PERAMALAN KUNJUNGAN WISATAWAN KE PALEMBANG: PEMODELAN DATA TIME SERIES LINEAR VS NONLINEAR

Imelda Saluza, S.Si., M.Sc.
Fakultas Ilmu Komputer, Universitas Indo Global Mandiri
Jl. Jend. Sudirman KM. 4 No. 629 Palembang, Sumatera Selatan
e-mail: imeldasaluza4@gmail.com

***Abstract* — Forecasting is one of the statistical models play an important role in decision making. Forecasting aims to predict / forecast what will happen in the future based on past data. One of the models used in forecasting is time series model. Forecasting techniques used in modeling of time series data is a time series model linear and non-linear time series. Linear time series model include exponential smoothing, Auto Regressive Integrated Moving avarege (ARIMA) or Box-Jenkins and others. While non-linear time series models include Artifisal Neural Network (ANN), Fuzzy and others. The models are typically used to forecast financial data (such as forecasting the exchange rate (exchange rate), forecasting gross domestic product, forecasting stock prices, and others). But in this study, both models will be used to forecast data tourist visits to Palembang of South Sumatra province, where the data of tourists visit marked by patterns of seasonality and strong volatility, causing the data tend to be non-stationary and it becomes difficult to model. Forecasting is intended for South Sumatra tourism planning and to plan for infrastructure development needs. The second performance of each model for MSE and MAE is for the linear model 0.6564 and 10:36, while for the nonlinear model is 1.09E-22 and 7.31E-12. From this it appears that the nonlinear models are superior in predicting the number of tourists compared to the linear model.**

***Keywords*—Forecasting, linear and nonlinear time series, tourist visits .**

***Abstrak*—Forecasting adalah salah satu model statistik memainkan peran penting dalam pengambilan keputusan. Peramalan bertujuan untuk memprediksi / perkiraan apa yang akan terjadi di masa depan berdasarkan data masa lalu. Salah satu model yang digunakan dalam peramalan model time series. teknik yang digunakan dalam pemodelan data time series Peramalan adalah model rangkaian waktu linear dan non-linear time series. waktu linier seri model termasuk pemulusan eksponensial, Auto Regresif Integrated Moving avarege (ARIMA) atau Box-Jenkins dan lain-lain. Sementara non-linear model time series termasuk Artifisal Neural Network (ANN), Fuzzy dan lain-lain. Model biasanya digunakan untuk meramalkan data keuangan (seperti peramalan nilai tukar (kurs), peramalan produk domestik bruto, peramalan harga saham, dan lain-lain). Namun dalam penelitian ini, kedua model akan digunakan untuk meramalkan data kunjungan wisatawan ke Palembang Provinsi Sumatera Selatan, di mana data kunjungan wisatawan ditandai dengan pola musiman dan volatilitas yang kuat, menyebabkan data cenderung non-stasioner dan menjadi sulit untuk model. Peramalan ditujukan untuk perencanaan pariwisata Sumatera Selatan dan merencanakan untuk kebutuhan pembangunan infrastruktur. Kinerja kedua masing-masing model untuk MSE dan MAE adalah untuk model linear 0,6564 dan 10:36, sedangkan untuk model nonlinear adalah 1.09E-22 dan 7.31E-12. Dari sini tampak bahwa model nonlinear lebih unggul dalam memprediksi jumlah wisatawan dibandingkan dengan model linear.**

***Kata kunci*—Peramalan, linear dan nonlinear time series, kunjungan wisatawan.**

I. PENDAHULUAN

Tidak dapat dipungkiri bahwa industri pariwisata dapat memberikan dampak yang positif dalam perkembangan ekonomi suatu daerah dan penyumbang devisa Negara yang cukup besar. Dengan adanya pariwisata sudah tentu akan mendatangkan berbagai dampak diberbagai segi kehidupan antara lain dampak lingkungan, sosial budaya serta dampak ekonomi. Dari segi ekonomi dengan adanya pariwisata dapat membawa berbagai dampak meliputi dampak langsung, dampak tidak langsung dan dampak berkelanjutan. Dampak langsungnya adalah bagi pekerja di kawasan wisata tersebut termasuk pemerintah daerah. Dampak tidak langsungnya salah satunya dapat berupa meningkatnya permintaan akan tranportasi umum publik. Dan dampak berkelanjutannya tentu berhubungan dengan pemerintah dan masyarkat yang bekerja di bidang pariwisata ataupun tidak secara langsung tetapi mendapatkan dampak positifnya. Oleh karenanya sangat beralasan jika daerah berlomba-lomba untuk mengembangkan potensi wisatanya, selain dapat mendatangkan pemasukkan daerah juga dapat dijadikan sebagai sarana promosi daerah baik secara nasional maupun internasional. Salah satu daerah yang cukup gencar mengembangkan potensi wisatanya adalah Sumatera Selatan.

Dalam beberapa dekade terakhir, kunjungan wisatawan domestik maupun internasional masih sangat rendah. Hal ini disinyalir berkaitan dengan sulitnya merubah citra rasa aman dan nyaman bagi publik yang akan berkunjung ke Sumatera Selatan yang berakibat masih minimnya wisatawan yang berkunjung ke daerah ini, namun berdampak pula pada pertumbuhan ekonomi daerah yang selama ini masih mengandalkan sumber daya alam yang ada seperti migas dan hasil-hasil perkebunan sebagai sumber devisa daerah. Jika sektor wisata dapat dibenahi, maka bukan tidak mungkin daerah ini akan mampu memberikan kontribusi yang cukup menjanjikan bagi ekonomi daerah, sekaligus dapat menggerakkan ekonomi kerakyatan sehingga mampu meningkatkan kesejahteraan.

Pada musim-musim tertentu jumlah kunjungan wisatawan lebih meningkat dibandingkan hari-hari biasa, seperti saat-saat musim liburan, hari besar keagamaan, dan lain-lain. Sehingga selain melakukan pembenahan, hendaknya juga meramalkan jumlah wisatawan yang akan berkunjung agar daerah dapat melakukan perencanaan pariwisata serta untuk merencanakan kebutuhan pembangunan infrastruktur.

Pada dasarnya peramalan adalah memperkirakan kejadian di waktu yang akan datang dengan melihat hasil ramalan sama atau tidak dengan kenyataannya. Hal ini dipengaruhi oleh time series (deret waktu). Suatu series data dapat diolah untuk menghasilkan suatu inferensi perilaku data time series. Periode dari suatu series data bisa harian, mingguan, bulanan, ataupun tahunan. Menurut Ekananda (2014), keunikan dari data time series adalah hakikatnya yang merekam perilaku data dari waktu ke waktu, sehingga peneliti dapat melihat bagaimana pengambil keputusan melakukan penyesuaian, perbaikan dan penyempurnaan terhadap hasil kerja di waktu lampau.

Selama ini banyak peramalan yang dilakukan secara intuitif atau dengan menggunakan model-model statistik. Menurut Tsay (2005), banyak model yang digunakan untuk meramal data-data time series, antara lain dapat menggunakan model seperti *exponential smoothing, AutoRegressive Integrated Moving Avarege (ARIMA)* atau *Box-Jenkins*, dan lain sebagainya. Seperti Pemilihan model-model tersebut yang digunakan pada perhitungan untuk meramal suatu hal tertentu tergantung dari berbagai aspek yang mempengaruhi, yaitu aspek waktu, pola data, tipe model sistem yang diamati, tingkat keakuratan peramalan yang diinginkan dan sebagainya. Tetapi model-model statistik tersebut hanya terbatas pada model-model linear saja. Sementara dalam banyak kasus peramalan data time series mempunyai kecendrungan nonlinear.

Untuk mendapatkan informasi-informasi yang dibutuhkan mengenai data time series, model yang digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA). Karena ARIMAmerupakan suatu statistik yang cocok digunakan untuk meramal sejumlah variabel secara cepat, sederhana, murah dan akurat karena hanya membutuhkan data variabel yang akan diramal. Model ARIMA menggunakan pendekatan iteratif dalam indentifikasi terhadap suatu model yang ada. Model yang dipilih diuji lagi dengan data masa lampau untuk melihat apakah model tersebut menggambarkan keadaan data secara akurat atau tidak. Suatu model dikatakan sesuai (tepat) jika residual antara model dengan titik-titik data historis bernilai kecil, terdistribusi secara acak dan bebas satu sama lainnya.

Banyak sekali fenomena-fenomena stasioner dapat didekati dengan menggunakan model time series linier. Namun demikian, model time series nonlinier diyakini mampu lebih mengungguli model time series linier. Data pariwisata biasanya memiliki pola musiman dan volatilitas, sehingga datanya membutuhkan pengolahan yang signifikan agar dapat digunakan untuk tujuan peramalan.

Seiring perkembangan ilmu pengetahuan maka berkembanglah beberapa model datatime series baru. Dalam beberapa dekade terakhir banyak bermunculan teknik kecerdasan buatan, seperti *Artifisial Neural Network* (ANN) untuk melakukan peramalan data time series nonlinier.*Artifisial Neural Network* (ANN) memberikan kinerja atau hasil ramalan yang baik karenanya jaringan syaraf telah digunakan sangat luas dalam menunjukkan pendekatan alternatif untuk peramalan data time series. Sebagian besar dari kesuksesan penerapan-penerapan tidak dipungkiri merupakan peran dari jaringan syaraf dalam memodelkan dan meramal data time series.Tujuan dari penelitian ini adalah untuk mengevaluasi kinerja peramalan dari model data time series linier (ARIMA) terhadap model nonlinier (ANN) serta memberikan hasil peramalan yang akurat sehingga dapat digunakan oleh daerah sebagai gambaran jumlah wisatawan yang akan berkunjung ke Sumatera Selatan.

II. METODOLOGI PENELITIAN

2.1 Stationeritas Data

Hal yang paling mendasar dan penting dalam melihat perilaku data time series adalah stationeritas data. Data time series dikatakan stationer jika secara stokastik data menunjukkan pola variasi (varians) yang konstan dari waktu ke waktu atau dengan kata lain tidak terdapat kenaikan atau penurunan pada data yang terlalu mencolok. Terdapat dua perilaku stationeritas data, yaitu:

1. Mean Stationerity. Data bersifat stationer pada nilai tengahnya (mean) yaitu apabila data tersebut berfluktuasi di sekitar suatu nilai tengah yang tetap sepanjang/ selama waktu observasi. Jika data tidak stationer, maka dapat dilihat sampai dimana data tersebut stationer. Langkah yang harus dilakukan adalah melakukan pembedaan (differencing) tahap pertama dan kedua terhadap data asli.
2. Variance Stationerity. Data bersifat stationer pada variansnya (variance) yaitu apabila data berfluktuasi

dengan varians yang tetap dari waktu ke waktu. Jika data jenis ini tidak stationer, maka dapat dilihat sampai dimana data tersebut stationer. Langkah umum untuk menanggulangi/ menghilangkan non stationeritas adalah mentransformasikan data asli dengan Ln (Logaritma natural) atau akar kuadrat.

Menurut Rober (1993) dalam melakukan kajian stationeritas perlu didefinisikan $\underline{y_t}$ sebagai simpangan y_t terhadap rata-rata μ (untuk proses AR) atau δ (untuk proses MA). Nilai $\underline{y_t}$ sebagai kondisi untuk analisis stationeritas.

$$\underline{y_t} = y_t - \mu = y_t - \delta$$

maka persamaan di atas menjadi:

$$\underline{y_t} = \theta(B)\varepsilon_t$$

atau

$$\underline{y_t} = \phi^{-1}(B)\theta(B)\varepsilon_t$$

variabel y_t akan stationer pada nilai $\underline{y_t}$ jika $\phi^{-1}(B)$ konvergen, yaitu:

$$1/[1 - \phi_1 B y_t - \phi_1 B^2 y_t - \phi_1 B^3 y_t - \cdots - \phi_P B^P] < 1$$

$\phi^{-1}(B)$ konvergen jika akar karakteristik pada persamaan:

$$\phi(B) = 1 - \phi_1 B y_t - \phi_1 B^2 y_t - \phi_1 B^3 y_t - \cdots - \phi_P B^P = 0$$

semua magnitude penyelesaian dari $B_1, B_2, \cdots, B_P$ berada diluar unit *circle* (lebih besar dari 1).

2.2 Evaluasi Kinerja Pemodelan Time Series

Model yang digunakan akan dinilai keakuratan ramalannya. Kaedah penilaian yang digunakan adalah *Mean Square Error* (MSE) dan *Mean Absolute Error* (MAE). Pendekatan MSE dan MAE digunakan untuk menilai prestasi jaringan yang dilatih karena MSE dan MAE mengenal secara pasti signifikasi hubungan diantara data ramalan dengan data aktual dengan seberapa besar error yang terjadi. Ketepatan model diukur secara relatif menggunakan MSE dan MAE didapat dari persamaan di bawah ini.

$$MSE = \frac{1}{n}\sum_{i=1}^{n} e_i^2 = \frac{1}{n}\sum_{t=1}^{n} (y_t - \hat{y}_t)^2$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n} |e_i| = \frac{1}{n}\sum_{t=1}^{n} |y_t - \hat{y}_t|$$

dengan,

n = bilangan ramalan

y_t = nilai aktual pada waktu t

$\hat{y}_t$ = nilai ramalan pada waktu t

Berdasarkan nilai MSE dan MAE yang terendah dari proses pelatihan diperoleh model yang optimum.

2.3 Rancangan Model Linear

Alur kerja sebagai gambaran umum langkah-langkah yang harus dilakukan sehingga dapat mempermudah pemahaman awal.

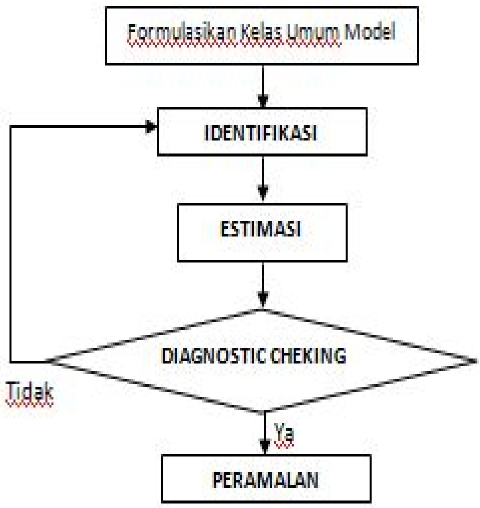

Gbr 1. Alur Kerja Model Linear

2.4 Rancangan Model NonLinear

Backpropagation merupakan model yang sangat baik dalam menangani masalah pengenalan pola-pola kompleks. Istilah *'Backpropagation'* diambil dari cara kerja jaringan ini, berikut merupakan alur kerja jaringan *backpropagation*

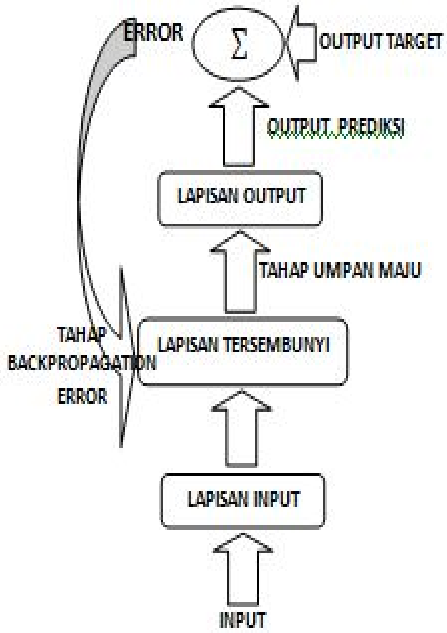

Gbr 2. Alur Kerja Model NonLinear

III. KAJIAN TEORITIS

3.1 Model Data Time Series Linier

Model-model data time series linier yang biasa digunakan antara lain adalah *exponential smoothing, AutoRegressive Integrated Moving Avarege (ARIMA)* atau *Box-Jenkins*, dan lain sebagainya. Dalam penelitian ini peneliti akan menggunakan *AutoRegressive Integrated Moving Avarege (ARIMA)* atau *Box-Jenkins* sebagai model data time series linier.

Metode ARIMA seringkali dituliskan dalam betuk operator *backshift*. Operator *backshift* sesungguhnya tidak melibatkan konsep statistik yang baru, notasi ini hanya suatu cara untuk memudahkan menuliskan model ARIMA.

Notasi *backshift* B beroperasi mengalikan Y_t dengan B, diperoleh Y_{t-1} yaitu $BY_t = Y_{t-1}$. Persamaan ini menyatakan bahwa B menggeser *subscript* waktu. Notasi B artinya memiliki pangkat satu, akan tetapi pangkat B boleh lebih dari satu. Jika mengalikan Y_t dengan B^5 maka diperoleh $B^5 Y_t = Y_{t-5}$. Secara umum didefinisikan sebagai berikut:

$$B^k Y_t = Y_{t-k}$$

Operator *backshift* B dapat diperluas definisinya menjadi diferensi $(1-B)$. Jika Y_t dikalikan dengan $(1-B)$ maka akan diperoleh persamaan berikut:

$$(1-B)Y_t = Y_t - BY_t = Y_t - Y_{t-1}$$

Perlu diingat bahwa B bukanlah merupakan suatu bilangan, sehingga $(1-B)$ juga bukan merupakan suatu bilangan tertentu namun merupakan suatu operator.

Proses *Autoregressive* (AR)

AR (1)

$$Y_t = \delta + \phi_1 Y_{t-1} + \varepsilon_t$$

$$Y_t - \phi_1 Y_{t-1} = \delta + \varepsilon_t$$

$$(1 - \phi_1 B) Y_t = \delta + \varepsilon_t$$

AR (2)

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t$$

$$Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} = \delta + \varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2) Y_t = \delta + \varepsilon_t$$

AR (p)

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \ldots + \phi_p Y_{t-p} + \varepsilon_t$$

$$Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \ldots - \phi_p Y_{t-p} = \delta + \varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \ldots - \phi_p B^p) Y_t = \delta + \varepsilon_t$$

dimana:

δ = nilai konstan

ϕ_p = parameter *autoregressive*

ε_t = nilai *error* pada saat *t*

Proses *Moving Average* (MA)

MA (1)

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

$$Y_t = \mu + (1 - \theta_1 B)\varepsilon_t$$

MA (2)

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2}$$

$$Y_t = \mu + (1 - \theta_1 B - \theta_2 B^2)\varepsilon_t$$

MA (q)

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \ldots - \theta_q \varepsilon_{t-q}$$

$$Y_t = \mu + (1 - \theta_1 B - \theta_2 B^2 - \ldots - \theta_q B^q)\varepsilon_t$$

$$Y_t = \mu + \theta_q(B)\varepsilon_t$$

dimana:

δ = nilai konstan

θ_q = parameter *moving average*

ε_t = nilai *error* pada saat *t*

Proses ARIMA

Berdasarkan AR (1) dan MA (1) akan diperoleh bentuk umum dari ARMA (1,1) sebagai berikut:

ARMA(1,1)

$$Y_t = \mu + \phi_1 Y_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

$$(1 - \phi_1 B) Y_t = \mu + (1 - \theta_1 B)\varepsilon_t$$

Jika nonstasioneritas ditambahkan pada campuran proses ARMA, maka model umum ARIMA (*p,d,q*) terpenuhi. Persamaan sederhana untuk AR (1) MA (1) dan dilakukan pembedaan (*differencing*) $(1-B)$ atau ARIMA (1,1,1) adalah sebagai berikut:

$$(1 - B)(1 - \phi_1 B) Y_t = \mu + (1 - \theta_1 B)\varepsilon_t$$

Identifikasi Model ARIMA

Autocorrelation Function (ACF) Proses *Autoregressive* (AR)

Untuk menentukan persamaan autokorelasi *Autoregressive* (*p*)hal pertama yang harus dilakukan adalah dengan mengalikan AR (1) dengan Y_{t-k} pada kedua sisi persamaan, dan untuk meyederhanakan masalah maka δ dianggap nol kemudian dicari nilai ekspektasinya sebagai berikut:

$$E[Y_{t-k} Y_t] = E[\phi_1 Y_{t-k} Y_{t-1}] + E[\phi_2 Y_{t-k} Y_{t-2}] + \ldots + E[\phi_p Y_{t-k} Y_{t-p}] + E[Y_{t-k}\varepsilon_t]$$

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \ldots + \phi_p \gamma_{k-p},\ k > 0$$

dimana $E[Y_{t-k} Y_t] = 0$ untuk $k > 0$ kemudian membagi persamaan di atas dengan γ_0, sehingga diperoleh

$$\frac{\gamma_k}{\gamma_0} = \frac{\phi_1\gamma_{k-1} + \phi_2\gamma_{k-2} + \ldots + \phi_p\gamma_{k-p}}{\gamma_0}$$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \ldots + \phi_p \rho_{k-p},\ k > 0$$

Persamaan di atas merupakan persamaan *autocorrelation* untuk *autoregressive* (*p*).

Autocorrelation Function (*ACF*) Proses *Moving Average* (MA)

Untuk mencari persamaan *Autocorrelation* persamaan *Moving Average* (*q*) dikalikan dengan Y_{t-k} dan untuk menyederhanakan persamaan δ dianggap nol, selanjutnya dicari nilai ekspektasinya sebagai berikut:

$$E[Y_{t-k} Y_t] = E[(\varepsilon_t - \theta_1 \varepsilon_{t-1} - \ldots - \theta_q \varepsilon_{t-q})(\varepsilon_{t-k} - \theta_1 \varepsilon_{t-1-k} - \ldots - \theta_q \varepsilon_{t-q-k})]$$

sehingga,

$$\gamma_k = E[(\varepsilon_t - \theta_1 \varepsilon_{t-1} - \ldots - \theta_q \varepsilon_{t-q})(\varepsilon_{t-k} - \theta_1 \varepsilon_{t-1-k} - \ldots - \theta_q \varepsilon_{t-q-k})]$$

$$\gamma_k = [\varepsilon_t\varepsilon_{t-k} - \theta_1 \varepsilon_t \varepsilon_{t-1-k} - \ldots - \theta_q \varepsilon_t \varepsilon_{t-q-k} - \theta_1 \varepsilon_{t-k}\varepsilon_{t-1} + \theta_1^2 \varepsilon_{t-1}\varepsilon_{t-1-k} + \ldots + \theta_1 \varepsilon_{t-1}\theta_q \varepsilon_{t-q-k} - \theta_q \varepsilon_{t-q}\varepsilon_{t-k} + \theta_q \varepsilon_{t-q}\theta_1 \varepsilon_{t-1-k} + \ldots + \theta_q^2 \varepsilon_{t-q}\varepsilon_{t-q-k}]$$

nilai ekspektasi dari persamaan di atas akan bergantung pada nilai *k*, jika $k = 0$ persamaan di atas menjadi

$$\gamma_0 = E[\varepsilon_t \varepsilon_{t-0} + \theta_1^2 \varepsilon_{t-1}\varepsilon_{t-1-0} + \ldots + \theta_q^2 \varepsilon_{t-q}\varepsilon_{t-q}]$$

seluruh suku yang lain pada persamaan di atas hilang karena adanya definisi $E[\varepsilon_t \varepsilon_{t+i}] = 0$ untuk $i \neq 0$ dan definisi $E[\varepsilon_t \varepsilon_{t+i}] = \sigma_\varepsilon^2$ untuk $i \neq 0$. Jadi persamaan di atas menjadi

$$\gamma_0 = \sigma_\varepsilon^2 + \theta_1^2 \sigma_\varepsilon^2 + \ldots + \theta_q^2 \sigma_\varepsilon^2$$

$$\gamma_0 = (1 - \theta_1^2 + \ldots + \theta_q^2)\sigma_\varepsilon^2$$

Secara umum untuk $k = k$ diperoleh persamaan berikut:

$$\gamma_k = -\theta_k \sigma_\varepsilon^2 + \theta_1 \theta_{k+1} \sigma_\varepsilon^2 + \ldots + \theta_{q-k}\theta_q \sigma_\varepsilon^2$$

$$\gamma_k = (-\theta_k + \theta_1 \theta_{k+1} + \ldots + \theta_{q-k}\theta_q)\sigma_\varepsilon^2$$

sehingga,

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{(-\theta_k + \theta_1\theta_{k+1} + \ldots + \theta_{q-k}\theta_q)\sigma_\varepsilon^2}{(1 - \theta_1^2 + \ldots + \theta_q^2)\sigma_\varepsilon^2}$$

MA (*q*)

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{(-\theta_k + \theta_1\theta_{k+1} + \ldots + \theta_{q-k}\theta_q)\sigma_\varepsilon^2}{(1 - \theta_1^2 + \ldots + \theta_q^2)\sigma_\varepsilon^2},\ k = 1, \ldots, q$$

Partial Autocorrelation Function (*PACF*) Proses *Autoregressive* (AR)

Selain *autocorrelation function* (*ACF*), *partial autocorrelation function* (*PACF*) digunakan secara bersama-sama untuk mengidentifikasi model ARMA dari suatu data time series. *Partial autocorrelation* mengukur tingkat keeratan antara Y_t dan Y_{t-k}, dengan asumsi pengaruh time lag 1,2,3,…, dan seterusnya sampai k-1 dianggap terpisah. Persamaan di bawah ini memperlihatkan bahwa koefisien yang terakhir dari masing-masing persamaan merupakan koefisien autokorelasi parsial. Ini berarti notasi $\hat{\phi}_1, \hat{\phi}_2 \ldots, \hat{\phi}_{m-1}$ dan $\hat{\phi}_m$ adalah *m* buah koefisien autokorelasi parsial yang pertama untuk time series tersebut.

$$Y_t = \hat{\phi}_1 Y_{t-1} + \varepsilon_t$$

$$Y_t = \hat{\phi}_1 Y_{t-1} + \ldots + \hat{\phi}_{m-1} Y_{t-m+1} + \hat{\phi}_m Y_{t-m}\varepsilon_t$$

jika ruas kiri dan kanan dari persamaan pertama di atas dikalikan dengan Y_{t-1}, hasilnya adalah

$$Y_t Y_{t-1} = \hat{\phi}_1 Y_{t-1} Y_{t-1} + Y_{t-1}\varepsilon_t$$

dengan mengambil nilai ekspektasinya maka akan menghasilkan

$$E(Y_tY_{t-1}) = E(\hat{\phi}_1 Y_{t-1}Y_{t-1}) + E(Y_{t-1}\varepsilon_t)$$

sehingga,
$\gamma_1 = \phi_1\gamma_0$

Berdasarkan definisi $E(Y_tY_{t-1}) = \gamma_1$, $E(\hat{\phi}_1 Y_{t-1}Y_{t-1}) = \gamma_0$ dan $E(Y_{t-1}\varepsilon_t) = 0$

Karena $\rho_k = \frac{\gamma_k}{\gamma_0}$, operasi di atas dapat diperluas dengan cara mengalikan kedua ruas dengan Y_{t-k}, kemudian dihitung nilai ekspektasinya yang merupakan nilai kovariansi. Selanjutnya dengan membagi terhadap γ_0, diperoleh sekumpulan persamaan Yule Walker yang dapat digunakan untuk mencari nilai-nilai $\hat{\phi}_1, \hat{\phi}_2 \ldots, \hat{\phi}_{m-1}$ dan $\hat{\phi}_m$. Nilai-nilai ini dapat digunakan untuk menduga nilai-nilai autokorelasi parsial sampai time lag *m*.

Dengan mengambil nilai ekpektasi pada kedua sisi persamaan diperoleh

$$\gamma_k = \phi_1\gamma_{k-1} + \phi_2\gamma_{k-2} + \ldots + \phi_p\gamma_{k-p}$$

$$\rho_k = \phi_1\rho_{k-1} + \phi_2\rho_{k-2} + \ldots + \phi_p\rho_{k-p}$$

selanjutnya diperoleh

$$\rho_1 = \phi_1\rho_0 + \phi_2\rho_1 + \ldots + \phi_p\rho_{p-1}$$

$$\vdots$$

$$\rho_k = \phi_1\rho_{p-1} + \phi_2\rho_{p-2} + \ldots + \phi_p\rho_0$$

dimana $\rho_1, \ldots, \rho_p$ adalah autokorelasi teoritis sampai lag ke *p*, sedangkan $\phi_1, \ldots, \phi_p$ adalah *p* koefisien AR (*autoregressive*) dari proses AR (*p*).

Partial Autocorrelation Function (*PACF*) Proses *Moving Average* (MA)
MA (*q*)
PACF merupakan gabungan dari fungsi menyeluruh secara eksponensial dan atau fungsi sinus meluruh tergantung pada akar-akar dari

$$C(z) = 1 + b_1z + b_2z^2 + \ldots + b_qz^q$$

[4]

3.2 Model Data Time Series Nonlinier

Salah satu model data time series nonlinier adalah *Artifisial Neural Network* (ANN), *Generalized AutoRegressive Conditional Heteroscedasticity* (GARCH), *Treshold AutoRegressive* (TAR), dan lain-lain. Namun pada penelitian ini yang digunakan adalah *Artifisial Neural Network* (ANN).

Artificial neural network (ANN) atau jaringan syaraf tiruan merupakan sistem informasi yang mempunyai cara kerja dan karakteristik menyerupai jaringan syaraf pada makhluk hidup, yaitu terdiri dari elemen-elemen pemrosesan sederhana yang disebut *neuron*. Setiap *neuron* dihubungkan dengan *neuron* lain dengan hubungan komunikasi yang disebut arsitektur jaringan. Menurut [2] jaringan syaraf tiruan merupakan sistem pemroses informasi yang memiliki karakterstik mirip dengan jaringan syaraf biologi.

Suatu jaringan syaraf terdiri dari elemen-elemen pemrosesan sederhana yang disebut neuron atau unit. Setiap neuron dihubungkan dengan neuron yang lain dengan link komunikasi langsung yang melalui pola hubungan yang disebut arsitektur jaringan. Bobot-bobot pada koneksi mewakili besarnya informasi yang digunakan jaringan. Metode yang digunakan untuk menentukan bobot koneksi tersebut dinamakan dengan algoritma pembelajaran. Setiap neuron mempunyai tingkat aktivasi yang merupakan fungsi dan input yang masuk padanya. Aktivasi yang dikirim suatu neuron ke neuron lain berupa sinyal.

Secara umum, persamaan prediksi model jaringan syaraf dengan satu lapisan tersembunyi untuk perhitungan peramalan $\hat{y}_t$ (output atau target) menggunakan input observasi masa lalu $x_{t-1}, x_{t-2}, \cdots, x_{t-p}$ biasa di tulis dalam bentuk:

$$\hat{y}_t = \psi_k(w_{k0} + \sum_{j=1}^{p} w_{kj}\psi_j(v_{j0} + \sum_{i=1}^{n} v_{ij}x_i))$$

dimana:

x_i : variabel input (*i = 1, 2, ..., n*)

v_{ij} : $[v_{11}, v_{12}, \cdots, v_{np}]$ bobot dari input ke-*i*yang menuju ke lapisan tersembunyi ke-*j* (*j = 1, 2, ..., p*)

v_{j0} : bobot koneksi antara unit konstan dan neuron

Ψ_j : fungsi aktivasi di neuron ke-*j* pada lapisan tersembunyi

w_{kj} : $[w_{11}, w_{12}, \cdots, w_{mp}]$ bobot dari lapisan tersembunyi ke-*j*yang menuju ke lapisan output ke-*k* (*k = 1, 2, ..., p*)

w_{k0} : bobot koneksi antara unit konstan dan neuron

Ψ_k : fungsi aktivasi di neuron ke-*k* pada lapisan output

Pada dasarnya, algoritma pelatihan standar *backpropagation* akan menggerakkan bobot dengan arah gradien negatif. Prinsip dasar dari algoritma *backpropagation* adalah memperbaiki bobot-bobot jaringan dengan arah yang membuat fungsi aktivasi menjadi turun dengan cepat.

Pelatihan *backpropagation* meliputi 3 fase sebagai berikut:

1. Fase 1, yaitu propagasi maju.

Pola masukan dihitung maju mulai dari layar masukan hingga layar keluaran menggunakan fungsi aktivasi yang ditentukan.

2. Fase 2, yaitu propagasi mundur.
   Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan yang terjadi itu dipropagasi mundur. Dimulai dari garis yang berhubungan langsung dengan unit-unit di layar keluaran.
3. Fase 3, yaitu perubahan bobot.
   Modifikasi bobot untuk menurunkan kesalahan yang terjadi. Ketiga fase tersebut diulang-ulang terus hingga kondisi penghentian dipenuhi.

Algoritma pelatihan untuk jaringan *backpropagation* dengan satu layar tersembunyi (dengan fungsi aktivasi sigmoid biner) adalah sebagai berikut:

a. Langkah 0
   Inisialisasi semua bobot dengan bilangan acak kecil
b. Langkah 1
   Jika kondisi penghentian belum dipenuhi, lakukan langkah 2-8
c. Langkah 2
   Untuk setiap pasang data pelatihan, lakukan langkah 3-8

Fase I : Proragasi maju

d. Langkah 3 (langkah 3-5 merupakan fase 1)
   Tiap unit masukan menerima sinyal dan meneruskannya ke unit tersembunyi diatasnya
e. Langkah 4
   Hitung semua keluaran di unit tersembunyi z_j (j = 1, 2,..., p)

$$z\_net_j = v_{jo} + \sum_{i=1}^{n} x_i v_{ji}$$

$$z_j = \psi(z\_net_j) = \frac{1}{1+e^{-z\_net_j}}$$

f. Langkah 5
   Hitung semua keluaran jaringan di unit keluaran y_k (k = 1, 2,...,m)

$$y\_net_k = w_{ko} + \sum_{j=1}^{p} z_j w_{kj}$$

$$y_k = \psi(y\_net_k) = \frac{1}{1+e^{-y\_net_k}}$$

Fase II : Propagasi Mundur

g. Langkah 6
   Hitung faktor δ unit keluaran berdasarkan kesalahan di setiap unit keluaran y_k (k = 1, 2,..., m)

$$\delta_k = (t_k - y_k)\,\psi'(y\_net_k) = (t_k - y_k) y_k (1 - y_k)$$

$t_k =$ target keluaran

δ_k merupakan unit kesalahan yang akan dipakai dalam perubahan bobot layar di bawahnya.

Hitung perubahan bobot w_{kj} dengan laju pemahaman α

$$\Delta w_{kj} = \alpha\, \delta_k z_j\,, \quad k = 1, 2, \cdots, m\,; j = 1, 2, \cdots, p$$

h. Langkah 7
   Hitung faktor δ unit tersembunyi berdasarkan kesalahan di setiap unit tersembunyi z_j (j = 1, 2, ..., p)

$$\delta\_net_j = \sum_{k=1}^{m} \delta_k w_{kj}$$

Faktor δ unit tersembunyi:

$$\delta_j = \delta\_net_j \psi'(z\_net_j) = \delta\_net_j z_j (1 - z_j)$$

Hitung perubahan bobot v_{ji}

$$\Delta v_{ji} = \alpha \delta_j x_i$$

Fase III : Perubahan Bobot

i. Langkah 8
   Hitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit keluaran, yaitu:

$$w_{kj}(baru) = w_{kj}(lama) + \Delta w_{kj}\,,$$

$$(k = 1, 2, \cdots, m\,; j = 0, 1, 2, \cdots, p)$$

Perubahan bobot garis yang menuju ke unit tersembunyi adalah:

$$v_{ji}(baru) = v_{ji}(lama) + \Delta v_{ji}\,,$$

$$(j = 1, 2, \cdots, p\,; j = 0, 1, 2, \cdots, n)$$

IV. HASIL DAN PEMBAHASAN

4.1 Data

Berdasarkan hasil-hasil penelitian terdahulu mengenai keberhasilan aplikasi model*AutoRegressive IntegratedMoving Average*(ARIMA) yangmampu menangkap karakteristik linier atau model*Artifisial Neural Network* (ANN) yang mampu menangkap karakteristik nonlinier. Oleh karenanya, dalam penelitian ini dilakukan studi kasus untuk mencari modelbaik untuk meramalkan jumlah kunjungan wisatawan ke Palembang Sumatera Selatan. Dalam penelitian ini data didapatkan dari Dinas Pariwisata untuk kunjungan bulanan.

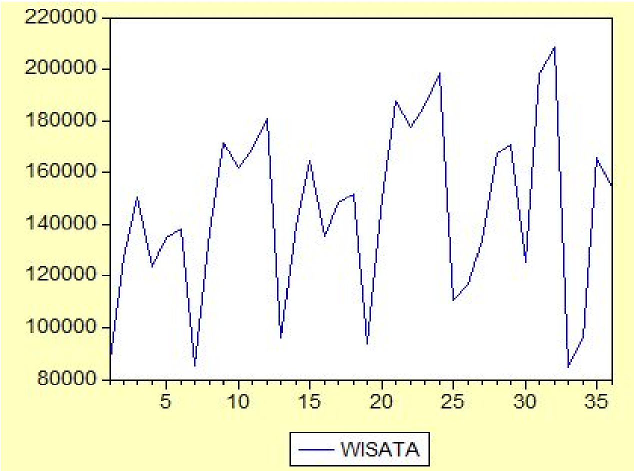

Gbr 3. Data Aktual

4.2 Hasil

Bagian ini membahas hasil empiris efektifitas modelLinear dan NonLinear. Kinerja dari model*AutoRegressive Integrated Moving Average (ARIMA), backpropagation Artifisial Neural Network* dan diukur menggunakan *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE).

PENGUKURAN	MODEL	
	LINEAR	NONLINEAR
MSE	0.6564	1.09E-22
MAE	10.36	7.31E-12

Tabel 1. Hasil Pengukuran Kinerja Model

dari tabel 1,terlihat bahwa modelnonlinear adalahmodel terbaik untuk meramalkan jumlah kunjungan wisatawan yang dating ke Palembang.

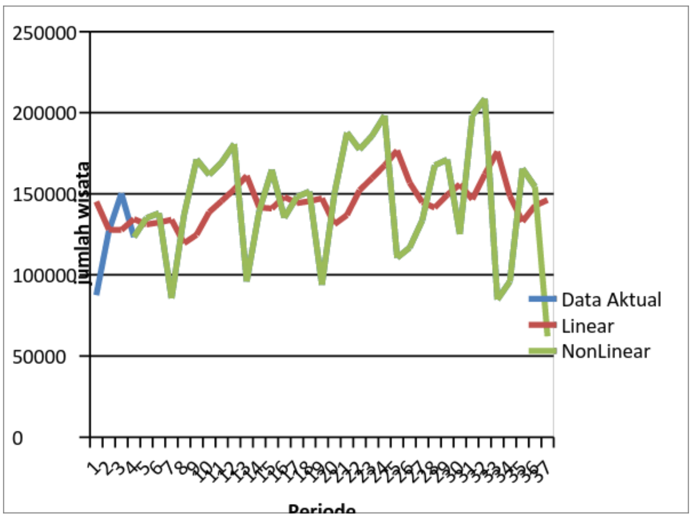

*Gbr 4.*Grafik Peramalan

dari kedua gambar di atas membahas hasil prediksi jumlah kunjungan wisatawan ke Palembang. Pada bagian ini akan membandingkan antara data asli dan data hasil prediksidengan menggunakan modelmodel*AutoRegressive Integrated Moving Average* (ARIMA),*Artifisial Neural Network*(ANN*)*. Jika gambar diperbesar dapat dilihat bahwa modelnonlinear mampu mengikuti data asli sedangkan modellinear dan model*Artifisial Neural Network*(ANN*)* memberikan hasil prediksi yang lebih baik dibandingkan dengan hasil prediksi *AutoRegressive Integrated Moving Average* (ARIMA) dilihat dari pengukuran errornya.

Hasil Peramalan dari model*AutoRegressive Integrated Moving Average* (ARIMA) dan*Artifisial Neural Network*(ANN*)* untuk satu periode ke depan, ditunjukkan pada tabel berikut:

Peramalan	Linear	Nonlinear
Wisata	146188.8	62141.41

Tabel 2. Hasil Peramalan Model Linear Vs NonLinear

V. KESIMPULAN

Berdasarkan hasil penelitian modelnonlinear atau *Artifisial Neural Network*(ANN*)* lebih baik dibandingan model linear atau *AutoRegressive Integrated Moving Average* (ARIMA) untuk memprediksi jumlah kunjungan wisatawan ke Palembang.

KEPUSTAKAAN

[1] Ekananda, M. (2014). Analisis Data Time Series Untuk Penelitian Ekonomi, Manajemen dan Akuntansi. Jakarta: Mitra Wacana Media.

[2] Fausett, Laurene. Fundamentals of Neural Networks Architectures, Algorithms, andApplications. Prentice Hall, 1994.

[3] Makridakis, S., Wheelwright, S.C., McGee, V.E. (2002). Metode aplikasi dan peramalan. Tangerang: Binarupa Aksara Publisher.

[4] Rosadi, D. 2011. Analisis Ekonometrika & Runtun Waktu Terapan dengan R. Yogyakarta: ANDI.

[5] Tsay, S., Rue. (2005). Analysis of Financial Time Series. United States of America: Wiley
-Interscience.