

BAB II TINJAUAN PUSTAKA

2.1. COVID-19

Coronavirus merupakan kelompok besar virus yang dapat menyebabkan penyakit pada hewan atau manusia [1]. Virus corona dapat menyebabkan gangguan pernapasan pada manusia seperti flu biasa hingga penyakit yang lebih parah seperti *Severe Acute Respiratory Syndrome (SARS)* dan *Middle East Respiratory Syndrome (MERS)* [1]. *Coronavirus* merupakan virus baru ditemukan yang menyebabkan penyakit *coronavirus* COVID-19 dan telah menjadi penyakit menular. Pada Desember 2019 virus dan penyakit baru ini diketahui setelah terjadi di Wuhan Cina. Dan virus ini telah menjadi pandemi di banyak negara [1]. Demam, batuk kering dan rasa lelah merupakan gejala COVID-19 yang paling umum. Hidung tersumbat, nyeri dan sakit, konjungtivitis, sakit kepala, diare, sakit tenggorokan, kehilangan indra perasa atau penciuman, ruam kulit atau perubahan warna jari dan kaki merupakan gejala yang mungkin jarang dialami beberapa pasien [17].

Gejala COVID-19 biasanya bersifat ringan dan akan kelihatan secara bertahap atau mungkin beberapa yang terinfeksi tapi memiliki gejala yang lebih ringan. Sekitar 80% yang terkena COVID-19 bisa pulih tanpa adanya perawatan. Serta 1 dari 5 yang terkena COVID-19 mengalami kesulitan bernapas dan sakit parah [17]. Bagi orang-orang yang terkena COVID-19 seperti orang lanjut usia, orang yang memiliki penyakit diabetes, darah tinggi, kanker, gangguan jantung dan paru-paru kemungkinan besar bisa mengalami sakit yang lebih serius. Namun orang dari segala usia dan siapa pun dapat terinfeksi dan mengalami sakit yang serius [17].

COVID-19 dapat tertular dari orang lain melalui percikan-percikan dari mulut atau hidung yang keluar dari orang yang terinfeksi COVID-19 seperti batuk, bersin atau saat berbicara dan akan terinfeksi jika menghirup percikan tersebut. Oleh karena itu sangat penting untuk menjaga jarak minimal 1 meter [17]. Percikan-percikan tersebut bisa juga menempel pada benda seperti gagang pintu, meja, pegangan tangan atau yang lainnya. Virus COVID-19 dapat bertahan pada benda seperti plastik dan *stainless steel* hingga 72 jam, pada tembaga bisa bertahan kurang dari 4 jam dan pada karton kurang dari 24 jam [17].

Jika orang lain menyentuhnya atau tanpa sengaja menyentuh mata, hidung atau mulut dapat juga menyebabkan infeksi. Gejalanya akan muncul sekitar hingga 6 hari setelah terinfeksi namun bisa juga terjadi 1-14 hari. Untuk saat ini belum ada vaksin untuk virus COVID-19 dan mungkin vaksin ini akan tersedia pada 2021. Oleh karena itu perlu menjaga kebersihan, rajin mencuci tangan, menggunakan *handsanitizer* serta menggunakan masker agar tidak terinfeksi virus COVID-19 [17][18].

Hal yang bisa dilakukan jika ada orang yang terinfeksi COVID-19 adalah dengan cara isolasi mandiri gunanya untuk memisahkan yang terkena COVID-19 dan untuk mencegah penularan. Serta karantina yang merupakan pembatasan kegiatan atau memisahkan orang yang tidak sakit namun ada kemungkinan terinfeksi COVID-19 dengan tujuan mencegah penyebaran pada orang yang baru terinfeksi mulai mengalami gejala. Dan apabila gejala parah maka perlu dibawa ke rumah sakit untuk perawatan yang lebih baik [17].

2.2 Prediksi (*Forecasting*)

Prediksi (*Forecasting*) adalah suatu kegiatan untuk memperkirakan peristiwa yang akan terjadi di masa depan dengan seakurat mungkin dan mengingat semua informasi dengan menggunakan data historis dan pengetahuan tentang peristiwa masa depan yang mungkin mempengaruhi perkiraan [19][20]. Kegiatan *forecasting* sangat penting dilakukan karena dapat menjadi masukan dalam pengambilan keputusan, pembuatan perencanaan dan strategi untuk membuat perkiraan informasi yang bersifat prediktif dalam menentukan arah tren masa depan di suatu perusahaan atau bidang lainnya seperti industri, politik hingga ekonomi. *Forecasting* terbagi menjadi 3 prakiraan jangka yaitu [19][20]:

1. Prakiraan jangka pendek (*Short-term forecast*)

Prakiraan jangka pendek dibutuhkan untuk penjadwalan personel, produksi dan transportasi. Sebagai bagian dari proses penjadwalan, prakiraan permintaan seringkali juga diperlukan, menengah dan panjang. Prakiraan ini terjadi dalam periode hari, minggu dan bulanan.

2. Prakiraan jangka menengah (*Medium-term forecast*)

Prakiraan jangka menengah dibutuhkan untuk menentukan kebutuhan sumber daya di masa depan, misalnya untuk membeli bahan mentah, mempekerjakan

personel, atau membeli mesin dan peralatan yang dapat terjadi dalam periode 1 tahun, 2 tahun ke masa depan

3. Prakiraan jangka panjang (*Long-term forecast*)

Prakiraan jangka panjang digunakan dalam perencanaan strategis. Keputusan tersebut harus mempertimbangkan peluang pasar, faktor lingkungan dan sumber daya internal yang dapat terjadi dalam periode yang sangat lama hingga 5 atau 10 tahun ke depan.

Metode prediksi yang tepat sangat bergantung pada data apa yang tersedia. Ada 2 teknik dalam prediksi yaitu menggunakan metode kualitatif dan metode kuantitatif [19][21]:

1. Metode kualitatif

Teknik prediksi kualitatif biasanya bersifat subjektif dan membutuhkan penilaian dari para ahli. Prakiraan kualitatif lebih sering digunakan dalam situasi ketika tidak ada data historis yang tersedia, atau jika data yang tersedia tidak relevan dengan prakiraan. Maka metode prediksi kualitatif harus digunakan.

2. Metode kuantitatif

Teknik prediksi kuantitatif membuat penggunaannya mengikuti aturan data historis dan model perkiraan. Model tersebut merangkum pola pada *file* data dan memaparkan hubungan statistik sebelumnya dengan nilai variabel saat ini. Kemudian model digunakan untuk memproyeksikan pola dalam data ke masa depan. Prediksi kuantitatif dapat diterapkan jika kondisi informasi numerik tentang masa lalu tersedia terpenuhi. Dan asumsi yang masuk akal tentang beberapa aspek dari pola masa lalu akan berlanjut di masa depan.

Ada berbagai macam model prediksi kuantitatif yang sering kali dikembangkan untuk tujuan tertentu. Setiap model memiliki properti, keakuratan, dan biaya sendiri-sendiri yang harus dipertimbangkan saat memilih model tertentu. Sebagian besar masalah prediksi kuantitatif menggunakan model regresi, model pemulusan, dan model runtun waktu umum [19].

1. Model regresi

Model regresi menggunakan hubungan antara variabel bebas dan satu atau lebih variabel prediktor terkait. Biasanya model regresi disebut model prediksi kausal,

karena variabel prediktor diperkirakan menggambarkan kekuatan penyebab atau dorongan nilai variabel yang diamati dan diminati.

2. Model pemulusan

Model pemulusan sering menggunakan fungsi sederhana dari pengamatan sebelumnya serta memberikan ramalan pada variabel yang diminati. Model ini mungkin memiliki dasar statistik formal, tetapi sering digunakan dan dibenarkan secara heuristik atas dasar yang mudah digunakan dan memberikan hasil yang memuaskan.

3. Model runtun waktu umum

Model runtun waktu umum biasanya menggunakan sifat statistik dari historis data untuk menentukan model formal yang kemudian akan digunakan untuk memperkirakan parameter yang belum diketahui dengan kuadrat terkecil.

2.3 Runtun Waktu (*Time Series*)

Runtun waktu (*Time series*) merupakan suatu metode kuantitatif dalam menentukan bentuk maupun pola dalam sebuah data historis yang telah dikumpulkan dalam rentang waktu seperti tahunan, bulanan, mingguan ataupun harian. Runtun waktu biasanya dipakai sebagai bahan dalam melakukan sebuah prediksi di masa yang akan datang [22]. Runtun waktu paling sederhana adalah seperti Gambar 2.1 di bawah ini:

| | Timestamp | Value |
|---|------------|-------|
| 0 | 2010-06-01 | 12 |
| 1 | 2010-06-02 | 10 |
| 2 | 2010-06-03 | 8 |
| 3 | 2010-06-04 | 5 |
| 4 | 2010-06-05 | 9 |
| 5 | 2010-06-06 | 2 |

Gambar 2. 1 Runtun waktu sederhana

Di mana unsur-unsurnya adalah [23]:

1. *Timestamp* adalah tanda waktu dalam kejadian yang didaftarkan. Akurasinya akan tergantung pada peristiwa yang diukur.

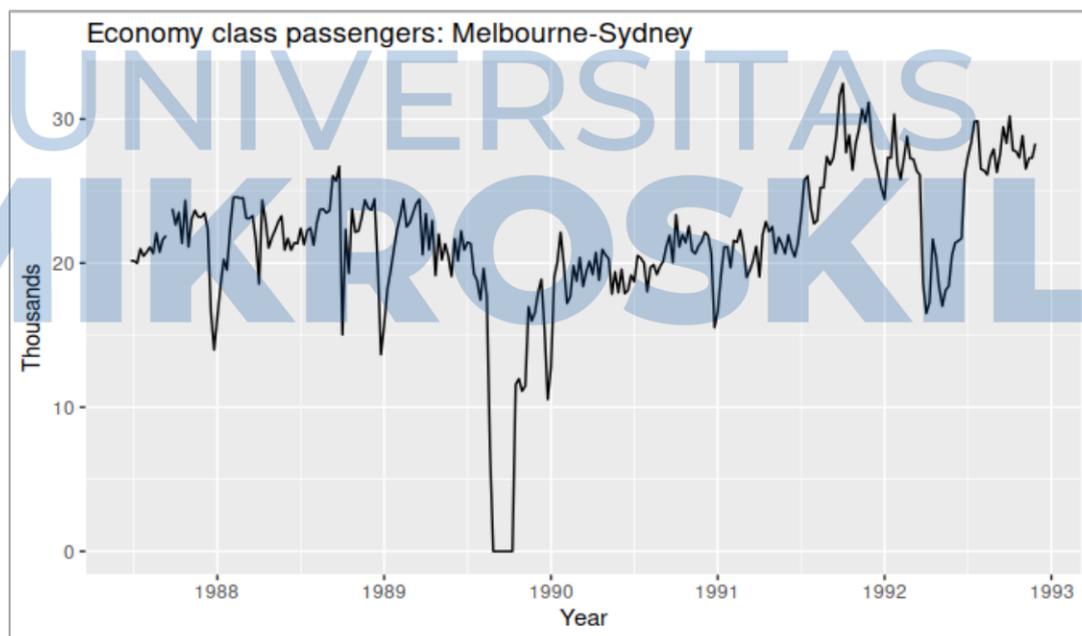
2. *Value* adalah nilai fenomena saat ini pada masa lalu, bisa hanya satu atau lebih nilai. Jika ada lebih dari satu nilai per *timestamp* berarti memiliki runtun waktu multivariabel.

Jenis *time series* [23]:

1. *Regular time series* merupakan data yang memiliki catatan di setiap periode waktu yang sama misalnya rangkaian suhu harian yang dapat dianggap sebagai rangkaian biasa karena satu catatan per hari, satu catatan per unit waktu.
2. *Irregular time series* merupakan data yang dikumpulkan tanpa frekuensi yang ditentukan, contohnya adalah *log* akses ke situs web. Karena setiap orang tidak mengakses secara bersamaan setiap waktu. Dan hal ini membuat catatan dengan interval waktu yang berbeda-beda.

2.3.1 Plot Runtun Waktu (*Time series Plots*)

Plot adalah cara yang digunakan untuk menunjukkan kumpulan data dari runtun waktu yang jelas di mana ada hubungan antara satu variabel dengan variabel yang lain dapat dilihat melalui grafik, *chart* dengan plot (alur) dan membantu membaca nilai dalam variabel seperti Gambar 2.2 di bawah ini [24].



Gambar 2. 2 Beban Penumpang mingguan di Ansett Airlines

Ada 2 jenis dari plot dalam runtun waktu (*time series*) [25]:

1. *Plot Lollipop*

Plot *lollipop* dapat juga disebut sebagai barplot dimana bentuk plot diubah ke dalam bentuk garis dan titik-titik yang menunjukkan hubungan antara variabel kategorik dan numerik. Bentuk plot ini menampilkan hierarki dengan warna yang dapat dibedakan berdasarkan grup atau populasi.

2. *Plot Treemap*

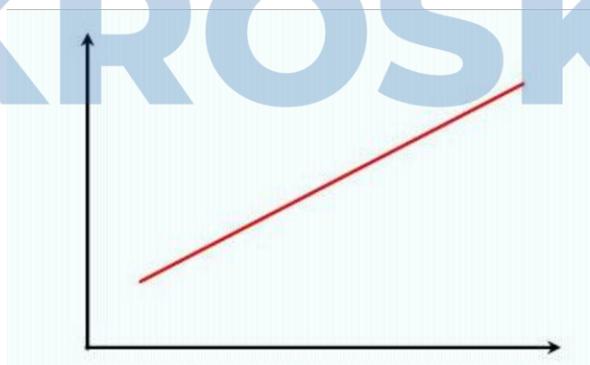
Treemap merupakan suatu teknik untuk membuat visualisasi data yang berfungsi untuk menampilkan data hierarki dengan persegi bersarang yang mewakili data seperti bentuk pohon. Data disusun dengan cabang pembantu dan direpresentasikan menggunakan persegi panjang, dimensi dan warna perseginya dihitung dengan variabel kuantitatif dan setiap persegi mewakili dua nilai numerik.

2.3.2 Pola Runtun Waktu (*Time Series Patterns*)

Banyak runtun waktu yang menyertakan pola supaya di saat melakukan pemilihan model prediksi, pola dapat terlebih dahulu diidentifikasi agar sesuai dengan model prediksi sehingga dapat menangkap pola dengan baik. Dalam mendeskripsikan runtun waktu, runtun waktu memiliki pola dalam bentuk [26]:

1. *Tren (Trend)*

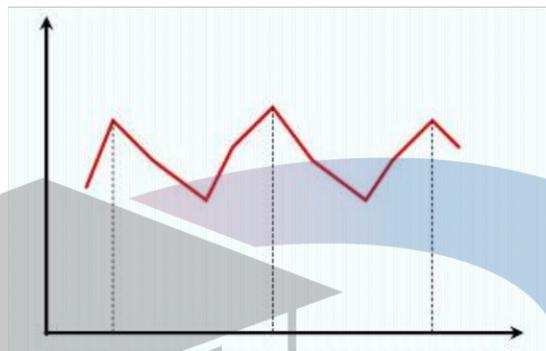
Pola tren dapat dilihat dengan adanya peningkatan dan penurunan dalam jangka panjang pada sebuah data yang dapat disebut istilah “perubahan arah”.



Gambar 2. 3 Pola Data Tren

2. Musiman (*Seasonal*)

Pola musiman dapat terjadi karena perubahan rangkaian waktu yang dipengaruhi oleh musiman seperti hari-hari tertentu dalam satu waktu atau kejadian yang merupakan frekuensi tetap.



Gambar 2. 4 Pola Data Musiman

3. Siklus (*Cyclic*)

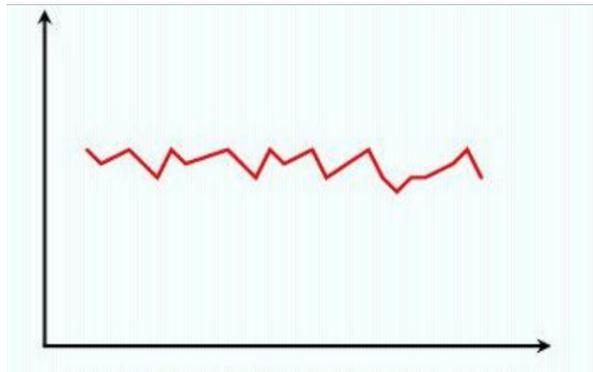
Pola siklus dapat terjadi dengan adanya naik turun dalam sebuah data tetapi bukan dari frekuensi yang tetap. Pola siklus biasanya dipengaruhi oleh bisnis dan ekonomi.



Gambar 2. 5 Pola Data Siklus

4. Pola horizontal

Pola ini dapat terjadi ketika data yang diobservasi berubah-ubah di sekitar tingkatan rata-rata yang konstan.



Gambar 2. 6 Pola data Horizontal

2.4 Analisis Runtun Waktu

Analisis runtun waktu merupakan kegiatan menganalisis yang digunakan dalam melakukan prediksi terhadap suatu runtun waktu dengan mempertimbangkan pengaruh waktu terhadap runtun waktu berupa jam, hari, bulan, tahun bahkan kuartal [27]. Analisis runtun waktu tidak hanya digunakan untuk data yang memiliki satu variabel namun bisa untuk data yang memiliki banyak variabel. Analisis dilakukan untuk menemukan sesuatu dari runtun waktu sehingga dapat digunakan sebagai perencanaan di masa yang akan datang [27]. Dalam melakukan analisis runtun waktu, perlu dilakukannya penyesuaian dengan cara melihat pola dan bentuk dari runtun waktu dari waktu ke waktu kemudian menentukan model prediksi yang tepat terhadap sebuah dataset, sehingga proses analisis data dapat disesuaikan dengan model yang dipilih [27][28].

Dalam melakukan analisis runtun waktu tentu sangat diperlukan *software* atau perangkat lunak seperti *R programming*, Minitab, JMP, dan SAS dimana *software* tersebut akan bekerja bersamaan dengan algoritma, teknik dan model prediksi yang akan digunakan. Biasanya *R* lebih sering digunakan dalam melakukan analisis runtun waktu karena memiliki kemampuan yang baik dalam melakukan analisis data runtun waktu dan menghasilkan perkiraan [19].

2.5 Stasioneritas Runtun Waktu (*Time series Stationarity*)

Stasioneritas runtun waktu adalah proses di mana statistik dalam runtun waktu tidak mengalami perubahan penurunan pada data seiring dari waktu ke waktu artinya fluktuasi (gejala turun naik) berada di dalam nilai rata-rata yang konstan dan tidak

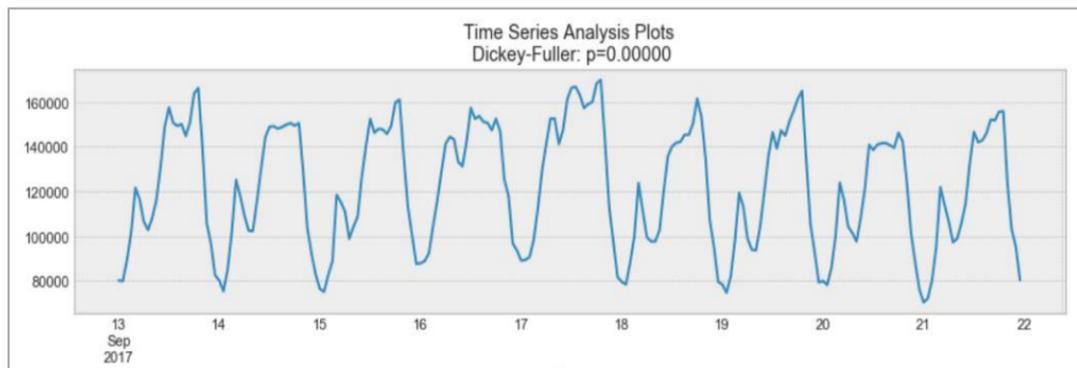
bergantung pada varian dan konstan dan tidak ada unsur tren dan musiman pada data [29]. Dengan kata lain memiliki *mean* dan varians yang konstan, dan kovarian tidak bergantung pada waktu [30]. Dalam *time series* biasanya terdapat data yang stasioner dan non-stasioner, jika datanya sudah stasioner maka data tersebut mudah dianalisis, jika belum stasioner maka data tersebut perlu diubah menjadi data yang stasioner. Untuk mengubah data dari non-stasioner ke stasioner dilakukan dengan cara pembeda (*differencing*), yaitu dengan mengurangi suatu data dengan data sebelumnya untuk beberapa periode tertentu sampai data itu menjadi stasioner [31]. Diperlukan data yang stasioner agar lebih mudah dilakukannya analisis lebih lanjut dengan proses yang menghasilkan data runtun waktu yang dapat disebut proses stokastik.

2.5.1 *The Dickey Fuller-Test*

Pendekatan yang dapat digunakan untuk mendeteksi stasioneritas dalam data runtun waktu adalah dengan uji statistik yang dikembangkan untuk mendeteksi jenis stasioneritas tertentu yang dihasilkan oleh model parametrik sederhana dari proses stokastik yaitu uji *Root test* dengan the *Dickey Fuller test* [32]. Uji *Dickey-Fuller* adalah uji statistik pertama yang dikembangkan untuk menguji hipotesis nol bahwa akar unit dalam model autoregresif dari runtun waktu tertentu, dan prosesnya tidak stasioner. Pengujian ini dapat menangani kasus model AR lag-1 (*Autoregressive*) sederhana. Pengujian ini memiliki tiga versi, yang berbeda dalam model proses root unit yang diuji [32]:

1. Uji akar unit (*root*): $\Delta y_i = \delta y_{i-1} + u_i$
2. Uji akar unit dengan penyimpangan (*drift*): $\Delta y_i = a_0 + \delta y_{i-1} + u_i$
3. Uji unit root dengan tren drift dan waktu deterministik: $\Delta y_i = a_0 + a_1 * t + \delta y_{i-1} + u_i$

Pengujian dikembangkan untuk mengakomodasi model dan data yang lebih kompleks dengan ini *Augmented Dickey-Fuller* (ADF) (menggunakan AR urutan p dan mendukung pemodelan tren waktu) [32].

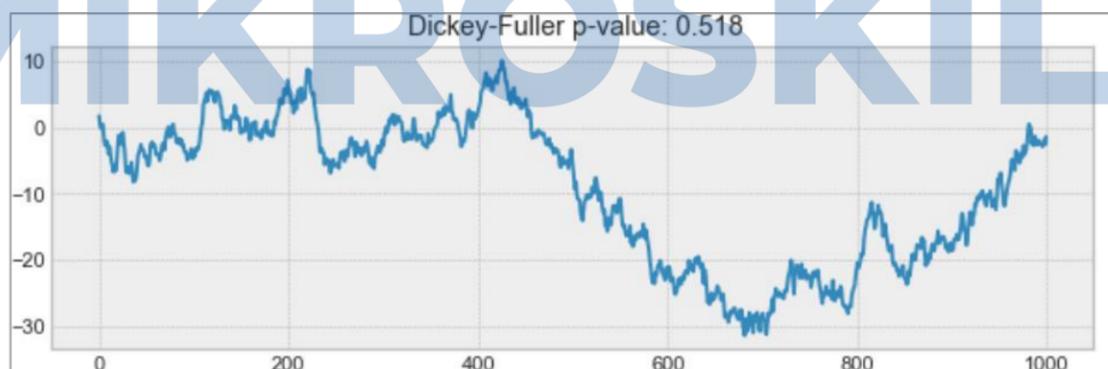


Gambar 2. 7 Contoh Proses Stasioner

Gambar 2.7 di atas merupakan suatu plot analisis data menggunakan teknik uji *Dickey-Fuller*, plot di atas tidak bergerak, *mean* dan variansnya tidak berubah seiring waktu. Dalam data runtun waktu sering kali ditemukan data yang non-stasioner, oleh karena itu cara yang dapat dilakukan untuk mengetahui data itu stasioner adalah dengan teknik *Dickey-Fuller* yang merupakan uji statistik yang digunakan untuk menentukan apakah runtun waktu stasioner atau tidak [30]. *P-value* adalah nilai *p* dalam *Dickey-Fuller* yang sangat penting untuk mengetahui kestasioneran suatu runtun waktu, data dapat dikatakan stasioner jika *p-value*-nya kecil dan sangat mendekati 0 [30].

Jika $p > 0$, mendekati angka 1 maka prosesnya tidak stasioner,

Jika $p = 0$, mendekati angka 0, maka proses dianggap stasioner. Kita dapat melihat bahwa nilai *p* pada plot di atas memiliki nilai $p = 0$, berarti data tersebut adalah stasioner.



Gambar 2. 8 Contoh proses Non-Stasioner

Dan plot pada Gambar 2.8 memiliki nilai $p > 0$ yaitu *p-value* = 0.518 dan ini berarti data tersebut adalah Non-stasioner.

2.6 Prophet Facebook

Prophet Facebook adalah *software* sumber terbuka yang dirilis oleh tim Sains Data Inti *Facebook* dan merupakan model yang dibuat untuk mengatasi masalah prediksi dengan memberikan pendekatan praktis untuk prediksi "dalam skala" (*at scale*) [6]. Hal ini bertujuan untuk mengotomatiskan fitur-fitur umum runtun waktu dengan menyediakan metode yang sederhana. *Prophet* memungkinkan para analis dengan berbagai latar belakang untuk membuat lebih banyak prakiraan daripada yang biasa dilakukan secara manual [33]. *Prophet* menyediakan prosedur untuk meramalkan data runtun waktu berdasarkan model aditif di mana tren non-linier sesuai dengan musim tahunan, mingguan, dan harian, ditambah efek liburan [33]. *Prophet* berfungsi paling baik dengan runtun waktu yang memiliki efek musiman yang kuat dan data historis di beberapa musim. *Prophet* juga kuat untuk kehilangan data dan perubahan tren, dan biasanya menangani pencilan dengan baik. *Input* ke *Prophet* selalu berupa kerangka data dengan dua kolom: *ds* dan *y*. Kolom *ds* (tanda untuk waktu/stempel waktu) harus dalam format yang diharapkan idealnya YYYY-MM-DD (*Year-Month-Day*) untuk tanggal, atau YYYY-MM-DD HH: MM: SS (*Year-Month-Day: Hour-Minute-Second*) untuk stempel waktu. Kolom *y* harus berupa angka dan mewakili ukuran yang ingin kita ramalkan [33].

Prophet terdiri dari 3 komponen yaitu tren, musim, dan hari libur, seperti yang ditunjukkan pada persamaan di bawah ini [34]:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (2.1)$$

Di sini, $g(t)$ adalah fungsi tren yang memodelkan perubahan non-periodik di nilai *time-series*, $s(t)$ mewakili perubahan periodik (misalnya, mingguan dan musim tahunan), dan $h(t)$ mewakili efek liburan yang terjadi pada jadwal yang berpotensi tidak teratur selama satu hari atau lebih. $\varepsilon(t)$ adalah istilah kesalahan atau *error* yang mewakili setiap perubahan istimewa yang tidak diakomodasi oleh mode, dan diasumsikan terdistribusi normal [34].

2.6.1 Tren (*Trend*)

Prophet cenderung mengimplementasikan dua model tren yang mungkin untuk $g(t)$ yaitu Nonlinear, *Saturating Growth* dan Linier Sepotong-Sepotong (*Piecewise Linear Model*) [6].

- a. Nonlinear, *Saturating Growth* yang direpresentasikan dalam bentuk model pertumbuhan logistik (3):

$$g(t) = \frac{C}{1 + e^{-k(t-m)}} \quad (2.2)$$

dimana:

C = daya dukung (yaitu nilai maksimum kurva).

k = tingkat pertumbuhan (yang mewakili "kecuraman" dari kurva).

m = parameter *offset*.

Persamaan logistik tersebut memungkinkan pemodelan pertumbuhan non-linier dengan saturasi, yaitu saat laju pertumbuhan suatu nilai menurun dengan pertumbuhannya. *Prophet* mendukung penyetulan otomatis dan manual untuk variabilitasnya. Perpustakaan (*library*) *Prophet* dapat memilih titik optimal dari perubahan tren dengan menyesuaikan data historis yang disediakan [35]. Selain itu, *Prophet* mengizinkan analisis untuk secara manual mengatur titik perubahan dari tingkat pertumbuhan dan nilai kapasitas pada titik waktu yang berbeda [35].

- b. Model Linier Sepotong-Sepotong (*Piecewise Linear Model*) adalah model yang sederhana dengan laju pertumbuhan yang konstan. Ini paling cocok untuk masalah tanpa pertumbuhan jenuh [35].

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T Y) \quad (2.3)$$

dimana:

k = tingkat pertumbuhan (yang mewakili "kecuraman" dari kurva).

m = parameter *offset*.

δ = vektor penyesuaian laju

2.6.2 Musiman (*Seasonality*)

Komponen musiman $s(t)$ memberikan model fleksibel dari perubahan periodik karena musiman mingguan dan tahunan. Data musiman mingguan dimodelkan dengan variabel *dummy* yang merupakan variabel yang digunakan untuk mengubah variabel

kualitatif menjadi kuantitatif seperti jenis kelamin, agama, ras dan lain-lain [35]. Enam variabel baru telah ditambahkan yaitu Senin, Selasa, Rabu, Kamis, Jumat, Sabtu, yang mengambil nilai 0 atau 1 tergantung pada hari dalam seminggu. Fitur hari minggu tidak ditambahkan karena akan menjadi kombinasi linier dari hari-hari lain dalam seminggu, dan fakta ini akan berdampak buruk pada model [35]. Model musiman tahunan di *Prophet* mengandalkan seri *Fourier* yaitu seri yang menggunakan fungsi periodik menjadi sinus cosinus. Serta dapat juga menggunakan runtun waktu sub-harian dan membuat prakiraan sub-harian serta menggunakan fitur musiman harian yang baru [35][6].

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi n t}{p}\right) + b_n \sin\left(\frac{2\pi n t}{p}\right) \right) \quad (2.4)$$

Dimana P mewakili periode regular yang mungkin dimiliki runtun waktu (misal, $P = 365$ untuk tahun atau $P = 7$ untuk data mingguan) dan N untuk memperlihatkan jumlah siklus yang ingin kita gunakan [6]. Ketika ingin menggabungkan setiap model runtun waktu musiman dalam $s(t)$ ke dalam vektor $X(t)$, model musiman yang akan muncul sebagai berikut:

$$s(t) = X(t)\beta \quad (2.5)$$

Dimana $\beta \sim \text{Normal}(0, \sigma^2)$ sehingga memberikan penghalusan (*smoothing*) sebelumnya pada musim.

2.6.3 Liburan dan Acara (*Holidays and Events*)

Komponen $h(t)$ mewakili hari-hari abnormal yang dapat diprediksi dalam setahun termasuk yang memiliki jadwal tidak teratur atau peristiwa besar misalnya, *Black Friday* atau hari spesial di Amerika Serikat. Untuk memanfaatkan fitur ini, analisis perlu menyediakan daftar kejadian khusus [35]. Untuk setiap liburan adalah i , kumpulan masa lalu dan tanggal masa depan untuk liburan adalah D_i . Fungsi indikator waktu yaitu t dan setiap hari libur sesuai perubahan ramalan adalah κ_i . Hal tersebut merupakan cara yang mirip dengan kemusiman dan membuat matriks dari *regressors*

$$Z(t) = [1(t \in D_1), \dots, 1(t \in D_L)]$$

dan mengambil

$$h(t) = Z(t)\kappa. \quad (2.6)$$

kemudian musim, digunakan $\kappa \sim \text{Normal}(0, \nu^2)$ [6].

2.7 Penelitian Terdahulu

Penelitian terdahulu diperlukan untuk mendukung pemahaman mengenai prediksi terhadap dataset dalam runtun waktu dengan model *Prophet Facebook*. Adapun beberapa penelitian terdahulu yang sudah pernah dilakukan dapat dilihat pada Tabel 2.1 berikut:



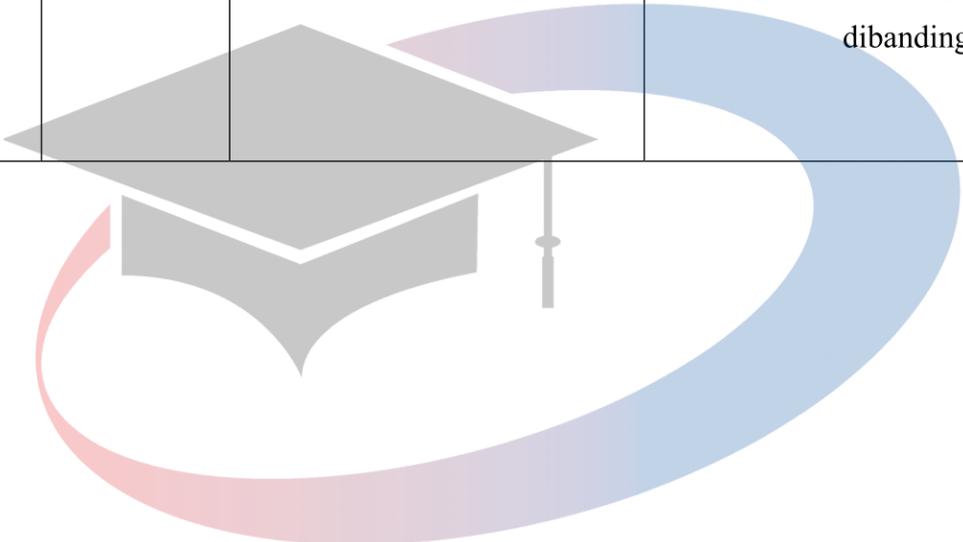
Tabel 2. 1 Penelitian Terdahulu

| No | Nama Peneliti | Tahun Penelitian | Judul Penelitian | Hasil yang diperoleh |
|----|---|------------------|--|---|
| 1. | K. Krishna Rani Samal, Korra Sathya Babu, Santosh Kumar Das, dan Abhirup Acharaya [36]. | 2019 | <i>Time Series based Air Pollution Forecasting using SARIMA and Prophet Model</i> | Prediksi Polusi Udara berbasis Time Series menggunakan SARIMA dan <i>Prophet</i> memberikan hasil kualitas akurasi yang baik, tetapi model <i>Prophet</i> lebih baik dalam mentransformasikan log serta memiliki RMSE dan MSE yang minimum. |
| 2. | Sakib Mahmud [37]. | 2020 | <i>Bangladesh COVID-19 Daily Cases Time Series Analysis using Facebook Prophet Model</i> | Model Prophet Facebook memprediksikan bahwa kasus harian akan terus meningkat jika tren hingga 21 Juli dari 9 Maret terus berlanjut. Dalam kasus prediksi vs kasus aktual dari 9 Maret hingga 21 Juli 2020 ditemukan secara statistik hubungan yang signifikan dan perbedaan yang sangat kecil yang diamati dan nilai prediksi sekalipun ada ditemukan beberapa nilai yang terlalu tinggi dan nilai yang terlalu rendah. Prediksi analisis ini benar berdasarkan tren saat ini hingga 21 Juli 2020. |

| | | | | |
|----|--|------|--|---|
| 3. | Indhuja M dan Sindhuja PP [38]. | 2020 | <i>Prediction of covid-19 cases in India using Prophet</i> | Prediksi kasus COVID-19 di India menggunakan <i>Prophet</i> , hasil prediksi jumlah kasus harian menggunakan <i>Prophet</i> mencapai hingga 1.500.000 kasus per hari dalam 4 minggu ke depan di India berdasarkan hasil tersebut pemerintah dapat melakukan pencegahan dan peraturan supaya jumlah kasus menurun. |
| 4. | Işıl Yenidoğan [16]. | 2020 | <i>Bitcoin Forecasting Using ARIMA and PROPHET</i> | Prediksi terhadap nilai-nilai mata uang dianggap berhasil dalam perkiraan 90 hari. Dalam hal ini, ARIMA dan <i>Prophet</i> di R ternyata penting untuk prediksi. <i>Prophet</i> membuat prediksi cukup dekat pada kenyataannya, yaitu presisi hingga 94,5%, model ARIMA hanya menyediakan presisi 68%. |
| 5. | Karthick Thiyagarajan, Sarath Kodagoda, Nalika Ulapane dan Mukesh Prasad [39]. | 2020 | <i>A Temporal Forecasting Driven Approach Using Facebook's Prophet Method for Anomaly Detection in</i> | Hasil ramalan adalah <i>Prophet Facebook</i> dalam seminggu memiliki akurasi prediksi yang tinggi dibandingkan model lainnya. Dan juga kinerja prediksi model <i>Prophet</i> baik digunakan dalam memperkirakan anomali dengan prediksi hanya satu hari ke depan. |

| | | | | |
|----|---|------|---|---|
| | | | <i>Sewer Air Temperature Sensor System</i> | |
| 6. | Resa Septiani Pontoh , S Zahroh , H R Nurahman , R I Aprillion, A Ramdani , D I Akmal[40] | 2021 | <i>Applied of feed-forward neural network and facebook prophet model for train passengers forecasting</i> | Berdasarkan analisis yang telah dilakukan untuk memprediksi jumlah penumpang Kereta Api di Pulau Jawa disimpulkan bahwa model <i>Prophet</i> berkinerja lebih baik daripada <i>Feed Forward Neural Network</i> (FFNN). MAPE FFNN diperoleh 4,27% dan MAPE untuk <i>Prophet</i> diperoleh 3,36%. Dengan demikian model <i>Prophet</i> memiliki tingkat akurasi yang tinggi karena tingkat kesalahan prediksi yang cukup kecil. |
| 7. | Abdulla I. Almazrouee , Abdullah M. Almeshal, Abdulrahman S. Almutairi, Mohammad R. Alenezi and Saleh N. Alhajeri[41] | 2020 | <i>Long-Term Forecasting of Electrical Loads in Kuwait Using Prophet and Holt-Winters Models</i> | Berdasarkan hasil dari peramalan model <i>Prophet</i> mencapai nilai yang sangat baik untuk MAPE, MAE, RMSE, CVRMSE, dan R2 dengan nilai masing-masing 1,75%, 147,89, 205,64, 7,61, dan 0,9942. Kinerja model <i>Holt-Winters</i> adalah 4,17, 343,33, 475,76, 17,59% dan 0,9694 untuk MAPE, MAE, RMSE, CVRMSE, dan R2. Dalam hal ini model <i>Prophet</i> lebih unggul dan menunjukkan akurasi yang lebih tinggi dibandingkan dengan model <i>Holt-Winters</i> . Dan juga <i>Prophet</i> |

| | | | | |
|--|--|--|--|---|
| | | | | menunjukkan kemampuan generalisasi yang lebih baik dibandingkan <i>Holt-Winters</i> . |
|--|--|--|--|---|



UNIVERSITAS
MIKROSKIL