



ANALISIS DATA UNTUK MEMPREDIKSI PAGU MINUS DAN MEMBANTU PPK DALAM PELAKSANAAN PENGUJIAN MATERIAL

Ida Puspita Ningtias¹, Julianda Rosyadi², Wawan Hadinata³,

Agustina Diprianti⁴, Anung Faizal Hanani Wijaya⁵

^{1,2,3,4,5} Direktorat Jenderal Perbendaharaan, Kementerian Keuangan, Jakarta

Alamat Korespondensi: idappt12@gmail.com

Abstract

Budget availability and fairness of billing are things that had to be assured by Pejabat Pembuat Komitmen (PPK) or Commitment Making Official before paying a bill with the state budget. Analyzing the data in Platform Pembayaran Pemerintah (PPP) or Government Payment Platform could help PPK to predict the budget availability and fairness of billing. PPP is an interconnection between the core system, support system, partner system, and monitoring system. This interconnection enables more reliable data collection because there is a data exchange within the ecosystem, such as the electricity bills. The data would be analyzed to predict the occurrence of shortfalls and to evaluate the billing fairness. For the prediction of the occurrence of shortfalls, clustered time series forecasting is used with the ARIMA model, while to assist in the fair assessment of billing, descriptive statistics of historical data are used to evaluate the current bills. From the results of the analysis, it can be seen that the ARIMA model can be used to predict the occurrence of a budget shortfall and descriptive statistics can be used as a basis for evaluating current bills.

Abstrak

Kecukupan pagu dan kewajaran tagihan adalah dua hal yang harus dipastikan oleh Pejabat Pembuat Komitmen (PPK) sebelum melakukan pembayaran atas tagihan yang menjadi beban anggaran negara. Analisis data pada Platform Pembayaran Pemerintah (PPP) dapat membantu PPK memprediksi kecukupan pagu dan menguji kewajaran tagihan. PPP merupakan interkoneksi antarsistem *core*, sistem pendukung, sistem mitra, dan sistem monitoring. Interkoneksi ini memungkinkan dilakukannya *data collection* yang lebih andal karena terjadi pertukaran data antar hierarki sistem secara langsung, salah satunya data tagihan listrik. Penelitian ini bertujuan untuk mengidentifikasi secara dini kemungkinan terjadinya kekurangan pagu dan membantu PPK dalam pelaksanaan kewenangan pengujian material. Prediksi terjadinya kekurangan pagu digunakan analisis *clustering time series* dengan model *Autoregressive Integrated Moving Average* (ARIMA), sementara untuk membantu pengujian kewajaran tagihan digunakan analisis statistik



deskriptif data historis. Dari hasil analisis terlihat bahwa model ARIMA dapat digunakan untuk melakukan prediksi terjadinya kekurangan pagu dan statistik deskriptif dapat digunakan sebagai dasar evaluasi tagihan berjalan.

Keywords: ARIMA, Kewenangan, Pagu Minus, Pengujian Material, Statistika Deskriptif.

JEL Classification: C10, H50, H6

PENDAHULUAN

Manajemen pagu dan pengujian tagihan merupakan isu rutin yang menjadi tanggung jawab sumber daya satuan kerja (satker), khususnya Pejabat Pembuat Komitmen (PPK). Isu ini relatif sulit diatasi pada ekosistem nondigital. Berkenaan dengan hal tersebut, Kementerian Keuangan (dalam hal ini Direktorat Jenderal Perbendaharaan) sejak tahun 2020, telah melakukan piloting Platform Pembayaran Pemerintah (PPP) untuk mengakomodasi transaksi elektronik satker dan pada akhirnya diharapkan mampu melakukan proyeksi pagu minus dan membantu PPK untuk melakukan pengujian kewajaran tagihan. Fitur ini dapat dimanfaatkan satker maupun unit pengelola platform.

Digitalisasi PPP dilakukan dengan prasyarat utama berupa interkoneksi antarsistem *core* (SPAN, SAKTI, dan Aplikasi Gaji Web), sistem pendukung dan/atau sistem mitra, dan sistem monitoring. Bahkan, hal inilah yang menjadi definisi PPP dalam Peraturan Menteri Keuangan Nomor 204 Tahun 2020.

Selain tujuan utamanya yaitu menghasilkan sistem pembayaran digital, interkoneksi dalam PPP juga memberikan manfaat dalam hal *data collection* (pengumpulan data). Perbaikan di aspek pengumpulan data

akan mendukung terwujudnya *data-driven policy making* (The World Bank, 2020). Interkoneksi antara sistem mitra dan/atau sistem pendukung dan sistem *core* milik Direktorat Jenderal Perbendaharaan (DJPb) menghasilkan pertukaran data yang bermanfaat bagi kedua belah pihak. Contoh data yang telah terkumpul dan akan dianalisis dalam tulisan ini adalah data tagihan PT Perusahaan Listrik Negara (Persero) {PT PLN (Persero)}.

PT PLN (Persero) menjadi salah satu mitra DJPb dalam digitalisasi pembayaran belanja listrik pemerintah. Berdasarkan hasil pengamatan peneliti setiap hari pada dashboard monitoring PPP, sejak bulan Agustus tahun 2021, tagihan listrik berjumlah lebih dari Rp30 miliar pada 218 satker piloting PPP dan telah dibayar dengan menggunakan sistem digital. Salah satu tahap dalam sistem pembayaran digital ini adalah pengiriman data tagihan oleh PT PLN (Persero) ke sistem milik DJPb yaitu SAKTI.

Titik kritis pertama dalam pembayaran tagihan melalui PPP adalah terkait kemungkinan terjadinya kekurangan pagu. Dampak atas kekurangan pagu dapat memunculkan permasalahan yang fatal dalam hal terjadi gagal bayar dan berakibat pemutusan layanan oleh mitra sehingga perlu adanya *early warning system* yang bertujuan memberikan peringatan lebih

awal kepada Kuasa Pengguna Anggaran (KPA) agar dapat menghindari terjadinya kekurangan pagu, khususnya pada akun 522111.

Penentuan *early warning system* menggunakan data *time series* telah dilakukan pada penelitian sebelumnya oleh Ramli et al. (2014) dalam menentukan prediksi krisis keuangan. Kondisi data yang kompleks pada data *time series* tagihan listrik menimbulkan permasalahan yaitu dibutuhkan penentuan model satu per satu sehingga dalam penelitiannya, Riyadi et al. (2016) menggunakan analisis *clustering time series* dengan model ARIMA. Konsep dalam menentukan *early warning system* pada analisis *clustering time series* yaitu melalui nilai prediksi atau *forecasting*-nya. Prediksi tagihan listrik diperoleh dengan melihat pola data historis tagihan kemudian merefleksikannya pada perkiraan tagihan masa depan (*time series*). Untuk memudahkan dalam menemukan model statistik yang sesuai untuk prediksi pada analisis *clustering time series*, dilakukan pengelompokan data-data yang memiliki kesamaan karakteristik.

Titik kritis lainnya dalam pembayaran melalui PPP adalah pengujian kebenaran material tagihan yang dilakukan oleh PPK. Meskipun tagihan yang masuk ke SAKTI telah digaransi kebenarannya oleh PT PLN (Persero), PPK tetap memiliki tugas dan kewenangan untuk melakukan pengujian. Di titik inilah analisis atas data historis dapat berperan.

Statistik deskriptif atas data historis merupakan gambaran data tagihan yang selama ini telah diuji oleh PPK dan dilakukan pembayaran atas beban keuangan negara. Statistik deskriptif ini

kemudian dijadikan sebagai dasar evaluasi kewajaran tagihan bulan berjalan. Hal ini seperti yang dilakukan oleh Rowa & Arthana (2019) yang menggunakan statistika deskriptif untuk merepresentasikan secara umum mengenai jawaban responden dari hasil kuesioner penelitiannya.

Berdasarkan penjelasan di atas, penelitian ini bertujuan untuk menemukan cara analisis data tagihan yang dapat membantu menyeragamkan dan membantu pelaksanaan pengujian material oleh PPK dalam ekosistem PPP. Selain itu, penelitian ini dilaksanakan untuk menemukan cara analisis data historis realisasi untuk menemukan pola dan memprediksi kemungkinan terjadinya kekurangan pagu. Diharapkan penelitian ini dapat menjadi cikal bakal analisis serupa di masa depan dan dapat melahirkan replikasi pada berbagai tagihan yang lebih kompleks dengan berbagai prasyarat khusus yang akan menjadi bagian dari saran yang akan disampaikan dalam tulisan ini.

TINJAUAN LITERATUR

Salah satu evaluasi World Bank pada tahun 2020 untuk Indonesia dalam laporan berjudul "*Indonesia Public Expenditure Review: Spending for Better Results*" adalah terkait kualitas data yang dimiliki Pemerintah Indonesia. Dalam laporan tahun 2020, Indonesia direkomendasikan untuk memperbaiki cara pengumpulan data dan pengelolaan sistem informasi yang terkait dengan belanja pemerintah (The World Bank, 2020). Mengacu ke cetak biru Platform Pembayaran Pemerintah (PPP) yang ditetapkan melalui Keputusan Direktur Jenderal Perbendaharaan nomor KEP-

286/PB/2019 tahun 2019, PPP dapat menjadi salah satu pilihan solusinya (Direktorat Jenderal Perbendaharaan, 2019).

Nilai tambah implementasi PPP dalam *data collection* mulai terealisasi ketika pada bulan Agustus tahun 2021 dilaksanakan transaksi perdana untuk pembayaran tagihan listrik beserta telepon dan internet. Sejak saat itulah terjadi pertukaran data dengan sistem mitra, yaitu milik PT PLN (Persero) dan PT Telkom Tbk (Persero). Setiap bulan, kedua mitra mengirim data tagihan langsung menuju sistem *core* PPP, yaitu SAKTI. Berdasarkan pengalaman 8 (delapan) siklus yang telah dilewati dan melihat data yang terkumpul, ada dua isu yang dapat dibantu dan diselesaikan dengan melakukan analisis atas data historis tagihan. Pertama, terkait terjadinya pagu minus yang mengakibatkan tidak terbayarnya tagihan atas beban negara secara tepat waktu dan yang kedua adalah mengenai kewenangan pengujian material oleh PPK. Untuk membantu dan mengatasi kedua isu tersebut, dibutuhkan analisis data yang dapat mengantisipasi potensi terjadinya pagu minus dan membantu proses pengujian material.

Kekurangan Pagu

Berdasarkan Pasal 18 Undang-Undang Nomor 1 Tahun 2004 tentang Perbendaharaan Negara (UU Perbendaharaan), Pengguna Anggaran atau Kuasa Pengguna Anggaran (PA/KPA) merupakan pejabat yang berwenang untuk meneliti tersedianya dana yang bersangkutan. Kondisi tidak tersedianya dana yang bersangkutan inilah yang disebut dengan kekurangan pagu. Kekurangan pagu dapat diatasi

dengan melakukan revisi Daftar Isian Pelaksanaan Anggaran (DIPA).

Kewenangan revisi DIPA diatur dalam Peraturan Menteri Keuangan Nomor 208 Tahun 2020. Kewenangan untuk melakukan revisi DIPA dibagi berdasarkan karakteristik tertentu menjadi kewenangan KPA, kewenangan Kantor Wilayah (Kanwil) DJPb, kewenangan Direktorat Pelaksanaan Anggaran DJPb, kewenangan Direktorat Jenderal Anggaran (DJA), sampai pada revisi DIPA yang memerlukan persetujuan DPR (Kementerian Keuangan, 2020).

Dalam catatan Direktorat Sistem Perbendaharaan, pada tahun 2021 terjadi kasus kekurangan pagu yang berakibat pada munculnya potensi gagal bayar dalam ekosistem PPP (Direktorat Sistem Perbendaharaan, 2021). Dalam ekosistem PPP, hanya dikenal satu jenis Surat Perintah Membayar (SPM) untuk melunasi tagihan listrik, yaitu langsung (LS). Oleh karena itu, diperlukan sebuah *early warning system* yang dapat memberikan sinyal kepada KPA untuk dapat segera mencegah terjadinya kekurangan pagu. Lebih cepat KPA menyadari potensi terjadinya kekurangan pagu, lebih cepat langkah dapat diambil, lebih ringan usaha yang diperlukan untuk mengatasi potensi kekurangan pagu tersebut.

Analisis Cluster

Analisis *cluster* adalah teknik analisis statistik yang digunakan untuk mengelompokkan objek-objek yang memiliki karakteristik serupa (Ulinnuh & Veriani, 2020). Konsep *cluster* yaitu dalam satu *cluster* terdiri dari objek yang memiliki tingkat kesamaan karakteristik yang tinggi sedangkan antar *cluster* memiliki tingkat kesamaan karakteristik

yang rendah. Metode dalam *clustering* terbagi menjadi dua (Wichern & Johnson, 2007), yaitu:

Pertama, Metode Hierarki adalah metode pengelompokan objek secara terstruktur berdasarkan kesamaan karakteristik dan jumlah *cluster* yang dibutuhkan tidak diketahui;

Kedua, Metode Non Hierarki adalah metode yang digunakan dalam mengelompokkan objek berdasarkan jumlah *cluster* yang akan terbentuk dapat ditentukan terlebih dahulu.

Dalam penggunaan metode hierarki, terdapat dua jenis pendekatan yaitu *agglomerative* (pemusatan) dan *divisive* (pemisahan) (Mutawalli et al., 2018). Tahapan dalam pendekatan *agglomerative* dilakukan dengan melakukan penggabungan setiap pasangan objek secara bertahap sehingga dihasilkan satu gerombol sedangkan pendekatan *divisive* dilakukan dengan melakukan pemisahan secara bertahap dari *cluster* yang besar menjadi *cluster* kecil hingga di dalam satu *cluster* hanya terdiri dari satu objek (Wichern & Johnson, 2007).

Dalam menentukan kesamaan karakteristik pada suatu objek, digunakan pengukuran jarak yang terdiri dari *single linkage*, *complete linkage*, *average linkage*, *ward's method* dan *centroid method*.

Pada dasarnya *cluster* yang baik yaitu objek dalam *cluster* bersifat homogen sedangkan antar *cluster* bersifat heterogen. Di dalam metode *cluster* hierarki, penentuan jumlah *cluster* yang optimal dapat diukur menggunakan koefisien *silhouette*. Nilai koefisien tersebut diperoleh dengan membandingkan rata-rata kemiripan pada setiap objek terhadap objek

lainnya dengan formula sebagai berikut (Bible et al., 2013).

$$s_j = \frac{b(j) - a(j)}{\max \{a(j), b(j)\}}$$

dengan keterangan:

$a(j)$ adalah rata-rata jarak antar objek dalam *cluster*, dan $b(j)$ adalah jarak terpendek antara objek *cluster* dan objek *cluster* terdekatnya (*nearest neighbor*). Semakin tinggi nilai s_j , maka semakin tinggi kualitas *clustering*/pengelompokan (Munthe, 2019).

Clustering Time Series

Perbedaan *clustering time series* dengan *cluster* pada umumnya yaitu pada *cluster* dengan data *time series* dilakukan pengukuran kesamaan karakteristik dengan menggunakan *autocorrelation based distance* (Riyadi et al., 2016). Formula pengukuran *autocorrelation based distance* sebagai berikut (Montero & Vilar, 2015):

$$d_{ACF}(X_T, Y_T) = \sqrt{(\hat{\rho}_{X_T} - \hat{\rho}_{Y_T})' \Omega^{-1} (\hat{\rho}_{X_T} - \hat{\rho}_{Y_T})}$$

dengan keterangan:

$d_{ACF}(X_T, Y_T)$ = jarak *autocorrelation vector* $X_T X_T$ dan $Y_T Y_T$

$\hat{\rho}_{X_T}$ = estimasi vektor *autocorrelation* X_T

$\hat{\rho}_{Y_T}$ = estimasi vektor *autocorrelation* Y_T

Ω = matriks bobot.

Jika jarak ACF tidak menggunakan bobot maka matriks bobotnya adalah matriks identitas.

Saat melakukan pemodelan menggunakan ARIMA, langkah-langkah

yang perlu dilakukan adalah memeriksa stasioneritas terhadap rata-rata (*mean*) maupun ragam (*variances*) (Fauzi, 2015). Selanjutnya data yang telah stasioner, ditampilkan pada plot ACF dan PACF untuk mengidentifikasi model (Isnarwaty, 2017). Teori umum ACF dan PACF adalah untuk membantu dalam penentuan model menurut Shmueli dan Lichtendahl Jr. seperti yang ditunjukkan pada Tabel 1 di bawah ini (Shmueli & Lichtendahl Jr, 2016):

Tabel 1. Teori Umum ACF dan PACF

Order	ACF	PACF
AR(<i>p</i>)	Autokorelasi turun secara eksponensial (<i>dies down</i>) mengikuti nilai lag	Terdapat lag yang <i>cut off</i> setelah lag <i>p</i>
MA (<i>q</i>)	Terdapat lag yang <i>cut off</i> setelah lag <i>q</i>	Autokorelasi turun secara eksponensial (<i>dies down</i>) mengikuti nilai lag
ARMA (<i>p,q</i>)	Autokorelasi turun secara eksponensial (<i>dies down</i>) mengikuti nilai lag	Autokorelasi turun secara eksponensial (<i>dies down</i>) mengikuti nilai lag
AR(<i>p</i>) atau MA(<i>q</i>)	Terdapat lag yang <i>cut off</i> setelah lag <i>q</i>	Terdapat lag yang <i>cut off</i> setelah lag <i>p</i>

Sumber: (Shmueli & Lichtendahl Jr, 2016)

Model ARIMA (*p,d,q*) yang terdiri dari orde *p* sebagai operator AR, orde *d*

sebagai *differencing* dan orde *q* sebagai operator dari MA, kemudian dilakukan pengujian diagnostik terhadap *residual* (Nurlaila, 2007). Pengujian diagnostik *residual* terdiri dari pengujian *white noise* yang bertujuan untuk mengetahui kebebasan *residual* dan pengujian normalitas (Wei, 2006).

Dalam menentukan ukuran kebaikan model yang digunakan untuk melakukan peramalan yaitu *Mean Absolute Percentage Error* (MAPE) (Yohansa, 2021). Semakin kecil nilai persentase dari MAPE maka model akan dikatakan baik karena selisih data aktual dan peramalan kecil. Menurut Mills (2019) dan Kirchgassner et al. (2012), perhitungan nilai MAPE adalah:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{x_{a(t)} - x_{r(t)}}{x_{a(t)}} \right| \times 100\%$$

dengan keterangan:

$x_{a(t)}$ = data aktual periode ke-*t*

$x_{r(t)}$ = data ramalan periode ke-*t*

t = waktu amatan, *t*=1, 2, ..., *n*

n = banyaknya waktu amatan

Muhammad Irvan Maulana dan Much Aziz Muslim menggunakan MAPE untuk mendapatkan tingkat akurasi 96,48% dalam memprediksi tagihan listrik usaha *laundry* menggunakan jaringan syaraf tiruan *backpropagation* (Maulana & Muslim, 2015).

Selain menggunakan MAPE, ukuran kebaikan model dapat menggunakan *Root Mean Square Error* (RMSE). Hal ini seperti yang dilakukan oleh Miftahur Rahman dalam penelitian pada Pesantren Sukorejo Jawa Timur saat melakukan prediksi pembayaran biaya tagihan listrik menggunakan model

Artificial Neural Network (ANN) (Rahman, 2019).

Kewenangan Pengujian Kebenaran Material oleh PPK

Kewenangan ini pertama muncul pada Pasal 18 Undang-Undang Nomor 1 Tahun 2004 tentang Perbendaharaan Negara sebagai wewenang PA/KPA. Di dalam pasal tersebut disebutkan bahwa salah satu wewenang PA/KPA adalah menguji kebenaran material surat-surat bukti mengenai hak pihak penagih.

Istilah PPK muncul dalam Peraturan Pemerintah Nomor 45 Tahun 2013 tentang Tata Cara Pelaksanaan Anggaran Pendapatan dan Belanja Negara dan diberi wewenang untuk melakukan pengujian ini. Pasal 12 PP ini menyatakan bahwa PPK berwenang memeriksa dan menandatangani surat-surat bukti mengenai hak pungut dari negara. Pengujian tersebut dilakukan dengan membandingkan bukti yang telah disahkan dengan keabsahan penyerahan/barang jadi/jasa dan spesifikasi teknis yang dipersyaratkan untuk dokumen perikatan. Pasal 13 kemudian menegaskan kembali tanggung jawab yang timbul dari kewenangannya dengan menyatakan bahwa PPK bertanggung jawab atas kebenaran material dan akibat yang ditimbulkan dari penggunaan bukti yang berkaitan dengan hak tagih kepada negara (Republik Indonesia, 2013).

Diamond (1999) menyebutkan bahwa kewenangan PPK yang berlaku di Indonesia ini merujuk pada tahap verifikasi dalam *Public Expenditure Management*. Pada tahap ini, harus dipastikan barang benar-benar telah diterima sesuai ketentuan kontrak, jasa benar-benar telah dilaksanakan, dan

tagihan telah diterima. Setelah tahap ini selesai, tagihan yang telah diverifikasi kebenarannya dapat masuk ke tahapan berikutnya yaitu pengajuan perintah pembayaran.

Statistika Deskriptif

Statistika deskriptif memegang peranan penting dalam penelitian saintifik (Turner & Houle, 2019). Statistika deskriptif biasanya digunakan untuk menjelaskan karakter data yang telah dikumpulkan dalam sebuah penelitian. Statistika deskriptif menjelaskan karakter data dengan memperlihatkan *central tendency* dan *variability*. *Central tendency* atau ukuran pemusatan data didefinisikan sebagai ukuran statistik yang menunjukkan sebuah nilai tunggal yang menggambarkan keseluruhan distribusi data. Adapun *variability* adalah ukuran sebaran data, semakin besar *variability*-nya semakin besar sebaran atau jarak antar nilai dalam sebuah data (Turner & Houle, 2019).

METODE PENELITIAN

Data yang digunakan dalam penelitian pengujian kewajaran tagihan adalah data tagihan listrik yang telah diterima SAKTI dari bulan Agustus tahun 2021 sampai dengan bulan Januari tahun 2022. Artinya telah terdapat data penyelesaian tagihan listrik selama enam siklus. Selain data yang telah disampaikan langsung kepada SAKTI, untuk memperkuat basis data dalam analisis ini dilakukan penambahan data melalui permintaan data secara resmi kepada PT PLN (Persero) untuk data tagihan sejak bulan Januari tahun 2019.

Analisis yang digunakan untuk membangun *early warning system* adalah analisis *clustering time series*.

Analisis *clustering time series* dilakukan melalui dua tahapan yakni analisis *clustering* menggunakan metode hierarki dan analisis *time series* menggunakan model ARIMA (Riyadi et al., 2016). Tahapan lengkap untuk kedua analisis tersebut adalah sebagai berikut (Lampiran 1).

1. *Preprocessing* data (Denis, 2016).
2. Eksplorasi data tagihan listrik pada PPP.
3. Membagi data tersebut menjadi data *training* dan data *testing*. Data *training* digunakan untuk analisis *clustering time series* dan pemodelan sedangkan data *testing* digunakan untuk evaluasi hasil peramalan (Mukminin, 2021).
4. Melakukan *clustering* dengan metode hierarki dan jarak *autocorrelation based distance* pada algoritma *complete linkage*.
5. Melakukan analisis *time series* dari masing-masing *cluster* dengan tahapan sebagai berikut:
 - a. Melakukan pengecekan kestasioneran data. Pengujian atas kestasioneran data terhadap rata-rata menggunakan uji *Augmented Dickey Fuller* (ADF). Pengujian atas kestasioneran data terhadap ragam menggunakan uji *Box Cox*.
 - b. Pemodelan dengan melihat plot ACF dan PACF untuk mengidentifikasi ordo p , d , dan q dari model ARIMA.
 - c. Melakukan *overfitting* pada model yang telah ditentukan dan menentukan *best model* dengan melihat nilai AIC terkecil.
 - d. Setelah menentukan *best model*, selanjutnya dilakukan

pendugaan parameter menggunakan metode *Maximum Likelihood Estimation* (MLE) (Pardede, 2013; Hamilton, 2020).

- e. Pengujian diagnostik *residual* menggunakan uji Ljung Box untuk memeriksa kebebasan *residual* (*white noise*) dan uji Kolmogorov Smirnov untuk memeriksa normalitas *residual* (Box et al., 2016).
- f. Melakukan prediksi atau peramalan (*forecasting*) realisasi tagihan listrik.
- g. Evaluasi hasil prediksi dengan membandingkan terhadap data *testing*.
- h. Menghitung jumlah realisasi tagihan listrik dan membandingkan terhadap pagu belanja listrik 522111.

Analisis yang digunakan untuk melakukan pengecekan kewajaran tagihan adalah statistika deskriptif atas data historis tagihan di bulan-bulan sebelumnya dengan rincian sebagaimana dalam Lampiran 2. Konsepnya adalah dengan membandingkan tagihan pada bulan berjalan terhadap informasi tagihan pada bulan-bulan sebelumnya. Semakin besar pergeseran nilai tagihan, semakin meragukan tagihan tersebut untuk disetujui sehingga PPK perlu melakukan pengecekan secara langsung/fisik. Sebaliknya, semakin kecil pergeserannya, semakin wajar tagihan tersebut dan PPK dapat menganggap pengujian telah cukup dan membayar tagihan yang diterima. Penentuan tingkat kewajaran tagihan diberikan ambang batas 20% berdasarkan *subject matter expert*.

Analisis statistika deskriptif yang digunakan dalam tulisan ini adalah usaha untuk mengkuantifikasi *common sense* yang biasa digunakan otak manusia dalam mempertimbangkan kewajaran tagihan, *mimicking how the brain works* (Susanto et al., 2019). Statistika deskriptif yang digunakan sebagai dasar untuk membandingkan nilai tagihan pada bulan berjalan dengan nilai tagihan pada bulan-bulan sebelumnya terdiri dari ukuran pemusatan data (*mean*, median, modus, min, dan max) dan ukuran penyebaran data (standar deviasi). Statistika deskriptif atas data historis dapat dijadikan alat evaluasi atas tagihan yang akan dibayarkan berikutnya. Ukuran pemusatan dan penyebaran data diambil dari tagihan pada Bulan Agustus 2021 hingga Bulan Januari 2022.

HASIL PENELITIAN DAN PEMBAHASAN

Clustering Time Series

Pola data tagihan dari PT PLN (Persero) di setiap satker memiliki besaran yang berbeda-beda. Meskipun demikian, satker-satker yang memiliki pola tagihan yang sama dapat dikelompokkan ke dalam suatu *cluster*. Pengelompokan tersebut menggunakan analisis *clustering time series*. Analisis ini sebagai *preprocessing data* sebelum dilakukan penentuan model peramalan data tagihan tiap satker yang terbaik sehingga bisa digunakan untuk menentukan kecukupan pagu satker.

Untuk melakukan analisis *clustering time series*, ukuran kesamaan karakteristik yang digunakan adalah *autocorrelation based distance* menggunakan algoritma *cluster* hierarki

complete linkage (Trebuna & Halcinova, 2013). Menurut ukuran dan algoritma, *dendogram* yang dihasilkan dapat diperoleh sebanyak empat *cluster* optimal yang digunakan dalam analisis ini dengan banyak anggota tiap *cluster* seperti Tabel 2.

Tabel 2. Banyak Anggota tiap *Cluster*


<i>Cluster</i>	Banyak Anggota	<i>Mean</i>
1	78	40.059.130
2	60	20.354.559
3	39	10.714.006
4	5	5.316.875

Sumber: Hasil olah data penulis

Menurut hasil *cluster* di atas, anggota terbanyak terdapat pada *cluster* 1 sejumlah 78 satker sedangkan *cluster* dengan anggota paling sedikit terdapat pada *cluster* 4 sejumlah 5 satker. Dari hasil *clustering*, rata-rata tagihan listrik terbesar terdapat pada *cluster* 1 yaitu sejumlah Rp40.059.130 sedangkan rata-rata tagihan listrik terendah terdapat pada *cluster* 4 yaitu sejumlah Rp5.316.875. Secara detail, plot *time series* untuk tiap *cluster* berdasarkan nilai rata-rata tagihan listrik semua satker di *cluster* yang bersangkutan dapat dilihat pada Grafik 1.

Pada *cluster* 1 terlihat jelas bahwa selama kurun waktu Bulan Agustus 2021 hingga Bulan Januari 2022, pengeluaran biaya untuk energi listrik terbesar dibandingkan *cluster* lainnya. Pergerakan perubahan pada *cluster* 1 juga besar yang dapat dilihat pada perubahan naik turun pada grafik. *Cluster* 3 dan *cluster* 4 grafiknya cenderung konstan setiap bulannya.

Analisis *time series* setiap *cluster* dilakukan dengan mengambil salah satu satker pada *cluster* yang bersangkutan

Grafik 1. Plot *Time Series* tiap *Cluster*

Sumber: Hasil olah data penulis

kemudian memodelkan menggunakan ARIMA dengan *orde* yang sesuai (Nurviana et al., 2022). Satker yang dijadikan sebagai sampel pada masing-masing *cluster* untuk melakukan pemilihan model *time series* adalah kode satker 527982 untuk *cluster* 1, 528099 untuk *cluster* 2, 652460 untuk *cluster* 3, dan 527933 untuk *cluster* 4.

Tahapan awal *clustering time series* dimulai dengan pengecekan kestasioneran data. Data yang tidak memenuhi stasioneritas terhadap rata-rata dilakukan proses pembedaan atau *differencing* sedangkan data yang tidak memenuhi stasioneritas terhadap variasi dilakukan transformasi data. Hasil pengujian stasioneritas data ditunjukkan pada Tabel 3.

Dari Tabel 3, nilai *p-value* untuk pengujian ADF kurang dari 5%. Hal ini menunjukkan bahwa data stasioner terhadap rata-rata. Sedangkan lambda pada pengujian *Box Cox* menunjukkan nilai mendekati 1 dan/atau -1 sehingga bisa diindikasikan bahwa data sudah stasioner terhadap variasinya. Data yang

Tabel 3. Uji Stasioneritas Data

<i>Cluster</i>	<i>P-value ADF Test</i>	λ Box Cox
1	0,01	-1,00
2	0,01	-1,00
3	0,02	0,97
4	0,01	-1,00

Sumber: Hasil olah data penulis

Tabel 4. Model ARIMA Tiap *Cluster*

<i>Cluster</i>	Model	AIC
1	ARIMA (0,2,1)	874,33
	ARIMA (0,2,2)*	876,20
2	ARIMA (1,2,1)	876,26
	ARIMA (0,1,1)*	878,75
	ARIMA (0,1,2)	880,71
3	ARIMA (2,1,1)	822,51
	ARIMA (1,0,1)	901,58
	ARIMA (2,0,0)*	900,66
4	ARIMA (1,0,0)	903,52
	ARIMA (0,2,2)*	691,09
	ARIMA (1,2,2)	693,05
	ARIMA (2,2,2)	695,05

Sumber: Hasil olah data penulis

Tabel 5. Uji Diagnostik *Residual*

Cluster	Pengujian	P-value
1	<i>Box-Ljung Test</i>	0,93
	<i>Kolmogorov-Smirnov Test</i>	0,76
	<i>T-Test</i>	0,26
2	<i>Box-Ljung Test</i>	0,57
	<i>Kolmogorov-Smirnov Test</i>	0,95
	<i>T-Test</i>	0,91
3	<i>Box-Ljung Test</i>	0,17
	<i>Kolmogorov-Smirnov Test</i>	1,00
	<i>T-Test</i>	0,74
4	<i>Box-Ljung Test</i>	0,94
	<i>Kolmogorov-Smirnov Test</i>	0,26
	<i>T-Test</i>	0,95

Sumber: Hasil olah data penulis

Tabel 6. Nilai MAPE Data *Training* dan *Testing*

Cluster	Model	MAPE (%)	
		<i>Training</i>	<i>Testing</i>
1	ARIMA (0,2,2)	8,08	13,83
2	ARIMA (0,1,1)	6,19	5,75
3	ARIMA (2,0,0)	8,80	3,55
4	ARIMA (0,2,2)	2,25	3,71

Sumber: Hasil olah data Penulis

sudah stasioner terhadap rata-rata dan variasi ini mengindikasikan bahwa tagihan listrik satker-satker tersebut mengalami fluktuasi yang konstan terhadap suatu nilai tertentu. Setelah stasioneritas data terpenuhi, selanjutnya dilakukan identifikasi model dengan melihat *correlogram* ACF dan PACF (Lampiran 3) pada masing-masing satker pada *cluster* yang bersangkutan. Berdasarkan *correlogram* ACF dan PACF diperoleh model ARIMA seperti pada Tabel 4.

Berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil seperti yang terlihat pada Tabel 4 dan dengan mempertimbangkan *residual* yang memenuhi kriteria *white noise* serta signifikansi parameter, pemilihan model ARIMA masing-masing *cluster* adalah ARIMA (0,2,2) untuk *cluster* 1,

Tabel 7. Hasil Prediksi *Cluster* 7 Tahun 2022

Bulan	Realisasi	Prediksi
Januari	115.205.308	104.669.666
Februari	101.228.493	104.717.933
Maret		104.766.199
April		104.814.466
Mei		104.862.733
Juni		104.911.000
Juli		104.959.267
Agustus		105.007.534
September		105.055.800
Oktober		105.104.067
November		105.152.334
Desember		105.200.601

Sumber: Hasil olah data penulis

ARIMA (0,1,1) untuk *cluster* 2, ARIMA (2,0,0) untuk *cluster* 3 serta ARIMA (0,2,2) untuk *cluster* 4. Hasil pengujian diagnostik *residual* pada model ARIMA sebagaimana ditunjukkan pada Tabel 5.

Tabel 5 menampilkan bahwa nilai *p-value* untuk *Box-Ljung Test*, *Kolmogorov-Smirnov Test* dan *T-Test* lebih besar daripada 5%. Ini mengindikasikan bahwa model memiliki kecukupan dalam hal memenuhi asumsi *residual* autokorelasi, berdistribusi normal serta sampel berasal dari dua populasi yang memiliki nilai tengah sama. Plot *residual* pada model ARIMA sebagaimana pada Lampiran 4.

Berdasarkan pengujian *residual* tersebut, didapatkan hasil bahwa empat model ARIMA terpilih sudah memenuhi kriteria *white noise* sehingga model ARIMA dapat digunakan untuk melakukan prediksi. Untuk mengukur evaluasi model yang baik dalam peramalan dapat dilihat melalui nilai MAPE pada masing-masing model ARIMA. Berdasarkan hasil perhitungan, diperoleh nilai MAPE sebagaimana Tabel 6.

Nilai MAPE yang semakin kecil mengindikasikan bahwa hasil ramalan akan semakin baik. Nilai rata-rata MAPE pada seluruh *cluster* untuk data *training* sebesar 6,33% sedangkan data *testing* sebesar 6,71%. Hal ini menandakan bahwa hasil prediksi dan ramalan yang diperoleh cukup baik. Pada Tabel 7 berikut didapatkan salah satu hasil prediksi pada *cluster* 1 untuk kode satker 527027.

Berdasarkan hasil prediksi seperti Tabel 7, bulan Januari dan Februari apabila dibandingkan antara nilai realisasi dan prediksi memiliki selisih 9% dan 3%. Miftahur Rahman juga memprediksi pembayaran tagihan listrik Pesantren Sukorejo Jawa Timur menggunakan model *Artificial Neural Network* (ANN) menghasilkan kesalahan hasil prediksi 9% (Rahman, 2019). Sedangkan Muhamad Irvan Maulana dan Much Aziz Muslim memprediksi tagihan listrik usaha *laundry* menggunakan jaringan syaraf tiruan *backpropagation* menghasilkan nilai *error* 3,52% (Maulana & Muslim, 2015). Javier Contreras, Rosario Espinola, Francisco J Nogales dan Antonio J Conejo juga memprediksi harga di pasar listrik Spanyol dan California menghasilkan rata-rata kesalahan prediksi 10% di pasar Spanyol dan 5% di pasar California (Contreras et al., 2003). Ini mengindikasikan bahwa nilai kesalahan prediksi tersebut masih di

bawah batas kewajaran 10% sehingga akurat untuk digunakan sebagai acuan melakukan prediksi tagihan listrik dan mengetahui kecukupan pagu anggaran.

Dari hasil prediksi selama tahun 2022 terhadap beberapa satker seperti pada Tabel 8, terdapat satu satker dengan pagu anggaran yang tidak cukup untuk melakukan pembayaran tagihan listrik. Dengan adanya *early warning* seperti ini, satker bisa memprediksikan anggaran tagihan listriknya ke depan sehingga bisa meminimalkan risiko gagal bayar tagihan listrik.

Analisis Kewajaran Tagihan

Banyaknya ID Pelanggan menjadi salah satu hal krusial bagi PPK dalam melakukan pengecekan kewajaran tagihan. Pada tagihan listrik di PLN sebagaimana pada Grafik 2, jumlah ID terbanyak yaitu 20 ID Pelanggan dimiliki oleh satu satker yaitu Kantor Pusat Sekretariat Jenderal Kementerian Keuangan.


Dalam Laporan Pelaksanaan Kegiatan *Walkthrough* dalam Rangka *Quality Assurance* (Direktorat Sistem Perbendaharaan, 2021), salah satu pertanyaan wawancara yang disampaikan kepada PPK di KPPN yang menjadi sampel adalah “bagaimana cara Bapak/Ibu meyakini kebenaran data tagihan yang masuk ke SAKTI?”. Jawaban yang didapatkan, selain melakukan pengecekan pada tagihan

Tabel 8. Kecukupan/Ketidakcukupan Pagu Anggaran Tahun 2022

Satker	Pagu	Prediksi	Keterangan
527982	144.000.000	117.475.917	Pagu Cukup
528099	120.000.000	118.775.981	Pagu Cukup
652460	180.000.000	82.937.374	Pagu Cukup
527933	18.900.000	13.473.667	Pagu Cukup
527027	1.216.296.000	1.259.221.600	Pagu Kurang


Sumber: Hasil olah data penulis

Grafik 2. Jumlah ID pada Satker



Sumber: Hasil olah data penulis

Grafik 3. Diagram Kewajaran Tagihan



Sumber: Hasil olah data penulis

hardcopy yang masih dikirim PLN setempat atau melalui *e-commerce*, digunakan *common sense* untuk mempertimbangkan terjadinya kenaikan dan penurunan tagihan. Apabila dianggap masih wajar, maka dapat diyakini kebenaran tagihannya.

Melalui penelitian ini, evaluasi yang dilakukan yaitu dengan melihat persentase selisih antara nilai tagihan baru dan statistik deskriptif dari data historis. Semakin besar selisih yang terjadi, artinya tagihan baru tersebut semakin berpotensi tidak wajar.

Sama dengan penelitian yang dilakukan oleh Rowa & Arthana (2019). Rowa dan Arthana menyampaikan bahwa nilai standar deviasi dari variabel *good corporate governance* dan pencegahan *fraud* yang dihasilkan lebih rendah dibandingkan dengan nilai

mean. Hal tersebut mengindikasikan bahwa statistika deskriptif yakni *mean* bisa digunakan sebagai representasi dari keseluruhan data yang ada.

Berdasarkan hasil penelitian terhadap 465 ID yang diuji, persentase tingkat kewajaran tagihan PLN Bulan Februari 2022 sebagaimana pada Grafik 3.

Hasil pengukuran dengan menggunakan data Bulan Februari menunjukkan sejumlah 131 dari 465 atau 28% tagihan dalam kategori tidak wajar sehingga diperlukan pengecekan oleh PPK. Sementara itu, sejumlah 334 dari 465 atau 72% tagihan dalam kategori wajar. Sebagian besar dari tagihan PLN Bulan Februari 2022 dalam kategori wajar.

KESIMPULAN DAN SARAN

Analisis *clustering time series* dengan ARIMA telah terbukti dapat digunakan untuk memprediksi kondisi kekurangan pagu pada satker khususnya pada akun 522111. Model ini dapat dijalankan ulang setiap bulan setelah terjadi realisasi untuk kemudian melakukan proyeksi kembali dan evaluasi ulang atas ketersediaan pagu. *Re-run* ini penting mengingat ada berbagai kondisi yang dapat berubah dari waktu ke waktu.

Berdasarkan hasil analisis kewajaran tagihan di atas, pengujian kewajaran tagihan dengan menggunakan statistika deskriptif dari informasi data tagihan bulan sebelumnya, dapat dibantu pengecekannya oleh model ini melalui sistem sebesar 72% karena tagihan terlihat wajar. Artinya PPK dapat fokus pada 28% tagihan yang perlu dilakukan pengecekan dan verifikasi lebih

mendalam/detail. Pengembangan atau penambahan metode pengujian berbasis analisis data lainnya dapat dilakukan untuk memperkuat pengujian yang dilakukan.

IMPLIKASI DAN KETERBATASAN

Implikasi praktis dari hasil penelitian ini adalah tersedianya satu alat bantu yang bisa menjadi solusi atas permasalahan pagu minus yang masih sering terjadi pada satker dan berakibat pada terjadinya tunggakan listrik pemerintah kepada PT PLN (Persero). Hasil penelitian ini menunjukkan bahwa potensi pagu minus dapat diprediksi lebih awal sehingga dapat dilakukan tindakan preventif untuk menghindari terjadinya tunggakan atau pemutusan aliran listrik yang dapat mengganggu layanan pemerintah.

Implikasi praktis lainnya dari hasil penelitian ini adalah berhasilnya digali potensi pemanfaatan *data analytics* dalam upaya mempermudah proses pengujian oleh PPK untuk tagihan-tagihan rutin seperti contoh kasus tagihan listrik dalam penelitian ini. Hal ini dapat meringankan tugas PPK dalam kegiatan pengujian sehingga bisa lebih produktif dalam melaksanakan tugas-tugas yang bersifat analisis. Selain itu, metode ini dapat direplikasi pada berbagai jenis tagihan lainnya dengan karakter tertentu yaitu sederhana dan berulang.

Implikasi teoritis dari hasil penelitian ini adalah diharapkan model yang digunakan dalam penelitian ini bisa memperkaya literatur kajian *data analytics* khususnya di bidang penerapan *data analytics* pada sektor

keuangan pemerintah dan bidang *robotic process automation* (RPA).

Keterbatasan penelitian ini adalah jumlah data yang terbatas yakni data tagihan dari bulan Januari 2019 sampai bulan Januari 2022. Penelitian berikutnya disarankan untuk menggunakan jumlah data yang lebih besar.

Keterbatasan lainnya adalah pengujian kewajaran tagihan menggunakan statistika deskriptif sederhana, penelitian berikutnya bisa mengembangkan metode yang lebih kompleks untuk meningkatkan akurasi pengujian.

REFERENSI

- Bible, J., Datta, S., & Datta, S. (2013). Cluster Analysis: Finding Groups in Data. *Informatics for Materials Science and Engineering*, 53-70. <http://dx.doi.org/10.1016/B978-0-12-394399-6.00004-7>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control Fifth Edition*. Hoboken: John Wiley & Sons, Inc.
- Contreras, J., Espinola, R., Nogales, F. J., & Conejo, A. J. (2003). ARIMA Models to Predict Next-Day Electricity Prices. *IEEE Transactions on Power Systems*, 18(3), 1014-1020. <https://doi.org/10.1109/TPWRS.2002.804943>
- Denis, D. J. (2016). *Applied Univariate, Bivariate, and Multivariate Statistics*. Hoboken: John Wiley & Sons, Inc.
- Diamond, J., & Potter, B. H. (1999). *Guidelines for Public Expenditure Management*. Jakarta: International

- Monetary Fund.
<https://doi.org/10.5089/9781557757876.071>
- Direktorat Jenderal Perbendaharaan. (2019). *Keputusan Direktur Jenderal Perbendaharaan Nomor 286 Tahun 2019 tentang Cetak Biru (Blueprint) Platform Pembayaran Pemerintah (Government Payment Platform) sebagai Pelaksanaan Layanan Shared Service Pembayaran Pemerintah*. Jakarta: Direktorat Jenderal Perbendaharaan.
- Direktorat Sistem Perbendaharaan. (2021). *Penyampaian Hasil dan Notula Diskusi Kendala Pembayaran Tagihan Listrik pada Satker Platform Pembayaran Pemerintah*. Jakarta: Direktorat Sistem Perbendaharaan
- Fauzi, A. (2015). *Peramalan Menggunakan Model Arima Pada Harga Saham Telkom Dan Lippo*. Surabaya: Institut Teknologi Sepuluh November.
- Hamilton, J. D. (2020). *Time Series Analysis*. Princeton: Princenton University Press
- Isnarwaty, D. P. (2017). *Peramalan Konsumsi Listrik Berdasarkan Pemakaian KWH untuk Kategori Industri I-4 di PT PLN (Persero) Distribusi Jawa Timur Menggunakan ARIMA Box-Jenkins*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Kementerian Keuangan. (2020). *Peraturan Menteri Keuangan Nomor 208 Tahun 2020 tentang Tata Cara Revisi Anggaran Tahun Anggaran 2021*. Jakarta: Kementerian Keuangan.
- Kirchgassner, G., Wolters, J., & Hassler, U. (2012). *Introduction to Modern Time Series Analysis*. Germany: Springer Science & Business Media.
- Maulana, M. I., & Muslim, M. A. (2015). Sistem prediksi tagihan listrik usaha jasa laundry menggunakan jaringan syaraf tiruan backpropagation. *UNNES Journal of Mathematics*, 4(1), 58-66.
- Mills, T. (2019). *Applied Time Series Analysis: A Practical Guide to Modeling and Forecasting*. Cambridge: Academic Press.
- Montero, P., & Vilar, J. A. (2015). TSclust: An R package for time series clustering. *Journal of Statistical Software*, 62(1), 1-43. <https://doi.org/10.18637/jss.v062.i01>
- Mukminin, A. (2021). *Analisis Sentimen Publik terhadap Pelayanan Tes Swab-PCR Covid-19 di Indonesia menggunakan Algoritma Support Vector Machine*. Surabaya: Universitas Dinamika.
- Munthe, A. D. (2019). Penerapan clustering time series untuk mengelompokkan provinsi di Indonesia berdasarkan nilai produksi padi. *Jurnal Litbang Sukowati*, 2(2), 1-11.
- Mutawalli, L., Zaen, M. A., & Suhriani, I. F. (2018). Sistem identifikasi persebaran pencemaran air oleh limbah di indonesia menggunakan average linkage dan K-Mean cluster. *Jurnal Manajemen Informatika dan Sistem Informasi*, 1(2), 36-42.
- Nurlaila, N. (2020). *Analisis Peramalan (Forecasting) Produksi Ikan Target Aktivitas Marine Recreational Fisheries di Pantai Besuki*,

- Kecamatan Besuki, Kabupaten Bondowoso. Malang: Universitas Brawijaya.
- Nurviana, Amelia, Sari, R. P., Nabilla, U., & Talib, T. (2022). Forecasting rice paddy production in Aceh using ARIMA and exponential smoothing models. *Jurnal Matematika Murni dan Aplikasi*, 7(2). 281-292. <https://doi.org/10.18860/ca.v7i2.13701>
- Pardede, T. (2013). *Analisis Kelas Laten (Laten Class Analysis) untuk Pengelompokan Data Kategorik. Prosiding Seminar Nasional Matematika, Sains dan Teknologi Volume 4*, 1-16.
- Rahman, M. (2019). Prediksi pembayaran tagihan listrik menggunakan model artificial neural network. *Justindo (Jurnal Sistem dan Teknologi Informasi Indonesia)*, 4(1), 7-12.
- Ramli, N. A., Hooy, C.-W., & Ismail, M. T. (2014). Application of fuzzy optimization and time series for early warning in predicting currency crisis. *Malaysia Journal of Mathematical Sciences*, 239-253.
- Republik Indonesia. (2013). *Peraturan Pemerintah Nomor 45 Tahun 2013 tentang Tata Cara Pelaksanaan Anggaran Pendapatan dan Belanja Negara*. Jakarta: Republik Indonesia.
- Riyadi, M. A. A., Fithriasari, K., & Widodo, D. A. (2016). Data mining peramalan konsumsi listrik dengan pendekatan cluster time series sebagai preprocessing. *Jurnal Sains Dan Seni ITS*, 5(1). 121-126.
- Rowa, C. W., & Arthana, I. K. (2019). Pengaruh good corporate governance terhadap pencegahan fraud pada bank perkreditan rakyat di Kupang. *Jurnal Akuntansi, Transparansi dan Akuntabilitas*, 7(2), 122-137.
- Shmueli, G., & Lichtendahl Jr, K. C. (2016). *Practical Time Series Forecasting with R: A Hands-On Guide [2nd Edition]*. Florida: Axelrod Schnall Publishers.
- Susanto, B., Jumnahdi, M., & Sunanda, W. (2019). *Menekan Susut Energi melalui Analisis Kewajaran Konsumsi Energi Listrik Pelanggan pada PLN UP3 Bangka. Prosiding Seminar Nasional Penelitian dan Pengabdian pada Masyarakat*. 84-87.
- The World Bank. (2020). *Indonesia Public Expenditure Review: Spending for Better Results*. <https://www.worldbank.org/en/country/indonesia/publication/indonesia-public-expenditure-review>
- Trebuna, P., & Halcinova, J. (2013). Mathematical Tools of Cluster Analysis. *Applied Mathematics*, 4, 814-816. <http://dx.doi.org/10.4236/am.2013.45111>
- Turner, D. P., & Houle, T. T. (2019). *Conducting and Reporting Descriptive Statistics. Headache*, 59(3), 300-305. <https://doi.org/10.1111/head.13489>
- Ulinnuh, N., & Veriani, R. (2020). Analisis cluster dalam pengelompokan provinsi di Indonesia berdasarkan variabel penyakit menular menggunakan Metode Complete Linkage, Average Linkage dan Ward. *Jurnal Nasional Informatika dan Teknologi Jaringan*, 5(1), 101-108.
- Wei, W. W. (2006). *Time Series Analysis: Univariate and Multivariate Methods, 2nd Edition*. Boston:

Pearson Addison Wesley.


Wichern, D. W., & Johnson, R. A. (2007).

Applied Multivariate Statistical Analysis. Hoboken: Pearson Prentice Hall.


Yohansa, M. (2021). *Time Series*

Clustering and Multi-Input Transfer Function Model for Covid-19 Incidences in Jakarta. Bogor: IPB University.

Lampiran 1. Alur Analisis Kecukupan Pagu dengan *Clustering Time Series*




Lampiran 2. Alur Analisis Kewajaran Tagihan dengan Statistik Deskriptif.




Lampiran 3. *Correlogram* ACF dan PACF tiap *Cluster*


Cluster 1




Cluster 3






Cluster 2



Cluster 4



Lampiran 4. *Plot Residual* pada Model ARIMA*Cluster 1**Cluster 3**Cluster 2**Cluster 4*