peramalan *Time Series*

Deret waktu (*time series*) merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu tetap. Model *time series* yang umum digunakan yaitu model *AutoRegressive Integrated Moving Average* (ARIMA). Menurut Aswi dan Sukarna (2006) pemilihan model *time series* ARIMA dilakukan berdasarkan pendekatan Box-Jenkins, yaitu identifikasi model yang bertujuan untuk mengetahui bahwa data yang digunakan stasioner dalam rata-rata dan variansi, penaksiran parameter, Pemeriksaan diagnostik yang terbagi menjadi dua, yaitu uji kesignifikan parameter dan uji kesesuaian model, Melakukan peramalan apabila parameter model signifikan dan asumsi *residual* terpenuhi.

2.2 Metode *Ensemble*

Peramalan *ensemble* merupakan suatu metode prediksi numerik yang digunakan untuk membangkitkan sampel dari suatu keadaan mendatang (Purnamasari, 2011). Pembentukan *ensemble* didasarkan pada beberapa model yang sesuai, sehingga hasil peramalannya didasarkan pada *probability density function* (pdf) bukan dari nilai peramalan tunggal (Zhu, 2005). Kelebihan dari peramalan dengan menggunakan *ensemble* yaitu dapat menangkap adanya unsur ketidakpastian. Namun, pada metode ini sering terjadi *underdispersive* atau *overdispersive* sehingga dibutuhkan suatu proses kalibrasi, salah satunya yaitu *Bayesian Model Averaging* (BMA).

2.3 *Bayesian Model Averaging* (BMA)

Metode *Bayesian Model Averaging* (BMA) memberikan pembaharuan terhadap pemodelan dengan tidak hanya menggunakan satu model terbaik, tetapi dengan menggunakan seluruh kemungkinan *ensemble* yang dapat dijadikan pertimbangan (Raftery dkk, 2003). Menurut Vrugt dkk (2008) menyatakan bahwa metode ini tidak hanya mengacu pada satu model yang terbaik saja, namun juga mempertimbangkan model lain yang signifikan kemudian diberikan bobot sesuai dengan besar kontribusi dari masing-masing model individu terhadap kemampuan prediksi. Hasil dari metode ini lebih akurat dan handal daripada hasil yang didapatkan dengan metode kalibrasi yang lain.

Misal diberikan $f_k = f_1, f_2, \dots, f_K$ dengan k adalah prediksi *ensemble* yang diperoleh dari K model dan y adalah peramalan *ensemble* yang terkalibrasi, maka model prediksi BMA (distribusi posterior) untuk peramalan *ensemble* dapat dituliskan dalam sebuah model *mixture* dengan bentuk sebagai berikut (Raftery dkk, 2003; Vrugt dkk, 2008; dan Purnamasari, 2011).

$$p(y|f_1, f_2, \dots, f_K) = \sum_{k=1}^K w_k g_k(y|\bar{f}_k) \quad (1)$$

dimana w_k menyatakan peluang posterior dari peramalan k yang terbaik. w_k memiliki nilai nonnegatif dan berjumlah satu dari keseluruhan model pada setiap anggota *ensemble*, dan dapat disebut sebagai bobot yang mencerminkan kontribusi model individu terhadap prediksi selama periode *training*. Sedangkan $g_k(y|\bar{f}_k)$ adalah pdf gamma yang dipengaruhi oleh jumlah peramalan *ensemble* f_k melalui hubungan $\mu_k = b_0 + b_{1k}f_k$ dan $\sigma_k = c_0 + c_{1k}f_k$, dimana nilai μ_k adalah nilai koreksi bias dari distribusi dan σ_k adalah nilai standar deviasi anggota *ensemble* yang diperoleh dengan menggunakan regresi linear pada masing-masing anggota *ensemble* K dan observasi. Untuk nilai b_0 dan b_1

yaitu diperoleh dari hasil meregresikan antara nilai peramalan *ensemble* dan nilai observasinya dengan menggunakan persamaan sebagai berikut (Tiro, 2010).

$$b_0 = \frac{(\sum Y_i)(\sum X_i^2) - (\sum X_i)(\sum X_i Y_i)}{n \sum X_i^2 - (\sum X_i)^2} \quad (2)$$

sedangkan untuk persamaan b_1 yaitu

$$b_1 = \frac{n \sum X_i Y_i - (\sum X_i)(\sum Y_i)}{n \sum X_i^2 - (\sum X_i)^2} \quad (3)$$

Dimana n adalah banyaknya data yang digunakan. X adalah variabel nilai peramalan *ensemble* dan Y adalah variabel nilai observasi. Nilai μ_k dan σ_k dapat digunakan untuk mengestimasi parameter skala dan parameter bentuk sehingga diperoleh pdf gamma $g_k(y|\bar{f}_k)$ (Sloughter dkk, 2010). Setelah melakukan prediksi model dengan menggunakan BMA, maka perlu dilakukan estimasi parameter bobot dan varians dari pdf BMA. Salah satu pendekatan yang bisa digunakan untuk mengestimasi kedua parameter tersebut yaitu algoritma *Markov Chain Monte Carlo* (MCMC) (Vrugt dkk, 2008).

2.4 Markov Chain Monte Carlo (MCMC)

Simulasi MCMC digunakan sebagai pendekatan untuk mengestimasi bobot dan variasi BMA. Simulasi MCMC menggunakan jalur yang memiliki perbedaan, secara serempak untuk sampel w_k , $k = 1, \dots, K$ dan σ^2 secara khusus, didasarkan pada pembobotan yang diberikan pada fungsi *likelihood*. Metode simulasi MCMC yang akhir-akhir ini dikembangkan adalah *DiffeRential Evolution Adaptive Metropolis* (DREAM). Pada DREAM, sejumlah N rantai Markov yang berbeda dijalankan secara simultan paralel. Jika *state* dari rantai tunggal diberikan oleh sebuah vektor θ berdimensi d , dimana $\theta = w_1, w_2, \dots, w_k$, maka masing-masing generasi dari N dalam DREAM mendefinisikan suatu populasi Ω berukuran $N \times d$. Lompatan dalam rantai $i = \{1, 2, \dots, N\}$ dibangkitkan dengan mengambil beda dari beberapa rantai lain dari Ω yang dipilih secara random:

$$g^i = \theta^i + \gamma(\delta) \sum_{j=1}^g \theta^{r(j)} - \gamma(\delta) \sum_{j=1}^g \theta^{r(n)} + e \quad (4)$$

dimana δ merupakan jumlah pasangan yang digunakan untuk menghasilkan titik ramalan dan $r(j), r(n) \in \{1, 2, \dots, N-1\}; r(j) \neq r(n)$. Dalam memutuskan penerimaan titik ramalan digunakan rasio metropolis. Deret hasil operasi dalam sampel MCMC dapat menghasilkan parameter robust secara efisien, karena gabungan pdf dari faktor rantai N untuk $\pi(\theta_1) \dots \pi(\theta_N)$, dengan state $\theta_1 \dots \theta_N$ dari rantai individu bersifat independen dalam berbagi bentuk setelah nilai DREAM menjadi independen (Vrugt dkk, 2008).

2.5 Continous Ranked Probability Score (CRPS)

CRPS merupakan suatu ukuran untuk menilai hasil kalibrasi yang dihasilkan dengan menggunakan metode BMA, dimana suatu hasil peramalan dapat dikatakan baik jika nilai CRPS yang dihasilkan adalah nilai yang paling minimum. Pemilihan metode CRPS sebagai metode evaluasi ketepatan hasil peramalan yang dihasilkan adalah nilai peramalan terkalibrasi dalam bentuk pdf. Persamaan menghitung CRPS adalah sebagai berikut (Prayoga dkk, 2015)

$$CRPS = \frac{1}{N} \sum_{i=1}^N \int_{x=-\infty}^{x=\infty} (F_i^f(x) - F_i^0(x))^2 dx \quad (5)$$

dimana $F_i^f(x)$ adalah cdf dari hasil peramalan ke- i , sedangkan $F_i^0(x)$ adalah pengamatan sebenarnya ke- i dan N adalah jumlah hari dilakukannya peramalan.

2.6 Curah Hujan

Curah hujan dapat diartikan sebagai ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap, dan tidak mengalir. Curah hujan 1 mm, artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi 1 mm atau tertampung air sebanyak 1 Liter. Menurut BMKG (2012) Kriteria intensitas hujan dibagi menjadi 4 kategori, yaitu:

- Hujan Ringan: intensitas 5-20 mm/hari
- Hujan Sedang: intensitas 20-50 mm/hari
- Hujan Lebat: intensitas 50-100mm/hari

d. Hujan Sangat Lebat: intensitas >100 mm/hari

3. Metode Penelitian

3.1 Jenis Penelitian

Jenis penelitian yang digunakan adalah penelitian kuantitatif dengan pendekatan eksploratif dengan menggunakan metode kalibrasi *Bayesian Model Averaging* (BMA) untuk kalibrasi hasil peramalan.

3.2 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang bersumber dari Publikasi Badan Pusat Statistik Kota Makassar pada tahun 2010 sampai dengan tahun 2018 yang merupakan hasil pengamatan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) wilayah IV, Stasiun Meteorologi Maritim Paotere Makassar. Data yang digunakan yaitu data curah hujan pada Bulan Januari 2010 - Desember 2018.

3.3 Definisi Operasional Peubah

Variabel penelitian yang digunakan yaitu variabel curah hujan bulanan Kota Makassar bulan Januari 2010 – Desember 2018 dengan skala rasio dan waktu dalam satuan bulanan. Curah hujan adalah ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap, dan tidak mengalir.

3.4 Teknik Analisis Data

Dalam penelitian ini, teknik analisis data yang dilakukan yaitu:

1. Membagi data menjadi dua bagian yaitu *in-sample* dan *out-sample*. Data *in-sample* terdiri dari Januari 2010 - Juli 2017. Data *out-sample* terdiri dari Agustus 2017 - Desember 2018.
2. Analisis deskriptif terhadap data curah hujan *in-sample* dan *out-sample*.
3. Melakukan analisis *time series* model ARIMA dengan menggunakan data *in-sample*.
4. Melakukan peramalan *ensemble* dari model ARIMA yang signifikan.
5. Melakukan proses kalibrasi peramalan *ensemble* dengan menggunakan metode BMA.
6. Mencari nilai CRPS dari metode *ensemble* dan BMA.

4. Hasil Dan Pembahasan

4.1 Deskripsi Data Penelitian

Data curah hujan kota Makassar yang digunakan sebanyak 108 bulan, yaitu bulan Januari 2010 sampai Desember 2018. Data curah hujan ini dibagi menjadi 2 bagian yaitu data *in-sample* dan *out-sample*. Data *in-sample* adalah data yang digunakan untuk *training* atau pemodelan yang terdiri dari 91 bulan yaitu bulan Januari 2010 – Juli 2017. Sedangkan data *out-sample* adalah data yang digunakan untuk *testing* atau kebaikan model yang terdiri dari 17 bulan yaitu bulan Agustus 2017 - Desember 2018. hasil analisis deskriptif data curah hujan kota Makassar dengan data *in-sample*.

Tabel 4.1.1 Deskriptif Data Curah Hujan *In-Sample* Kota Makassar

Statistik	Nilai
N	91,00
Rata-rata	251,40
Simpangan Baku	262,10
Rentang	976,60
Nilai Minimum	0,00
Nilai Maksimum	976,60
Skewness	1,09
Kurtosis	0,29

Pada Tabel 4.1.1 diketahui bahwa curah hujan kota Makassar pada bulan Januari 2010 sampai Juli 2017 memiliki rata-rata 251,40 mm. Hal ini menunjukkan bahwa rata-rata curah hujan yang terjadi di kota Makassar pada tahun 2010 sampai 2017 merupakan hujan yang sangat lebat. Curah hujan tertinggi yaitu mencapai 976,60 mm dan curah hujan terendah mencapai 0,00 mm. Selisih nilai atau rentang data curah hujan tertinggi dengan terendah memiliki nilai yang tinggi yaitu 976,60, memberikan indikasi besarnya keragaman yang terjadi, hal ini dapat

diketahui dari nilai simpangan baku sebesar 262,10. Nilai skewness yang bernilai positif yaitu sebesar 1,09 menunjukkan bahwa pola distribusi data curah hujan tidak simetri serta kurtosis yang bernilai positif yaitu sebesar 0,29. Analisis deskriptif data curah hujan kota Makassar dengan data *out-sample* dapat dilihat pada Tabel 4.1.2

Tabel 4.1.2 Deskriptif Data Curah Hujan *Out-Sample* Kota Makassar


Statistik	Nilai
N	17,00
Rata-rata	299,80
Simpangan Baku	342,40
Rentang	954,00
Nilai Minimum	1,00
Nilai Maksimum	955,00
Skewness	0,89
Kurtosis	-0,90

Pada Tabel 4.1.2 diketahui bahwa curah hujan kota Makassar pada bulan Agustus 2017 sampai Desember 2018 memiliki rata-rata 299,8 mm. Hal ini menunjukkan bahwa rata-rata curah hujan yang terjadi di kota Makassar pada tahun 2017 sampai 2018 merupakan hujan yang sangat lebat. Curah hujan tertinggi yaitu mencapai 955,00 mm dan curah hujan terendah mencapai 1,00 mm.

4.2 Analisis *Time Series* Model ARIMA

4.2.1 Plot Data *Time Series*

Peramalan *time series* model ARIMA untuk data *in-sample* curah hujan Kota Makassar digunakan untuk mengetahui model terbaik yang akan digunakan untuk membangkitkan data peramalan *ensemble*.

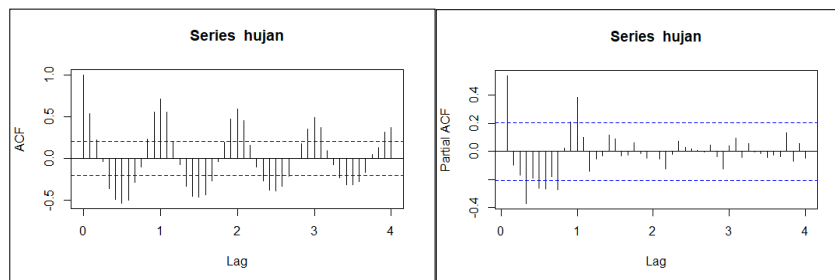


Gambar 4.2.1.1 Plot *Time Series* Data *In-sample* Curah Hujan Bulanan Kota Makassar

Berdasarkan Gambar 4.2 diketahui bahwa ada pola musiman pada data dan ada kecenderungan variasi musim, hal ini disebabkan karena curah hujan merupakan fenomena musiman.


4.2.2 Identifikasi Kestasioneran Data

Langkah awal kestasioneran dilakukan dengan menggunakan melihat plot ACF dan PACF seperti Gambar 4.2.2.1.



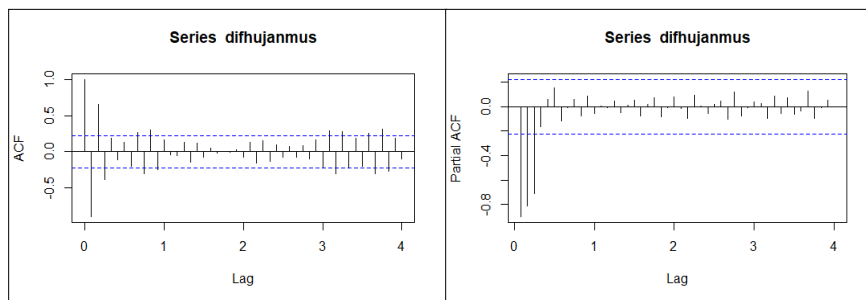
Gambar 4.2.2.1 Plot ACF dan PACF Data *In-Sample* Curah Hujan Bulanan Kota Makassar

Berdasarkan Gambar 4.2.2.1 plot ACF dan plot PACF memiliki pola yang turun menuju nol secara perlahan atau lambat dari lag 1. Nilai korelasi yang signifikan dan mengalami penurunan secara lambat, dapat dikatakan bahwa data belum stasioner dalam rata-rata non musiman dan rata-rata musiman 12. Maka untuk mengatasi masalah tersebut dan untuk menghilangkan kuatnya pengaruh musiman dilakukan *differencing* pertama non musiman ($d=1$) dan untuk menghilangkan kuatnya pengaruh musiman dilakukan *differencing* pertama musiman dua belas ($D=1$). Hasil data curah hujan setelah dilakukan *differencing* pertama non musiman dan musiman 12 dapat dilihat pada Gambar 4.2.2.2.



Gambar 4.2.2.2 Plot Time Series Data In-sample Curah Hujan Bulanan Kota Makassar Hasil Differencing Non Musiman dan Musiman 12

Berdasarkan plot pada Gambar 4.2.2.2 diketahui bahwa data telah stasioner dan dilihat pada hasil uji *Augmented Dickey Fuller* diperoleh nilai p -value 0,01 yang lebih kecil dari nilai α (0,05). Hal ini menunjukkan bahwa data telah stasioner. Data tersebut dapat langsung digunakan untuk mendapatkan model ARIMA musiman yang terbaik berdasarkan plot ACF dan PACF pada Gambar 4.2.2.3.



Gambar 4.2.2.3 Plot ACF dan PACF Data In-sample Curah Hujan Bulanan Kota Makassar Hasil Differencing Non Musiman dan Musiman 12

4.2.3 Identifikasi Model ARIMA Musiman yang sesuai

Dugaan model ARIMA musiman berdasarkan analisis kestasioneran data yaitu ARIMA (1,1,1)(0,1,1)¹², ARIMA (2,1,2)(0,1,1)¹², dan ARIMA (3,1,3)(0,1,1)¹². Model ARIMA yang memenuhi kesignifikanan parameter digunakan untuk membangkitkan data peramalan *ensemble* untuk periode-periode berikutnya. Berdasarkan Tabel 4.2.3.1 hanya ada satu model ARIMA yang memenuhi yaitu ARIMA (3,1,3)(0,1,1)¹². Model tersebut memenuhi kesignifikanan parameter dengan nilai p -value yang lebih kecil dari nilai α (0,05), asumsi *white noise* terpenuhi dengan nilai p -value 0,335 yang lebih besar dari nilai α (0,05), dan uji normalitas residual dengan nilai p -value (0,095) yang lebih besar dari nilai α (0,05). Pada Tabel 4.2.3.1 model yang digunakan untuk membangkitkan data *ensemble* yaitu model ARIMA (3,1,3)(0,1,1)¹² karena model tersebut memenuhi kriteria kesignifikanan parameter dan layakakan model. Secara matematis model ARIMA tersebut dituliskan seperti berikut.

$$\phi_p(B)(1-B)(1-B^{12})\dot{Z}_t = \theta_q(B)\Theta_Q(B^{12})a_t$$

$$(1-\phi_1B-\phi_2B^2-\phi_3B^3)(1-B)(1-B^{12})\dot{Z}_t = (1-\theta_1B-\theta_2B^2-\theta_3B^3)(1-\Theta_1B^{12})a_t$$

Tabel 4.2.3.1 Evaluasi Model ARIMA Musiman

Model	Parameter Model		White Noise (P-Value)	Residual Normal (P-Value)	Keterangan
	Parameter	P-Value			
ARIMA (1,1,1)(0,1,1) ¹²	AR(1)	0,113	0,304	0,010	Tidak Memenuhi
	MA(1)	0,000			
	SMA(12)	0,000			
	Constant	0,099			
ARIMA (2,1,2)(0,1,1) ¹²	AR(1)	0,173	0,249	0,010	Tidak memenuhi
	AR(2)	0,062			
	MA(1)	0,378			
	MA(2)	0,359			
	SMA(12)	0,000			
	Constant	0,000			
ARIMA (3,1,3)(0,1,1) ¹²	AR(1)	0,000	0,335	0,095	Memenuhi
	AR(2)	0,000			
	AR(3)	0,015			
	MA(1)	0,000			
	MA(2)	0,000			
	MA(3)	0,000			
	SMA(12)	0,000			
	Constant	0,000			

4.3 Peramalan Ensemble Data Curah Hujan Kota Makassar

Peramalan *ensemble* dalam penelitian ini dilakukan dengan dengan memperbarui model dari bulan ke bulan, bukan melakukan peramalan dalam banyak periode. Peramalan untuk model yang sesuai dilakukan dengan menggunakan satu *Lead time*, artinya peramalan untuk satu tahap atau bulan ke depan (*Lead* ke-1).

Dengan menggunakan data *in-sample* bulan Januari 2010 sampai Juli 2017, maka peramalan pertama yaitu bulan Agustus 2017. Dengan memperbarui data *in-sample* yaitu mengurangi satu data terlama dan menambahkan satu data terbaru, sehingga menjadi Februari 2010 sampai Agustus 2017, maka akan diperoleh data peramalan untuk September 2017. Pembaruan data ini dilakukan secara terus-menerus sampai bulan Desember 2018.

4.4 Kalibrasi Data Peramalan Curah Hujan Kota Makassar Menggunakan Bayesian Model Averaging (BMA)

4.4.1 Model Prediksi Bayesian Model Averaging (BMA)

Dalam proses kalibrasi ini digunakan nilai *training window* (*m*) yaitu 5. Penggunaan nilai *m* yang berbeda akan memberikan hasil peramalan yang berbeda pula walaupun dengan waktu yang sama. Tahap selanjutnya yang dilakukan setelah menentukan nilai *m* yaitu adalah mencari nilai b_0 , b_1 , σ^2 , dan nilai bobot. Nilai b_0 dan b_1 digunakan untuk mencari nilai koreksi bias dari peramalan *ensemble* untuk menggeser nilai rata-rata agar dapat mendekati nilai observasi. Nilai b_0 dan b_1 diperoleh dengan cara meregresikan data hasil peramalan *ensemble* terhadap data observasi dengan jumlah data yang digunakan sebanyak *m*. Untuk kalibrasi data peramalan Juni 2018 dengan nilai $m=5$, maka data yang digunakan yaitu data bulan Januari 2018 sampai Mei 2018. Dari proses regresi yang dilakukan maka diperoleh nilai b_0 dan b_1 yaitu sebagai berikut.

Nilai b_0 dan b_1 yaitu

$$b_0 = \frac{(\sum Y_i)(\sum X_i^2) - (\sum X_i)(\sum X_i Y_i)}{n \sum X_i^2 - (\sum X_i)^2}$$

$$b_0 = \frac{(2.274)(1.098.741,04) - (2.105,14)(1.255.165,44)}{91(1.098.741,04) - (2.105,14)^2}$$

$$b_0 = \frac{(2.498.537.120) - (2.642.298.974)}{(99.985.434,4) - (4.431.614,42)}$$

$$b_0 = \frac{-143.761.855}{95.553.820}$$

$$b_0 = -1,504$$

$$b_1 = \frac{n \sum X_i Y_i - (\sum X_i)(\sum Y_i)}{n \sum X_i^2 - (\sum X_i)^2}$$

$$b_1 = \frac{91(1.255.165,44) - (2.105,14)(2.274)}{91(1.098.741,04) - (2.105,14)^2}$$

$$b_1 = \frac{114.220.055 - 4.787.088,36}{(99.985.434,4) - (4.431.614,42)}$$

$$b_1 = \frac{109.432.967}{95.553.820}$$

$$b_1 = 1,14$$

Nilai koreksi bias yang diperoleh untuk kalibrasi data peramalan bulan Juni 2018 menggunakan data hasil peramalan *ensemble* yaitu sebagai berikut:


$$\begin{aligned} \mu_k &= b_0 + b_1 f_k \\ \mu_k &= -1,504 + 1,14(130,60) \\ \mu_k &= 147,38 \end{aligned}$$

Nilai estimasi varian dan bobot diperoleh dengan menggunakan pendekatan BMA. Dari pendekatan tersebut diperoleh nilai varian dengan nilai $m = 5$ yaitu $\sigma_k = 47,47$ dan nilai bobot yaitu $w_1 = 1$. Semakin besar nilai bobot dari model, maka semakin tinggi tingkat kontribusi peramalan *ensemble* terhadap hasil peramalan terkalibrasi. Selain itu, diperoleh nilai $\alpha_1 = 9,64$ dan $\beta_1 = 15,29$. Maka dari itu diperoleh model prediksi BMA untuk peramalan *ensemble* sebagai berikut.

$$\begin{aligned} p(y|f_1) &= w_1 g_1(y|f_1) \\ &= w_1 g_1(\alpha_1, \beta_1) \\ &= 1 g_1((9,64), (15,29)) \end{aligned}$$

4.4.2 Peramalan Curah Hujan Bulanan Kota Makassar dengan Metode BMA

Peramalan curah hujan dilakukan dengan menggunakan *training window* (m) yaitu 5. Peramalan dengan $m = 5$ berarti dalam melakukan kalibrasi peramalan data yang digunakan yaitu data 5 bulan sebelum bulan peramalan. Peramalan untuk bulan Juni 2018 dengan $m = 5$, berarti data yang digunakan untuk melakukan kalibrasi peramalan yaitu bulan Januari - Mei 2018. Penggunaan nilai m yang berbeda-beda dapat mempengaruhi hasil peramalan.




Gambar 4.4.2.1 Pdf Curah Hujan Bulan Juni 2018 dengan Metode BMA (*Lead* 1), dengan menggunakan $m = 5$

Pada Gambar 4.4.2.1 menunjukkan hasil peramalan untuk bulan Agustus dengan nilai $m = 5$ mampu menangkap nilai observasi curah hujan yaitu 1 mm karena nilai observasi tersebut masuk ke dalam nilai interval peramalan terkalibrasi yang dihasilkan yaitu (-61,02 – 156,41) mm.

Tabel 4.4.2.1 Parameter Distribusi untuk Juni 2018 *Lead* ke-1


m	Bobot (w)	μ kalibrasi	σ^2 kalibrasi
5	1	147,39	12,14

Pada Gambar 4.4.2.2 disajikan hasil peramalan terkalibrasi untuk periode lainnya dengan menggunakan metode BMA. Peramalan curah hujan pada bulan Februari, Maret, dan Mei 2018 dengan menggunakan metode BMA seperti pada Gambar 4.4.2.2 dapat menangkap nilai observasi. Dimana nilai observasi masuk atau berada pada nilai interval batas atas dan bawah ramalan terkalibrasi. Sedangkan peramalan pada bulan April 2018 nilai interval peramalan tidak mampu menangkap nilai observasi karena nilai observasi berada diluar nilai interval batas atas dan bawah hasil ramalan yang telah dikalibrasi dengan menggunakan metode BMA .



Gambar 4.4.2.2 Pdf Curah Hujan dengan Metode BMA untuk Beberapa Bulan Lainnya (*Lead* ke-1)

Hasil kalibrasi peramalan *ensemble* curah hujan kota Makassar tahun 2018 dengan metode BMA dapat dilihat pada Gambar 4.4.2.3.



Gambar 4.4.2.3 Grafik Curah Hujan Hasil Peramalan BMA dengan Nilai Obsevasi

Dari Gambar 4.4.2.3 dapat dilihat bahwa pola data hasil ramalan terkalibrasi mengikuti kenaikan atau penurunan dari pola data observasi. Walaupun ada beberapa periode waktu hasil ramalan terkalibrasi tidak dekat dengan nilai observasinya seperti bulan Januari, April, Oktober, dan Desember 2018.

4.5 Evaluasi Kinerja Peramalan *Ensemble* dengan BMA

Evaluasi hasil peramalan untuk masing-masing *training window* (m) untuk *lead* 1 yaitu dengan menggunakan nilai *Continuous Ranked Probability Score* (CRPS), dengan prosedur dasar yaitu dengan membandingkan distribusi hasil ramalan dengan pengamatan, yang keduanya dipresentasikan sebagai fungsi distribusi kumulatif.

Tabel 4.5.1 Evaluasi Hasil Peramalan

Lead	Peramalan	CRPS ($m = 5$)
1	<i>Ensemble</i>	62,072
	Kalibrasi BMA	25,241

Berdasarkan Tabel 4.5.1 dapat diketahui bahwa hasil peramalan dengan menggunakan metode kalibrasi BMA lebih baik daripada metode *ensemble*. Hal ini dapat dilihat dari nilai CRPS kalibrasi BMA yang dihasilkan lebih kecil dari metode *ensemble*.

5. Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan dari penelitian ini, maka dapat diambil kesimpulan sebagai berikut.

1. Model ARIMA yang memenuhi kriteria kesignifikanan yaitu ARIMA (3,1,3)(0,1,1)¹².
2. Model prediksi curah hujan bulanan kota Makassar dengan metode BMA yaitu:

$$p(y|f_1) = w_1 g_1(y|f_1)$$

3. Hasil kalibrasi peramalan yang dihasilkan dengan menggunakan $m = 5$ optimum dalam menangkap nilai observasi. Peramalan *ensemble* terkalibrasi dengan BMA menangkap nilai observasi dengan $m = 5$ untuk bulan Februari, Maret, Mei, Juni, Juli, dan Agustus 2018, dimana nilai observasi masuk dalam interval peramalan. Sedangkan untuk bulan Januari, April, September, Oktober, November, dan Desember 2018, nilai observasi tidak masuk ke dalam interval peramalan.

5.2 Saran

Berdasarkan kesimpulan yang diperoleh, maka beberapa saran yang ditujukan untuk penelitian selanjutnya yaitu sebagai berikut.

1. Menggunakan data dengan jumlah yang besar agar hasil peramalan lebih baik.
2. Jumlah *ensemble* yang digunakan lebih banyak dan *training window* lebih bervariasi agar nilai yang dapat diramalkan lebih banyak.

References

Aswi, & Sukarna. (2006). *Analisis Deret Waktu*. Makassar: Andira Publisher.

- BMKG. (2012). *Analisis Hujan April 2012 dan Prakiraan Hujan Juni, Juli, dan Agustus 2012 Sulawesi Selatan*. Maros: Badan Meteorologi, Klimatologi, dan Geofisika.
- Doswell, C. A., & Brooks, H. E. (2001). Normalized Damage from Major Tornadoes in the United State: 1890-1999. *Weather and Forecasting*, 168-176.
- Prayoga, G. S., Kuswanto, H., & Irhamah. (2015). Aplikasi Metode Bayesian Model Averaging Dengan Pendekatan Markov Chain Monte Carlo (MCMC) Untuk Peramalan Curah Hujan Bulanan Di Stasiun Meteorologi Sukowono Jember.
- Purnamasari, R. (2011). Penggunaan Metode Bayesian Model Averaging (BMA) Dengan Pendekatan Markov Chain Monte Carlo (MCMC) Untuk Peramalan Kecepatan Angin Rata-rata Harian Stasiun Meteorologi Juanda.
- Raftery, A. E., Balabdaoui, F., Gneiting, T., & Polakowski, M. (2003). Using Bayesian Model Averaging to Calibrate Forecast Ensemble.
- Sloughter, J. M., Gneiting, T., & Raftery, A. E. (2010). Probabalistic Wind Speed Forecasting Using Ensembles and Bayesian Model Averaging. *Journal of the American Statistical Association*, 25-35.
- Tiro, M. A. (2010). *Analisis Korelasi dan Regresi*. Makassar: Andira Publisher.
- Vrugt, J. A., Diks, C. G., & Clark, M. P. (2008). Ensemble Bayesian Model Averaging Using Markov Chain Monte Carlo Sampling. *Environ Fluid Mech*.
- Zhu, Y. (2005). Ensemble Forecast: A New Approach to Uncertainty and Predictability. *Advances In Atmospheric Sciences*, 781-788.

