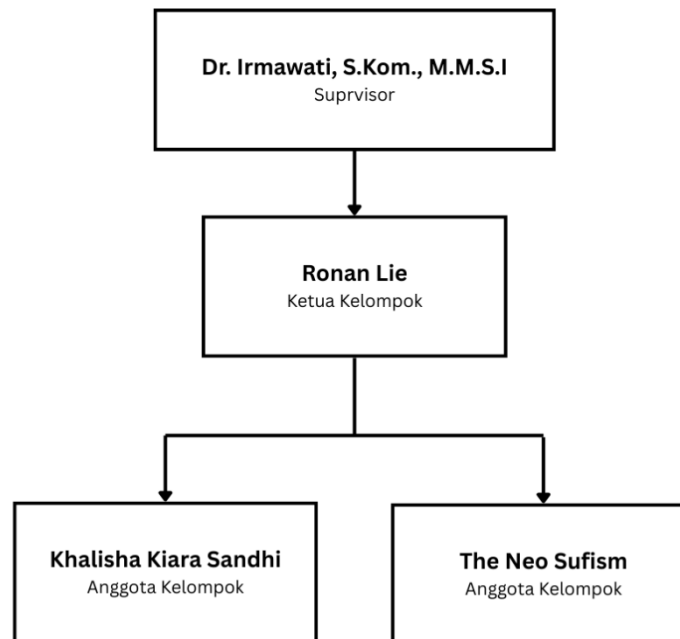


BAB III

PELAKSANAAN PRO-STEP : ROAD TO CHAMPION

3.1 Kedudukan dan Koordinasi

Kelompok *Road To Champion* terdiri atas tiga anggota, yaitu Khalisha Kiara Sandhi, The Neo Sufism, dan Ronan Lie sebagai ketua kelompok dalam pelaksanaan Lomba Karya Tulis Ilmiah (LKTIN 2025). Kelompok ini dibimbing oleh dosen internal Universitas Multimedia Nusantara yaitu Ibu Dr. Irmawati, S.Kom., M.M.S.I., sebagai *supervisor* lomba. Gambar 3.1 menggambarkan alur koordinasi antara dosen pembimbing lapangan dan tiga anggota kelompok *Road To Champion*.

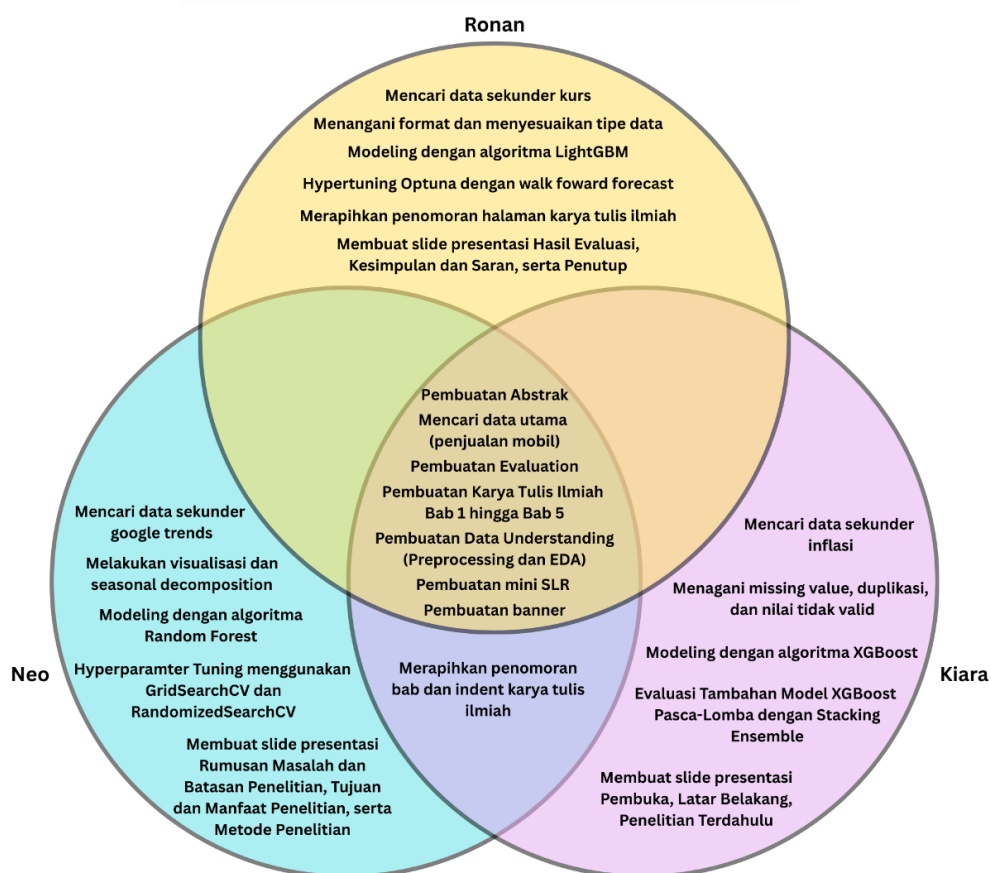


Gambar 3.1 Bagan Alur Koordinasi

Dalam pelaksanaan program *Road To Champion*, koordinasi dilakukan secara langsung antara semua anggota dengan *supervisor* melalui pertemuan mingguan di Lab Big Data UMN setiap hari Senin. Selain itu, jika diperlukan, koordinasi tambahan juga dapat dilakukan secara *online* menggunakan WhatsApp maupun Zoom. Bagan alur pada Gambar 3.1 menunjukkan bahwa dosen pembimbing lapangan (*supervisor*) memiliki wewenang untuk memberi arahan dan tugas kepada anggota kelompok, sedangkan setiap anggota memiliki kewajiban untuk menerima

arahan dari dosen pembimbing lapangan (*supervisor*), sekaligus melaksanakan tugas yang diberikan. Ketika pengerjaan tugas sudah ada kemajuan atau telah selesai, setiap anggota dapat melaporkan progres dari tugas yang sedang dikerjakan maupun yang sudah selesai ke dosen pembimbing lapangan (*supervisor*) pada sesi koordinasi berikutnya.

Salah satu tugas yang diberikan oleh dosen pembimbing lapangan (*supervisor*) adalah pembagian pengerjaan algoritma yang digunakan untuk pelaksanaan penelitian dan lomba, sehingga setiap anggota memiliki tanggung jawab atas algoritma masing-masing, yaitu XGBoost (tanggung jawab anggota Khalisha Kiara Sandhi), Random Forest (tanggung jawab anggota The Neo Sufism), dan LightGBM (tanggung jawab anggota Ronan Lie). Selain itu, terdapat beberapa pembagian tugas yang dilakukan secara individu maupun bersama dengan anggota lainnya, seperti pengolahan data, pembuatan *slide* presentasi, dan pembuatan laporan. Gambar 3.2 menunjukkan pembagian peran dalam pelaksanaan program *Road To Champion*.



Gambar 3.2 Pembagian Peran dalam Pelaksanaan Program *Road To Champion*

Sebagai bagian dari tanggung jawab tersebut, semua anggota mengikuti seluruh tahapan CRISP-DM dengan benar, mulai dari pemahaman bisnis, pemahaman data, persiapan data, pemodelan, hingga evaluasi performa model. Hasil analisis dibahas terlebih dahulu dalam kelompok untuk saling berdiskusi dan berbagi *insight* untuk memastikan hasil analisis dapat digabungkan secara konsisten sebelum ditunjukkan ke dosen pembimbing lapangan (*supervisor*) pada pertemuan mingguan untuk mendapatkan masukan dan arahan. Dalam pertemuan mingguan, setiap anggota dapat melaporkan progres pekerjaan, kendala, dan hasil eksperimen yang telah dilakukan, sedangkan dosen pembimbing lapangan (*supervisor*) dapat memberikan arahan, saran perbaikan, konfirmasi kesesuaian karya, serta pendampingan dalam latihan presentasi.

Setelah lomba selesai dilaksanakan, setiap anggota yang bertanggung jawab atas algoritma yang dipegang masing-masing melakukan optimasi untuk meningkatkan akurasi tiap model yang dipegang tersebut. Gambar 3.2 menunjukkan pembagian peran antar anggota kelompok dalam pelaksanaan program *Road To Champion*. Dapat dilihat dari gambar 3.2 bahwa optimasi yang dilakukan tiap anggota kelompok adalah pelaksanaan evaluasi tambahan pasca-lomba dengan menggunakan metode *ensemble stacking* untuk algoritma XGBoost, pelaksanaan *hyperparameter tuning* menggunakan GridSearchCV dan RandomizedSearchCV untuk algoritma Random Forest, serta pelaksanaan *hypertuning* Optuna dengan *walk-forward forecast* untuk algoritma LightGBM.

Seluruh pekerjaan dan progres kelompok dibagikan secara aktif antar anggota menggunakan WhatsApp dan Discord sebagai media komunikasi, sehingga setiap anggota dapat langsung berdiskusi, bertukar informasi, dan menyelesaikan kendala yang muncul selama pengerjaan proyek. Google Colab digunakan untuk mengerjakan kode, melakukan eksperimen, serta menyimpan hasil kerja sementara, karena platform ini memungkinkan setiap anggota mengakses, mengedit, dan menjalankan kode yang sama secara bersamaan. Selain itu, GitHub dimanfaatkan untuk berbagi dan menyimpan *dataset* penelitian, sehingga data dapat dikelola secara terstruktur dan aman, serta seluruh anggota memiliki akses yang sama terhadap data yang digunakan dalam analisis.

3.2 Pencatatan Rangkuman Mingguan Proses *PRO-STEP: Road To Champion Program*

Pada pelaksanaan *PRO-STEP: Road To Champion Program*, terdapat beberapa pekerjaan yang dilakukan. Pekerjaan ini diberikan oleh dosen pembimbing lapangan (*supervisor*), yaitu Ibu Dr. Irmawati, S.Kom., M.M.S.I, selama berjalannya *PRO-STEP: Road To Champion Program*. Tabel 3.1 memperlihatkan pelaksanaan pekerjaan yang diberikan oleh dosen pembimbing lapangan (*supervisor*), yang mencakup pencarian lomba, pembuatan model *time series forecasting* dan abstrak, pembuatan *full paper*, hingga rangkaian acara *onsite* di Jambi.

Tabel 3.1 Detail Pekerjaan yang dilakukan dalam *PRO-STEP : Road to Champion Program*

No.	Minggu	Proyek	Keterangan
1	2-7	Pencarian Lomba	Mencari lomba yang sesuai untuk pelaksanaan <i>PRO-STEP : Road To Champion Program</i> .
2	7-8	Penyusunan dan Pengumpulan Abstrak	Tahap peserta menyusun dan mengirimkan abstrak karya tulis ilmiah untuk dinilai oleh juri sebagai seleksi awal.
3	9	Pengumuman Lulus Abstrak	Pihak penyelenggara mengumumkan abstrak yang lolos seleksi untuk melanjutkan ke tahap pengumpulan <i>full paper</i> .
4	8-11	Pembuatan Model <i>Time Series Forecasting</i>	Proses pembuatan model peramalan penjualan mobil bulanan menggunakan algoritma <i>machine learning</i> .
5	8-11	Penyusunan <i>Full Paper</i>	Pelaksanaan penyusunan karya tulis ilmiah secara lengkap berdasarkan abstrak yang telah dibuat.
6	11	Registrasi dan Pengumpulan <i>Full Paper</i> Gelombang II	Peserta lolos abstrak melakukan registrasi dan menyerahkan <i>full paper</i> pada gelombang pertama.
7	12	Pembuatan Slide Presentasi dan Banner	Peserta membuat <i>slide</i> presentasi dan <i>banner</i> yang akan digunakan pada acara final.
8	12	Pengumuman 10 Besar Finalis	Pengumuman peserta yang lolos ke tahap final berdasarkan penilaian <i>full paper</i> oleh penyelenggara lomba.
9	12	Registrasi Ulang dan Konfirmasi Kehadiran Peserta	Finalis melakukan registrasi ulang dan melakukan konfirmasi kehadiran secara langsung di Jambi untuk mengikuti seluruh rangkaian acara final.
10	13	Pelaksanaan Final Lomba LKTIN Carbon 7.0 secara Langsung (Onsite)	Peserta hadir di Jambi dan mengikuti seluruh rangkaian acara final Carbon 7.0.
11	14-17	Evaluasi Tambahan Model XGBoost Pasca-Lomba dengan <i>Stacking Ensemble</i>	Analisis tambahan untuk menilai kembali kinerja XGBoost dengan pendekatan <i>stacking ensemble</i> setelah lomba selesai.

3.3 Uraian Pelaksanaan Kerja Dalam PRO-STEP : Road To Champion Program

Pekerjaan dalam PRO-STEP: *Road to Champion Program* dilaksanakan melalui beberapa tahapan yang mencakup proses pelaksanaan, identifikasi kendala yang ditemukan, serta penyusunan solusi atas kendala yang ditemukan. Proses pelaksanaan mencakup masa persiapan sebelum lomba, pembuatan model, penyusunan karya ilmiah, hingga pelaksanaan lomba secara langsung di Jambi, beserta dengan evaluasi tambahan pasca-lomba. Selain itu, bagian identifikasi kendala yang ditemukan, berisi berbagai hambatan yang muncul selama proses tersebut, sedangkan bagian solusi atas kendala yang ditemukan berisi upaya yang dilakukan untuk mengatasi kendala yang ada.

3.3.1 Proses Pelaksanaan

Proses pelaksanaan pekerjaan dalam PRO-STEP: *Road to Champion Program* terdiri atas beberapa tahap, yaitu:

3.3.1.1 Pencarian Lomba

Tahap pertama yang dilakukan adalah proses pencarian lomba yang sesuai dengan ketentuan Program *Road to Champion*. Tahap ini berlangsung dari minggu ke-2 hingga minggu ke-7 dari Program *Road to Champion*. Pada tahap ini, setiap anggota kelompok bersama dengan dosen pembimbing lapangan (*supervisor*), bekerja sama dalam mencari berbagai lomba yang sesuai dengan ketentuan dari kampus, melalui beberapa platform seperti *website* penyelenggara, media sosial, dan sumber informasi lainnya. Setelah memperoleh beberapa opsi, seluruh pilihan didiskusikan dengan dosen pembimbing lapangan untuk kemudian menentukan lomba yang paling sesuai dengan kriteria program.

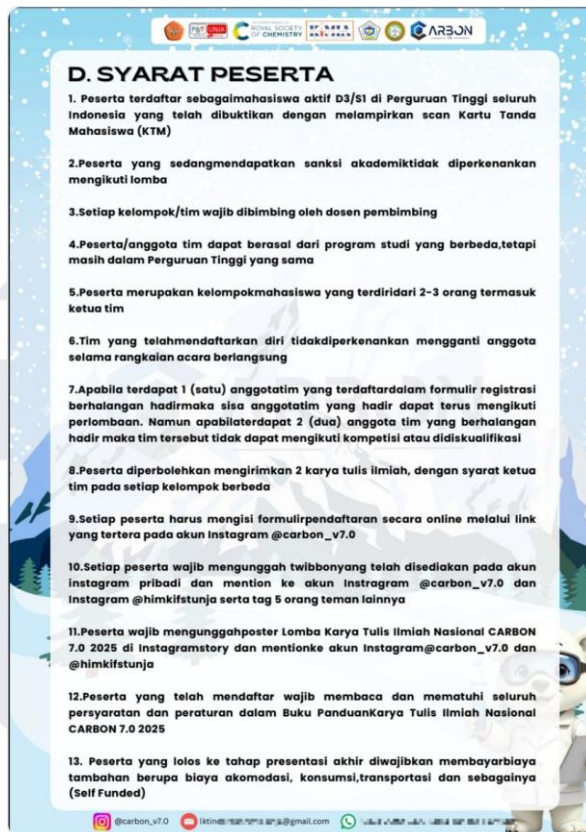
Hasil akhir yang diperoleh dari tahap pertama ini adalah penemuan dan penetapan lomba yang diikuti, yaitu Lomba Karya Tulis Ilmiah Nasional (LKTIN) 2025 pada Carbon 7.0. Lomba ini diselenggarakan oleh Himpunan Mahasiswa Kimia (HIMKI) Fakultas Sains dan Teknologi Universitas Jambi dan ditemukan melalui poster lomba LKTIN 2025 *website* dan media sosial Carbon v7.0. Salah satu

unggahan Instagram Carbon v7.0 yang memberikan informasi tentang Lomba Karya Tulis Ilmiah Nasional (LKTIN) 2025 ditunjukkan pada Gambar 3.3.



Gambar 3.3 Unggahan Instagram Carbon v7.0 terkait LKTIN 2025

Unggahan ini tidak hanya memberikan informasi singkat tentang kompetisi, tetapi juga menyertakan tautan Google Drive untuk memudahkan peserta dalam mengakses *guidebook* LKTIN 2025, format abstrak dan *full paper*, serta beberapa formulir yang perlu diisi oleh peserta. *Guidebook* LKTIN 2025 berisi panduan lengkap lomba terkait tata cara, ketentuan, dan persyaratan yang perlu dipatuhi oleh peserta selama pelaksanaan lomba, contohnya seperti persyaratan peserta, ketentuan penulisan, ketentuan karya, *timeline*, hadiah, dan informasi lainnya. Gambar 3.4 menunjukkan salah satu halaman dalam *guidebook* LKTIN 2025, yaitu halaman syarat peserta.



Gambar 3.4 Halaman Syarat Peserta dalam *Guidebook* LKTIN 2025

3.3.1.2 Penyusunan dan Pengumpulan Abstrak

Tahap penyusunan dan pengumpulan abstrak menjadi tahap kedua dalam pelaksanaan pekerjaan pada PRO-STEP: *Road to Champion Program*. Kegiatan ini dilakukan pada minggu ke-7 dan minggu ke-8, di mana proses penulisan abstrak berlangsung sepanjang periode tersebut. Pengumpulan abstrak kemudian dilaksanakan pada tanggal 24 September 2025.

Pada tahap penyusunan, abstrak untuk karya tulis ilmiah disusun dengan memperhatikan struktur, isi, dan format yang sesuai dengan ketentuan penulisan abstrak yang ditunjukkan pada *guidebook* dan juga *template* abstrak, sehingga gagasan dan tujuan penelitian dapat tersampaikan secara jelas dan ringkas. Abstrak pada *full paper* ini berisi latar belakang masalah, metode penelitian, model yang digunakan, dan hasil penelitian yang dilakukan. Pertama, dijelaskan bahwa industri otomotif merupakan salah satu sektor penting dalam

ekonomi Indonesia dan perlunya ada prediksi penjualan untuk mendukung keputusan strategi perusahaan. Selanjutnya, dijelaskan permasalahan yang ada pada penelitian sebelumnya, yaitu keterbatasan model statistik konvensional yang kurang mampu menangkap hubungan non-linear dan kompleks antar variabel.

Kedua, abstrak menjelaskan metode penelitian, yaitu penggunaan model *machine learning* XGBoost, Random Forest, dan LightGBM, yang digunakan untuk memprediksi penjualan bulanan (data *time series*) dan membandingkan performanya melalui metrik MAPE. Kemudian, dijelaskan juga bahwa proses penelitian berlangsung mulai dari pemrosesan data *time series*, pembuatan fitur *rolling window* dan interaksi eksternal, hingga pelatihan model dengan memanfaatkan *rolling forecast*.

ABSTRAK

Industri otomotif merupakan salah satu sektor penting dalam perekonomian Indonesia, di mana penjualan mobil bulanan sangat dipengaruhi oleh kondisi ekonomi dan perilaku konsumen. Oleh karena itu, peramalan penjualan menjadi aspek strategis yang berperan dalam mendukung efisiensi produksi, manajemen persediaan, serta perencanaan pemasaran. Meskipun demikian, penelitian-penelitian sebelumnya masih terbatas pada penggunaan model statistik konvensional yang belum mampu menangkap hubungan nonlinier dan kompleks antar variabel. Untuk menjawab keterbatasan tersebut, penelitian ini membandingkan kinerja tiga model *machine learning* XGBoost, Random Forest, dan LightGBM dalam memprediksi penjualan mobil bulanan di Indonesia dengan mempertimbangkan faktor makroekonomi (nilai tukar dan inflasi) serta tren digital (Google Trends). Proses penelitian meliputi praproses data deret waktu, pembuatan fitur *rolling window* dan interaksi eksternal, pelatihan model menggunakan skema *rolling forecast*, serta evaluasi dengan metrik MAPE. Berdasarkan hasil eksperimen, model XGBoost menunjukkan performa paling unggul dengan nilai MAPE rata-rata sebesar 10.48%, dibandingkan Random Forest dan LightGBM. Analisis lebih lanjut mengungkapkan bahwa variabel nilai kurs berkontribusi dalam meningkatkan akurasi model, sedangkan data Google Trends dan inflasi transportasi tidak memberikan pengaruh positif yang konsisten terhadap hasil prediksi. Dengan demikian, XGBoost dapat disimpulkan sebagai model paling stabil dan efektif dalam meramalkan penjualan otomotif di Indonesia serta menegaskan pentingnya pemanfaatan faktor makroekonomi khususnya nilai kurs dalam pengembangan model prediksi berbasis *machine learning*.

Kata Kunci : *penjualan mobil, peramalan, machine learning, time series, tren digital*

Gambar 3.5 Hasil Penyusunan Abstrak untuk *Full Paper*

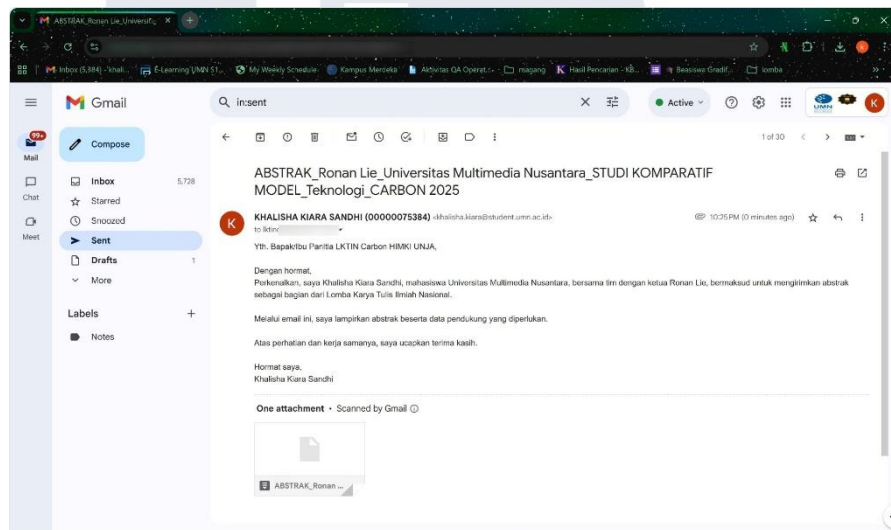
Ketiga, abstrak menjelaskan hasil dari penelitian yang dilakukan, di mana XGBoost disimpulkan menjadi model paling stabil dan efektif dalam melakukan prediksi penjualan mobil, dengan performa terbaik yang ditunjukkan oleh rata-rata MAPE 10,48%. Hal ini membuat XGBoost lebih unggul dibandingkan Random Forest dan LightGBM. Selain itu, analisis lebih lanjut terkait pengaruh variabel makroekonomi (nilai tukar dan inflasi transportasi) dan minat masyarakat (Google Trends) terhadap hasil prediksi model dijelaskan dalam abstrak, di mana hasilnya menunjukkan bahwa nilai tukar (kurs) berkontribusi besar terhadap akurasi prediksi, sementara Google Trends dan inflasi transportasi berkontribusi sangat kecil. Gambar 3.5 menunjukkan hasil abstrak yang telah disusun dan dilakukan revisi untuk kemudian dimasukkan ke dalam *full paper*.

Setelah abstrak selesai disusun, abstrak diberikan kepada dosen pembimbing lapangan (*supervisor*) untuk diperiksa kelengkapan, kesesuaian isi, dan kualitas penulisan. Kemudian, dosen pembimbing lapangan memberikan masukan dan saran untuk revisi. Masukan dan revisi dari dosen pembimbing lapangan kemudian diterapkan sehingga abstrak siap untuk dikumpulkan.

Gambar 3.6 Bukti Pengumpulan Abstrak Melalui Google Form

Tahap pengumpulan abstrak dimulai dengan pengiriman abstrak melalui Google Form, beserta data tambahan lain yang

diminta pada formulir. Gambar 3.6 menunjukkan bukti bahwa *form* pengumpulan abstrak telah berhasil diisi dan dikirim. Selanjutnya, abstrak dikirimkan juga oleh perwakilan kelompok melalui email kepada alamat email lomba LKTIN resmi, yang telah disediakan oleh penyelenggara lomba, seperti yang dapat dilihat pada Gambar 3.7. Setelah kedua pengiriman tersebut, abstrak dikonfirmasi kepada *contact person* penyelenggara untuk memastikan bahwa pengiriman telah sesuai dengan persyaratan lomba.



Gambar 3.7 Bukti Pengumpulan Abstrak Melalui Email

3.3.1.3 Pengumuman Lulus Abstrak

Pengumuman lulus abstrak yang berlangsung pada minggu ke-9, tepatnya pada tanggal 4 Oktober 2025, yang merupakan tahap ketiga yang dilakukan dalam proses pelaksanaan pekerjaan *Road to Champion Program*. Pada tahap ini, setiap peserta yang lulus abstrak akan mendapatkan sebuah email, tepatnya pada email ketua kelompok. Email tersebut berisi sebuah ucapan selamat, dengan beberapa informasi tambahan terkait acara LKTIN Carbon 7.0. Informasi tambahan tersebut mencakup pengingat *timeline* lomba dan *form* pengumpulan *full paper*. Gambar 3.8 menunjukkan bukti lulus abstrak yang diterima oleh ketua kelompok.



Gambar 3.8 Bukti lulus abstrak yang diterima oleh ketua kelompok.

3.3.1.4 Pembuatan Model *Time Series Forecasting*

Tahap keempat dalam pelaksanaan pekerjaan *Road to Champion* berlangsung selama dua minggu, tepatnya pada minggu ke-8 dan ke-11 dari Program *Road to Champion*. Pada tahap ini, perbandingan tiga algoritma yang digunakan dalam penelitian difokuskan pada bagian pengerjaan model XGBoost. Pelaksanaan tahap ini dilakukan dengan menggunakan Google Colab sebagai platform utama dalam proses pengerjaan kode penerapan model yang telah dipilih sebelumnya. Kemudian, GitHub juga digunakan sebagai platform tambahan yang memungkinkan penyimpanan *dataset* secara *online*. Selain itu, pelaksanaan tahap ini menghasilkan kode Python yang menggunakan tiga model *machine learning*, yaitu XGBoost, Random Forest, dan LightGBM untuk melakukan prediksi penjualan mobil. Ketiga model ini kemudian dilakukan pengujian pada

parameternya, sehingga ketiga model tersebut dapat melakukan prediksi penjualan mobil dengan akurasi yang tinggi, untuk kemudian dilakukan perbandingan hasil prediksi model antara ketiganya. Pembuatan model mengikuti lima tahapan CRISP-DM, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, dan *Evaluation*.

Pertama, penelitian masalah dilakukan untuk tahap *Business Understanding*, sehingga pemanfaatan *machine learning* dapat digunakan untuk menemukan solusi. Hasil dari riset yang telah dilakukan, menunjukkan bahwa industri otomotif menghadapi pasar yang fluktuatif, sehingga strategi produksi dan penjualan yang tepat diperlukan untuk mencegah kerugian perusahaan. Berdasarkan hal ini, penelitian ini berfokus pada prediksi penjualan bulanan lima *brand* mobil di Indonesia (Honda, Daihatsu, Toyota, Suzuki, dan Mitsubishi), sebagai 5 mobil pertama yang tertera pada data utama yang digunakan. Prediksi penjualan dibuat dengan memanfaatkan algoritma XGBoost, Random Forest, dan LightGBM. Algoritma-algoritma ini dipilih karena kemampuannya dalam menangkap pola non-linier dengan akurasi tinggi pada *dataset* berskala kecil hingga menengah. Selain itu, penelitian ini menyelidiki pengaruh elemen makroekonomi, seperti inflasi transportasi dan nilai tukar, serta minat masyarakat (Google Trends), terhadap peningkatan akurasi prediksi dari model yang digunakan. Data utama penjualan mobil diperoleh dari GAIKINDO [18] untuk periode 2021-2025, sedangkan data eksternal nilai tukar rupiah terhadap dolar Amerika Serikat diperoleh dari *website* Investing.com [19]. Selain itu, data eksternal minat masyarakat diperoleh dari *website* Google Trends [20], yang mencakup pengambilan data lima *brand* mobil untuk periode 1 Januari 2021 hingga 31 Juli 2025, sedangkan data inflasi transportasi yang diperoleh dari *website* Satu Data Perdagangan [21] dengan sumber data inflasi yang diperoleh dari Badan Pusat Statistik (BPS).

Pada tahap *Data Understanding*, analisis awal dilakukan

pada data agar kemudian dapat digunakan secara optimal untuk prediksi penjualan menggunakan *machine learning*. Pada Python, fungsi `.isnull().sum()` digunakan untuk mengecek nilai yang hilang untuk mengetahui apakah ada nilai yang hilang yang dapat mempengaruhi prediksi. Di sisi lain, struktur data diperiksa menggunakan fungsi `.describe()` dan `.info()` untuk mendapatkan informasi tentang tipe, distribusi, dan ringkasan statistik masing-masing variabel. *Exploratory Data Analysis* (EDA), yang mencakup dekomposisi musiman, pengecekan stasioner, diferensiasi pada data yang tidak stasioner, *boxplot* penjualan per *brand* setiap tahun, dan visualisasi *timeseries* untuk melihat tren, juga dilakukan pada tahap pemahaman data ini.

Pada tahap *Data Preparation*, dilakukan beberapa proses untuk memastikan data siap digunakan dalam melakukan prediksi penjualan. Proses yang dilakukan meliputi: penyeragaman kolom waktu ke format *datetime* formal `%Y-%m-%d`, pembersihan dan perubahan tipe kolom *Price*, konversi tanggal dan agregasi data mingguan menjadi bulanan pada data eksternal kedua (data Google Trends), serta pemetaan bulan ke format `YYYY-MM` dan pembersihan data eksternal ketiga (data Inflasi Transportasi). Sebagai tambahan, setiap *dataset* dilakukan pengecekan jumlah bulan per tahun untuk memastikan bahwa data yang digunakan konsisten dan tidak ada ketimpangan pada data. Dari hasil pengecekan tersebut, ditemukan bahwa data eksternal ketiga (data Inflasi Transportasi) memiliki data sebelum tahun 2021, sehingga dilakukan penghapusan data sebelum tahun 2021 untuk menjaga konsistensi data yang digunakan untuk melatih model. Selain itu, ditemukan juga bahwa, pada *dataset* utama (data GAIKINDO), terdapat data penjualan yang tidak tersedia, tepatnya pada tanggal 1 Desember 2023, sehingga dilakukan penambahan data pada bulan yang hilang tersebut, menggunakan nilai rata-rata. Kemudian, tahap persiapan data dilanjutkan dengan melakukan *feature engineering*, seperti *reset*

index, penyamaan nama kolom waktu pada data eksternal, penyesuaian tanggal data eksternal menjadi awal bulan agar sesuai dengan data utama. Selain itu, dilakukan juga penggabungan semua data (data utama GAIKINDO, dan data eksternal nilai tukar, Google Trends, serta inflasi transportasi) dengan menggunakan fungsi *merge* pada Python. Penggabungan semua data ini disimpan pada satu *dataframe* bernama *df_merge* dengan total 55 baris dan 13 kolom. Gambar 3.9 menunjukkan *dataframe* *df_merge* yang telah dibuat.

	waktu	DAIHATSU	HONDA	MITSUBISHI	SUZUKI	TOYOTA	Nilai_Kurs	GT_Honda	GT_Daihatsu	GT_Toyota	GT_Suzuki	GT_Mitsubishi	Inflasi_Transportasi
0	2021-01-01	8993.0	7231.0	9108.0	6400.0	15474.0	14214	319	32	125	87	35	-0.30
1	2021-02-01	9412.0	6812.0	7567.0	4600.0	14645.0	14010	257	28	100	67	28	0.30
2	2021-03-01	16770.0	11350.0	13088.0	8669.0	26034.0	14250	242	26	91	65	27	-0.25
3	2021-04-01	15861.0	8474.0	13820.0	8100.0	22618.0	14520	245	28	106	65	28	0.00
4	2021-05-01	8310.0	5832.0	10160.0	5341.0	17361.0	14445	339	39	149	84	35	0.71
...
50	2025-03-01	6371.0	2382.0	7380.0	3223.0	13711.0	16475	216	21	77	65	23	-0.08
51	2025-04-01	6075.0	1590.0	5197.0	2767.0	13779.0	16555	184	17	65	58	20	-0.01
52	2025-05-01	7537.0	3148.0	5897.0	2004.0	9313.0	16600	176	16	58	59	19	-0.07
53	2025-06-01	5992.0	2360.0	6501.0	3499.0	8712.0	16245	207	19	71	68	24	0.07
54	2025-07-01	6354.0	4171.0	6121.0	2666.0	7617.0	16190	175	16	58	55	29	0.00

55 rows x 13 columns

Gambar 3.9 *Dataframe* *df_merge*

Sebelum melanjutkan ke tahap modeling, fitur variabel waktu seperti bulan, *sinus* dan *cosinus* bulan untuk menggambarkan musiman, dan *rolling statistics* (mean dan standar deviasi) dibuat. Selain itu, dibuat pula fitur untuk *lag features* dan interaksi antara penjualan *brand* dengan data eksternal, seperti nilai tukar, inflasi transportasi, dan Google Trends. Kemudian, data dinormalisasi menggunakan *StandardScaler* pada Python untuk menyamakan skala seluruh fitur sebelum proses pemodelan dilaksanakan.

Pada tahap modeling, model yang telah dipilih diterapkan untuk memprediksi data penjualan, dengan melakukan optimasi dan penambahan penggunaan data eksternal untuk meningkatkan akurasi prediksi model. Pada setiap model yang digunakan, diterapkan strategi *rolling forecast* untuk melakukan prediksi penjualan. *Rolling forecast* sendiri merupakan sebuah strategi prediksi di mana model dilatih secara bertahap menggunakan data hingga titik tertentu dan diuji pada titik berikutnya.

Untuk model *XGBoost*, pemilihan parameter dilakukan

melalui beberapa percobaan yang mengacu pada beberapa penelitian sebelumnya. Setelah menemukan beberapa kombinasi parameter yang menghasilkan akurasi yang baik, parameter tersebut kemudian dibahas bersama kelompok untuk pengaturan akhir yang optimal, sambil memastikan bahwa kondisi pelatihan antar model tetap setara, agar perbandingan performa ketiga algoritma dapat dilakukan secara adil tanpa dipengaruhi perbedaan konfigurasi dasar yang terlalu jauh. Pada akhirnya, parameter yang disamakan untuk tiap modelnya adalah `n_estimators` sebesar 700, `max_depth` sebesar 7, dan `random_state` 42. Tabel 3.2 menunjukkan seluruh parameter model XGBoost yang digunakan pada tahap modeling.

Tabel 3.2 Parameter XGBoost yang Digunakan pada Tahap Modeling

Parameter	Nilai
<code>n_estimators</code>	700
<code>learning_rate</code>	0.03
<code>max_depth</code>	7
<code>subsample</code>	0.8
<code>colsample_bytree</code>	0.8
<code>objective</code>	'reg:squarederror'
<code>random_state</code>	42

Dalam tahap terakhir CRISP-DM (tahap Evaluasi), kinerja masing-masing model (XGBoost, Random Forest, dan LightGBM) dievaluasi dengan menggunakan metrik *Mean Absolute Percentage Error* (MAPE). Hasil evaluasi ini kemudian dimasukkan ke dalam tabel komparasi untuk kemudian dilihat dan dibandingkan performa dari ketiga model tersebut. Tabel 3.3 menunjukkan tabel komparasi ketiga model berdasarkan nilai MAPE.

Tabel 3.3 Tabel Komparasi Ketiga Model Berdasarkan Nilai MAPE

Brand	Nilai MAPE (%)		
	Random Forest	XGBoost	LightGBM
DAIHATSU	7.886	6.054	30.705
HONDA	16.825	13.142	52.037
MITSUBISHI	7.996	7.400	32.085
SUZUKI	13.384	14.851	38.694
TOYOTA	11.911	10.954	34.948

Selain itu, untuk mengetahui model yang memiliki kinerja

terbaik dalam memprediksi penjualan mobil, nilai *Mean Absolute Percentage Error* (MAPE) dari setiap model dihitung. Nilai rata-rata ini dihitung dengan menggunakan fungsi `.mean()` pada Python. Nilai MAPE rata-rata untuk setiap model yang digunakan dalam melakukan prediksi penjualan ditunjukkan pada Tabel 3.4.

Tabel 3.4 hasil rata-rata nilai MAPE tiap model

Model	Rata-rata Nilai MAPE
Random Forest	11.60 %
XGBoost	10.48 %
LightGBM	37.70 %

Selanjutnya, visualisasi dilakukan dengan membandingkan data aktual dengan hasil prediksi dari ketiga model (Daihatsu, Honda, Mitsubishi, Suzuki, dan Toyota). Dalam visualisasi ini, perbedaan warna garis digunakan untuk membedakan data hasil prediksi masing-masing model dari data aktual. Berdasarkan hasil visualisasi *line graph* yang diperoleh, dapat disimpulkan bahwa garis hasil prediksi model XGBoost memiliki pola pergerakan yang paling mendekati garis data aktual. Selain itu, model Random Forest menunjukkan garis hasil prediksi yang cukup sesuai dengan data aktual, meskipun ada beberapa perbedaan selama beberapa waktu. Sementara itu, pola pergerakan model LightGBM tidak terlalu sesuai dengan data aktual karena adanya gangguan pada garis hasilnya.

Selain itu, analisis *permutation importance* juga dilakukan untuk menilai kontribusi fitur eksternal terhadap peningkatan akurasi prediksi setiap model yang digunakan. Analisis ini dilakukan dengan menghitung rata-rata *importance* antar *brand*, yang kemudian divisualisasikan untuk masing-masing model. Dengan analisis ini, pengaruh faktor-faktor eksternal seperti nilai tukar, inflasi transportasi, dan Google Trends, terhadap akurasi prediksi penjualan dapat lebih mudah dipahami dan diinterpretasikan, sehingga kemudian dapat digunakan untuk mengambil keputusan strategis terkait penjualan mobil. Hasil analisis menunjukkan bahwa, dari ketiga model yang digunakan, nilai kurs merupakan faktor eksternal

yang paling berpengaruh terhadap hasil prediksi.

3.3.1.5 Penyusunan *Full Paper*

Tahap kelima yang dilakukan mencakup proses penyusunan karya tulis ilmiah atau yang disebut dengan *full paper* pada LKTIN 2025. Tahap ini berlangsung dari minggu ke-8 (setelah pengumpulan abstrak) hingga minggu ke-11 dari pelaksanaan Program *Road to Champion*. Pada tahap ini, pembuatan karya tulis ilmiah dikembangkan berdasarkan abstrak yang telah dibuat dan dikumpulkan sebelumnya. Selain itu, pembuatan karya ini mengikuti ketentuan penulisan yang tertera di buku panduan (*guidebook*) LKTIN Carbon 7.0. Beberapa contoh ketentuan penulisan yang perlu diikuti adalah batas maksimal 15 halaman (terhitung dari bab 1 hingga 5, beserta halaman pertama daftar pustaka), penggunaan spasi 1,5, pengaturan paragraf rata kiri-kanan (*justified*), dan juga penggunaan gaya sitasi APA. Untuk menyusun karya tulis ilmiah ini, platform Google Docs digunakan sehingga memudahkan anggota kelompok untuk mengerjakannya secara bersamaan. Karya tulis ilmiah yang dibuat untuk pelaksanaan Lomba Karya Tulis Ilmiah Nasional (LKTIN) 2025, berjudul *Studi Komparatif Model Machine Learning pada Data Time Series Penjualan Mobil di Indonesia*, dan dibuat secara lengkap mulai dari bab 1 hingga bab 5.

Bab pertama berisi 5 subbab, yaitu Latar Belakang, Rumusan Masalah, Batasan Masalah, Tujuan Penelitian, dan Manfaat Penelitian. Pertama, latar belakang penelitian membahas tentang pentingnya industri otomotif bagi perekonomian, karakteristik penjualan mobil yang fluktuatif, serta pengaruh faktor makroekonomi (nilai kurs dan inflasi transportasi) dan minat masyarakat (data Google Trends). Pada latar belakang, ditunjukkan juga bahwa metode konvensional dalam memprediksi penjualan memiliki keterbatasan yang membuat penggunaan *machine learning* seperti Random Forest, XGBoost, dan LightGBM diperlukan. Kedua, rumusan masalah berisi pertanyaan penelitian mengenai performa model *machine learning*

serta pengaruh variabel makroekonomi dan minat masyarakat. Ketiga, batasan masalah menjelaskan ruang lingkup data, variabel, metode, dan metrik evaluasi yang digunakan. Keempat, tujuan penelitian mencakup pembangunan model prediksi, analisis pengaruh faktor-faktor tersebut, serta perbandingan kinerja model. Kelima, manfaat penelitian menjelaskan kontribusi penelitian bagi akademisi, industri otomotif, dan pemerintah.

Selanjutnya, bab 2 mencakup landasan teori dan penelitian terkini. Landasan teori yang dibahas pada bab ini adalah teori dasar tentang peramalan (*forecasting*) data baris waktu, teori tentang metode *machine learning* untuk melakukan peramalan (seperti XGBoost, Random Forest, dan LightGBM), dan teori tentang evaluasi model peramalan yang salah satunya adalah *Mean Absolute Percentage Error* (MAPE). Selain itu, bab ini juga mencakup dua belas penelitian terkini yang relevan dengan topik penelitian. Kemudian, penelitian terkini ini dirangkum menjadi tabel dengan tiga kolom, yang mencakup hasil utama penelitian, performa model yang dibuat, kelebihan dan kelemahan model, serta efektivitas model pada berbagai jenis *dataset*. Tabel penelitian terkini ini ditunjukkan pada Gambar 3.10. Landasan teori dan penelitian terbaru ini kemudian digunakan sebagai acuan untuk memilih metode penelitian, model yang digunakan, dan interpretasi hasil. Berdasarkan pembahasan tersebut, ditetapkan bahwa penelitian ini menggunakan metode *machine learning* untuk prediksi (*forecasting*) data *time series*, dengan menggunakan model XGBoost, Random Forest dan LightGBM karena kemampuannya dalam menangkap pola non-linier dan kompleks pada *dataset* berskala kecil dengan akurasi tinggi, menggunakan MAPE sebagai metrik evaluasi.

No	Sitasi	Metodologi	Hasil Penelitian
1	(Lehna et al, 2022)	LSTM–VAR Hybrid	LSTM unggul untuk hubungan non-linier, VAR lebih baik untuk linier; kombinasi LSTM–VAR meningkatkan akurasi prediksi.
2	(Qiu et al, 2024)	XGBoost, RF, PatchTST	Model linier lebih unggul untuk data dengan tren kuat; XGBoost, Random Forest, dan LightGBM lebih baik untuk pola non-linier; Transformer unggul untuk pola musiman dan korelasi kompleks.
3	(Ahaggach et al, 2024)	RF, XGBoost, ARIMA	ARIMA dan regresi dominan untuk pola linier; RF dan XGBoost efektif untuk pola non-linier; DL mulai berkembang namun masih terbatas karena biaya komputasi.
4	(Saptadi et al, 2025)	RF, XGBoost	Metode ensambel seperti Random Forest dan XGBoost unggul dalam menangkap hubungan nonlinier dan menghasilkan akurasi tinggi, sedangkan model deep learning (LSTM, ANN) juga menjanjikan namun terbatas oleh kebutuhan data dan komputasi. Model linier berkinerja buruk pada data penjualan yang kompleks.
5	(Ahmed et al, 2025)	XGBoost, LightGBM, DeepAR	ARIMA terbaik untuk data linier; XGBoost, LightGBM, dan DeepAR unggul untuk dataset non-linier dan berdimensi tinggi.
6	(Chowdhury et al, 2025)	LSTM	LSTM lebih unggul dibandingkan SVR dan RF untuk pola non-linier dan jangka panjang, terutama pada dataset besar dan fluktuatif.
7	(Fourkiotis & Tsadiras, 2024)	XGBoost	XGBoost paling efektif untuk peramalan multivariat yang kompleks; LSTM membutuhkan dataset besar untuk hasil optimal.
8	(Lara-Benítez et al., 2021)	LSTM, CNN	LSTM menghasilkan akurasi tertinggi; CNN memiliki efisiensi dan stabilitas lebih baik.
9	(Muth et al, 2024)	LSTM, MLP, XGBoost	ANN (LSTM, MLP) menunjukkan kinerja terbaik; RF dan XGBoost unggul pada data terstruktur; ARIMA tetap efektif untuk tren stabil
10	(Ahmed et al, 2024)	CNN–LSTM	CNN–LSTM hybrid memberikan akurasi tertinggi; LSTM unggul untuk data temporal, CNN untuk pola spasial.
11	(Ganguly & Mukherjee, 2024)	RF	RF yang dioptimalkan memiliki R^2 tertinggi (0.945) dan RMSLE terendah (1.172); GB, SVR, dan XGBoost sedikit di bawahnya.
12	(Ahaggach et al., 2024)	RF	Random Forest konsisten menghasilkan akurasi tinggi untuk data non-stasioner, mengungguli KNN.

Gambar 3.10 Tabel Penelitian Terkini pada *Full Paper*

Bab 3 menjelaskan metode penelitian yang digunakan, termasuk penerapan kerangka CRISP-DM dalam proses prediksi penjualan. Untuk memudahkan pemahaman alur penelitian, bab ini dimulai dengan memberikan gambar *pipeline* penelitian yang menggambarkan alur proses secara keseluruhan. Kemudian, isi bab ini dilanjutkan dengan penjelasan menyeluruh tentang setiap langkah dari alur penelitiannya, mulai dari pengumpulan data, persiapan data, proses pemodelan, dan prediksi, serta evaluasi hasil. Pertama, bab ini menjelaskan bahwa tahap pengumpulan data mencakup sumber data

utama yaitu data penjualan mobil tahun 2021 hingga 2025 yang diperoleh dari *website* GAIKINDO, data eksternal pertama yaitu data kurs terhadap Amerika Serikat yang diperoleh dari *website* Bank Indonesia, data eksternal kedua yaitu data inflasi transportasi yang diperoleh dari *website* Badan Pusat Statistik (BPS), serta data eksternal ketiga yaitu minat masyarakat yang diperoleh dari Google Trends. Kedua, dijelaskan pada bab ini bahwa persiapan data terbagi menjadi dua bagian utama, yaitu penanganan data dan *feature engineering*. Penanganan data dilakukan dengan menangani data yang berkaitan dengan kualitas data seperti *missing values*, duplikasi, nilai yang tidak valid, dan lain sebagainya, sedangkan *feature engineering* dilakukan dengan menambahkan fitur tambahan seperti fitur waktu, *rolling statistics*, interaksi dengan variabel makroekonomi, dan *lag* variabel, sehingga model mampu mempelajari dan memahami pola deret waktu, serta pengaruh *lag* dari kondisi ekonomi terhadap penjualan. Ketiga, bab ini menjelaskan bagaimana tahap pemodelan dan prediksi penjualan dilakukan dengan menggunakan tiga algoritma utama, yaitu XGBoost, Random Forest, dan LightGBM, dengan pendekatan *rolling forecast*. Terakhir, dalam bab ini dijelaskan bahwa pada tahap evaluasi hasil, akurasi model diukur dengan menggunakan metrik *Mean Absolute Percentage Error* (MAPE). Pada tahap evaluasi hasil ini juga dijelaskan bahwa performa model dinilai melalui visualisasi perbandingan antara nilai aktual dan nilai prediksi, dan pengaruh fitur eksternal dianalisis melalui *permutation importance*.

Selanjutnya, bab 4 berisi hasil dan pembahasan dari penelitian yang dilakukan. Bab ini membahas tahap evaluasi dalam kerangka CRISP-DM, di mana performa tiga model *machine learning* (XGBoost, Random Forest, dan LightGBM) dalam memprediksi penjualan mobil ditampilkan melalui tabel Hasil Evaluasi. Gambar 3.11 menunjukkan tabel hasil evaluasi yang telah dibuat.

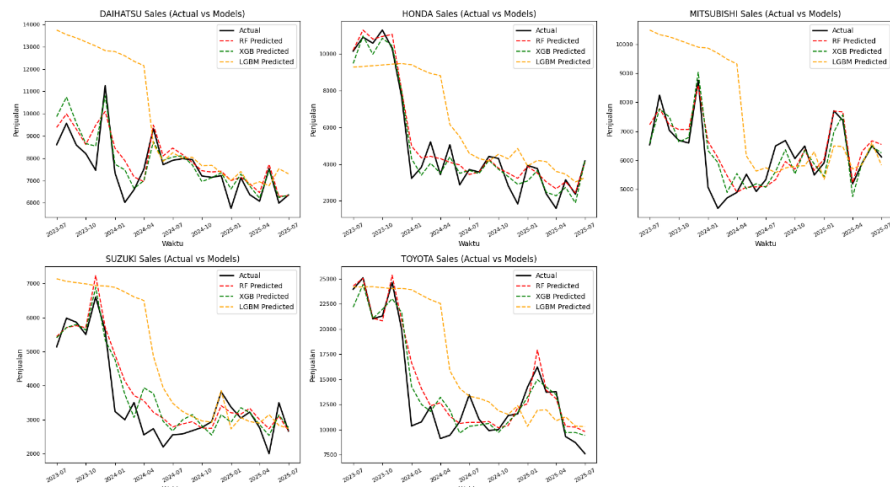
Metrik\ Merek	MAPE (%)		
	RF	XGB	LGBM
Daihatsu	7.89	6.05	30.71
Honda	16.83	13.14	52.04
Mitsubishi	8.00	7.40	32.09
Suzuki	13.38	14.85	38.69
Toyota	11.91	10.95	34.95
Average	11.60	10.48	37.70

Gambar 3.11 Tabel Hasil Evaluasi Ketiga Model

Berdasarkan gambar tabel tersebut, bab ini memaparkan bahwa model XGBoost memiliki nilai *Mean Absolute Percentage Error* (MAPE) terendah pada hampir semua *brand* kendaraan, yang menandakan bahwa model ini memiliki akurasi prediksi paling tinggi. Selain itu, XGBoost memiliki nilai MAPE terendah sebesar 10,48%, diikuti oleh Random Forest dengan 11,60%, dan LightGBM memiliki nilai MAPE tertinggi sebesar 37,70%. Hasil ini menunjukkan bahwa XGBoost lebih baik menangkap pola dan karakteristik data penjualan mobil daripada kedua model lainnya.


Selanjutnya, bab ini menyajikan visualisasi perbandingan antara nilai aktual dan hasil prediksi masing-masing model menggunakan *line graph*, seperti yang dapat dilihat dari Gambar 3.12. Visualisasi ini dibuat untuk memudahkan interpretasi perbandingan antara nilai asli dan nilai prediksi yang dihasilkan oleh ketiga model (XGBoost, Random Forest, dan LightGBM). Berdasarkan hasil *line graph* tersebut, bab ini menjelaskan bahwa XGBoost (garis berwarna hijau) memiliki prediksi paling mendekati data aktual dan mampu mengikuti pola tren penjualan dengan baik. Dijelaskan juga pada bab ini bahwa Random Forest juga memiliki prediksi yang cukup akurat, meskipun cenderung lebih halus dan sedikit tertinggal dari tren aktual, sedangkan LightGBM memiliki prediksi dengan akurasi terendah dan

paling jauh dari data penjualan aktual dibandingkan model lainnya.



Gambar 3.12 Line Graph Perbandingan Nilai Aktual dan Nilai Hasil Prediksi Ketiga Model

Selain itu, bab ini membahas pengaruh variabel eksternal, termasuk inflasi transportasi, Google Trends, dan nilai tukar (kurs), melalui analisis *permutation importance*. Analisis *permutation importance* ini digunakan untuk mempermudah identifikasi variabel eksternal mana yang paling berpengaruh pada ketiga model yang digunakan. Gambar 3.13 menunjukkan hasil *permutation importance* ketiga model yang digunakan.



Gambar 3.13 Hasil Permutation Importance Ketiga Model yang Digunakan

Berdasarkan hasil *permutation importance*, bab ini menjelaskan bahwa faktor yang paling berpengaruh pada prediksi ketiga model adalah nilai kurs, yang menandakan bahwa pergerakan nilai tukar sangat menentukan performa penjualan mobil pada tiap *brand*. Selain itu, bab ini juga menjelaskan bahwa prediksi ketiga model tidak banyak dipengaruhi oleh fitur inflasi transportasi dan Google Trends.

Terakhir, bab kelima menyajikan kesimpulan hasil penelitian dan juga saran bagi penelitian selanjutnya, industri otomotif, dan pembuat kebijakan. Pada bagian kesimpulan, dijelaskan bahwa model XGBoost memiliki performa terbaik dengan nilai prediksi rata-rata MAPE 10,48%, diikuti Random Forest (11,60%) dan LightGBM (37,70%). Berdasarkan klasifikasi tingkat akurasi berdasarkan penelitian sebelumnya yang mengategorikan nilai MAPE 10-20% sebagai baik dan 20-50% sebagai cukup [22], menunjukkan bahwa XGBoost dan Random Forest termasuk kategori baik, sedangkan LightGBM termasuk kategori cukup. Selain itu, seperti yang dijelaskan dalam bagian kesimpulan ini, hasil analisis *permutation importance* menunjukkan bahwa nilai tukar atau kurs merupakan faktor paling berpengaruh terhadap hasil prediksi model ketiga. Inflasi transportasi dan Google Trends, di sisi lain, memiliki dampak yang sangat kecil terhadap hasil prediksi ketiga model yang digunakan.


Kemudian, pada bagian saran, dijelaskan bahwa penelitian selanjutnya dapat menggunakan optimasi *hyperparameter* otomatis seperti GridSearchCV atau RandomizedSearchCV, menggunakan model *hybrid* atau *ensemble*, menambahkan variabel eksternal seperti suku bunga, harga BBM, dan kebijakan pemerintah, atau mengumpulkan pola yang lebih kompleks dengan lebih banyak data, agar akurasi prediksi dapat meningkat. Selain itu, bagi industri otomotif, hasil penelitian ini dapat digunakan untuk perencanaan produksi dan strategi pemasaran dengan mempertimbangkan fluktuasi nilai tukar dan minat masyarakat, sedangkan bagi pembuat kebijakan, stabilisasi nilai tukar dan penyediaan data ekonomi yang terbuka akan mendukung pengembangan model prediksi yang lebih akurat dan aplikatif.

Pada akhirnya, karya tulis ilmiah ini berhasil disusun sesuai dengan ketentuan penulisan yang tertera dalam *guidebook* LKTIN Carbon 7.0. Ketentuan tersebut adalah penyusunan karya tulis ilmiah dengan batas maksimal 15 halaman, yang terhitung dari bagian inti,

yaitu bab 1 hingga bab 5, beserta dengan halaman pertama daftar pustaka. Rincian halaman karya tulis ilmiah yang telah dibuat mencakup dua halaman bab pertama, tiga halaman bab kedua, tiga halaman bab ketiga, tiga halaman bab keempat, satu halaman bab kelima, dan satu halaman daftar pustaka.

3.3.1.6 Registrasi dan Pengumpulan *Full Paper* Gelombang II

Pada minggu ke-11 dari pelaksanaan Program *Road to Champion*, yang tepatnya terletak pada tanggal 20 Oktober 2025, proses registrasi dan pengumpulan *full paper* Gelombang II dilakukan. Proses registrasi ini merupakan tahap keenam dalam pelaksanaan kegiatan *Road to Champion Program*. Pertama, tahap ini dilaksanakan dengan mengisi *form* yang telah disediakan oleh penyelenggara lomba, ketika email pengumuman lolos abstrak diberikan kepada ketua kelompok. Pada *form* tersebut, setiap perwakilan kelompok diwajibkan untuk mengunggah *file* PDF karya tulis ilmiah atau *full paper* yang telah selesai dibuat, serta melampirkan informasi tambahan lainnya, seperti data ketua kelompok, anggota, dan bukti pembayaran biaya registrasi sebesar Rp165.000 per kelompok. Gambar 3.14 menunjukkan bukti bahwa *form* pengumpulan *full paper* telah diisi dan dikirim dengan sukses.



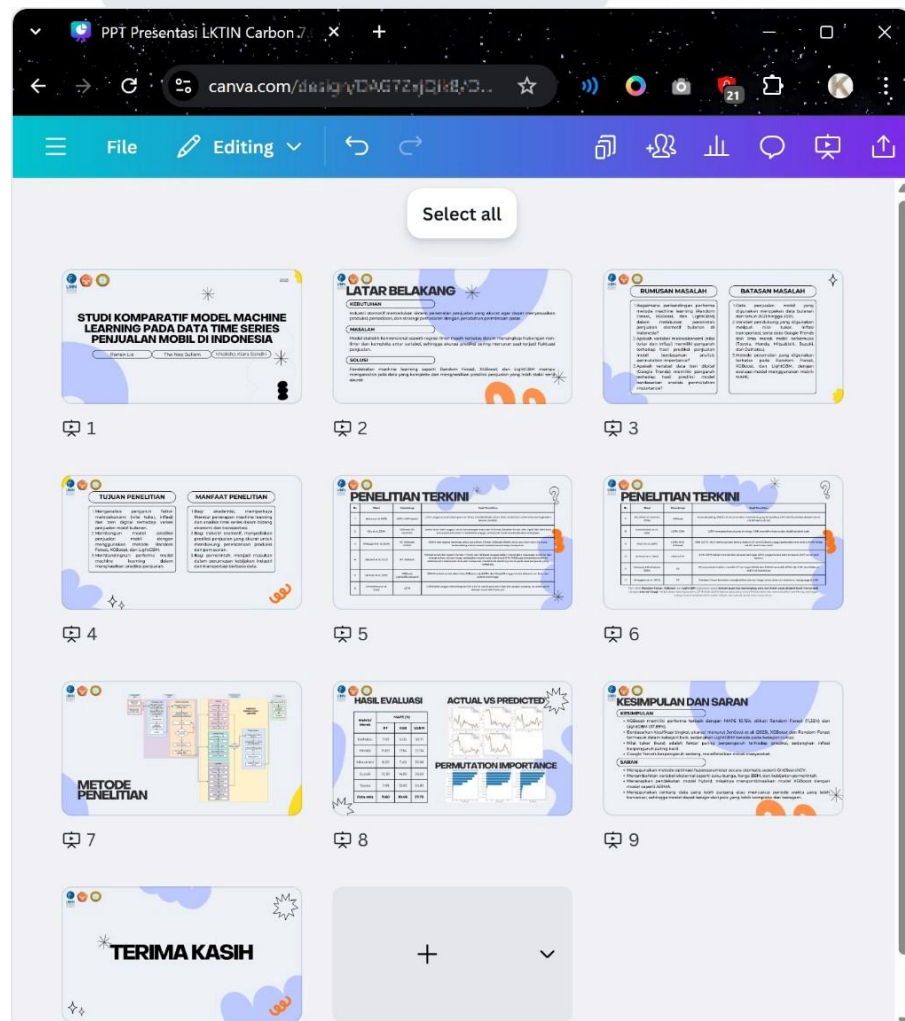
Gambar 3.14 Bukti pengisian *form* pengumpulan *full paper*

Kedua, setiap kelompok juga diwajibkan untuk mengirim email kepada penyelenggara lomba yang berisi *file* PDF *full paper*, seperti yang telah diunggah pada *form* pengumpulan. Terakhir, setelah

pengisian *form* dan pengiriman email selesai dilakukan, setiap perwakilan kelompok perlu memberikan konfirmasi kepada *contact person* LKTIN Carbon 7.0 bahwa *form* telah diisi, pembayaran registrasi telah dilakukan, dan email *full paper* telah dikirimkan. Melalui pelaksanaan tiga tahapan tersebut, proses registrasi serta pengumpulan *full paper* Gelombang II berhasil diselesaikan.

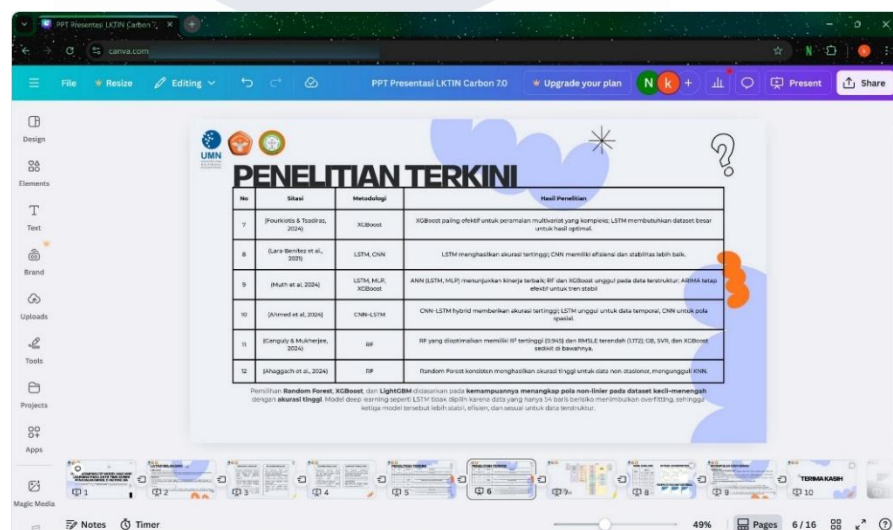
3.3.1.7 Pembuatan *Slide* Presentasi dan *Banner*

Pembuatan *slide* presentasi dan banner untuk LKTIN Carbon 7.0 dilakukan pada minggu ke-12. Pembuatan *slide* dan *banner* ini adalah tahap ketujuh dari pekerjaan *Road to Champion Program*. Setiap kelompok diberikan batas maksimal 10 halaman untuk *slide* presentasi.



Gambar 3.15 Hasil *Slide* Presentasi Menggunakan Canva (Total 10 Halaman)

Gambar 3.15 menunjukkan hasil *slide* presentasi yang dibuat menggunakan Canva, dengan batas maksimal 10 halaman. Untuk membuat *slide* presentasi dan *banner*, platform Canva digunakan karena performanya yang cepat dalam memuat dan menyimpan desain, serta mempermudah kerja sama antar anggota kelompok. Isi *slide* presentasi terdiri atas bagian pembukaan, penjelasan isi *full paper*, dan penutupan. Penjelasan isi *full paper* mencakup pembahasan mengenai latar belakang masalah, rumusan dan batasan masalah, tujuan dan manfaat penelitian, penelitian terkini, metode penelitian, hasil evaluasi beserta visualisasinya (termasuk perbandingan data aktual dengan data prediksi melalui *line graph* dan hasil *permutation importance*), serta kesimpulan dan saran. Gambar 3.16 menunjukkan salah satu *slide* presentasi yang telah dibuat terkait penelitian terkini.



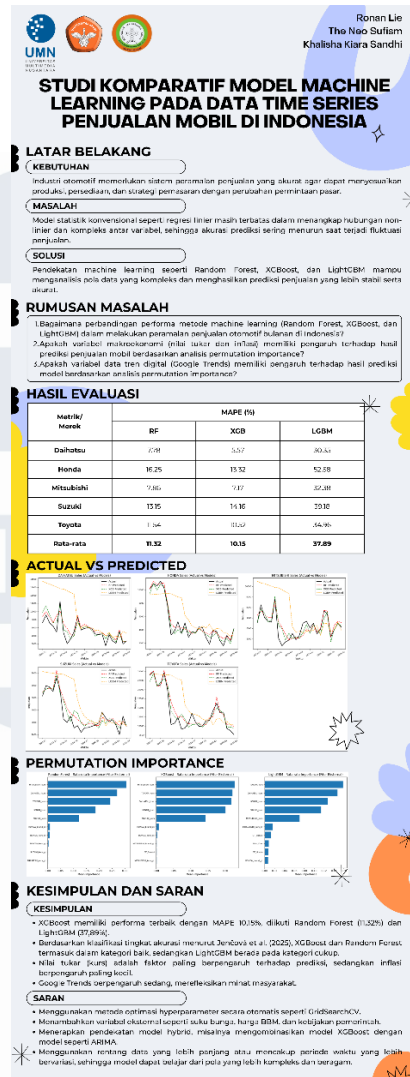
No	Referensi	Metode	Hasil Penelitian
7	(Pournazeri & Tashiro, 2024)	XGBoost	XGBoost paling efektif untuk pemilihan multibuat yang kompleks, LSTM membutuhkan dataset besar untuk hasil optimal.
8	(Lara Benito et al., 2023)	LSTM, CNN	LSTM menghasilkan akurasi tertinggi, CNN memiliki efisiensi dan stabilitas lebih baik.
9	(Muti et al., 2024)	LSTM, MLP, XGBoost	ANN (LSTM, MLP) menunjukkan kinerja terbaik, RF dan XGBoost unggul pada data terstruktur, AdaBoost efektif untuk tren tidak stabil.
10	(Shiroud et al., 2024)	CNN-LSTM	CNN-LSTM hybrid memberikan akurasi tertinggi, LSTM unggul untuk data temporal, CNN untuk pola spasial.
11	(Faragly & Mahmoud, 2024)	ML	RF yang dioptimalkan memiliki RF tertinggi (93%) dan RMSE terendah (0.772), GB, SVM, dan XGBoost berada di bawahnya.
12	(Khaghighi et al., 2024)	RF	Random Forest konsisten menghasilkan akurasi tinggi untuk data non-stasioner, menggunakan teknik.

Penelitian Random Forest, XGBoost, dan LightGBM didasarkan pada kemampuan menangkap pola non-linear pada dataset kecil-menengah dengan akurasi tinggi. Model deep learning seperti LSTM tidak dipilih karena data yang hanya 34 baris berisiko menimbulkan overfitting, sehingga setiap model tersebut lebih sesuai, efisien, dan akurat untuk data tersebut.

Gambar 3.16 Slide Presentasi untuk LKTIN Carbon 7.0

Selanjutnya, *banner* dapat berupa *banner* biasa atau *X-banner*, dengan ukuran wajib 160x60 cm. *Banner* yang telah dibuat menggunakan Canva, berisi materi yang sama dengan *slide* presentasi, namun lebih disederhanakan agar lebih mudah dibaca. Selain itu, tema yang digunakan untuk latar belakang *banner* juga disamakan dengan *slide* presentasi agar tampilan antara *slide* dan *banner* selaras. Gambar 3.17 menunjukkan hasil *banner* yang telah dibuat untuk Lomba Karya

Tulis Ilmiah Nasional (LKTIN) Carbon 7.0.



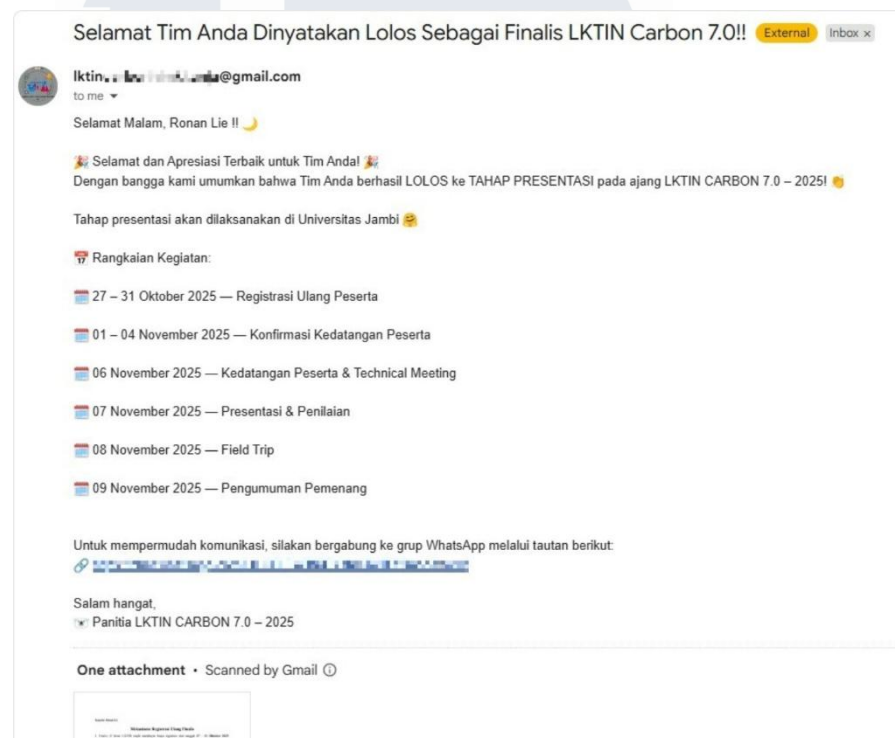
Gambar 3.17 Banner untuk LKTIN Carbon 7.0

Setelah pembuatan *slide* presentasi dan *banner* selesai, dilakukan latihan presentasi untuk mengatur pembagian penyampaian materi pada setiap *slide* presentasi. Selain itu, latihan presentasi juga dilakukan dengan pendampingan pembimbing lapangan melalui simulasi presentasi dan sesi tanya-jawab. Latihan ini bertujuan untuk mengevaluasi pemaparan materi, kesiapan dalam menghadapi pertanyaan yang berpotensi diajukan, serta meningkatkan kesiapan pelaksanaan presentasi lomba.

3.3.1.8 Pengumuman 10 Besar Finalis

Pengumuman 10 besar finalis berlangsung pada minggu ke-


12. Informasi pengumuman tersebut disampaikan secara resmi oleh penyelenggara Lomba Karya Tulis Ilmiah Nasional (LKTIN) tepatnya pada tanggal 25 Oktober 2025, melalui email yang dikirimkan kepada ketua kelompok. Pengumuman ini merupakan tahap kedelapan yang dilakukan pada pelaksanaan program *Road to Champion*. Gambar 3.18 menunjukkan bukti penerimaan email 10 besar finalis.



Gambar 3.18 Bukti penerimaan email 10 besar finalis

Pada tahap ini, ketua kelompok menerima email dari penyelenggara lomba yang berisi ucapan selamat atas lolosnya ke babak final, beserta beberapa informasi tambahan. Informasi tambahan tersebut mencakup alur pelaksanaan LKTIN Carbon 7.0 secara keseluruhan serta sebuah *file* PDF yang berisi informasi terkait biaya tambahan akomodasi yang perlu dibayar oleh peserta finalis selama kegiatan final di Jambi. Selain itu, pengumuman finalis ini juga diunggah melalui media sosial penyelenggara lomba, yaitu Instagram Carbon v7.0. Pada pengumuman tersebut, diumumkan bahwa kelompok dengan ketua yang bernama Ronan Lie, berhasil

menempati peringkat ketujuh dari sepuluh finalis yang lolos ke babak final. Gambar 3.19 menunjukkan pengumuman 10 besar finalis yang diunggah melalui *story* Instagram.



Gambar 3.19 Pengumuman 10 Besar Finalis melalui *story* Instagram Carbon v7.0

3.3.1.9 Registrasi Ulang dan Konfirmasi Kedatangan Peserta

Pada tahap kesembilan dari pelaksanaan pekerjaan program *Road To Champion*, tepatnya pada minggu ke-12, dilaksanakan proses registrasi ulang dan konfirmasi kedatangan peserta. Pertama, registrasi ulang dilakukan oleh salah satu anggota kelompok, melalui WhatsApp ke *contact person* LKTIN Carbon 7.0. Registrasi ulang ini dilakukan tepatnya pada tanggal 31 Oktober 2025, dengan mengirimkan bukti transfer biaya tambahan sebesar Rp. 764.000 per anggota kelompok. Gambar 3.20 menunjukkan detail biaya tambahan yang perlu dibayar oleh tiap peserta.

LAMPIRAN II

Berikut merupakan estimasi biaya selama peserta berada di Jambi.

FASILITAS	JUMLAH	BIAYA PER SATUAN (Rp.)	TOTAL (Rp.)
Penginapan	3 Hari	Rp. 125.000	Rp. 375.000
Konsumsi	5 x makan	Rp. 25.000	Rp. 125.000
<i>Snack</i>	2 x makan	Rp. 7.000	Rp. 14.000
<i>Souvenir</i>	1	Rp. 60.000	Rp. 60.000
ID Card + ATK	1	Rp. 40.000	Rp. 40.000
<i>Fieldtrip</i> + Transportasi	Selama di jambi	Rp. 150.000	Rp. 150.000
TOTAL BIAYA YANG DIBUTUHKAN			Rp. 764.000

Keterangan:

1. Biaya diatas merupakan biaya perindividu bukan tim.
2. Pembayaran dapat dilakukan melalui rekening Bank Mandiri atas nama [REDACTED] dengan nomor rekening [REDACTED], atau rekening Bank Mandiri atas nama [REDACTED] i dengan nomor rekening [REDACTED], maupun melalui DANA ke nomor [REDACTED] atas nama [REDACTED]
3. Biaya transportasi dari Perguruan Tinggi asal ke Universitas Jambi tidak ditanggung oleh panitia, melainkan ditanggung peserta/Perguruan Tinggi asal tiap masing-masing individu.

Gambar 3.20 Detail biaya tambahan LKTIN Carbon 7.0

Setelah mengirimkan bukti transfer, *contact person* LKTIN 2025 akan mengirimkan formulir kegiatan LKTIN Carbon 7.0, yang wajib diisi oleh setiap perwakilan kelompok. Isi dari formulir tersebut adalah data karya, asal instansi, data dosen pembimbing, data mahasiswa, riwayat penyakit yang diderita, dan alergi (makan/minum/obat). Kedua, konfirmasi kedatangan peserta dilakukan pada tanggal 4 November 2025 melalui pengisian formulir pada grup WhatsApp Finalis LKTIN Carbon 7.0. Formulir konfirmasi ini terdiri atas beberapa informasi yang perlu diisi oleh perwakilan kelompok, yaitu nama ketua kelompok, asal universitas, nomor *handphone* ketua kelompok, tanggal dan waktu kedatangan, serta lokasi penjemputan.

3.3.1.10 Pelaksanaan Final Lomba LKTIN Carbon 7.0 secara Langsung (*Onsite*)

Pada tahap kesepuluh dalam pelaksanaan pekerjaan program *Road to Champion*, dilakukan final lomba LKTIN Carbon 7.0 secara langsung (*onsite*) di Universitas Jambi. Tahap ini berlangsung pada minggu ke-13 dari pelaksanaan program, tepatnya pada tanggal 6 hingga 9 November 2025. Kedatangan peserta dan pertemuan teknis, presentasi dan penilaian, *fieldtrip*, dan pengumuman pemenang adalah beberapa acara yang dilakukan selama empat hari pelaksanaan final lomba LKTIN 2025 di Jambi.



Gambar 3.21 Dokumentasi kedatangan di Bandara Sultan Thaha Jambi

Pada hari pertama, 6 November 2025, rangkaian acara yang dilakukan adalah Kedatangan Peserta dan *Technical Meeting*. Kelompok Ronan Lie, The Neo Sufism, dan Khalisha Kiara Sandhi melakukan penerbangan selama 1 jam 20 menit dengan jadwal keberangkatan pukul 10.05 dari Bandara Soekarno-Hatta dan tiba di Bandara Sultan Thaha Jambi pada pukul 11.25, bersamaan dengan satu kelompok lain serta dosen pembimbing lapangan yang juga mengikuti babak final di Jambi. Gambar 3.21 menunjukkan dokumentasi kedatangan di Bandara Sultan Thaha Jambi.

Setibanya di Jambi, panitia Carbon 7.0 menjemput seluruh kelompok di bandara, kemudian mengantar kelompok-kelompok tersebut menuju Hotel Amanah. Setelah memasuki kamar, masing-masing anggota dapat merapikan barang bawaan, kemudian acara dilanjutkan dengan pelaksanaan ISHOMA atau istirahat, sholat, dan makan. Selanjutnya, *technical meeting* (TM) dilaksanakan pada pukul 19.30 hingga 22.00. *Technical meeting* ini berisi penyampaian aturan babak final, persyaratan presentasi, tata cara penilaian, urutan acara, serta sesi tanya jawab antara peserta dan panitia. Dokumentasi pelaksanaan *technical meeting* dapat dilihat pada Gambar 3.22.



Gambar 3.22 Dokumentasi pelaksanaan *technical meeting*.

Rangkaian acara final LKTIN 2025 berlanjut dengan pelaksanaan presentasi dan penilaian pada hari kedua, tepatnya pada tanggal 7 November 2025. Presentasi dan penilaian ini dilaksanakan di Universitas Jambi dari pukul 08.30 hingga 11.30. Sesuai dengan peringkat pada pengumuman 10 besar finalis yang diunggah melalui *story* Instagram, kelompok Ronan Lie, The Neo Sufism, dan Khalisha Kiara Sandhi berada pada urutan presentasi nomor 7. Setiap kelompok yang melakukan presentasi, diberikan total waktu 25 menit, dengan

pembagian waktu 10 menit sesi presentasi dan 15 menit sesi tanya jawab. Presentasi dilakukan dengan pembagian 3 hingga 4 *slide* per anggota kelompok, dari total 10 *slide*. Gambar 3.23 menunjukkan dokumentasi proses presentasi dan penilaian di Universitas Jambi.



Gambar 3.23 Dokumentasi proses presentasi dan penilaian di Universitas Jambi.

Setelah sesi presentasi atau penyampaian materi selesai dilakukan, juri akan diberi kesempatan untuk mengajukan beberapa pertanyaan kepada peserta, sehingga peserta memberikan jawaban sesuai dengan apa yang telah dikerjakan. Salah satu pertanyaan yang diajukan oleh juri berkaitan dengan dasar penentuan bahwa akurasi model yang didapatkan, sudah termasuk dalam kategori baik. Pertanyaan tersebut dijawab dengan merujuk pada penelitian sebelumnya, yang menjelaskan bahwa nilai $MAPE \leq 10\%$ dianggap sangat akurat, 10-20% dianggap baik, 20-50% dianggap cukup, dan $>50\%$ dianggap tidak akurat [22].

Berdasarkan standar tersebut, MAPE dari model XGBoost (10,48%) dan Random Forest (11,60%) termasuk kategori baik, sedangkan LightGBM (37,70%) termasuk pada kategori cukup. Setelah sesi tanya jawab selesai, kelompok kembali ke tempat duduk. Kemudian, setelah semua kelompok selesai melakukan presentasi, panitia mengarahkan semua peserta untuk melakukan foto bersama.

Gambar 3.24 menunjukkan dokumentasi LKTIN 2025 setelah presentasi.



Gambar 3.24 Dokumentasi LKTIN 2025 Setelah Pelaksanaan Presentasi

Pada hari ketiga, tepatnya pada tanggal 8 November 2025, rangkaian acara dilanjutkan dengan pelaksanaan *Field Trip*. Pertama, seluruh peserta dibawa ke Museum Sinjai, namun karena museum masih tutup, peserta dialihkan ke Candi Muaro Jambi. Di lokasi tersebut, seluruh peserta mengikuti rangkaian kegiatan yang disediakan, termasuk mengunjungi warung kopi serta area penjualan souvenir dan makanan, yang menggunakan alat transaksi berbentuk kayu. Setelah itu, acara dilanjutkan dengan mengunjungi toko oleh-oleh khas Jambi. Kemudian, acara hari ketiga tersebut diakhiri dengan agenda *free night*.

Pada hari keempat, 9 November 2025, Pengumuman Pemenang diadakan dari pukul 09.20 hingga 09.40. Sebelum diumumkannya pemenang LKTIN 2025, acara hari keempat diawali dengan beberapa rangkaian kegiatan, seperti sambutan dari perwakilan penting, pembacaan doa, dan pertunjukan tari tradisional. Selanjutnya, dilaksanakan pengumuman pemenang LKTIN Carbon, yang terdiri atas 7 kategori: *Juara 1*, *Juara 2*, *Juara 3*, *Best Poster 1*, *Best Poster 2*, *Best Team Presentation 1*, dan *Best Team Presentation 2*. Setelah beberapa nama disebutkan, kelompok Ronan Lie, The Neo

Sufism, dan Khalisha Kiara Sandhi berhasil meraih penghargaan *Best Team Presentation 2* dan menerima sertifikat serta uang pembinaan. Gambar 3.25 menunjukkan dokumentasi penyerahan sertifikat *Best Team Presentation 2* kepada ketua kelompok.

Setelah itu, kegiatan dilanjutkan dengan *talkshow* yang disampaikan oleh Kevin Lius Bong dan Faris Akbar. Setelah *talkshow* selesai, seluruh peserta diantarkan kembali ke penginapan untuk merapikan barang dan bersiap diri untuk pulang ke daerah masing-masing. Kelompok Ronan Lie, The Neo Sufism, dan Khalisha Kiara Sandhi, bersama dosen pembimbing lapangan dan dua kelompok lain dari Universitas Multimedia Nusantara, kemudian melakukan penerbangan pulang, yang berlangsung selama 2 jam 40 menit, mulai pukul 18:50 hingga 20:10.



Gambar 3.25 Penyerahan sertifikat *Best Team Presentation 2*

3.3.1.11 Evaluasi Tambahan Model XGBoost Pasca-Lomba dengan *Stacking Ensemble*

Setelah lomba selesai dilaksanakan, dilakukan tahap evaluasi

tambahan untuk meningkatkan akurasi model XGBoost dalam memprediksi penjualan mobil. Tahap merupakan tahap terakhir yang berlangsung pada minggu ke-14 hingga minggu ke-17 dari pelaksanaan Program *Road to Champion*. Tujuan dari evaluasi tambahan ini adalah untuk menilai kemampuan model terhadap data aktual, meningkatkan kinerja prediksi, dan membandingkan hasil prediksi XGBoost dengan kombinasi model lain dalam pendekatan *stacking ensemble*. Pendekatan *stacking ensemble* dipilih karena penelitian sebelumnya menunjukkan bahwa metode *ensemble learning*, terutama *stacking*, secara konsisten meningkatkan akurasi prediksi penjualan dibandingkan algoritma tunggal [23].

Metode *stacking ensemble* adalah pendekatan *ensemble learning* yang menggabungkan lebih dari satu algoritma dasar untuk meningkatkan akurasi prediksi [24]. Metode *stacking ensemble* ini terdiri dari dua level pemodelan, yaitu level 0 (*base learner*) dan level 1 (*meta learner*) [25]. Pada level 0 (*base learner*), setiap model menghasilkan prediksi awal berdasarkan data yang tersedia. Selanjutnya, pada level 1, prediksi dari masing-masing *base learner* digunakan sebagai input oleh *meta learner* untuk mempelajari pola lebih lanjut dan menghasilkan prediksi akhir yang optimal [26].

Pada tahap evaluasi tambahan ini, tiga model (XGBoost, Random Forest, dan LightGBM) digunakan sebagai *base learner*. Ketiga model diterapkan melalui beberapa skenario untuk memprediksi penjualan setiap *brand* mobil menggunakan pendekatan *rolling forecast*, sehingga performanya dapat dibandingkan secara langsung dengan pendekatan utama berbasis XGBoost yang telah digunakan sebelumnya. Skenario optimasi model XGBoost yang dilakukan meliputi: *stacking* ketiga model sekaligus (XGBoost, Random Forest, dan LightGBM), *stacking* XGBoost dan Random Forest, serta *stacking* XGBoost dan LightGBM.

Setelah prediksi awal diperoleh dari masing-masing *base learner*, hasil prediksi tersebut digunakan sebagai input bagi *meta learner*.

learner, yaitu Linear Regression. Model ini dipilih sebagai *meta learner* karena penelitian sebelumnya yang menyebutkan bahwa linear regression efektif untuk masalah regresi [27], termasuk prediksi angka penjualan mobil. Dalam setiap skenario *stacking*, linear regression berperan dalam menggabungkan prediksi dari *base learner* untuk mempelajari pola secara optimal dan menghasilkan prediksi akhir yang lebih akurat. Setiap *base learner* tetap menggunakan parameter yang sama seperti yang diterapkan dalam penelitian *full paper* untuk lomba LKTIN.

Selanjutnya, semua model dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE). Evaluasi dilakukan pada empat model, yaitu model XGBoost_Baseline (prediksi langsung dari *base learner* XGBoost tanpa proses *stacking*, sebagai acuan utama), XGB_RF_LGBM_Stacking (*stacking* XGBoost, Random Forest, dan LightGBM), XGB_RF_Stacking (*stacking* XGBoost dan Random Forest), dan XGB_LGBM_Stacking (*stacking* XGBoost dan LightGBM). Nilai MAPE untuk setiap *brand* pada masing-masing model kemudian dimasukkan ke dalam sebuah *dataframe* dan digabungkan menjadi satu tabel sehingga hasil dapat dibandingkan dengan mudah. Selain itu, untuk menemukan model dengan akurasi terbaik, dilakukan perhitungan rata-rata nilai MAPE dari masing-masing model, menggunakan fungsi `.mean()` pada Python. Tabel hasil MAPE untuk setiap *brand* pada masing-masing model, bersama dengan nilai rata-rata MAPE untuk masing-masing model, ditampilkan pada Gambar 3.26.

Model Brand	XGB_Baseline	XGB_RF_LGBM_Stacking	XGB_RF_Stacking	XGB_LGBM_Stacking
DAIHATSU	6.054	4.931	5.260	4.946
HONDA	13.142	13.080	13.127	13.063
MITSUBISHI	7.400	6.071	7.108	6.611
SUZUKI	14.851	9.584	11.207	12.846
TOYOTA	10.954	9.250	10.374	9.625
Rata-Rata	10.480	8.583	9.415	9.418

Gambar 3.26 Tabel Hasil MAPE Setiap *Brand* pada Setiap Model

Gambar 3.26 menunjukkan bahwa model XGB_RF_LGBM_Stacking memperoleh nilai rata-rata MAPE terendah, yaitu 8,58%, sehingga menjadi model dengan performa terbaik pada tahap evaluasi tambahan. Model XGB_RF_LGBM_Stacking ini merupakan model yang menggunakan XGBoost, Random Forest, dan LightGBM sebagai *base learner* untuk menghasilkan prediksi awal, yang selanjutnya diproses oleh *meta learner* Linear Regression. Hasil ini menunjukkan bahwa penggabungan prediksi ketiga algoritma sebagai base learner mampu meningkatkan akurasi prediksi dibandingkan dengan penggunaan model XGBoost secara individu (tunggal), seperti yang dapat dilihat pada model XGB_Baseline, yang hanya memperoleh nilai rata-rata MAPE 10.48%.

Selain itu, dua skenario *stacking* lainnya, yaitu XGB_RF_Stacking dan XGB_LGBM_Stacking, juga menunjukkan peningkatan kinerja dibandingkan model *baseline*, dengan nilai rata-rata MAPE masing-masing sebesar 9,42%. Meskipun performanya masih berada di bawah model XGB_RF_LGBM_Stacking, kedua skenario tersebut tetap membuktikan bahwa penggabungan prediksi dari lebih dari satu *base learner* memberikan kontribusi positif terhadap akurasi model.

Setelah penerapan *stacking ensemble*, hampir semua *brand* mobil mengalami penurunan nilai MAPE. Peningkatan akurasi paling signifikan terjadi pada *brand* Suzuki, di mana nilai MAPE menurun dari 14,85% pada model XGBoost_Baseline menjadi 9,58% pada model XGB_RF_LGBM_Stacking. Hasil ini menunjukkan bahwa *stacking ensemble* lebih mampu menangkap pola fluktuatif pada data penjualan dibandingkan penggunaan model tunggal.

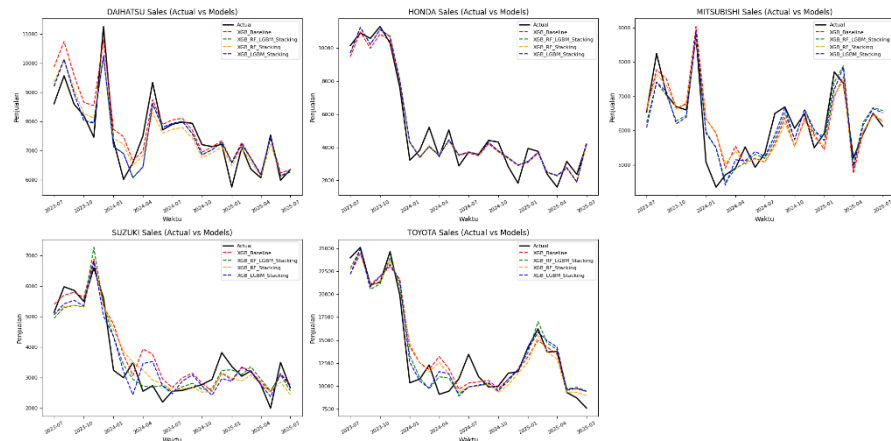
Model	Rata-rata MAPE	Kategori Akurasi
XGB_Baseline	10.48 %	Baik
XGB_RF_LGBM_Stacking	8.58 %	Sangat Akurat
XGB_RF_Stacking	9.42 %	Sangat Akurat
XGB_LGBM_Stacking	9.42 %	Sangat Akurat

Gambar 3.27 Kategori Nilai Akurasi Berdasarkan Nilai MAPE

Menurut penelitian sebelumnya, nilai MAPE dapat digunakan sebagai referensi untuk menilai tingkat akurasi, di mana akurasi $\leq 10\%$ dianggap sangat akurat, 10-20% dianggap baik, 20-50% dianggap cukup, dan $>50\%$ dianggap tidak akurat [22]. Berdasarkan kategori tersebut, ketiga model dengan penerapan *stacking ensemble* (XGB_RF_LGBM_Stacking, XGB_RF_Stacking, dan XGB_LGBM_Stacking) termasuk dalam kategori sangat akurat, sedangkan model XGBoost_Baseline termasuk pada kategori baik. Hasil evaluasi ini menegaskan bahwa penerapan *stacking ensemble* berhasil mengoptimalkan model XGBoost dalam prediksi penjualan mobil berbasis *time series*. Gambar 3.27 menunjukkan kategori nilai akurasi berdasarkan nilai MAPE untuk keempat model.

Sebagai tambahan, dilakukan visualisasi menggunakan *line graph* untuk membandingkan hasil prediksi yang telah dilakukan oleh keempat model (XGBoost_Baseline, XGB_RF_LGBM_Stacking, XGB_RF_Stacking, dan XGB_LGBM_Stacking) dengan data aktual dari *dataset*. Visualisasi ini dilakukan untuk memudahkan pengamatan performa masing-masing model dalam mengikuti tren penjualan setiap *brand* sepanjang waktu, sekaligus menilai seberapa dekat keempat model berhasil memprediksi penjualan, dengan nilai aktual. Gambar 3.28 menunjukkan visualisasi perbandingan hasil prediksi keempat model dengan data aktual. Pada gambar tersebut, garis hitam menunjukkan data aktual, sedangkan garis berwarna menunjukkan prediksi dari masing-masing model. Model XGBoost_Baseline ditunjukkan oleh garis berwarna merah,

XGB_RF_LGBM_Stacking oleh garis berwarna hijau, XGB_RF_Stacking oleh garis berwarna oranye, dan XGB_LGBM_Stacking oleh garis berwarna biru.



Gambar 3.28 Visualisasi Perbandingan Nilai Hasil Prediksi dan Nilai Aktual

Berdasarkan visualisasi pada Gambar 3.28, model XGB_RF_LGBM_Stacking (garis berwarna hijau) terlihat paling konsisten dalam mengikuti tren penjualan pada data aktual, termasuk pada periode dengan kenaikan atau penurunan penjualan yang cukup tajam. Model XGB_RF_Stacking (garis berwarna oranye) dan XGB_LGBM_Stacking (garis berwarna biru) juga menunjukkan performa prediksi yang cukup baik, meskipun masih terdapat beberapa titik prediksi yang belum sepenuhnya mengikuti pola data aktual. Sementara itu, model XGBoost_Baseline (garis berwarna merah) terlihat paling tidak akurat, terutama ketika ada perubahan besar yang membuat prediksinya tidak mengikuti pola data yang sebenarnya. Hasil visualisasi ini mendukung hasil evaluasi MAPE sebelumnya, bahwa metode *stacking ensemble* mampu meningkatkan akurasi dan stabilitas prediksi model XGBoost.

Selain itu, fokus utama evaluasi tambahan ini tetap pada XGBoost sebagai model *baseline* yang dioptimalkan melalui pendekatan *stacking ensemble*. Meskipun tiga algoritma digunakan sebagai base learner, yaitu XGBoost, Random Forest, dan LightGBM, penggunaan Random Forest dan LightGBM lebih difokuskan sebagai model pembanding untuk mengevaluasi apakah algoritma lain dapat

menghasilkan performa prediksi yang sebanding dalam peramalan time series penjualan mobil. Pendekatan ini bertujuan untuk memastikan bahwa peningkatan akurasi yang diperoleh berasal dari optimasi model XGBoost melalui mekanisme *stacking*, dan bukan hanya dari penggunaan algoritma lain.

Berdasarkan semua tahapan evaluasi tambahan yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *stacking ensemble* mampu mengoptimalkan kinerja model XGBoost dalam melakukan prediksi penjualan mobil berbasis time series. Penggabungan beberapa base learner, khususnya kombinasi XGBoost, Random Forest, dan LightGBM, terbukti menghasilkan prediksi yang lebih akurat dan stabil dibandingkan penggunaan model XGBoost secara tunggal. Hasil evaluasi menggunakan MAPE yang didukung oleh visualisasi perbandingan antara prediksi dan data aktual menunjukkan bahwa model XGB_RF_LGBM_Stacking secara konsisten memberikan performa terbaik, sehingga metode *stacking ensemble* dapat dijadikan pendekatan yang efektif dan relevan untuk meningkatkan akurasi prediksi penjualan mobil.

3.3.2 Kendala yang Ditemukan

Selama menjalankan kegiatan dalam PRO-STEP: *Road to Champion Program*, terdapat beberapa tantangan yang muncul. Berikut adalah beberapa dari tantangan tersebut: Beberapa kendala tersebut dijelaskan sebagai berikut:

1. Mengalami kendala dalam menerapkan metode *forecasting time series* karena materi tersebut sudah cukup lama tidak dipraktikkan secara langsung. Hal ini membuat proses pembuatan model membutuhkan waktu tambahan untuk meninjau kembali konsep dasar, jenis-jenis metode prediksi, dan alur kerja model.
2. Kesulitan dalam memilih model *forecasting time series* karena ukuran *database* yang kecil, sedangkan sebagian besar model *forecasting time series* umumnya membutuhkan jumlah data yang besar untuk melatih data dan menghasilkan akurasi yang stabil. Kondisi ini mendorong perlunya analisis tambahan agar model tetap efektif dalam

melakukan prediksi pada data yang terbatas.

3. Menghadapi tantangan dalam penerapan algoritma XGBoost karena belum pernah memiliki pengalaman secara langsung dalam pengimplementasiannya. Dengan kurangnya pemahaman mengenai cara kerja, struktur parameter, dan teknik optimasi, proses penerapan algoritma ini membutuhkan waktu yang lebih banyak dalam pengimplementasian modelnya.
4. Mengalami kesulitan terkait *ensemble learning*, karena sebelumnya hanya mengetahui bahwa *ensemble learning* merupakan gabungan beberapa model, namun belum memahami konsep, jenis-jenis metode, dan mekanisme kerjanya secara rinci. Hal ini menyebabkan kesulitan dalam menentukan metode yang paling tepat untuk digunakan pada evaluasi tambahan pasca-lomba.
5. Belum familier dan belum memiliki pengalaman dalam menerapkan *stacking ensemble* pada *ensemble learning*, sehingga kesulitan dalam memahami cara kerja *stacking*, struktur model, serta bagaimana prediksi dari beberapa model digabung sehingga dapat meningkatkan akurasi model.

3.3.3 Solusi atas Kendala yang Ditemukan

Sebagai tindak lanjut atas kendala yang muncul selama pelaksanaan program, diterapkan beberapa strategi penyelesaian untuk memastikan proses pengerjaan dapat berjalan secara efektif. Adapun solusi yang dilakukan adalah sebagai berikut:

1. Mempelajari kembali materi *forecasting time series* melalui berbagai sumber pembelajaran yang dapat diakses melalui Google, seperti jurnal akademik, artikel *online*, dan dokumentasi resmi, sehingga materi tersebut dapat diterapkan secara langsung dalam percobaan dan pengerjaan asli pembuatan model.
2. Melakukan riset untuk mempelajari penelitian-penelitian sebelumnya yang menggunakan metode *forecasting time series* dengan kondisi data serupa, menggunakan platform Google. Hal ini dilakukan untuk mengidentifikasi model yang dapat memberikan akurasi baik

meskipun jumlah data terbatas.

3. Melakukan pembelajaran mandiri melalui dokumentasi resmi XGBoost, yang menyediakan penjelasan lengkap mengenai parameter, struktur model, cara optimasi, dan masih banyak informasi lainnya. Selain itu, dilakukan juga pembelajaran mandiri melalui referensi *online*, termasuk artikel ilmiah dan beberapa *website* terkait, sehingga pemahaman terhadap cara kerja XGBoost meningkat dan proses implementasinya dapat dilakukan dengan lebih efektif.
4. Mempelajari konsep, jenis-jenis metode, serta prinsip dasar penggabungan beberapa model terkait *ensemble learning*. Pembelajaran dilakukan melalui beberapa referensi online (contohnya *website* GeeksforGeeks), jurnal, dan artikel ilmiah, sehingga dapat ditentukan jenis metode *ensemble learning* yang paling sesuai untuk digunakan dalam evaluasi tambahan pasca-lomba.
5. Untuk mengatasi kendala dalam penerapan *stacking ensemble*, dilakukan pembelajaran mandiri melalui referensi *online* dan juga jurnal ilmiah mengenai cara kerja *stacking*, struktur model, dan prosedur penggabungan prediksi dari beberapa *base model* sehingga dapat dilakukan percobaan latihan dan diimplementasikan dengan benar.

3.4 Hasil Lomba/Kompetisi

Setelah berpartisipasi dalam Lomba Karya Tulis Ilmiah Nasional (LKTI) 2025 yang diselenggarakan oleh Carbon 7.0 dari Universitas Jambi, kelompok *Road To Champion* Khalisha Kiara Sandhi, The Neo Sufism, dan Ronan Lie, berhasil mendapatkan sertifikat penghargaan *Best Team Presentation 2*. Kelompok yang mendapatkan penghargaan akan mendapatkan sertifikat sesuai dengan jumlah anggota kelompoknya, sehingga nama setiap anggota kelompok tertera pada sertifikat masing-masing. Penghargaan ini juga disertai dengan penyerahan uang pembinaan sebesar Rp150.000, sebagai apresiasi atas upaya dan prestasi yang dicapai kelompok. Gambar 3.29 memperlihatkan sertifikat *Best Team Presentation 2* yang diberikan kepada salah satu anggota kelompok, yaitu Khalisha Kiara Sandhi.



Gambar 3.29 Sertifikat *Best Team Presentation* 2

Selain itu, lomba ini juga menghasilkan banyak pengalaman berguna selama penyelenggaraan lomba pada tanggal 25 September hingga 9 November 2025, khususnya pada 4 hari pelaksanaan acara final. Beberapa pengalaman berguna yang didapatkan di antaranya: mendapatkan kesempatan untuk mempresentasikan hasil pembuatan model dan karya tulis ilmiah melalui *slide* presentasi dan juga *banner*, menambah kemampuan *public speaking* melalui pelaksanaan presentasi, menambah wawasan melalui pemaparan karya tulis ilmiah yang dibuat oleh kelompok lain, serta menambah relasi melalui interaksi antar peserta lomba.