

VISUALISASI DAN PREDIKSI KEDATANGAN PENUMPANG NGURAH RAI MENGGUNAKAN METODE HOLT-WINTERS

Diaz Ridzky Anandianto¹⁾ Wasino²⁾ Tri Sutrisno³⁾

¹⁾²⁾³⁾ Sistem Informasi, FTI, Universitas Tarumanagara

Jl. Letjen S Parman no 1, Jakarta 11440 Indonesia

¹⁾ diaz.825190088@stu.untar.ac.id ²⁾ wasino@fti.untar.ac.id ³⁾ tris@fti.untar.ac.id

ABSTRACT

I Gusti Ngurah Rai International Airport is one of the airports in Indonesia which is located in Bali which has a large number of passenger arrivals because Bali has many interesting tourist attractions to visit. I Gusti Ngurah Rai international airport data certainly has a large size so that Business Intelligence (BI) technology is needed, namely a dashboard to process this data and gain insight. Forecasting the number of passenger arrivals is also carried out in order to be able to analyze what the number of passenger arrivals would be like in the future. Therefore, in this case the dashboard was made using the prototyping method and data mining with forecasting or forecasting using the Holt-Winters triple exponential smoothing method. The smoothing parameters used are $\alpha = 0.3$, $\beta = 0.01$, and $\gamma = 0.01$ with the MAPE result of 32.04%. With the visualization on the dashboard, it is hoped that it will make it easier for the company that manage the airport to monitor the number of passenger arrivals at I Gusti Ngurah Rai International Airport so that they are able to make decisions in managing the airport.

Key words

Bali, Business Intelligence, Passenger, Airport, Forecast.

1. Pendahuluan

Bandar udara atau bandara adalah kawasan yang digunakan sebagai tempat pesawat udara lepas landas dan mendarat, naik turun penumpang, dan bongkar muat barang dengan fasilitas seperti keamanan penerbangan, keselamatan, dan fasilitas penunjang lainnya. Bandara internasional I Gusti Ngurah Rai merupakan salah satu bandara di Indonesia yang terletak di Bali. Jumlah kedatangan mancanegara melalui bandara internasional I Gusti Ngurah Rai memiliki jumlah tertinggi di Indonesia [1]. Hal terbesar yang mempengaruhi jumlah kedatangan tersebut yaitu karena Bali memiliki banyak tempat-tempat wisata yang menarik untuk dikunjungi.

Data penumpang bandara internasional I Gusti Ngurah Rai tentunya memiliki ukuran yang besar. Dalam mengolah data tersebut dan mendapatkan wawasan, perusahaan pengelola bandara memerlukan teknologi *Business Intelligence* (BI). BI merupakan suatu proses

dalam mengolah data yang sudah diekstraksi terlebih dahulu lalu menjadikannya sebagai informasi dan wawasan dalam pengambilan keputusan dengan memvisualisasikan data tersebut. Jika diterapkan, BI dapat mempermudah mengambil informasi penting bagi organisasi atau perusahaan [2]. Oleh karena itu, pada kasus ini akan menggunakan teknologi BI yaitu *dashboard* yang dapat memvisualisasikan jumlah kedatangan penumpang berdasarkan data – data seperti kategori, negara, bandara dan maskapai pada bandara internasional I Gusti Ngurah Rai.

Selain visualisasi data, perusahaan pengelola juga membutuhkan peramalan atau *forecast* jumlah kedatangan penumpang untuk beberapa bulan ke depan. Metode *forecasting* yang digunakan adalah *Holt-Winters triple exponential smoothing*. Penulis di [3] menggunakan metode tersebut dan mendapatkan hasil yang cukup baik dalam meramal jumlah wisatawan mancanegara yang berkunjung ke Indonesia. Penulis di [4] mengatakan bahwa metode tersebut memiliki akurasi yang tinggi karena mempertimbangkan tidak hanya faktor tren, tetapi juga faktor musim sehingga dapat meramal harga bahan pangan dengan hasil yang akurat.

2. Landasan Teori

2.1 Dashboard

Dashboard adalah suatu alat untuk menampilkan data dengan visual yang berguna untuk melakukan analisis dan mendapatkan pemahaman agar dapat mengambil keputusan. Ada tiga kategori *dashboard* yaitu sebagai berikut.

- *Strategis*: *Dashboard* ini merupakan alat reporting yang dapat membantu memantau strategi jangka lama pada suatu perusahaan
- *Operasional*: *Dashboard* ini biasanya berisi data-data *real time* pada masa kini dalam jangka harian.
- *Analitik*: *Dashboard* ini menggunakan data masa lampau untuk mengidentifikasi tren yang dapat membantu membuat keputusan yang lebih baik kedepannya.

2.2 Dimensional Modelling

Dalam merancang *data warehouse* dibutuhkan pemodelan data dengan teknik *dimensional modelling* atau model dimensional. Model dimensional sangat cocok untuk aplikasi *business intelligence* dan *data warehouse* [5]. Dalam model dimensional, tabel fakta akan terhubung dengan tabel dimensi menggunakan *foreign key* yang digunakan untuk analisis, sedangkan tabel dimensi berisi atribut – atribut yang akan digunakan untuk menjelaskan data yang masuk ke dalam tabel fakta.

2.3 Forecasting

Forecasting atau peramalan adalah salah satu metode *data mining* yang dapat mengetahui suatu hal yang akan terjadi di masa depan berdasarkan data masa lampau [6]. *Forecasting* dapat menjadi dasar bagi perusahaan dalam pengambilan keputusan dan dapat mengubah kondisi saat ini menjadi lebih baik pada masa yang akan datang.

2.4 Holt-Winters Triple Exponential Smoothing

Metode *Holt-Winters triple exponential smoothing* adalah salah satu metode *forecasting* yang dapat dipakai jika data yang digunakan memiliki *trend* atau tren dan *seasonality* atau periode musiman. Ada dua tipe dari metode *Holt-Winters*, yaitu aditif dan multiplikatif. Tipe aditif digunakan jika pola tren pada data lebih sering konstan atau lurus. Pada Persamaan 1 sampai Persamaan 4 berikut ini adalah rumus *Holt-Winters* aditif.

$$L_t = \alpha(Y_t - S_t - s) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

.....(1)

$$B_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

.....(2)

$$S_t = \gamma(Y_t - t) + (1 - \gamma)S_{t-s}$$

.....(3)

$$F_{t+m} = (L_t + m * b_t) + S_t - s + m$$

.....(4)

Jika pola tren pada data menunjukkan adanya fluktuasi (naik atau turun), maka digunakan metode *Holt-Winters* multiplikatif. Pada Persamaan 5 sampai Persamaan 8 berikut ini adalah rumus *Holt-Winters* multiplikatif.

$$L_t = \alpha(Y_t / S_t - s) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

.....(5)

$$B_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

.....(6)

$$S_t = \gamma(Y_t / t) + (1 - \gamma)S_{t-s}$$

.....(7)

$$F_{t+m} = (L_t + m * b_t) + S_t - s + m$$

.....(8)

Keterangan:

t : Periode data observasi

L_t : Estimasi indeks level

α (alpha): Konstanta pemulusan untuk level (0 < α < 1)

Y_t : Observasi baru atau data aktual periode t

β (beta): Konstanta pemulusan untuk estimasi tren (0 < β < 1)

B_t : Estimasi indeks tren

γ (gamma): Konstanta pemulusan untuk estimasi musiman (0 < γ < 1)

S_t : Estimasi indeks periode musiman

m : Jumlah periode ke depan yang diramalkan

s : Panjangnya periode musim

F_{t+m} : Nilai prediksi m periode ke depan

Sebelum dilakukan *forecasting* dibutuhkan nilai inisialisasi. Untuk menginisialisasi metode *Holt-Winters triple exponential smoothing* dibutuhkan nilai inisialisasi level L_s, tren B_s, dan indeks musiman S_p. Data yang diperlukan untuk metode peramalan ini setidaknya data selama 2 periode. Nilai awal pemulusan level didapatkan dengan menggunakan nilai rata-rata 12 bulan pertama. Pada Persamaan 9 dapat dilihat rumus nilai inisialisasi level L_s.

$$L_s = (Y_1 + Y_2 + \dots + Y_s) / s$$

.....(9)

Keterangan:

L_s : Inisialisasi level

Y_s : Harga jumlah Kedatangan ke-s

S : Periode musiman (s = 12)

Untuk mendapatkan nilai awal tren dibutuhkan data selama dua musim atau 24 bulan. Pada Persamaan 10 dapat dilihat rumus nilai inisialisasi tren B_s.

$$B_s = (((Y_{s+1} - Y_1) / s) + ((Y_{s+2} - Y_2) / s) + \dots + ((Y_{s+s} - Y_s) / s)) / s$$

.....(10)

Keterangan:

B_s : Inisialisasi tren

Y_{s+1} : Jumlah kedatangan ke-(s+1)

S : Periode musiman (s = 12)

Untuk mendapatkan nilai awal untuk indeks musiman pada 12 bulan pertama dapat dipilih antara aditif atau multiplikatif sesuai pola tren pada data. Pada Persamaan 11 dan Persamaan 12 dapat dilihat rumus nilai inisialisasi indeks periode musiman S_p.

$$(Multiplikatif) S_1 = Y_1 / L_s, S_2 = Y_2 / L_s, \dots, S_p = Y_p / L_s$$

.....(11)

$$(Additif) S_1 = Y_1 - L_s, S_2 = Y_2 - L_s, \dots, S_p = Y_p - L_s$$

.....(12)

Keterangan:

Sp : Inisialisasi indeks musiman

Yp : Jumlah kedatangan ke-p

p : Periode musiman di tahun pertama (p = 1, 2, 3 ... 12)

2.5 Mean Absolute Percentage Error (MAPE)

Setelah dilakukan prediksi harus juga diukur seberapa akurat prediksi tersebut. Salah satu metode tersebut adalah MAPE. Pada Persamaan 13 dapat dilihat rumus untuk menghitung MAPE.

$$MAPE = \left(\frac{1}{n}\right) * \sum \left(\frac{|Av - Fv|}{|Av|}\right) * 100 \dots \dots \dots (13)$$

Keterangan:

Av: Actual value (Nilai Asli)

Fv: Forecast value (Nilai Prediksi)

n: Jumlah observasi

MAPE tentunya butuh diinterpretasikan apakah peramalan yang dilakukan sudah baik atau belum. Pada Tabel 1 berikut ini merupakan interpretasi dari MAPE.

Tabel 1. Interpretasi MAPE

Nilai MAPE	Interpretasi
<10%	Sangat akurat
10-20%	Baik
20-50%	Cukup
>50%	Tidak akurat

3. Hasil Percobaan

Model *prototype* adalah salah satu model *system development* yang digunakan. Model tersebut memiliki beberapa tahapan sebagai berikut.

1. Mendefinisikan kebutuhan *prototype*.
2. Membuat *prototype*.
3. Uji coba *prototype*.

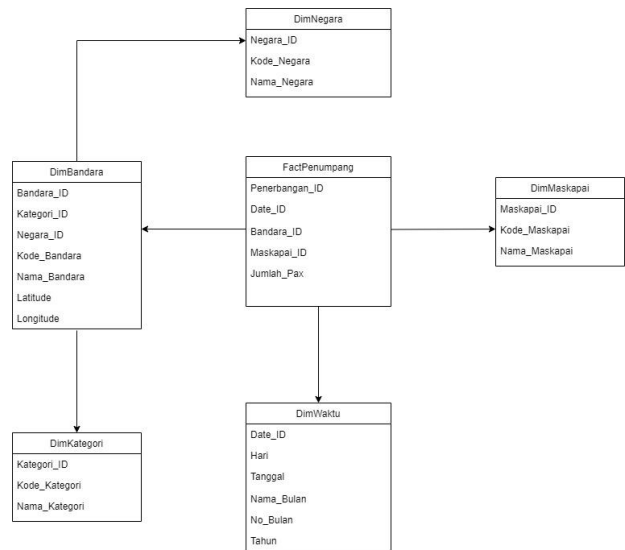
3.1 Mendefinisikan kebutuhan *prototype*

Dashboard ini didesain untuk memvisualisasikan data jumlah kedatangan penumpang bandara internasional I Gusti Ngurah Rai dari tahun 2017 sampai 2022 berdasarkan data – data seperti kategori, negara, bandara dan maskapai. Pada tahap ini, *key performance indicator* juga ditentukan untuk memantau jumlah kedatangan penumpang.

3.2 Membuat *prototype*

Pada tahap ini dibuat rancangan *database* , seperti *entity relationship diagram*, *class diagram*, *use case diagram*, *snowflake schema*, dan *user interface*. Pada Gambar 1 ditunjukkan desain model dimensional menggunakan *snowflake schema* untuk *data mart* yang

menyimpan data jumlah kedatangan penumpang bandara internasional I Gusti Ngurah Rai.




Gambar 1. Desain *Snowflake Schema* untuk *data mart*

Tahap selanjutnya adalah melakukan proses *extract, transform, load* (ETL) untuk memasukkan data kedalam *data mart*. Tahap ETL ini memiliki tiga tahapan yaitu.

1. *Extract*: Mengekstrak data dari sumber.
2. *Transform*: Mentransformasi data seperti *sorting data*, menambahkan data, *split data*, *merge data*, dan *group by data*.
3. *Load*: Memasukkan data ke *database* tujuan.


Software yang digunakan pada saat proses ETL adalah Pentaho Data Integration. Proses ekstraksi dilakukan dengan mengambil data dari sumber data berbentuk *database* dan *file Excel*. Kemudian dilakukan proses *transform* seperti *split data*, *merge data*, *sorting data*, *group by data*, dan menambahkan data baru. Setelah data ditransformasi dilakukan *load* data ke *data mart* tujuan. Contoh proses ETL pada tabel DimMaskapai dapat dilihat pada Gambar 2, ETL pada tabel DimWaktu pada Gambar 3, ETL pada tabel DimNegara pada Gambar 4, ETL pada tabel DimBandara pada Gambar 5, ETL pada tabel Dim Kategori pada Gambar 6, dan ETL pada tabel FactPenerbangan pada Gambar 7.




Gambar 2. Proses ETL tabel DimMaskapai




Gambar 3. Proses ETL tabel DimWaktu



Gambar 4. Proses ETL tabel DimNegara



Gambar 5. Proses ETL tabel DimBandara




Gambar 6. Proses ETL tabel DimKategori



Gambar 7. Proses ETL tabel FactPenerbangan

Setelah proses ETL data sudah selesai, tahap selanjutnya adalah melakukan *forecasting* dengan metode *Holt-Winters triple exponential smoothing* menggunakan *software* RStudio. Sebagai contoh, data yang digunakan adalah data dari Juli 2020 sampai Agustus 2022. Metode *Holt-Winters triple exponential smoothing* multiplikatif digunakan pada data tersebut dikarenakan terdapat fluktuasi seperti pada *plotting* data pada Gambar 8, kemudian meramalkan kedatangan penumpang pada 12 bulan berikutnya. Data secara detail dapat dilihat pada Tabel 2.



Gambar 8. *Plotting* data dari Juli 2020 hingga Agustus 2022

Tabel 2. Data kedatangan penumpang Juli 2020 – Agustus 2022

Bulan	Jumlah Penumpang
Juli 2020	36758
Agustus 2020	86419

September 2020	88503
Oktober 2020	121512
November 2020	170121
Desember 2020	228738
Januari 2021	83240
Februari 2021	77681
Maret 2021	134450
April 2021	150969
Mei 2021	139860
Juni 2021	229821
Juli 2021	32138
Agustus 2021	42413
September 2021	119990
Oktober 2021	236771
November 2021	278937
Desember 2021	353505
Januari 2022	280348
Februari 2022	195207
Maret 2022	301669
April 2022	311212
Mei 2022	503361
Juni 2022	576415
Juli 2022	654320
Agustus 2022	645899

Perhitungan lebih detail mengenai metode *Holt-Winters triple exponential smoothing* dijelaskan berikut ini. Langkah pertama diawali dengan mencari nilai inisialisasi atau nilai awal untuk pemulusan level, tren, dan periode musiman. Untuk nilai awal indeks level L_s didapatkan nilai sebesar 129006 dan untuk nilai awal indeks tren B_s didapatkan nilai sebesar 11693.70833. Untuk nilai indeks periode musiman S_p dapat dilihat pada Tabel 3.

Tabel 3. Nilai periode musiman

Bulan	Y_t	S_p
Juli 2020	36758	0.284932484
Agustus 2020	86419	0.669883571
September 2020	88503	0.686037859
Oktober 2020	121512	0.941909679
November 2020	170121	1.318706107
Desember 2020	228738	1.773080322
Januari 2021	83240	0.645241307
Februari 2021	77681	0.602150288
Maret 2021	134450	1.042199588
April 2021	150969	1.170247895
Mei 2021	139860	1.084135622
Juni 2021	229821	1.78147528

Langkah selanjutnya adalah melakukan perhitungan pemulusan level L_t , tren B_t , dan periode musiman S_t . Pada peramalan ini menggunakan nilai $\alpha=0,3$, $\beta=0,01$, dan

$\gamma=0,01$. Perhitungan pemulusan dapat dilihat pada Tabel 4.

Tabel 4. Perhitungan pemulusan

Bulan	Y_t	L_t	B_t	S_t
Juli 2021	32138	132327 .2856	11609. 98411	0.28451 1834
Agustus 2021	42413	119750 .285	11368. 11426	0.66672 6523
September 2021	119990	144253 .7447	11499. 46771	0.68749 5462
Oktober 2021	236771	184439 .2564	11786. 32815	0.94532 7925
November 2021	278937	200814 .8839	11832. 22115	1.31940 9301
Desember 2021	353505	208664 .9847	11792. 39994	1.77229 0789
Januari 2022	280348	284665 .8231	12434. 48433	0.64863 7213
Februari 2022	195207	305225 .1716	12515. 73297	0.60252 4293
Maret 2022	301669	309254 .8795	12430. 87272	1.04153 2296
April 2022	311212	304961 .0715	12263. 62591	1.16875 0391
Mei 2022	503361	361346 .4112	12704. 84305	1.08722 4416
Juni 2022	576415	358904 .0226	12553. 37073	1.77972 0949
Juli 2022	654320	949959 .8419	18338. 39522	0.28855 4586
Agustus 2022	645899	968437 .2223	18339. 78507	0.66672 8755

Langkah selanjutnya adalah melakukan perhitungan peramalan jumlah kedatangan penumpang untuk 12 bulan kedepan sampai bulan Agustus 2023. Langkah tersebut dapat dilihat pada Tabel 5.

Tabel 5. Forecasting 12 bulan kedepan

Bulan	Y_t	F_t
Juli 2021	32138	40089.91736
Agustus 2021	42413	96421.21227
September 2021	119990	89952.18587
Oktober 2021	236771	146705.4582
November 2021	278937	258763.8767
Desember 2021	353505	377040.3974
Januari 2022	280348	142248.2109
Februari 2022	195207	178899.0355
Maret 2022	301669	331149.4398
April 2022	311212	376452.0745
Mei 2022	503361	343914.5945
Juni 2022	576415	666363.0631
Juli 2022	654320	105684.0243
Agustus 2022	645899	645590.1165
September 2022		678404.7143
Oktober 2022		950164.9716
November 2022		1350358.127
Desember 2022		1846366.098
Januari 2023		687643.7563
Februari 2023		649807.9484
Maret 2023		1142368.993
April 2023		1303338.43
Mei 2023		1232363.753
Juni 2023		2049945.009
Juli 2023		337659.3216
Agustus 2023		792416.8886

Langkah selanjutnya adalah mencari nilai *Mean Average Percentage Error* (MAPE) untuk melihat seberapa besar *error* dari peramalan yang telah dilakukan. Pada Tabel 6 ditampilkan perhitungan MAPE tersebut.

Tabel 6. Perhitungan MAPE

Bulan	Y_t	F_t	APE
Juli 2021	32138	40089.91736	24.7430374%
Agustus 2021	42413	96421.21227	127.3388166%
September 2021	119990	89952.18587	25.03359791%
Oktober 2021	236771	146705.4582	38.03909337%
November 2021	278937	258763.8767	7.23214321%
Desember 2021	353505	377040.3974	6.657726883%
Januari 2022	280348	142248.2109	49.26012994%
Februari 2022	195207	178899.0355	8.354190398%
Maret 2022	301669	331149.4398	9.772445879%
April 2022	311212	376452.0745	20.96322586%
Mei 2022	503361	343914.5945	31.67635265%
Juni 2022	576415	666363.0631	15.60474017%
Juli 2022	654320	105684.0243	83.84826625%
Agustus 2022	645899	645590.1165	0.047822267%
MAPE			32.04082777%

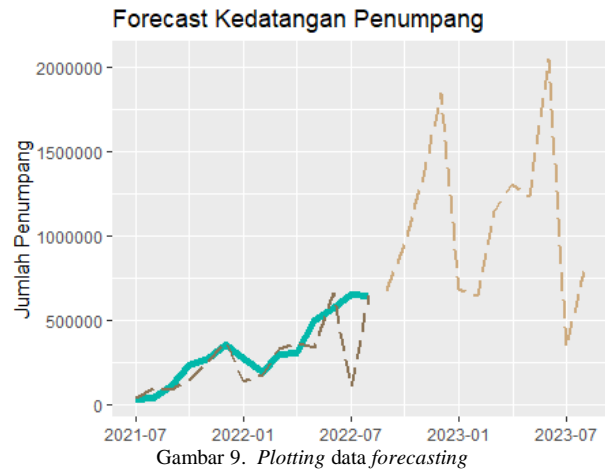
Kemudian konstanta alpha, beta, dan gamma dibutuhkan beberapa kali percobaan dalam peramalan untuk menentukan MAPE terkecil yang akan ditampilkan pada *dashboard*. Hasil percobaan konstanta dan MAPE dapat dilihat pada Tabel 7.

Tabel 7. Hasil percobaan konstanta penghalus

No.	Konstanta penghalus			MAPE
	Alpha	Beta	Gamma	
1	0.3	0.01	0.01	32.04%
2	0.4	0.3	0.3	34.4%
3	0.2	0.01	0.02	32.65%
4	0.2	0.03	0.01	32.69%
5	0.1	0.01	0.02	34.04%

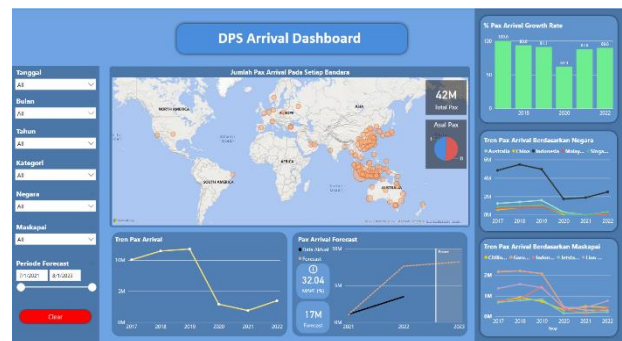
Dari hasil percobaan pada Tabel 1, dapat dilihat dengan menggunakan metode *Holt-Winters* dengan konstanta penghalus alpha = 0.3, beta = 0.01, and gamma = 0.01 menghasilkan MAPE sebesar 32.04% yang sudah cukup untuk ditampilkan pada *dashboard*. Pada Gambar 9 ditampilkan hasil *plotting data forecasting* dengan

MAPE terkecil. Garis hijau menampilkan data aktual jumlah kedatangan, garis cokelat gelap menandakan peramalan jumlah kedatangan yang sudah terjadi, dan dan garis cokelat terang data peramalan kedatangan jumlah kedatangan penumpang 12 bulan yang akan datang.



Gambar 9. Plotting data forecasting

Tahap terakhir adalah memvisualisasikan data kedalam *dashboard* menggunakan Power BI. Pada Gambar 10 ditampilkan hasil pembuatan *dashboard* kedatangan penumpang bandara internasional I Gusti Ngurah Rai.



Gambar 10. Dashboard Power BI

Pada *dashboard* tersebut terdapat visual-visual yang menampilkan informasi yang dibutuhkan, *key performance indicator*, dan hasil *forecasting*. Berikut ini adalah penjelasan setiap visual pada *dashboard* tersebut.

- Visual *line chart* ‘Tren Pax Arrival’: menampilkan tren jumlah kedatangan penumpang.
- Visual *pie chart* ‘Asal Pax’: menampilkan jumlah kedatangan penumpang berdasarkan kategori kedatangan.
- Visual *map* ‘Jumlah Pax Arrival Pada Setiap Bandara’: menampilkan jumlah kedatangan penumpang berdasarkan bandara.
- Visual *bar chart* ‘Tren Pax Arrival Berdasarkan Maskapai’: menampilkan jumlah kedatangan penumpang berdasarkan lima maskapai tertinggi.
- Visual *card* ‘Total Pax’: menampilkan total kedatangan penumpang.

- Visual *line chart* 'Tren Pax Arrival Berdasarkan Negara': menampilkan jumlah kedatangan penumpang berdasarkan lima negara tertinggi.
- Visual *bar chart* '% Pax Arrival Growth Rate': menampilkan persentase pertumbuhan kedatangan penumpang.
- Visual *line chart* 'Pax Arrival Forecast': menampilkan hasil *forecasting* jumlah penumpang serta.
- Visual *card* 'MAPE': menampilkan tingkat akurasi *forecasting*.
- Visual *card* 'Forecast': menampilkan jumlah *forecasting* kedatangan penumpang.

Kemudian juga terdapat beberapa *filter* atau *slicer* pada *software* Power BI untuk membantu *user* dalam analisis sesuai kebutuhan. *Filter-filter* tersebut telah disesuaikan pengaruh penggunaannya dengan visual-visual yang ada pada *dashboard*.

- *Filter* 'Tanggal': dapat memilih bulan yang ingin divisualisasikan.
- *Filter* 'Bulan': dapat memilih bulan yang ingin divisualisasikan.
- *Filter* 'Tahun': dapat memilih tahun yang ingin divisualisasikan.
- *Filter* 'Kategori': dapat memilih kategori antara domestik atau mancanegara dengan tujuan bandara Ngurah Rai.
- *Filter* 'Negara': dapat memilih negara asal kedatangan penumpang dengan tujuan bandara Ngurah Rai.
- *Filter* 'Maskapai': dapat memilih maskapai yang digunakan dengan tujuan bandara Ngurah Rai.
- *Filter* 'Periode Forecast': dapat memilih periode waktu *forecast* agar dapat melihat secara detail.

3.3 Uji coba *prototype*

Tahap uji coba *prototype* yang pertama dilakukan adalah uji coba sistem, yaitu pembuat *prototype* dengan memeriksa apakah data yang divisualisasikan sudah sesuai. Setelah uji coba sistem sudah selesai, tahap uji coba *prototype* yang kedua dilakukan adalah uji coba kepada *user*. Jika *prototype* sudah sesuai dengan kebutuhan *user*, maka *dashboard* sudah siap untuk digunakan. Jika belum sesuai, maka *prototype* diperbaiki sesuai *feedback* dari *user*.

4. Kesimpulan

Metode *prototyping* yang digunakan pada pembuatan *dashboard* ini dapat membantu perusahaan pengelola untuk membuat *dashboard* ini menjadi lebih baik lagi agar dapat digunakan dalam memantau jumlah kedatangan penumpang pada bandara internasional I Gusti Ngurah Rai. Hasil *forecasting* jumlah kedatangan

penumpang mendapatkan MAPE sebesar 32.04% yang sudah cukup untuk meramal beberapa bulan kedepan. Selain itu, metode untuk memprediksi kedatangan penumpang juga dapat menggunakan metode lain yang mempertimbangkan data tren dan musiman data untuk mendapatkan tingkat akurasi yang lebih baik lagi.

REFERENSI

- [1] Hudiayanti, C., Bachtiar, F., & Setiawan, B., 2019, Perbandingan Double Moving Average dan Double Exponential Smoothing untuk Peramalan Jumlah Kedatangan Wisatawan Mancanegara di Bandara Ngurah Rai. Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer, 3(3), 2667-2672.
- [2] Akbar, R., Wulandari, W., Hasanah, Z., & Gravina, H. (2017). IMPLEMENTASI BUSINESS INTELLIGENCE UNTUK MENENTUKAN MAHASISWA PENERIMA BEASISWA. Jurnal Ilmiah Rekayasa Dan Manajemen Sistem Informasi, 3(1), 65–69.
- [3] Aryati, A., Purnamasari, I., & Nasution, Y., 2021, Peramalan dengan Menggunakan Metode Holt-Winters Exponential Smoothing. EKSPONENSIAL, 11(1), 99-106.
- [4] Nindian Puspa Dewi, & Listiowarni, I., 2020. Implementasi Holt-Winters Exponential Smoothing untuk Peramalan Harga Bahan Pangan di Kabupaten Pamekasan. Digital Zone: Jurnal Teknologi Informasi Dan Komunikasi, 11(2), 219-231.
- [5] Sherman, R., 2014. Business intelligence guidebook : from data integration to analytics. Elsevier.
- [6] Elfajar, A., Setiawan, B., & Dewi, C., 2017. Peramalan Jumlah Kunjungan Wisatawan Kota Batu Menggunakan Metode Time Invariant Fuzzy Time Series. Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer, 1(2), 85-94.

Diaz Ridzky Anandianto, Seorang mahasiswa program studi Sistem Informasi Fakultas Teknologi Informasi Universitas Tarumanagara, Indonesia.

Wasino, memperoleh gelar S.Kom dari STMIK Budi Luhur, Indonesia tahun 1999. Kemudian tahun 2001 memperoleh gelar M.Kom dari STTI Benarif Indonesia, Indonesia. Saat ini sebagai dosen tetap program studi Sistem Informasi Fakultas Teknologi Informasi Universitas Tarumanagara, Indonesia.

Tri Sutrisno, memperoleh gelar S.Si dari Universitas Diponegoro, Indonesia tahun 2011. Kemudian tahun 2015 memperoleh gelar M.Sc dari Universitas Gadjah Mada, Indonesia. Saat ini sebagai dosen tetap program studi Sistem Informasi Fakultas Teknologi Informasi Universitas Tarumanagara, Indonesia.