

BAB II

LANDASAN TEORI

2.1. Kriminalitas

Pengertian secara ilmu bahasa kriminalitas atau tindak kejahatan adalah segala karakter manusia yang akan menimbulkan banyak kemudharatan materi psikologi dan mengusik kehidupan bersama. Kejahatan akan terjadi kapan saja dan dimana saja dan juga kejahatan harus di perangi karena kejahatan sebagaimana menurut ilmu hukum akan menyebabkan kerugian yang sangat besar berpengaruh di dalam kehidupan masyarakat (Astuti, 2013). Secara tiorem juga menguraikan kejahatan sebagai suatu yang menurut undang-undang dasar adalah pelanggaran dan menggunakan mekanisme yang memiliki aturan-aturan seperti (penyelidikan, tuntutan, dakwaan dan vonis) untuk meresponnya, namun akan tetapi definisi tersebut memiliki kelemahan yang sangat mendasar yaitu meskipun sebuah aksi yang sangat berbahaya dan merusak (Astuti, 2013).

Istilah Kekerasan Dalam Rumah Tangga (KDRT) digunakan untuk menggambarkan seluruh kegiatan berupa pemukulan, penganiyaan, dan kekerasan pada wanita, pasangan, atau wanita (Dobash & Dobash, 2015). KDRT juga dapat didefinisikan sebagai pola perilaku agresif dalam hubungan intim, di mana kekerasan diterapkan oleh satu pasangan untuk mendapatkan atau mempertahankan kekuasaan dan mengendalikan pasangan intim lainnya (Jordan, 2015). Kekerasan dalam rumah tangga dapat dibedakan dari bentuk-bentuk kekerasan lainnya, khususnya kekerasan terhadap orang asing

dan sipil(Meth, 2012). Tindakan KDRT umumnya berdampak pada pihak perempuan seperti kegiatan pemerkosaan dan kekerasan seksual baik oleh pasangan, kenalan, atau orang asing, atau dalam konteks konflik bersenjata; pelecehan seksual selama masa kanak-kanak; perdagangan untuk tujuan seks atau kerja paksa, prostitusi paksa, mutilasi alat kelamin perempuan, perkawinan anak, dan praktik tradisional yang berbahaya lainnya, dan pembunuhan atas nama kehormatan atau terkait dengan mahar(Garcia-Moreno & Stöckl, 2016).

2.2. Time series


Time series adalah urutan titik data untuk variabel yang biasanya diukur pada waktu yang berturut-turut pada interval waktu yang seragam(Robinson & Sciences, 2020). Menurut ahli lain mengatakan bahwa segala nilai pada rentang skala yang sama dan diurutkan dengan waktu sebagai indeks disebut *time series*(Brillinger, 2015). Gagasan *time series* tampak mendasar bagi hampir semua aktivitas. Serial waktu digunakan secara umum dan juga mirip untuk komunikasi, deskripsi, dan visualisasi. Karena waktu adalah konsep fisik, parameter dan karakteristik lainnya adalah model matematika untuk deret waktu dapat memiliki interpretasi dunia nyata.(Brillinger, 2015).

Analisis pada data *time series* atau yang disebut dengan *time series analysis* merupakan suatu proses untuk memahami suatu data *time series* dan membuat nilai *forecasting* pada pola data tersebut(Robinson & Sciences, 2020). Teknik *time series analysis* diterapkan pada *time series* mengarah pada peningkatan pemahaman terhadap data dan pola didalamnya. Tujuannya mencakup

ringkasan, keputusan, deskripsi, dan prediksi (Brillinger, 2015). *Time series analysis* memiliki beberapa tujuan diantaranya seperti berikut (Robinson & Sciences, 2020) :

1. Melihat deskripsi utama data, biasanya dilakukan setelah melakukan bentuk *plotting* pada data.
2. Menjelaskan isi data, dengan melihat hubungan variabel dengan variabel lainnya.
3. Prediksi, atau yang biasa disebut dengan *forecasting*.
4. Kontrol kualitas data, biasanya dilakukan dengan *monitoring* data.

Salah satu contoh data *time series* seperti yang ada pada buku yang ditulis oleh (Søren & Murat, 2011) seperti pada Gambar 2.1 mengenai *Gross National Product* (GNP) negara Amerika Serikat dari tahun 1947 hingga tahun 2010.



Gambar 2.1 Contoh Grafik *Time series*

Sumber: (Søren & Murat, 2011)

Pada karya nya (Søren & Murat, 2011) juga mengatakan bahwa penerapan *time series* dapat ditemukan diberbagai bidang seperti kesehatan, ekonomi, keuangan, dan operasi manajemen pada suatu organisasi.


2.3. Forecasting

Forecasting terdiri dari pembentukan harapan tentang keadaan masa depan atau proses entitas sosial, seperti populasi atau subpopulasinya, dan entitas terkait, seperti ekonomi dan lembaga politik dan sosial(Kenneth, 2015). Ahli lain juga menyebutkan bahwa *forecasting* merupakan suatu bidang ilmu yang memprediksi peristiwa di masa mendatang dengan bantuan data historis masa lalu menggunakan model matematika(Jay & Render, 2015). *Forecasting* juga didefinisikan sebagai hasil nilai yang akan datang dengan ketentuan variabel – variabel yang mendukung. Semakin bagus variabel semakin bagus hasil prediksi(William J et al., 2014). *Forecasting* adalah masalah penting yang mencakup banyak bidang termasuk bisnis dan industri, pemerintah, ekonomi, ilmu lingkungan, kedokteran, ilmu sosial, politik, dan keuangan. Masalah peramalan sering diklasifikasikan seperti jangka pendek, jangka menengah, dan jangka panjang. Masalah peramalan jangka pendek melibatkan peristiwa prediksi hanya beberapa periode waktu (hari, minggu, dan bulan) kedepan(Montgomery et al., 2016).

2.4. Stasioneritas

Salah satu asumsi dari data *time series* untuk proses dengan metode *time series analysis* adalah data tersebut harus berbentuk stasioner (Brillinger, 2015). Stasioneritas dapat disebut sebagai kondisi dimana tidak adanya perubahan sistematis dalam tren data, tidak ada perubahan sistematis dalam varian data, dan penghapusan variasi yang ketat secara berkala (Robinson & Sciences, 2020). Singkatnya suatu keadaan *equilibrium* di mana perilaku keseluruhan dari data *time series* tidak mengalami perubahan dari waktu ke waktu. Ketika kondisi ini tidak berlaku, seri dikatakan *nonstasioner* (Tiao, 2015). Cara lain untuk memahami stasioneritas adalah bahwa data *time series* memiliki rata-rata *mean* dan varians konstan tanpa pola yang dapat diprediksi dan berulang (Pal & Prakash, 2017).


Berdasarkan Gambar 2.2 yang diambil dari (Montgomery et al., 2016) mengenai penjualan produk farmasi dengan *range* waktu dari minggu pertama hingga ke-120 memiliki data dengan tingkat ketetapan yang selalu sama.



Gambar 2. 2 Contoh Grafik Stasioner

Sumber : (Montgomery et al., 2016)

Berbeda dengan gambar 2.3 yang diambil dari sumber yang sama menunjukkan data mengikuti memiliki tingkat ketetapan yang berbeda-beda untuk setiap *lag* waktu.



Gambar 2. 3 Contoh Grafik Non Stasioner

Sumber : (Montgomery et al., 2016)

Tes untuk menentukan apakah suatu data *time series* dikatakan stasioner atau non stationer disebut sebagai tes hipotesis. Tes *Augmented Dickey – Fuller* (ADF) adalah cara yang paling umum digunakan untuk menilai data *time series* untuk mengecek stationeritas suatu data(Aileen, 2019). Penggunaan tes ADF pada dasarnya menggunakan gagasan dari pemakaian differensi yang melihat perubahan nilai yang muncul pada *time series* dengan nilai pada waktu sebelumnya yang dapat ditulis seperti berikut(Pal & Prakash, 2017) :

$$\Delta y_t = y_t - y_{t-1} \quad (1)$$

Rumus 2. 1 Tes Augmented Dickey-Fuller

Sumber : (Pal & Prakash, 2017)

Dimana :

- y_t = Nilai data *time series* sekarang
- y_{t-1} = Nilai data *time series* satu *lag* sebelumnya

Pada bukunya (Pal & Prakash, 2017) mengatakan model diatas dapat dinyatakan sebagai model regresi linier dari indeks waktu sebelumnya. Regresi linier pada Δy_t dapat dirumuskan sebagai berikut:

$$\Delta y_t = \gamma y_{t-1} + \beta_1 \Delta y_{t-1} + \dots + \beta_k \Delta y_{t-k} + \varepsilon_t \quad (2)$$

Rumus 2. 2 Tes Augmented Dickey-Fuller

Sumber : (Pal & Prakash, 2017)

Dimana :

- y_t = Nilai data *time series* sekarang
- β_k = Koefesien pada waktu k
- ε_t = Tingkat *error*.
- Jika $\gamma = 0$, maka H_0 diterima yaitu tidak stasioner
- Jika $\gamma < 0$, maka H_1 diterima yaitu stasioner

Data yang masih dalam keadaan non stasioner perlu dilakukan *transform* menjadi stasioner. Metode yang dapat digunakan yaitu sebagaimana pada (2.1) menjadi berikut (Montgomery et al., 2016):

$$x_t = y_t - y_{t-1} = \Delta y_t \quad (3)$$

Rumus 2. 3 Tes Augmented Dickey-Fuller Montgomery

Sumber : (Montgomery et al., 2016)

Dimana :

- y_t = Nilai data *time series* sekarang
- y_{t-1} = Nilai data *time series* satu *lag* sebelumnya
- x_t = Data hasil transformasi.

2.5. Auto Regressive

Model *Auto-Regressive*(AR) atau ARIMA (p,0,0) akan melakukan proses regresi dengan menggunakan nilai perhitungan sebelumnya. Bentuk fungsi AR dengan parameter $\phi_1, \phi_2, \dots, \phi_p$ menggunakan ordo p atau AR(p) secara umum memiliki persamaan sebagai sebagai berikut (Montgomery et al., 2016):

$$y_t = \delta + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (4)$$

Rumus 2. 4 Persamaan Auto Regressive

Sumber : (Montgomery et al., 2016)

Dimana :

- δ = konstanta awal
- ϕ_p = koefisien *auto regressive*
- ε_t = nilai *white noise*

2.6. *Moving Average*

Menurut (Aileen, 2019) Model *Moving Average* (MA) bergantung pada hasil gambaran proses di mana nilai pada setiap titik waktu adalah fungsi dari kesalahan atau *error* pada nilai terakhir, nilai kesalahan antara satu dengan lainnya dianggap independen. Model *Moving Average* atau ARIMA (0,0,q) secara umum memiliki persamaan sebagai berikut (Montgomery et al., 2016):

$$y_t = \mu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (5)$$

Rumus 2. 5 Persamaan *Moving Average*

Sumber : (Montgomery et al., 2016)

Dimana :

- μ = suatu konstanta
- θ_q = nilai pembobotan berat *moving average*
- ε_t = nilai *white noise*

2.7. ARMA

Model campuran *Moving Average* dan *Auto Regressive* atau ARIMA (1,0,1) dengan menambahkan parameter p dan q atau bisa disebut dengan ARIMA(p, 0, q) secara umum memiliki persamaan sebagai berikut :

$$y_t = \delta + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (6)$$

Rumus 2. 6 Persamaan ARIMA

Sumber : (Tiao, 2015)

Dimana :

- δ = konstanta awal
- ϕ_p = koefisien *auto regressive*
- θ_q = nilai pembobotan berat *moving average*
- e_t = nilai *white noise*

Kelas model ini telah ditemukan bermanfaat untuk mewakili berbagai rangkaian waktu stasioner, nonstasioner, dan musiman di berbagai bidang keilmuan (Tiao, 2015). Kelas model *autoregressive-moving average* (ARMA) bergantung pada asumsi bahwa proses yang mendasarinya lemah stasioner, yang membatasi rata-rata dan varians menjadi konstan (Time & Analysis, 2019).

2.8. Autocorrelation Function

Autokorelasi bertujuan untuk menentukan hubungan antara suatu titik nilai data *time series* saling berhubungan dengan titik data yang lain secara *linear* sebagai suatu fungsi dari perbedaan waktu mereka (Aileen, 2019). Fungsi autokorelasi adalah metode yang menentukan hubungan korelasi antara dua titik data dengan membagi kovarian dari kedua data dengan varian dari *time series*, sehingga terbentuk persamaan sebagai berikut (Søren & Murat, 2011) :

$$\rho_k = \frac{E[(y_t - \mu)(y_{t+k} - \mu)]}{\sigma_y^2} \quad (7)$$

Rumus 2. 7 Fungsi Autocorrelation

Sumber :(Søren & Murat, 2011)

Dimana :

- y_t = Nilai data pada waktu t
- μ = Perkiraan nilai rata-rata y
- σ_y^2 = Nilai varian dari y
- ρ_k = dengan k = 1, 2, 3,... merupakan nilai dari fungsi autokorelasi.

2.9. Partial Autocorrelation Function

Fungsi autokorelasi parsial menurut (Montgomery et al., 2016) merupakan fungsi pembetulan autokorelasi antara y_t dengan nilai y_{t-k} dengan menyesuaikan $y_{t-1}, y_{t-2}, \dots, y_{t-k+1}$. Persamaan dari PACF dapat ditulis sebagai berikut (Montgomery et al., 2016):

$$\rho(j) = \sum_{i=1}^k \phi_{ik} \rho(j-1), j = 1, 2, \dots, k \quad (8)$$

atau

$$\rho(1) = \phi_{1k} + \phi_{2k}\rho(1) + \dots + \phi_{kk}\rho(k-1)$$

$$\rho(2) = \phi_{2k}\rho(1) + \phi_{2k} + \dots + \phi_{kk}\rho(k-2)$$

$$\rho(k) = \phi_{1k}\rho(k-1) + \phi_{2k}\rho(k-2) + \dots + \phi_{kk}$$

Persamaan dapat ditulis sebagai hasil dari persamaan notasi matriks sebagai berikut :

$$\mathbf{P}_k \phi_k = \rho_k$$

Rumus 2. 8 Persamaan *Partial Autocorrelation*

Sumber : (Montgomery et al., 2016)

Dimana :

- ϕ_{kk} = Himpunan autokorelasi parsial dengan *lag* waktu.
- ρ_k = dengan $k = 1, 2, 3, \dots$ merupakan nilai dari fungsi autokorelasi parsial.

2.10. ARIMA

Autoregressive Integrated Moving Average (ARIMA) adalah metode untuk menyesuaikan data deret waktu ke model untuk mendapatkan prediksi masa depan dari data historis. Secara teori, ARIMA mencakup tiga komponen: *autoregressive* (AR), *moving average* (MA), dan istilah *Integrated* (I) (Chiu et al., 2019). Penambahan data non stasioner pada persamaan (5) dapat disebut sebagai *autoregressive integrated moving average* orde (p, d, q) dan disebut dengan model ARIMA(p,d,q). Maka bentuk dari ARIMA (1,1,1) adalah :

$$y_t = \delta + y_{t-1} + \phi_1 y_{t-1} - \phi_1 y_{t-2} + \theta_1 \varepsilon_{t-2} + \varepsilon_t \quad (9)$$

Rumus 2. 9 Persamaan ARIMA

Sumber : (Chiu et al., 2019)

Dimana:

- δ = konstanta awal
- ϕ_p = koefisien *auto regressive*
- θ_q = nilai pembobotan berat *moving average*
- ε_t = nilai *white noise*

Nilai dari p, d, dan q sendiri dapat ditentukan dengan menggunakan nilai *Akaike Information Criterion* (AIC). Pemilihan nilai terbaik ditentukan dengan nilai terkecil untuk setiap nilai p, d, dan q (Chiu et al., 2019).

2.11. ARIMAX

Secara umum pemodelan *Auto Regressive Integrated Moving Average* dengan tambahan variabel independen atau *exogenous* disebut dengan ARIMAX. Penambahan variabel ini diharapkan dapat menambah nilai *explanatory* pada model analisis (Ihueze & Onwurah, 2018). Menurut (Dini, 2012) menyebutkan bahwa penambahan variabel dalam *time series analysis* pada data model dapat menambahkan kualitas dan performa peramalan dalam penelitian. Pada penelitian (Lee et al., 2013). menyebutkan bahwa Model ARIMAX adalah perpanjangan dari model ARIMA, di mana kovariat eksternal dapat ditambahkan tergantung pada korelasi silang antara mereka dan variabel respon. Pembuatan fungsi pada model ARIMAX cukup dengan menambahkan variabel *exogenous* pada rumus 2.9 dengan hasil sebagai berikut :

$$y_t = \delta + y_{t-1} + \phi_1 y_{t-1} - \phi_1 y_{t-2} + \theta_1 \varepsilon_{t-2} + \varepsilon_t \quad (10)$$
$$+ \beta_1 x_{1,t} + \beta_k x_{k,t}$$

Rumus 2. 10 Persamaan ARIMAX

Sumber : (Lee et al., 2013)

Dimana :

- y_t = variabel dependen pada waktu ke-t
- $x_{k,t}$ = variabel eksogen ke-k pada saat t, $k = 1, 2, \dots, k$

Membangun ARIMAX adalah proses berulang serupa dengan membangun model ARIMA atau dengan nama lain *Box-Jenkins* yang univariat, yaitu,

identifikasi model, estimasi parameter, dan pemeriksaan diagnostik(Ihueze & Onwurah, 2018).

2.12. Vector Auto Regressive

Menurut (Ahammad Hossain et al., 2015) forecasting dengan hasil yang baik untuk model *time series* dapat disediakan dengan menggunakan model VAR. Pada penelitian (Abid, 2019) Vector autoregression (VAR) biasanya digunakan untuk sistem *forecasting* pada data *time series* dan untuk menganalisis pengaruh kesalahan acak pada sistem variabel. Proses VAR pada umumnya sering digunakan pada kasus prediksi bidang ekonomi karena penggunaan model yang mudah dan ulet terutama pada data *time series* yang *multivariate*. Hal ini menjadikannya banyak digunakan untuk keperluan *forecasting*(Karlsson, 2013). Ahli lain (Christoffersen, 2012) setuju dengan pendapat bahwa VAR merupakan model paling umum dengan data *multivariate*. Sama seperti AR, fungsi VAR berawal terbentuk dari :

$$y_t = \delta + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

Pada kasus *bivariate* menjadi :

$$y_{1,t} = \delta_{0,1} + \phi_{11} y_{1,t-1} + \dots + \phi_{1p} y_{1,t-p} + \varepsilon_{1,t} \quad (11)$$

$$y_{2,t} = \delta_{0,1} + \phi_{21} y_{2,t-1} + \dots + \phi_{2p} y_{2,t-p} + \varepsilon_{2,t}$$

Rumus 2. 11 Persamaan *Vector Auto Regressive*

Sumber : (Christoffersen, 2012)

Dimana :

- δ = konstanta awal
- ϕ_p =koefesien *auto regressive*
- ε_t =nilai *white noise*

Jika variabel yang dimasukkan di sisi kanan setiap persamaan dalam VAR adalah sama (seperti di atas) maka VAR disebut tidak dibatasi dan OLS dapat digunakan persamaan demi persamaan untuk memperkirakan parameter(Christoffersen, 2012).

2.13. RMSE dan MAE

Metode yang digunakan untuk mengukur hasil prediksi salah satunya adalah *Root Mean Square Erro*(RMSE). Metode ini umum digunakan untuk mengukur hasil dari persamaan regresi. Berikut adalah formula dari RMSE :

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (predicted_i - actual_i)^2}{N}} \quad (12)$$

Rumus 2. 12 Persamaan RMSE

Sumber : (Dubovikov, 2018)

Dimana :

- N = total poin data
- $Predicted - actual$ = Selisih prediksi dan aktual
- $\sum N$ = total dari selisih seluruh poin

Metode lain yang juga digunakan adalah *Mean Absolute Error*(MAE) :

$$MAE = \frac{1}{N} \sum_{i=1}^N |predicted_i - actual_i| \quad (13)$$

Rumus 2. 13 Persamaan RMSE

Sumber : (Dubovikov, 2018)

Dimana :

- N = total poin data
- $Predicted - actual$ = Selisih prediksi dan aktual
- $\sum N$ = total dari selisih seluruh poin

Perhatikan bahwa MAE sangat mirip dengan RMSE. Dibandingkan dengan MAE, RMSE memiliki akar kuadrat, bukan nilai absolut, dan kesalahan kuadrat. Meskipun MAE dan RMSE mungkin tampak identik, ada beberapa perbedaan teknis di antara keduanya. RMSE menghukum kesalahan besar lebih dari MAE. Properti ini berasal dari fakta bahwa RMSE menggunakan kesalahan kuadrat, sedangkan MAE menggunakan nilai absolut(Dubovikov, 2018).

2.14. Heatmapping

Peta kepadatan atau *heatmapping* menunjukkan penyebaran dan konsentrasi nilai dalam wilayah geografis. Semakin dekat antara titik dari grup secara geografis, maka semakin tinggi intensitas dari warna area tersebut daripada daerah lain(Alexander, 2019).

2.15. Tools

2.15.1. Python

Python adalah bahasa pemrograman tingkat tinggi yang ditulis oleh Guido van Rossum 1991. Python adalah bahasa yang ditafsirkan yang bertujuan untuk menekankan keterbacaan kode menggunakan sintaksis sederhana dan untuk menghindari kasus dan pengecualian khusus.(Guzzi, 2018). Python banyak digunakan dalam ilmu data, salah satu motivasi untuk penggunaan Python dalam ilmu data, adalah kemungkinan untuk dengan mudah mendistribusikan *libray package* melalui komunitas.(Guzzi, 2018).

2.15.2. Tableau

Tableau adalah software atau alat yang menyediakan berbagai jenis penerapan visualisasi yang mudah digunakan, intuitif untuk seluruh pengguna dari berbagai tingkatan untuk membantu mereka mempersiapkan, menganalisis, dan memvisualisasikan *dataset*(tableau, 2020). Tableau versi 2020.1 pertama kali pada 24, Februari 2020(tableau, 2020). Tableau memiliki antarmuka pengguna yang intuitif, kemampuan dinamis dan terus berkembang, dan dedikasi untuk membangun dan mendukung komunitas yang terlibat dalam analisis visual(tableau, 2020).

2.16. Penelitian Sebelumnya

Tabel 2. 1 Penelitian Sebelumnya

No	Nama Journal, Vol, No	Penulis	Hasil Penelitian	Kontribusi di Penelitian ini
1	Pervasive and Mobile Computing, 53	Catlett Charlie, Cesario Eugenio, Talia Domenico, Vinci Andrea	Hasil validasi pada data ARIMA mendapat nilai rata-rata terendah untuk tingkat <i>mean absolute error</i> sebesar 30 dibanding REPTree dan ZeroR. Penggunaan ARIMA cocok untuk memprediksi frekuensi kriminalitas(Catlett et al., 2019)	Metode ARIMA dapat memprediksi tingkat kriminalitas dengan akurasi yang tinggi.
2	Proceedings of the 3rd International Conference on Informatics and Computing, ICIC 2018	Azhari, Utomo Pradita Eko Prasetyo	Hasil menunjukan bahwa hasil MAPE dan RMSE adalah 32.30 dan 6.68(Azhari & Utomo, 2018)	Ditemukannya relasi pencurian motor dengan jumlah persebaran motor dengan metode ARIMAX untuk keperluan prediksi
3	Procedia Computer Science, 124	Wiwik Anggraenia, Kuntoro Boga Andri, Sumaryanto, Faizal Mahananto	Hasil prediksi dibandingkan dengan algoritma VAR dengan hasil MAPE pada ARIMAX sebesar 0.15% yakni 15.27% lebih baik dari VAR(Anggraeni et al., 2017)	ARIMAX dapat dibandingkan dengan VAR untuk satu <i>dataset</i> yang sama.

No	Nama Journal, Vol, No	Penulis	Hasil Penelitian	Kontribusi di Penelitian ini
4	Ultimatics : Jurnal Teknik Informatika	Suryono, Michael Saputra Oetama, Raymond	Hasil prediksi harga forex dengan menggunakan ARIMA mendapat hasil MAPE sebesar 3.16%.(Suryono & Oetama, 2019)	ARIMA cocok untuk prediksi pada data <i>time series</i> .
5	ULTIMA InfoSys	Satyo, Adhitio Karno, Bayangkari	Analisis Data <i>Time series</i> Menggunakan LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average) dalam Bahasa Python(Satyo & Karno, 2020)	Penggunaan RMSE sebagai teknik evaluasi yang umum digunakan dalam <i>time series</i> .

Pada penelitian milik (Catlett et al., 2019) dan (Azhari & Utomo, 2018) menunjukkan bahwa penggunaan ARIMA dan ARIMAX cocok untuk memprediksi kriminalitas di suatu wilayah. Adapun penelitian milik (Suryono & Oetama, 2019) akan digunakan sebagai referensi alur penelitian ARIMAX pada penelitian ini. Penelitian ini dibandingkan dengan metode VAR mengingat pada penelitian (Anggraeni et al., 2017) ARIMAX dapat dibandingkan dengan VAR dalam kemampuannya dalam melakukan *forecasting* mengingat kedua metode dapat menangani dataset *multivariate variables*. Adapun penelitian (Satyo & Karno, 2020) digunakan sebagai referensi penggunaan RMSE yang umum digunakan sebagai validasi model *time series*.