

Peramalan Jumlah *Incident Information Technology* PT XYZ Menggunakan *Artificial Neural Network* (ANN)

Dini Amalia¹, Wiyli Yustanti²

^{1,2} Program Studi S1 Sistem Informasi, Fakultas Teknik, Universitas Negeri Surabaya

¹dini.20003@mhs.unesa.ac.id

²wilyliyustanti@unesa.ac.id

Abstrak— Peramalan adalah teknik untuk memprediksi peristiwa yang akan terjadi di masa depan dengan menggunakan data historis sebagai perbandingan. Dalam penelitian ini, peneliti mencoba untuk mengetahui kinerja metode ANN untuk peramalan jumlah insiden di PT XYZ dan membangun aplikasi untuk peramalan jumlah insiden di PT XYZ. Penelitian ini menggunakan metrik evaluasi *Mean Absolute Percentage Error* (MAPE) sebagai metrik evaluasi yang akan diinterpretasikan. Semakin kecil nilai MAPE, maka semakin baik arsitektur modelnya. Model terbaik adalah model yang menghasilkan nilai MAPE terkecil dan tidak mengalami kondisi *underfitting* maupun *overfitting*. Berdasarkan hasil penelitian ditemukan bahwa seluruh model terbaik dari masing-masing arsitektur model menghasilkan nilai MAPE kurang dari 10 dan tidak mengalami kondisi *underfitting* maupun *overfitting*. Oleh karena itu, dapat diinterpretasikan bahwa seluruh model yang dihasilkan tergolong sangat akurat untuk digunakan sebagai model peramalan insiden di PT XYZ untuk 4 minggu kedepan. Aplikasi peramalan jumlah insiden berbasis *website* yang dibuat untuk meramalkan jumlah insiden dengan periode 4 minggu kedepan menggunakan model terbaik yang telah disimpan sebelumnya juga menghasilkan nilai MAPE kurang dari 10 dan tidak mengalami kondisi *underfitting* dan *overfitting*.

Kata Kunci— Peramalan deret waktu, *Incident*, *Artificial Neural Network*, MAPE, *Underfitting*, *Overfitting*

I. PENDAHULUAN

Teknologi Informasi saat ini semakin maju dan sangat dimanfaatkan oleh perusahaan. Teknologi informasi dapat membantu perusahaan dalam mendapatkan, mengelola, memproses dan menyimpan data untuk menghasilkan informasi yang berkualitas, relevan, dan akurat [1]. Kunci keberhasilan dalam sebuah perusahaan atau organisasi dalam menghadapi lingkungan bisnis yang kompetitif terletak pada lingkungan yang menyeimbangkan penggunaan teknologi informasi yang efektif dan efisien untuk proses dan strategi bisnisnya [2]. Setiap organisasi harus memiliki kemampuan untuk memberikan layanan kepada pelanggan, seperti mengelola dan memahami cara memberikan layanan yang dapat menciptakan nilai bagi organisasi serta membantu menangani dan mengelola masalah arsitektur TI yang kompleks [3]. Hal tersebut diistilahkan dengan manajemen layanan TI atau *Information Technology Service Management* (ITSM) yang berfokus pada perspektif pelanggan untuk pengelolaan layanannya [4].

Kebutuhan dan penggunaan teknologi informasi pada perusahaan saat ini semakin meningkat dan sudah menjadi

bagian terpenting dalam setiap perusahaan sehingga tidak terlepas dari munculnya insiden. PT XYZ menggunakan kerangka kerja ITSM berdasarkan pada *best practice Information Technology Infrastructure Library* (ITIL) untuk mengelola layanan TI yang disediakan, salah satunya *Incident Management*. Tujuan dari manajemen insiden adalah untuk meminimalisir dampak negatif yang disebabkan oleh insiden dengan cara memulihkan layanan operasional secepat dan setepat mungkin [5]. Kemungkinan yang terjadi apabila jumlah insiden tiba-tiba meningkat dan tidak segera diselesaikan adalah performa layanan akan menurun dan melanggar *Customer Focused* [6]. Jumlah insiden yang cukup banyak akan sulit dikelola meskipun telah ditangani dengan baik. Oleh karena itu, tindakan mengurangi atau mencegah jumlah insiden merupakan hal yang penting bagi sebuah organisasi [4].

Pengambilan keputusan oleh pengelola insiden dapat dibantu dengan meramalkan jumlah insiden di masa yang akan datang. Peramalan adalah teknik untuk memprediksi peristiwa yang akan terjadi di masa depan dengan menggunakan data historis sebagai perbandingan. Ketika melakukan peramalan diperlukan perhitungan yang akurat sehingga dibutuhkan metode peramalan yang tepat [7]. Terdapat banyak metode yang dapat diterapkan ketika melakukan peramalan, salah satunya Jaringan Syaraf Tiruan (JST) atau *Artificial Neural Network* (ANN). Metode ANN merupakan sistem untuk memproses informasi yang memiliki karakter kinerja tertentu seperti jaringan saraf manusia (Wiranata dkk., 2020). Metode ini dapat digunakan untuk data deret waktu (*time series*) *non-linear* yang tidak dapat diatasi oleh metode statistik [8]. Salah satu teknik untuk melakukan peramalan adalah *Machine Learning* (ML). Metode ANN dapat dikembangkan dengan teknik ini untuk mendapatkan solusi peramalan. Penggunaan metode ANN dengan ML sangat banyak digunakan karena dapat digunakan untuk menyelesaikan masalah yang cukup kompleks, seperti untuk menganalisis gambar atau objek serta untuk menganalisis data deret waktu [9].

Penelitian dengan studi kasus serupa oleh [6] terkait peramalan insiden IT di sebuah perusahaan masih ditemukan satu penelitian, yaitu peramalan jumlah insiden IT di PT Pertamina (Persero) menggunakan metode statistik seperti *Single Moving Average*, *Double Moving Average*, dan *Single Exponential Smoothing*. Dari ketiga metode yang digunakan *Double Moving Average* menjadi metode terbaik karena memiliki nilai MAPE terkecil yaitu sebesar 13,5% dengan nilai

akurasi sebesar 86.5% untuk tipe insiden “Non-ERP Application Maintenance Services”.

Saat ini PT XYZ hanya menganalisa data historis insiden TI secara sederhana sehingga belum menganalisa lebih lanjut, oleh karena itu penelitian ini akan melakukan peramalan jumlah insiden TI di PT XYZ dengan menggunakan metode ANN berdasarkan data historis jumlah insiden untuk *service* yang selalu mendominasi yaitu sebanyak 5 *Incident Service* dalam 5 tahun terakhir periode mingguan dengan harapan dapat mengidentifikasi pola atau tren yang dapat memberikan wawasan mendalam tentang permasalahan yang paling sering terjadi. Kinerja metode ANN diharapkan meningkat dan menghasilkan data peramalan yang akurat. Hasil peramalan jumlah insiden nantinya akan dianalisis lebih lanjut oleh pengelola insiden untuk diantisipasi penanganannya supaya insiden yang terjadi lebih cepat terselesaikan dan jumlah aktualnya juga akan lebih sedikit dari jumlah peramalannya sehingga memungkinkan jumlah insiden di periode berikutnya juga berkurang.

II. METODOLOGI PENELITIAN

Tahapan dari seluruh proses pada penelitian ini menggunakan kerangka kerja *Cross Industry Standard Process for Data Mining* (CRISP-DM). Penerapan kerangka kerja ini menggunakan bahasa pemrograman *Python* dengan bantuan aplikasi *Visual Studio Code* dengan ekstensi *Jupyter Notebook*, sebagai *code editor* untuk mengolah data. Adapun tahapan proses CRISP-DM yang dijabarkan oleh [10] dan [11] adalah sebagai berikut:



Gbr 1. Tahapan Siklus CRISP-DM

A. Business Understanding

Business Understanding merupakan tahap pertama dalam CRISP-DM. Kegiatan dilakukan pada tahapan ini adalah memahami situasi bisnis, menentukan tujuan bisnis, dan menentukan tujuan dilakukannya *data mining*. Tujuan dari memahami situasi bisnis adalah untuk mendapatkan gambaran terkait sumber daya yang tersedia dan diperlukan.

B. Data Understanding

Pada tahap *Data Understanding*, kegiatan yang dilakukan adalah melakukan pengumpulan data awal kemudian mempelajari dan mengumpulkan data, mendeskripsikan data,

dan melakukan verifikasi terhadap kualitas data. Deskripsi data bisa dilakukan menggunakan analisis statistik.

C. Data Preparation

Apabila kualitas data sudah baik dan bisa diolah, selanjutnya menentukan teknik *data mining* yang akan digunakan. Berikut adalah tahapan *Data Preparation* pada penelitian ini.

- Imputasi *missing value* dan *outlier*
- Menyiapkan data untuk pemodelan
- Memisahkan data menjadi data *train* dan data *test*

D. Modelling

Apabila kualitas data sudah baik dan bisa diolah, selanjutnya menentukan teknik *data mining* yang akan digunakan. Pemilihan teknik *data mining* tergantung pada masalah bisnis dan data yang akan diolah. Tahap *Modelling* pada penelitian ini menggunakan metode *Artificial Neural Network* (ANN). ANN merupakan sistem untuk memproses informasi yang memiliki karakter kinerja tertentu seperti jaringan saraf manusia [12]. Model matematis akan meniru struktur saraf untuk belajar dan memperoleh pengetahuan berdasarkan pengalaman. Teknologi ini membantu mengefektifkan penyelesaian masalah yang dinamis dan *non-linear* seperti pengenalan pola dan prediksi [13]. ANN merupakan salah satu algoritma dalam *Machine Learning* (ML). ML sendiri merupakan ilmu yang memberi kemampuan terhadap komputer untuk belajar tanpa diprogram secara eksplisit. Definisi lain dari ML adalah kombinasi antara algoritma komputer dengan metode statistik untuk belajar dalam menemukan pola tersembunyi dari kumpulan data yang banyak [14].

E. Evaluation

Pada tahap evaluasi, hasil dari *data mining* yang dihasilkan akan diinterpretasikan dengan tujuan mendapatkan model yang sesuai dan tindakan-tindakan lebih lanjut juga harus ditentukan. Tahap *evaluation* dimulai dengan mendefinisikan fungsi-fungsi baru untuk mendapatkan model terbaik untuk disimpan sebagai model peramalan di periode selanjutnya.

F. Deployment

Pada tahap *Deployment* atau penerapan dilakukan penyusunan laporan tentang pengetahuan yang diperoleh pada tahap evaluasi atau juga dapat berupa komponen perangkat lunak. Tahap terakhir dari CRISP-DM ini terdiri dari perencanaan, pemantauan, dan pemeliharaan. Pada tahap ini menggunakan *Streamlit* sebagai kerangka kerja penyusunan aplikasi peramalan tiket insiden berbasis *website*.

III. HASIL DAN PEMBAHASAN

Pada bagian ini akan membahas tentang hasil dari setiap tahapan CRISP-DM pada penelitian ini, dimulai dari tahap *Business Understanding* yang membahas tujuan bisnis hingga

tahap *Deployment* yang menghasilkan sebuah *website* peramalan tiket insiden.

A. Business Understanding

Penelitian ini memahami situasi bisnis pada PT XYZ terkait pelaporan insiden teknologi informasi yang terjadi di PT XYZ seperti gangguan pada perangkat yang sedang digunakan, koneksi jaringan, keamanan teknologi informasi, dan lain-lain. Setelah memahami situasi bisnisnya akan menentukan tujuan bisnisnya, yaitu untuk mengetahui perkembangan jumlah insiden di masa yang akan datang menggunakan teknik peramalan deret waktu.

B. Data Understanding

Data yang digunakan pada penelitian ini adalah data historis yang berisi jumlah insiden dari 5 *incident service* terbanyak dalam periode mingguan dari Januari 2019 hingga Desember 2023, yaitu *Desktop Services*, *Domain Services*, *Oracle Services*, *Email Services*, dan *IAAS Services*. Data tersebut termasuk pada data deret waktu yang berkategori *Univariate* sehingga akan dilakukan peramalan secara satu-persatu sesuai dengan masing-masing data. Dataset yang digunakan terdiri dari kolom “WEEK” yang merupakan urutan periode mingguan 5 tahun terakhir dan kolom “TOTAL” yang merupakan jumlah insiden di setiap periode. Dataset yang digunakan untuk peramalan deret waktu pada penelitian ini dapat dilihat di Tabel I. Deskripsi data lainnya untuk masing-masing frekuensi data berdasarkan analisis deskripsi statistik dapat dilihat pada Tabel II.

TABEL I
DATASET INSIDEN MINGGUAN Masing-masing LAYANAN

WEEK	desktop	domain	oracle	email	iaas
1	89	26	54	41	14
2	129	80	85	54	45
3	208	62	80	112	31
4	190	47	70	96	36
5	228	84	78	72	20
⋮	⋮	⋮	⋮	⋮	⋮
257	136	111	20	23	19
258	232	97	14	29	13
259	140	112	20	27	6
260	107	72	21	15	8
261	80	40	10	10	2

TABEL II
DESKRIPSI STATISTIK Masing-masing DATASET AWAL

Variabel	desktop	domain	oracle	email	iaas
Count	261	261	261	261	261
Mean	120	65	51	48	17
Min	0	0	0	0	0
25%	92	44	31	28	10
50%	123	59	51	42	16
75%	153	85	69	58	24
Max	263	183	172	1024	59
Std	50.7	36.7	29	65	10.5
Var	2570	1351	814	4279	110

Tabel II menunjukkan kolom *Count* menunjukkan banyaknya data atau jumlah baris pada data, kolom *Mean* menunjukkan nilai rata-rata dari jumlah insiden secara keseluruhan, kolom *Std* menunjukkan bahwa nilai Standar Deviasi relatif tinggi maka data tersebut memiliki keragaman yang signifikan, kolom *Min* menunjukkan nilai minimal dari jumlah insiden, kolom 25%, 50%, dan 75% menunjukkan data kuartil data, dan kolom *Max* menunjukkan nilai maksimal dari jumlah insiden.

Setelah semua kebutuhan data terkumpul, kualitas dari masing-masing data akan dilakukan pengecekan untuk mengetahui *missing value* atau *outlier* pada data. Didapatkan masing-masing data merupakan data yang *non-linear* serta memiliki *missing value* dan *outlier* sehingga harus dibersihkan terlebih dahulu untuk memperbaiki kualitas datanya supaya mengoptimalkan model yang akan dibangun.

C. Data Preparation

1. Imputasi Missing Value dan Outlier

Data yang terdeteksi sebagai *missing value* dan *outlier* akan dibersihkan menggunakan imputasi nilai median masing-masing dataset. Dikarenakan jumlah *missing value* dan *outlier* masing-masing dataset cukup banyak, maka hasil data yang telah diimputasi akan memiliki banyak nilai yang kembar sehingga mempersulit pencarian model terbaiknya. Setelah melakukan imputasi nilai median menggunakan kode diatas, dapat diketahui statistik untuk masing-masing data yang telah diimputasi menggunakan nilai median pada Tabel III.

TABEL III
DESKRIPSI STATISTIK DATA SETELAH IMPUTASI

Variabel	desktop	domain	oracle	email	iaas
Count	261	261	261	261	261
Mean	121.6	63.7	50.3	43.6	17.6
Min	1	1	3	7	1
25%	99	48	37	32	12
50%	123	59	51	42	16
75%	148	77	65	55	23
Max	196	136	96	84	37
Std	36.5	24.9	21.6	16.5	8
Var	1332	619.6	464.9	271	65.7

2. Menyiapkan Data untuk Pemodelan

Data-data yang sudah bersih akan digunakan untuk pemodelan. Namun sebelum masuk ke tahap pemodelan, data-data tersebut harus diproses lebih lanjut agar bisa dimasukkan ke dalam model. Dimulai dari mengubah kolom “WEEK” menjadi indeks data kemudian mengkonversi tipe data *pandas series* pada kolom “TOTAL” menjadi *numpy array* dan memasukkan data tersebut ke dalam *dataframe* baru.

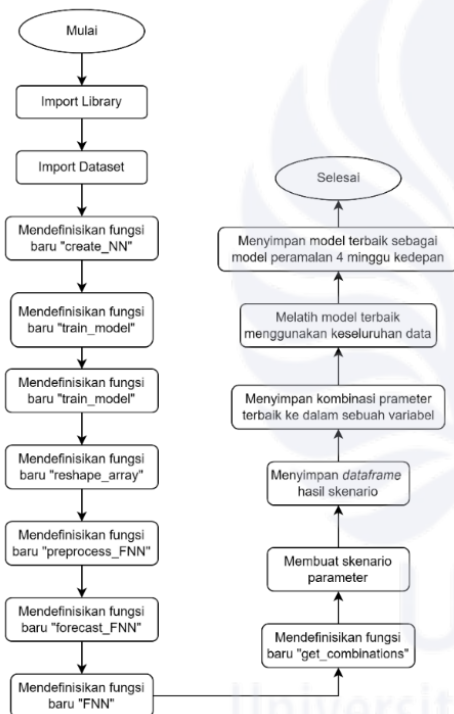
3. Memisahkan data menjadi data train dan data test

Data yang akan digunakan untuk pemodelan dilakukan pemisahan data terlebih dahulu menjadi data *train* dan data *test*. *Split* data untuk data deret waktu harus dipastikanurut, maka data *train* akan dimulai dari indeks ke-0 hingga indeks ke-234,

sedangkan data *test* akan dimulai dari indeks ke-235 hingga indeks ke-261. Rasio perbandingan pemisahan data yang digunakan adalah 90% untuk data *train* dan 10% untuk data *test*, karena setelah dilakukan percobaan persentase pemisahan tersebut menghasilkan model yang lebih baik daripada persentase pemisahan data 80% dan 20%. Maka 90% dari 261 data adalah 235 data dan 10% nya adalah 26 data.

D. Modelling

Tahap ini akan menghasilkan fungsi-fungsi baru yang digunakan untuk proses pencarian arsitektur model terbaik, dimulai dari membuat fungsi untuk menyusun skenario arsitektur model, melatih model, menyimpan model terbaik untuk dijadikan sebagai model peramalan periode 4 minggu kedepan. Kebutuhan pengolahan data sebagai data *input* dan arsitektur model ANN yang digunakan untuk masing-masing model tidak selalu sama tergantung kondisi datanya dan hasil performa modelnya. Urutan pengkodean penyusunan fungsi-fungsi yang diperlukan untuk membuat model dapat dilihat pada Gbr 2.



Gbr 2. Flowchart Pengkodean Tahap Modelling

Pada penelitian ini, penyusunan arsitektur model dilakukan secara *trial error*. Meskipun menggunakan fungsi iterator untuk mengkombinasikan parameter, model yang dihasilkan tidak selalu optimal sehingga masih membutuhkan penyesuaian parameter secara manual. Setelah mendapatkan model terbaik, model tersebut akan disimpan untuk dijadikan model peramalan periode 4 minggu kedepan. Sebelum itu, diperlukan fungsi “*iteratools.product()*” yang didefinisikan di dalam fungsi “*get_combinations*” untuk mengefisienkan waktu pencarian parameter terbaik. Rancangan parameter-parameter yang sudah ditentukan akan secara otomatis mengkombinasikan parameter menggunakan fungsi tersebut.

Adapun penjabaran rancangan parameter masing-masing model yang akan dikombinasikan menggunakan fungsi “*get_combinations*” untuk mencari parameter terbaik akan ditampilkan pada Tabel IV. Nilai masing-masing parameter pada Tabel IV adalah parameter-parameter yang telah disesuaikan secara *trial error* dan menghasilkan beberapa skenario dengan arsitektur terbaik yang memiliki nilai *error* yang kecil.

TABEL IV.
RANCANGAN KOMBINASI PARAMETER MODEL

Parameter	Nilai				
	desktop	domain	oracle	email	iaas
input nodes	100, 180, 192	48, 70, 96	36, 48, 96	150, 170, 190	69, 100
hidden nodes	100, 150, 160	36, 48	24, 36	100, 150	50, 90
output nodes	1	1	1	1	1
activation	relu	relu	relu, sigmoid	relu	relu
learning rate (lr)	0.1, 0.01	0.1, 0.01	0.001	0.1, 0.01	0.1, 0.01
epochs	100, 500	100, 500	100, 500	100, 1000	150, 200, 300
batch sizes	None	None	None	5, 20	5, 20

Hasil kebutuhan pengolahan data dan kombinasi parameter terbaik dapat dilihat pada Tabel V. Tabel tersebut berisi nilai parameter-parameter terbaik yang dicari menggunakan rancangan parameter pada Tabel IV. Penjabaran nilai *error* terkecil yang dihasilkan oleh masing-masing model dapat dilihat pada hasil tahap *Evaluation*. Tabel V menunjukkan kebutuhan pengolahan data beserta parameter-parameter terbaik yang akan digunakan untuk meramalkan nilai masing-masing *incident services* 4 minggu kedepan.

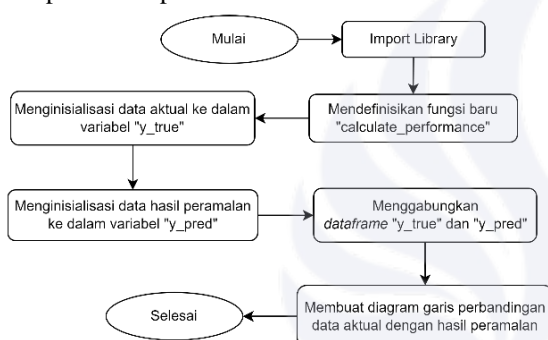
TABEL V.
KOMBINASI PARAMETER TERBAIK

Parameter	desktop	domain	oracle	email	iaas
Scaling Data	✓	✓	✓	✓	✓
Inverse Input	-	✓	✓	✓	-
input nodes	180	96	96	150	100
hidden nodes	100	48	24	100	50
output nodes	1	1	1	1	1
activation	relu	relu	relu	relu	relu
learning rate (lr)	0.01	0.1	0.001	0.1	0.1
epochs	500	500	100	1000	300

batch sizes	None	None	None	5	5
-------------	------	------	------	---	---

E. Evaluation

Arsitektur ANN terbaik merupakan model yang memiliki nilai *error* terkecil dari seluruh arsitektur model yang sudah tersusun. Metrik evaluasi yang digunakan untuk menginterpretasikan hasil pemodelan adalah *Mean Absolute Percentage Error* (MAPE). Model terbaik didapatkan dari skenario model yang nilai MAPEnya kecil serta tidak mengalami *underfitting* dan *overfitting*. Kondisi model *Underfitting* adalah model yang memiliki kondisi dengan ciri-ciri *False/error* yang berlebihan dan nilai akurasi rendah. Sedangkan kondisi *Overfitting* merupakan kondisi model yang terjadi ketika hasil peramalannya terlalu baik yang artinya model tersebut tidak benar-benar mempelajari pola data dengan baik (Firmansyach dkk., 2023). Adapun urutan pengkodean penyusunan fungsi-fungsi yang diperlukan untuk mengevaluasi model dapat dilihat pada Gbr 3.

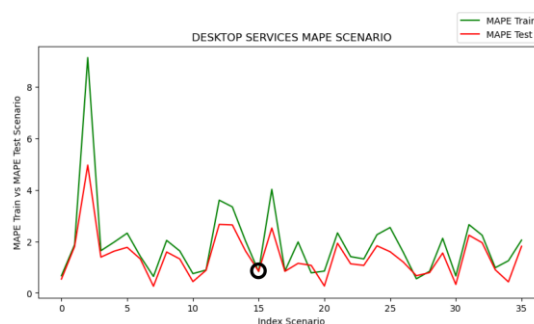


Gbr 3. Flowchart Pengkodean Tahap Evaluation

Berikut adalah hasil evaluasi pada masing-masing model yang sudah dievaluasi menggunakan nilai MAPE yang tidak mengalami *underfitting* dan *overfitting*.

1. Hasil Evaluasi Desktop Services


Pencarian kombinasi parameter terbaik pada pemodelan *desktop services* menghasilkan 36 kombinasi parameter dan model terbaik terdapat pada skenario ke-16, yaitu menghasilkan nilai MAPE data *train* sebesar 0.83 dan nilai MAPE data *test* sebesar 0.84 yang diinterpretasikan sebagai model yang tidak mengalami kondisi *underfitting* ataupun *overfitting* karena memiliki selisih yang kecil. Pemodelan data *desktop services* dengan nilai metrik evaluasi yang kecil dapat diinterpretasikan bahwa model tersebut sangat akurat untuk digunakan sebagai model untuk peramalan tiket insiden. Visualisasi nilai MAPE dari hasil pemodelan data *train* dan *test* untuk data *desktop services* dapat dilihat pada Gbr 4.



Gbr 4. Diagram Garis MAPE Train dan MAPE Test Desktop Services

2. Hasil Evaluasi Domain Services


Pencarian kombinasi parameter terbaik pada pemodelan *domain services* menghasilkan 24 kombinasi parameter dan model terbaik terdapat pada skenario ke-22, yaitu menghasilkan nilai MAPE data *train* sebesar 1.09 dan nilai MAPE data *test* sebesar 1.09 yang diinterpretasikan sebagai model yang tidak mengalami kondisi *underfitting* ataupun *overfitting* karena memiliki selisih yang kecil. Pemodelan data *domain services* dengan nilai metrik evaluasi yang kecil dapat diinterpretasikan bahwa model tersebut sangat akurat untuk digunakan sebagai model untuk peramalan tiket insiden. Visualisasi nilai MAPE dari hasil pemodelan data *train* dan *test* untuk data *domain services* dapat dilihat pada Gbr 5.




Gbr 5. Diagram Garis MAPE Train dan MAPE Test Domain Services

3. Hasil Evaluasi Oracle Services

Pencarian kombinasi parameter terbaik pada pemodelan *oracle services* menghasilkan 24 kombinasi parameter dan model terbaik terdapat pada skenario ke-17, yaitu menghasilkan nilai MAPE data *train* sebesar 1.48 dan nilai MAPE data *test* sebesar 1.47 yang diinterpretasikan sebagai model yang tidak mengalami kondisi *underfitting* ataupun *overfitting* karena memiliki selisih yang kecil. Pemodelan data *oracle services* dengan nilai metrik evaluasi yang kecil dapat diinterpretasikan bahwa model tersebut sangat akurat untuk digunakan sebagai model untuk peramalan tiket insiden. Visualisasi nilai MAPE dari hasil pemodelan data *train* dan *test* untuk data *oracle services* dapat dilihat pada Gbr 6.



Gbr 6. Diagram Garis MAPE Train dan MAPE Test Oracle Services




Gbr 8. Diagram Garis MAPE Train dan MAPE Test IAAS Services

4. Hasil Evaluasi Email Services

Pencarian kombinasi parameter terbaik pada pemodelan *email services* menghasilkan 48 kombinasi parameter dan model terbaik terdapat pada skenario ke-3, yaitu menghasilkan nilai MAPE data *train* sebesar 0.59 dan nilai MAPE data *test* sebesar 0.6 yang diinterpretasikan sebagai model yang tidak mengalami kondisi *underfitting* ataupun *overfitting* karena memiliki selisih yang kecil. Pemodelan data *email services* dengan nilai metrik evaluasi yang kecil dapat diinterpretasikan bahwa model tersebut sangat akurat untuk digunakan sebagai model untuk peramalan tiket insiden. Visualisasi nilai MAPE dari hasil pemodelan data *train* dan *test* untuk data *email services* dapat dilihat pada Gbr 7.

```
streamlit run C:\ANN\web.py
```

Kode 1. Perintah Menjalankan Aplikasi di CMD



Gbr 7. Diagram Garis MAPE Train dan MAPE Test Email Services

5. Hasil Evaluasi IAAS Services

Pencarian kombinasi parameter terbaik pada pemodelan *IAAS services* menghasilkan 48 kombinasi parameter dan model terbaik terdapat pada skenario ke-29, yaitu menghasilkan nilai MAPE data *train* sebesar 1.81 dan nilai MAPE data *test* sebesar 1.91 yang diinterpretasikan sebagai model yang tidak mengalami kondisi *underfitting* ataupun *overfitting* karena memiliki selisih yang kecil. Pemodelan data *IAAS services* dengan nilai metrik evaluasi yang kecil dapat diinterpretasikan bahwa model tersebut sangat akurat untuk digunakan sebagai model untuk peramalan tiket insiden. Visualisasi nilai MAPE dari hasil pemodelan data *train* dan *test* untuk data *IAAS services* dapat dilihat pada Gbr 8.

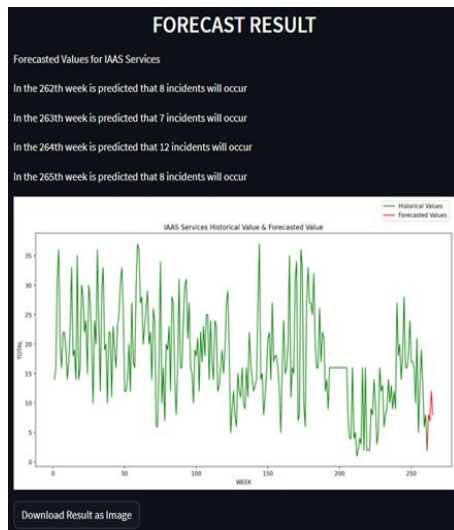
F. Deployment

Pada tahap ini sistem akan dibangun menggunakan bahasa pemrograman *Python*, *framework streamlit* sebagai kerangka kerja antarmuka dan alat untuk membangun aplikasi berbasis *website*, dan fungsi “load_model” dari *library* “*tensorflow.keras.models*” untuk memuat model yang telah disimpan pada tahap *modelling*. Aplikasi yang telah dibuat masih berada di *localhost*, untuk menampilkan hasil aplikasi perlu menjalankan perintah yang diketikkan di *Command Prompt* (CMD) terlebih dahulu dengan perintah seperti pada Kode 1. Kemudian *streamlit* akan mengarahkan tampilan perangkat ke *browser* yang sedang kita gunakan secara otomatis dan akan muncul tampilan seperti Gbr 9.



Gbr 9. Tampilan Website Peramalan Tiket Insiden

Gambar 49 merupakan tampilan *website* yang akan muncul di *browser* pengguna. *Website* ini hanya terdiri dari 4 fitur saja, yaitu *dropdown* pilihan *incident services* yang berisi 5 pilihan, *dropdown* pilihan jumlah periode peramalan mingguan yang berisi angka jumlah periode 1 hingga 4 minggu kedepan, tombol “Forecast” untuk menampilkan hasil peramalan sesuai pilihan pengguna, dan tombol “Download Result as Image” untuk mengunduh hasil peramalan berupa gambar. Tombol “Download Result as Image” hanya akan muncul ketika pengguna telah mengklik tombol “Forecast”. Setelah pengguna mengklik tombol “Forecast”, *website* akan menampilkan hasil seperti yang dapat dilihat pada Gbr 10.



Gbr 10. Tampilan Website Setelah Mengklik Tombol "Forecast"

Alur penggunaan *website* ini adalah membuka *website* peramalan jumlah tiket insiden, kemudian pilih *incident services* dan jumlah periode mingguan yang ingin diramalkan. Setelah memilih kedua pilihan tersebut, sistem menampilkan teks validasi pilihan yang kemudian dicek oleh pengguna. Apabila pilihannya sudah sesuai, pengguna dapat mengklik tombol "Forecast" untuk sistem menampilkan hasil peramalan dan tombol "Download as Image" untuk mengunduh hasil peramalan berupa gambar. Pengguna dapat mengunduh hasil peramalan jika membutuhkan. Hasil peramalan jumlah tiket insiden berbasis *website* dari masing-masing *incident services* untuk 4 minggu kedepan beserta penjabaran perbandingan nilai aktual dengan peramalannya dan perolehan nilai MAPE dapat dilihat pada Tabel VI.

TABEL VI.

PERBANDINGAN DATA AKTUAL VS DATA PERAMALAN DESKTOP SERVICES 4 MINGGU KEDEPAN

<i>Incident Services</i>	<i>WEEK</i>	<i>Actual</i>	<i>Forecasted</i>	<i>MAPE</i>
<i>Desktop Services</i>	262	68	53	0.34
	263	71	36	
	264	47	28	
	265	54	41	
<i>Domain Services</i>	262	112	44	0.52
	263	99	44	
	264	114	50	
	265	83	52	
<i>Oracle Services</i>	262	20	7	0.51
	263	15	5	
	264	14	9	
	265	13	8	
<i>Email Services</i>	262	21	10	0.67
	263	22	7	
	264	21	7	
	265	17	3	

<i>Incident Services</i>	<i>WEEK</i>	<i>Actual</i>	<i>Forecasted</i>	<i>MAPE</i>
<i>IAAS Services</i>	262	5	8	0.31
	263	9	7	
	264	17	12	
	265	9	8	

IV. KESIMPULAN

Berdasarkan hasil penelitian peramalan jumlah *incident Information Technology* PT XYZ menggunakan *Artificial Neural Network* (ANN), maka dapat ditarik kesimpulan sebagai berikut:

1. Model terbaik dari masing-masing pemodelan data yang sudah dibersihkan menghasilkan nilai MAPE yang sangat akurat untuk digunakan sebagai model peramalan data 4 minggu kedepan. Model terbaik di antara beberapa skenario kombinasi parameter didapatkan dari nilai MAPE *train* dan *test* yang tidak mengalami *underfitting* maupun *overfitting*. Model terbaik *desktop services* menghasilkan nilai MAPE *train* sebesar 0.83 dan MAPE *test* sebesar 0.84. Model terbaik *domainservices* menghasilkan nilai MAPE *train* sebesar 1.09 dan MAPE *test* sebesar 1.09. Model terbaik *oracle services* menghasilkan nilai MAPE *train* sebesar 1.48 dan MAPE *test* sebesar 1.47. Model terbaik *email services* menghasilkan nilai MAPE *train* sebesar 0.59 dan MAPE *test* sebesar 0.6. Model terbaik *IAAS services* menghasilkan nilai MAPE *train* sebesar 1.81 dan MAPE *test* sebesar 1.91.
2. Aplikasi peramalan jumlah tiket insiden berbasis *website* yang dibuat sangat mudah dipahami karena hanya memilih salah satu jenis peramalan dengan jumlah periode yang ingin diramalkan kemudian mengklik tombol "Forecast", maka hasil peramalan akan tampil secara otomatis dan dapat diunduh menggunakan tombol "Download Result as Image" apabila pengguna membutuhkannya. Hasil peramalan untuk periode 4 minggu kedepan menghasilkan nilai MAPE *desktop services* sebesar 0.34, nilai MAPE *domain services* sebesar 0.52 nilai MAPE *oracle services* sebesar 0.51, nilai MAPE *email services* sebesar 0.67, dan nilai MAPE *IAAS services* sebesar 0.31.

V. SARAN

Berdasarkan hasil penelitian ini, pencarian model terbaik masih belum optimal dan efisien karena masih melakukan penyesuaian untuk pencarian kombinasi parameter terbaik secara manual. Oleh karena itu, saran yang diajukan penulis adalah sebagai berikut.

1. Menggunakan metode optimasi *hyperparameter* untuk mendapatkan model yang lebih optimal.
2. Menggunakan lebih banyak data untuk pelatihan model yang lebih baik.
3. Melakukan uji stasioner supaya data yang digunakan sebagai *input* dapat dilatih dengan baik dan menghasilkan model yang lebih optimal.

REFERENSI

- [1] Satria, W. (2020). Jaringan Syaraf Tiruan Backpropagation untuk Peramalan Penjualan Produk (Studi Kasus di Metro Electronic dan Furniture). *Djtechno : Journal of Information Technology Research*, 1(1).
- [2] Uddin, B. (2019). Evaluasi Penerapan Manajemen Layanan TI Menggunakan Kerangka Kerja IT Infrastructure Library (ITIL) Sub Domain Service Desk, Incident Management, dan Problem Management. *Jurnal TEDC*, 8(2).
- [3] Imron, A., Cholil, W., & Atika, L. (2020). Perancangan Helpdesk Sistem Model Berbasis Itil Versi 3 Domain Problem Management Dan Incident Management. *Jurnal Ilmiah Informatika Global*, 11(1).
- [4] Swain, A. K., & Garza, V. R. (2023). Key Factors in Achieving Service Level Agreements (SLA) for Information Technology (IT) Incident Resolution. *Information Systems Frontiers*, 25(2), 819–834. <https://doi.org/10.1007/s10796-022-10266-5>
- [5] Jouravlev, R., Anand, A., Orbezo, J. C., Casteel, E., Corona, M., DuMoulin, T., Hearsom, P., Hunnebeck, L., Leach, M., Rae, B., Rance, S., & Yagi, T. (2019). *ITIL @ Foundation ITIL 4 Edition 2*. TSO (The Stationery Office). <https://www.axelos.com>
- [6] Febrian, F., & Salim, R. (2022). Implementation of Incident Forecasting Using Moving Average and Exponential Smoothing Methods at Shared Services ICT PT Pertamina (Persero). *International Research Journal of Advanced Engineering and Science*, 7(1), 162–169.
- [7] Hasan, N. F., Kusri, K., & Fatta, H. Al. (2019). Peramalan Jumlah Penjualan Menggunakan Jaringan Syaraf Tiruan Backpropagation Pada Perusahaan Air Minum Dalam Kemasan. *Jurnal Teknik Informatika dan Sistem Informasi*, 5(2). <https://doi.org/10.28932/jutisi.v5i2.1607>
- [8] Abraham, E. R., Dos Reis, J. G. M., Vendrametto, O., Neto, P. L. de O. C., Toloi, R. C., de Souza, A. E., & Morais, M. de O. (2020). Time Series Prediction with Artificial Neural Networks: An Analysis Using Brazilian Soybean Production. *Agriculture (Switzerland)*, 10(10), 1–18. <https://doi.org/10.3390/agriculture10100475>
- [9] Masini, R. P., Medeiros, M. C., & Mendes, E. F. (2021). *Machine Learning Advances for Time Series Forecasting*. <http://arxiv.org/abs/2012.12802>
- [10] Wiranata, I. K. R., Gandhiadi, G. K., & Harini, L. P. I. (2020). Peramalan Kunjungan Wisatawan Mancanegara ke Provinsi Bali Menggunakan Metode Artificial Neural Network. *E-Jurnal Matematika*, 9(4), 213. <https://doi.org/10.24843/mtk.2020.v09.i04.p301>
- [11] Hayadi, B. H., Sudipa, I. G. I., & Windarto, A. P. (2021). Model Peramalan Artificial Neural Network pada Peserta KB Aktif Jalur Pemerintahan menggunakan Artificial Neural Network Back-Propagation. *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 21(1), 11–20. <https://doi.org/10.30812/matrik.v21i1.1273>
- [12] Wanto, A., Defit, S., & Perdana Windarto, A. (2021). Algoritma Fungsi Pelatihan pada Machine Learning berbasis ANN untuk Peramalan Fenomena Bencana. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(2), 254–264. <https://doi.org/10.29207/resti.v5i2.3031>
- [13] Khumaidi, A. (2020). Data Mining for Predicting the Amount of Coffee Production Using CRISP-DM Method. *Techno Nusa Mandiri : Journal of Computing and Information Technology As an Accredited Journal Rank*, 17(1). www.unkris.ac.id
- [14] Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- [15] Firmansyach, W. A., Hayati, U., & Wijaya, Y. A. (2023). Analisa Terjadinya Overfitting dan Underfitting pada Algoritma Naive Bayes dan Decision Tree dengan Teknik Cross Validation. *Jurnal Mahasiswa Teknik Informatika*, 7(1), 262–269.