BAB II

TINJAUAN PUSTAKA

2.1 Kajian Pustaka

Sebelumnya telah banyak dilakukan penelitian di bidang peramalan khususnya yang berkaitan dengan peramalan pola musiman. Beberapa penelitian sebelumnya yang berkaitan dengan peramalan untuk pola musiman antara lain:

1) Tahun 2014 Annisa Ul Ukhra melakukan penelitian dengan judul Pemodelan dan Peramalan Data Deret Waktu dengan Metode Seasonal Arima. Penelitian ini menggunakan salah satu metode analisis *time series* untuk meramalkan data dengan pola musiman. Metode yang digunakan pada penelitian ini adalah metode SARIMA. Metode ini digunakan untuk meramalkan jumlah penumpang pesawat terbang yang berujung pada hasil ramalan dengan jumlah yang tidak jauh berbeda dengan data aktual. Namun penelitian ini tidak menyertakan nilai kesalahan peramalan seperti yang digunakan oleh peneliti-peneliti lain sebelumya. Nilai kesalahan permalan yang dimaksud adalah *Mean Square Error* (MSE), *Mean Aveaage Deviation* (MAD), *Mean Absolute Percentage Error* (MAPE) dan lain-lain [3].

2) Tahun 2015 Mohammad Valipour melakukan penelitian dengan judul *Long-term runoff study using SARIMA and ARIMA models in the United States.* Dalam penelitian ini, kemampuan model SARIMA dan ARIMA dievaluasi untuk perkiraan limpasan jangka panjang. Hasil yang didapat menunjukkan

bahwa model SARIMA memperkirakan limpasan tahunan lebih baik dari model ARIMA. Model SARIMA sangat sensitif terhadap pola musiman. Meskipun demikian, performa model SARIMA akan sangat menurun apabila terjadi kesalahan dalam penentuan jumlah pengulangan berkala (musiman) [6].

3) Tahun 2013 Evelina Padang, Gim Tarigan dan Ujian Sinulingga melakukan penelitian dengan judul Peramalan Jumlah Penumpang Kereta Api Medan-Rantau Prapat dengan Metode Pemulusan Eksponensial Holt-Winters. Penelitian ini membandingkan kedua model dari metode *Holt-Winter's Exponential Smoothing* yaitu model perkalian musiman dan model penambahan musiman untuk meramalkan jumlah penumpang kereta api. Setelah kedua model dibandingkan, nilai MSE dan MAPE terkecil didapatkan dengan menggunakan model penambahan musiman [7].

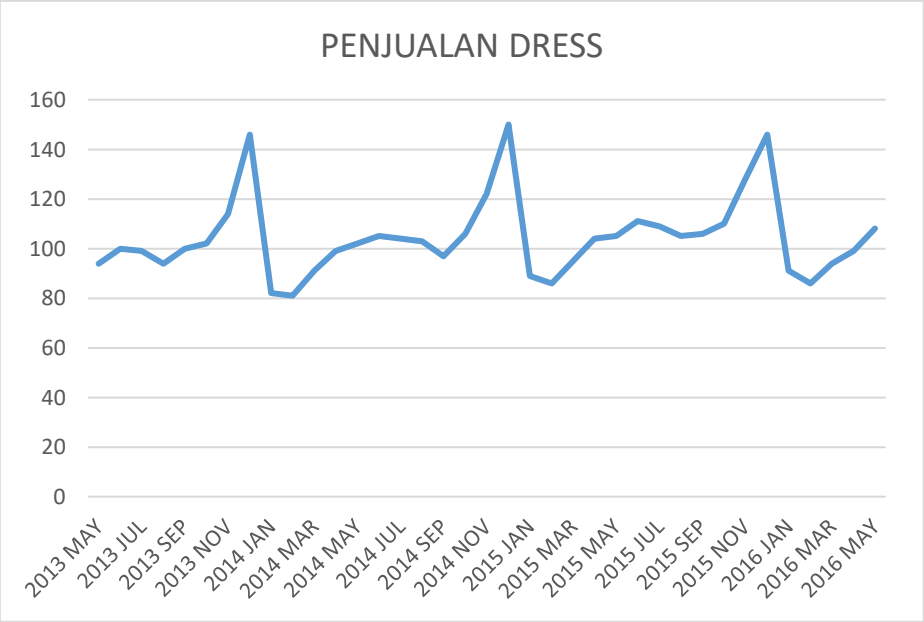
2.2 Peramalan

Peramalan adalah kegiatan untuk memperkirakan apa yang akan terjadi pada masa yang akan datang [8]. Peramalan (*forecasting*) merupakan bagian vital bagi setiap organisasi bisnis dan untuk setiap pengambilan keputusan manajemen yang sangat signifikan.

Peramalan Deret Waktu atau *Time Series Forecasting* adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu [1].

2.3 Pola Data Musiman (*Seasonal)*

Pola data musiman adalah salah satu dari 4 bentuk pola data deret waktu yang menunjukkan perulangan indeks pada kurun waktu tertentu seperti hari, minggu, bulan atau kuartal [9]. Variasi musiman adalah fluktuasi yang muncul secara reguler setiap tahun yang biasanya disebabkan oleh iklim, kebiasaan (mempunyai pola tetap dari waktu ke waktu). Contoh yang menunjukan variasi musiman seperti penjualan pakaian akan meningkat pada saat hari raya, penjualan buku dan tas sekolah akan meningkat pada saat awal sekolah.



Gambar 2. 1 Contoh grafik pola data musiman

2.4 Time Series Model

Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien. Menurut [10], teknik peramalan terbagi menjadi dua bagian, yang pertama metode peramalan subjektif dan metode peramalan objektif. Metode

peramalan subjektif mempunyai model kualitatif dan metode peramalan objektif mempunyai dua model, yaitu model time series dan model kausal. Model kualitatif berupaya memasukkan faktor-faktor subyektif dalam model peramalan, model ini akan sangat bermanfaat jika data kuantitatif yang akurat sulit diperoleh. Contoh dari metode ini ialah metode delphi, opini juri eksekutif, komposit kekuatan dan survey pasar konsumen.

Model time series merupakan model yang digunakan untuk memprediksi masa depan dengan menggunakan data historis. Dengan kata lain, model time series mencoba melihat apa yang terjadi pada suatu kurun waktu tertentu dan menggunakan data masa lalu untuk memprediksi [10]. Contoh dari model time series ini antara lain Moving average, Exponential Smoothing dan proyeksi trend.

2.5 Metode Seasonal Autoregressive Integrated Moving Average (SARIMA)

Metode *Seasonal Autoregressive Integrated Moving Average* atau lebih dikenal dengan metode *SARIMA* adalah metode peramalan *Time Series* untuk data model stokastik dengan pola data musiman [1]. Metode *SARIMA* dapat dipakai untuk data yang bersifat musiman yang dapat memberikan hasil peramalan yang tidak jauh beda dengan data aktual.

Langkah-langkah pemodelan *Seasonal Autoregressive Integrated Moving Average* (SARIMA) adalah [3]:

1. Proses identifkasi model.
2. Pendugaan parameter model.
3. Pemeriksaan residual(sisaan).

4. Mengunakan model untuk peramalan jika model memenuhi syarat.

Secara umum, notasi SARIMA adalah :

ARIMA (p,d,q) $(P,D,Q)^s$ (2.1)

Dimana :

p,d,q : Bagian tidak musiman dari model

$(P,D,Q)^s$: Bagian musiman dari model

S : Jumlah periode per musim

Rumus umum dari ARIMA (p,d,q)$(P,D,Q)^s$ adalah sebagai berikut [3]:

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_q(B^S)a_t \quad (2.2)$$

dengan :

$\phi_p(B)$: AR *Non Seasonal*

$\Phi_P(B^S)$: AR *Seasonal*

$(1-B)^d$: *differencing non seasonal*

$(1-B^S)^D$: *differencing seasonal*

$\theta_q(B)$: MA *non seasonal*

$\Theta_q(B^S)$: MA *seasonal*

Tahap differencing adalah olah data dengan menghitung nilai perbedaan antara Zt dengan Zt-1. Data dihitung selisihnya dengan data periode sebelumnya. Hal ini dilakukan untun menghilangkan unsur tren pada data.

Dalam menetapkan nilai p dan q dapat dibantu dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dengan acuan pada tabel 2.1 [11].

Tabel 2. 1 Pola ACF dan PACF untuk identifikasi parameter tentatif

Model	Pola ACF	Pola PACF
AR (p)	Menurun secara cepat (*dies down*)	Muncul *spike* yang signifikan hingga *lag* ke-p dan *cut off*setelah *lag* ke-p
MA (q)	muncul *spike* yang signifikan hingga *lag* ke-q dan *cut off* setelah *lag* ke-q	menurun secara cepat (*dies down*)
ARMA (p,q)	menurun secara cepat (*dies down*)	menurun secara cepat (*dies down*)
AR (p) atau MA (q)	muncul *spike* yang signifikan hingga *lag* ke-q dan *cut off* setelah *lag* ke-q	muncul *spike* yang signifikan hingga *lag* ke-p dan *cut off* setelah *lag* ke-p

Tahapan pemeriksaan residual terbagi menjadi pemeriksaan L-jung Box (*white noise)*, dan kenormalan residual. Pengujian untuk memenuhi asumsi *white noise* dilakukan pengujian L-jung Box dengan hipotesa [12] :

$H_0 : \rho_1 = \rho_2 = \rho_{...} = \rho_k = 0$

H_1 : minimal ada satu nilai $\rho_k \neq 0$, dimana k = 1,2,...,K

dengan statistik uji :

$$Q = n(n+2)\sum_{k=1}^{K}(n-k)^{-1}\hat{\rho}_k \qquad (2.3)$$

Dimana n adalah banyak pengamatan dan $\hat{\rho}_k$ adalah sampel ACF residual pada lag ke-k, dan K adalah lag maksimum. Daerah kritis = Q > $x^2_{(a,K-m)}$ atau *P-value* < α *=5%.*

Pengujian kenormalan distribusi dapat dilakukan uji Kolmogorov-Smirnov dengan hipotesa [13]:

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Dengan statistik uji :

$$D = \underset{x}{Sup}[|F_n(x) - F_0(x)|] \quad (2.4)$$

Dimana D adalah nilai deviasi absolut maksimum antara F (x) n dan ( ) 0 F x , Sup masing-masing merupakan fungsi *Kolmogorov* peluang kumulatif yang dihitung dari data sampel, fungsi peluang kumulatif distribusi normal, dan nilai supremum untuk semua α_t . Daerah Kritis: Tolak H0 jika $D \geq D_{(1-\alpha,n)}$ atau *P-value* < α , dengan α = 5% [12].

Model terbaik ditentukan berdasarkan nilai *error*, semakin kecil nilai *error* yang dihasilkan maka semakin baik model tersebut sekaligus menentukan model tersebut layak untuk digunakan pada peramalan [14].

2.6 Metode Holt-Winter's Exponential Smoothing

Metode ini digunakan ketika data menunjukan adanya trend dan perilaku musiman [10]. Untuk menangani musiman, telah dikembangkan parameter persamaan ketiga yang disebut metode "Holt- Winters" sesuai dengan nama penemuya.

Metode Holt-Winters sering disebut metode pemulusan eksponensial yang melakukan pendekatan [10]. Metode *Holt-Winter's Exponential Smoothing* adalah metode peramalan dengan pendekatan pemulusan eksponensial berdasarkan hasil peramalan pada periode sebelumnya. Metode ini terbagi menjadi dua bagian yakni :

1. Metode Pemulusan Eksponensial Holt-Winters dengan Metode Perkalian Musiman (*Multiplicative Seasonal Method*) yang digunakan untuk variasi data musiman yang mengalami peningkatan/penurunan (fluktuasi),
2. Metode Pemulusan Eksponensial Holt-Winters dengan Metode Penambahan Musiman (*Additive Seasonal Method*) yang digunakan untuk variasi musiman yang bersifat konstan.

Metode Holt-Winters didasarkan pada tiga persamaan pemulusan, yakni persamaan pemulusan keseluruhan, pemulusan tren, dan persamaan pemulusan musiman. Untuk Pemulusan Eksponensial Holt-Winters dengan Metode Perkalian Musiman mempunyai persamaan sebagai berikut:

Pemulusan Keseluruhan

$$S_t = \alpha \frac{X_t}{I_{t-L}} + (1-\alpha)(S_{t-1} + b_{t-1}) \quad (2.5)$$

Pemulusan Trend

$$b_t = \beta(S_t - S_{t-1}) + (1-\beta)b_{t-1} \quad (2.6)$$

Pemulusan Musiman

$$I_t = \gamma \frac{X_t}{S_t} + (1-\gamma)(I_{1-L}) \quad (2.7)$$

Ramalan

$$F_{t+m} = (S_t + b_t m) I_{1-L+m} \quad (2.8)$$

Untuk Pemulusan Eksponensial Holt-Winters dengan Metode Penambahan Musiman mempunyai persamaan sebagai berikut:

Pemulusan Keseluruhan

$$S_t = \alpha(X_t - I_{1-L}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.9)$$

Pemulusan Trend

$$b_t = \beta(S_{t-1} - S_t) + (1 - \beta) b_{t-1} \quad (2.10)$$

Pemulusan Musiman

$$I_t = \gamma(X_t - S_t) + (1 - \gamma) I_{t-L} \quad (2.11)$$

Ramalan

$$F_{t+m} = (S_t + b_t m) I_{1-L+m} \quad (2.12)$$

Makna simbol-simbol yang digunakan pada persamaan (2.5) sampai (2.12) adalah:

Xt = nilai aktual pada periode akhir t

α = konstanta penghalusan untuk data ($0 < \alpha < 1$)

β = konstanta penghalusan untuk trend ($0 < \beta < 1$)

γ = konstanta penghalusan untuk musiman ($0 < \gamma < 1$)

S_t = nilai pemulusan awal

b_t = konstanta pemulusan

I = faktor penyesuaian musiman

L = panjang musim

F_{t+m} = ramalan untuk m periode ke depan dari t.

2.7 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 :

2.7.1 Mean Absolute 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) [15].

$$MAD = \frac{\sum |aktual - peramalan|}{n} \quad (2.14)$$

dimana :

n = jumlah data

2.7.2 Mean Absolute Percentage *Error* (MAPE)

Masalah yang sering muncul pada perhitungan akurasi dengan metode perhitungan MSE dan MAD adalah nilainya 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 *mean absolute percentage error* atau MAPE. MAPE adalah nilai rata-rata dari selisih absolut antara nilai hasil peramalan dan nilai aktual, nilai ditunjukkan dalam persentase [16].

$$\text{MAPE} = \frac{\sum_{t=1}^{T} \frac{|\text{peramalan} - \text{aktual}|}{\text{aktual}}}{n} * 100\% \quad (2.15)$$

dimana :

n = jumlah data