BAB II

TINJAUAN PUSTAKA

Bab ini menjelaskan mengenai tinjauan pustaka yang menjadi dasar dalam penelitian ini. Tinjauan pustaka meliputi penjelasan tanaman cabai, penjelasan peramalan, penjelasan time series serta metode yang digunakan yaitu ARIMA dan *Intervention Model*. Pada bab ini juga dijelaskan mengenai penelitian terdahulu serta hasil dari metode yang digunakan.

2.1 Tanaman Cabai Rawit

Bertanam cabai, terutama cabai besar dan cabai rawit, saat ini masih menjadi primadona bagi kebanyakan petani sayuran di Indonesia, baik petani sayuran yang telah lama usaha dalam komoditas ini maupun petani yang sengaja terjun ke pertanian secara dadakan karena tergiur melihat hitung-hitungan beragribisnis cabai khususnya pada cabai rawit. Kebutuhan cabai di pasar lokal dan pasar ekspor yang tidak pernah bisa selalu terpenuhi oleh para petani serta harga yang menggiurkan membuat banyak orang awam pun berniat bertanam cabai.

Di balik bayangan yang menguntungkan tersebut banyak kendala yang siap menghadang para petani cabai umunya. Pada banyak kasus yang terjadi, beberapa petani menjadi frustasi ketika tanaman mereka tidak menghasilkan,

terserang hama dan penyakit, atau harga yang rendah. Beragribisnis cabai memiliki tingkat resiko yang tinggi.

Tanaman cabai khususnya cabai rawit pada umum nya memiliki masa tanam selama dua bulan. Penanaman cabai dalam satu hektar menghasilkan enam ton apabila dalam cuaca kemarau, sedangkan pada musim hujan dalam satu hektar dapat menghasilkan tiga ton, hal tersebut terjadi dikarenakan tingginya curah hujan dapat menimbulkan kelembaban pada tanah maupun tanaman, sehingga tanaman mengalami kelebihan air dan mudah terserang hama penyakit.

2.2 Peramalan

Peramalan adalah proses pembuatan prediksi untuk nilai di masa depan dengan menggunakan data di masa lalu dan masa sekarang dan memproyeksikannya dengan model matematis [3]. Peramalan sering juga diartikan dengan istilah perkiraan dan prediksi yang merujuk kepada metode-metode statistik. Kegiatan peramalan merupakan bagian dari keputusan manajemen dengan mengurangi ketergantungan pada hal-hal yang belum pasti. Untuk mendapatkan nilai prediksi dari suatu pola data, terdapat beberapa metode yang dapat diterapkan untuk melakukan peramalan.

Dalam berbagai metode tersebut memiliki kelebihan dan kekurangannya masing-masing tergantung dengan jenis dan pola data yang ditangani. Kelebihan dan kekurangan ini terkait dengan tinggat akurasi yang akan dihasilkan dari peramalan tersebut.

2.3 Time Series

Dalam ilmu statistik *time series* (deret waktu) adalah rangkaian data dari nilai pengamatan yang direkam dalam kurun waktu tertentu [4]. Analisa deret waktu merupakan metode yang mempelajari deret waktu dari segi teori maupun diterapkan untuk membuat predisi atau peramalan. Suatu data deret waktu terdiri dari urutan titik-titik data yang berturut-turut yang diukur pada suatu interval waktu yang kontinu, yang memiliki jarak antar dua titik data yang sama dan untuk setiap satuan waktu dalam interval waktu hanya memiliki satu titik data. Analisa deret waktu meliputi metode-metode untuk menganalisis data deret waktu untuk mendapatkan nilai statistik yang bermakna dan karakteristik lain dari data tersebut. Peramalan data deret waktu adalah penggunaan model untuk memprediksi nilai masa depan berdasarkan nilai-nilai yang diamati sebelumnya.

Sementara analisis regresi sering digunakan dengan cara seperti untuk menguji teori bahwa nilai-nilai saat ini dari satu atau lebih deret waktu independen mempengaruhi nilai saat ini dari seri waktu lain, jenis analisis time series ini tidak disebut "analisis deret waktu", yang berfokus pada membandingkan nilai-nilai dari serangkaian waktu satu atau beberapa tergantung seri waktu di berbagai titik dalam waktu.

2.4 ARIMA

ARIMA sering juga disebut metode runtun waktu Box-Jenkins. Model Autoregresif Integrated Moving Average (ARIMA) adalah model yang secara penuh mengabaikan independen variabel dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan yang akurat. ARIMA cocok jika observasi dari deret waktu (time series) secara statistik berhubungan satu sama lain (dependent) [5].

Pada model ARIMA terjadi proses *Autoregressive* (AR) berodordo-p atau proses *Moving Average* (MA) berordo-q atau merupakan kombinasi keduanya. Pembeda brordo-d dilakukan jika data deret waktu tidak stsioner. Kebanyakan data deret waktu tidak stasioner [6]. Kebanyakan data deret waktu bersifat non stasioner, sedangkan pada proses AR dan MA dari model ARIMA membutuhkan data yang stasioner. Syarat utama dalam membuat model ARIMA adalah data bersifat Stasioner, baik dalam rata-rata maupun ragam. Data dapat dikatakan stasioner jika fluktuasi data berada di sekitar nilai yang konstan (stasioner dalam rata-rata) dan ragam dari fluktuasi tersebut tetap konstan dari waktu ke waktu (stasioner dalam ragam).

Berikut ini merupakan rumus dasar ARIMA:

$$\emptyset(B)(1-B)^d y_t = \theta(b)\varepsilon_t$$

Diketahui:

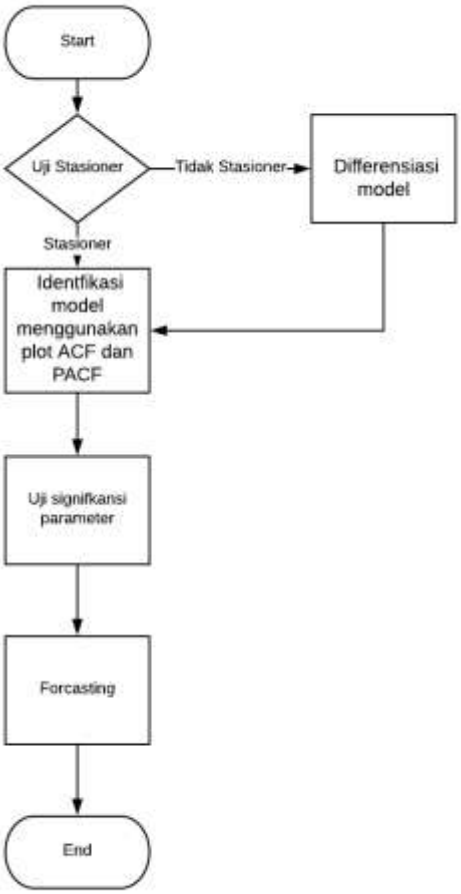
Autoregressive parameter = $\emptyset(B) = 1 - \emptyset_1 B - \emptyset_2 B^2 - \cdots - \emptyset_p B^p$

Moving Average parameter = $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_p B^q$

White noise or error term = ε_t

Differencing term = d

Backshift operator = B



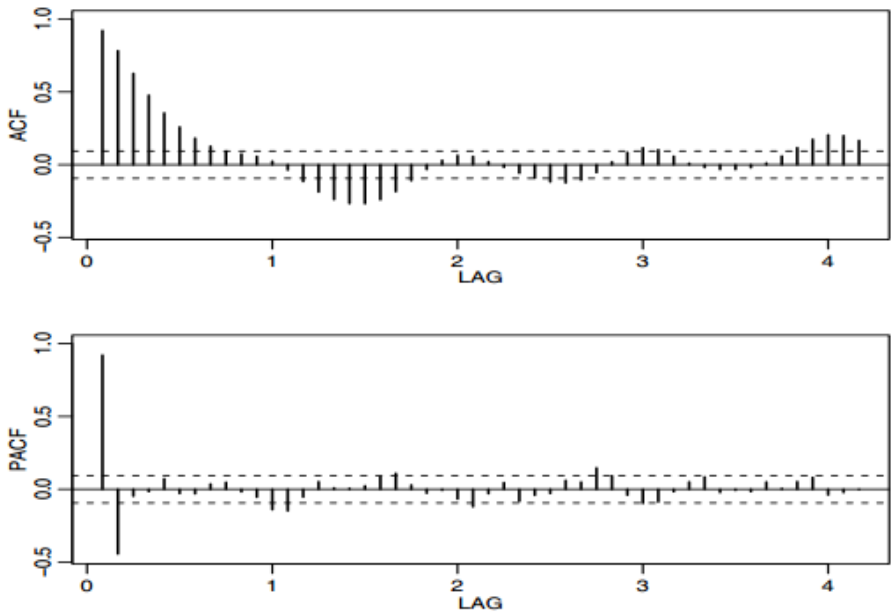
Gambar 2.1 Tahapan ARIMA

Pada tahap identifikasi, variabel yang akan diramalkan terlebih dahulu diuji kestasioneran datanya. Kestasioneran data dapat diuji dengan cara plot data dan menghitung autocorrelation function (ACF). Melalui plot data, dilihat secara visual apakah data memiliki kecendrungan semakin meningkat, semakin menurun, atau terdapat fluktuasi musiman. Sedangkan dari nilai ACF, jika nilai ACF mendekati nol pada lag kedua atau ketiga, maka data tersebut stasioner. Jika data yang diamati memiliki pola musiman, pada plot ACF akan terlihat nilai ACF yang signifikan pada kelipatan musimnya. Deret data non-stasioner dapat dijadikan stasioner dengan melakukan proses differencing (pembedaan). Jumlah berapa kali dilakukan proses differencing menunjukan tingkat differensiasi model. Untuk pola data yang mengandung unsur musiman, secara khusus dapat digunakan model seasonal ARIMA.

Unsur musiman dapat dihilangkan dengan seasonal differencing . Setelah data menjadi stasioner, langkah yang selanjutnya dilakukan adalah menentukan model tentative. Untuk menentukan model tentative, diperlukan analisis dari ACF dan PACF. Pola ACF dan PACF bisa berpola cut off dan dies down. Pertama, ACF dan PACF dari data time series bisa berpola cut off. Penentuan apakah suatu data time series dimodelkan dengan AR, MA atau ARIMA tergantung pola ACF dan PACF. Model AR digunakan jika plot ACF dies down sementara PACF cut off. Model MA digunakan jika plot ACF cut off dan plot ACF dies down. Sedangkan jika kedua plot ACF dan PACF merupakan dies down, maka model yang digunakan adalah model ARIMA.

Tabel 2.1 Pola ACF dan PACF untuk identifikasi parameter tentative

Model	ACF	PACF
AR(p)	Menurun secara cepat (Dies Down)	memotong secara tiba-tiba dengan signifikan (Cuts Off) hingga *lag* ke-p
MA(q)	memotong secara tiba-tiba dengan signifikan (Cuts Off) hingga *lag* ke-p	Menurun secara cepat (Dies Down)
ARMA(p, q)	Menurun secara cepat (Dies Down)	Menurun secara cepat (Dies Down)



Gambar 2.2 Plot ACF dan PACF

Dalam gambar ini, PACF terjadi cuts off setelah lag ke-2, sementara ACF menunjukan grafik dies down. Sehingga mendapat suatu dugaan AR (2).

2.5 Intervention Model

Model Intervensi adalah suatu model analisis data time series yang pada awalnya banyak digunakan untuk mengeksplorasi dampak dari kejadian-kejadian

external yang diluar dugaan terhadap variable yang menjadi obyek pengamatan [6].

Dalam model fungsi transfer, input z, adalah deret waktu eksogen umum yang mempengaruhi seri ouput x. Dimana khusus input Z, adalah serangkaian variabel indikator yang mewakili terjadinya kejadian unik dan unik yang diperkirakan berefek pada variabel x. Hal tersebut mengacu pada peristiwa yang dapat diidentifikasi sebagai Intervention Model. Model intervensi terdiri dari tiga tahap biasa yaitu identifikasi, estimasi, pemeriksaan diagnostik. Sedangkan proses estimasi dan pemeriksaan diagnostik serupa dengan pemodelan ARIMA.

Berikut ini merupakan rumus dasar Intervention model:

$$\mathrm{X_t} = \sum_{j=1}^{k} \frac{\omega_{sj}(B)B^{b\,j}}{\delta_{rj}(B)} I_{jt} + \mathrm{N_t}$$

Dimana :

x_t : variable respon pada saat t

J : banyaknya intervensi terjadi, j = 1,2,…,k

I_{jt} : variable intervensi

b : waktu tunda berpengaruhnya intervensi I terhadap X

ω_s : $\omega_0 - \omega_1 B - \cdots - \omega_s B^s$ (s menunjukan lamanya suatu intervensi berpengaruh pada data setelah b periode)

δ_r : $1 - \delta_1 B - \cdots - \delta_r B^r$(r pola efek intervensi setelah b+s periode sejak kejadian intervensi pada waktu ke T)

N_t : model ARIMA tanpa adanya pengaruh intervensi

Berikut ini beberapa aturan yang dapat digunakan untuk menduga nilai r, s, b dari suatu fungsi transfer:

1. Nilai b menyatakan y_t tidak terpengaruh oleh x_t sampai periode t + b. Besarnya b dapat ditentukan dari lag yang pertama kali pada plot korelasi silang. Nilai ini merupakan yang paling mudah untuk ditentukan apabila korelasi silang diperoleh dari ˆrho(0) = ˆrho (1) = ˆrho (2) = 0 tetapi ˆrho (3) = 0, 5 maka dapat ditentukan b = 3. Dengan kata lain terdapat tiga periode sebelum deret berkala input yang mulai mempengaruhi deret berkala output.
2. Nilai s menyatakan seberapa lama deret y_t terus dipengaruhi x_{t-b-1}, x_{t-b-2}, ..., x_{t-b-s} sehingga dapat dikatakan bahwa nilai s adalah bilangan pada lag plot korelasi sillang sebelum terjadinya pola menurun.
3. Nilai r menyatakan bahwa y_t dipengaruhi oleh nilai masa lalunya (y_{t-1}, y_{t-2}, ..., y_{t-r}, r = 0) bila ada beberapa lag plot pada korelasi silang yang terpotong.

   (a) r = 0 bila ada beberapa lag plot pada korelasi yang terpotong.

   (b) r = 1 bila plot pada korelasi silang menunjukkan suatu pola eksponensial menurun.

   (c) r = 2 bila plot pada korelasi silang menunjukkan suatu pola eksponensial menurun dan pola sinus.

Orde (b, s, r) ditentukan berdasarkan lag-lag dari perhitungan korelasi silang yang bersesuaian dengan kriteria tersebut diatas. Angka dari orde (b, s, r) tidak terbatas pada 0, 1, 2 saja tetapi bisa lebih besar dari itu [7]. Namun dari berbagai proses perhitungan yang telah dilakukan sebelumnya orde (r, s, b) jarang menyentuh angka-angka besar, terutama orde r dimana orde yang umum ditemukan hanyalah 0, 1, 2. Berikut beberapa bentuk fungsi transfer yang umum digunakan dalam peramalan:

Tabel 2.2 Fungsi Transfer Orde r 0

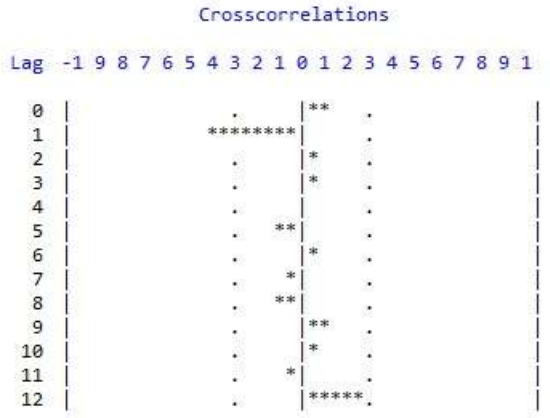
(r,s,b)	Fungsi Transfer
(0,0,2)	$v(B)x_t$
(0,1,2)	$v(B)x_t$
(0,2,2)	$v(B)x_t = (\omega_0 - \omega_1 B$

Tabel 2.3 Fungsi Transfer orde r 1

(r,s,b)	Fungsi Transfer
(1,0,2)	$\frac{v(B)x_t}{-\omega_0}$
(1,1,2)	$\frac{v(B)x_t}{-(\omega_0 - \omega_1 B)}$
(1,2,2)	$\frac{v(B)x_t}{-(\omega_0 - \omega_1 B - \omega_1 B^2)}$

Tabel 2.4 Fungsi Transfer orde r 2

(r,s,b)	Fungsi Transfer
(2,0,2)	$\frac{v(B)x_t}{-\quad\omega_0\quad}$
(2,1,2)	$\frac{v(B)x_t}{-\quad(\omega_0-\omega_1 B)\quad}$
(2,2,2)	$\frac{v(B)x_t}{-\quad(\omega_0-\omega_1 B-\omega_1 B^2)\quad}$



Gambar 2.3 Contoh Crosscorrellations

Dalam menggunakan software SAS untuk menentukan b,s,r diperoleh plot crosscorrelation yang juga merupakan plot korelasi antara data pengamatan dengan respon intervensi yang diberikan dimana intervensi yang diberikan adalah pulse function i. Plot respon intervensi ini berguna untuk menentukan orde b,s,r yang dibutuhkan dalam membangun model intervensi. Dalam penentuan orde b,s,r adalah sebagai berikut. Orde b menyatakan pada lag berapa respon intervensi mulai memberikan pengaruh pada data amatan. Orde s menyatakan seberapa lama respon intervensi memberikan pengaruh pada data amatan sementara orde r

menyatakan seberapa lama data amatan dipengaruhi oleh data amatan pada periode sebelumnya.

2.6 Evaluasi Hasil Peramalan

Evaluasi hasil peramalan digunakan untuk mengetahui keakuratan hasil peramalan yang telah dilakukan terhadap data yang sebenarnya. Terdapat banyak metode untuk melakukan perhitungan kesalahan peramalan. Beberapa metode yang digunakan adalah :

2.6.1 Mean Absolut Deviation (MAD)

Mean Absolute Deviation adalah ukuran kesalahan peramalan keseluruhan untuk sebuah model. Nilai MAD dihitung dengan mengambil jumlah nilai absolut dari kesalahan peramalan dibagi dengan jumlah periode data (n).

$$MAD = \frac{\sum |kesalahan\ peramalan|}{n}$$

2.6.2 Mean Absolute Percentage Error (MAPE)

Mean absolute percentage error atau MAPE adalah nilai rata-rata dari selisih absolut antara nilai hasil peramalan dan nilai aktual, nilai ditunjukkan dalam persentase [8]. Nilai dari MAD bergantung pada besarnya nilai dari *item* yang diramalkan. Apabila satuan dari item yang diramalkan adalah ribuan atau jutaan, nilai dari MAD dan atau MSE bisa jadi sangat besar. Untuk menghindari

hal ini, dapat digunakan metode penghitungan akurasi dengan menghitung MAPE.

$$MAPE = \sum_{n=1}^{n} \frac{|\text{peramalan} - \text{aktual}|}{\text{aktual}} x\ 100\%$$

2.7 Penelitian Sebelumnya

Beberapa *paper* yang telah dipublikasikan terkait hasil dari metode ARIMA dan ARIMA-Intervention Model:

Tabel 2.5 Penelitian Sebelumnya

Judul Penelitian	Metode	Hasil
ARIMA Modeling and Forecasting of Water Level in the middle Reach of the Yangze River, 2017, (Z. Yu, Z, Jiang, G. Lei, F. Liu)	ARIMA	Evaluasi kinerja prediksi model ARIMA dengan statistik dataset tahun 2016. Model yang dihasilkan memuaskan pada bidang studi yang diteliti meskipun perbedaan telah diamati ketika terjadi fluktuasi tajam pada permukaan air [9].
ARIMA forecast models for scheduling usage of esources in IT-infrastructure 2017 (K. Dmytro, T. Sergii, P. Andiy)	ARIMA	Hasil analisis menunjukkan hasil positif menggunakan ARIMA sebagai model prediksi dasar untuk kinerja terbaik dan kemampuan untuk memprediksi proses transient. Dalam analisis ini menunjukkan akurasi di bawah 10%. [10].

Application of Time Series Intervention Modelling for Modelling and Forecasting Cotton Yield, 2014 (M. Ray, V. Ramasubramanian, A. Kumar, A. Rail)	ARIMA - Intervention	Analisis intervensi digunakan untuk menilai dampak dari peristiwa khusus pada rangkaian waktu yang menarik. Dengan alternatif, analisis intervensi dapat dilakukan untuk menyesuaikan nilai-nilai yang tidak biasa dalam seri Yt yang mungkin dihasilkan sebagai konsekuensi dari peristiwa intervensi. Analisis Intervensi akan memastikan bahwa hasil analisis rangkaian dari seri waktu, seperti struktur model yang sesuai, perkiraan parameter model, dan perkiraan nilai masa depan yang tidak terdistorsi secara serius oleh pengaruh dari nilai-nilai tidak biasa [11].
ARIMA Modeling with Intervention to Forcast and Analyze Chinese Stock Price, 2011 (J.E. Jarrett and E. Kyper)	ARIMA - Intervention	Indeks harga pasar saham di Cina dimodelkan oleh metode analisis ARIMA Intervensi dan menghasilkan kecocokan untuk suatu analisis dan dapat menarik kesimpulan tentang bagaimana perilaku indeks dari waktu ke waktu [12].