



KERJA PRAKTIK - EF234603

**Penerapan Algoritma Traveling Salesman Problem, Vehicle Routing Problem, dan Clustering dalam Meningkatkan Efisiensi Pengelolaan Pajak Kendaraan Bermotor di Badan Pendapatan Daerah Provinsi Jawa Timur**

Departemen Teknik Informatika - ITS

Jalan Teknik Kimia, Sukolilo, Kota Surabaya, Jawa Timur, 60111

Periode: 8 Agustus 2024 – 8 November 2024

**Oleh:**

Anggara Saputra

5025211241

**Pembimbing Jurusan**

Fajar Baskoro, S.Kom., M.T.

**Pembimbing Lapangan**

Irfanur Ilham Febriansyah

**DEPARTEMEN TEKNIK INFORMATIKA**

Fakultas Teknologi Elektro dan Informatika Cerdas

Institut Teknologi Sepuluh Nopember

Surabaya 2024

*[Halaman ini sengaja dikosongkan]*



*[Halaman ini sengaja dikosongkan]*

## DAFTAR ISI

<b>DAFTAR ISI .....</b>	<b>v</b>
<b>DAFTAR GAMBAR.....</b>	<b>viii</b>
<b>DAFTAR TABEL .....</b>	<b>ix</b>
<b>DAFTAR PERSAMAAN .....</b>	<b>x</b>
<b>DAFTAR KODE SUMBER.....</b>	<b>xi</b>
<b>LEMBAR PENGESAHAN .....</b>	<b>xii</b>
<b>ABSTRAK.....</b>	<b>xiv</b>
<b>KATA PENGANTAR .....</b>	<b>xvi</b>
<b>BAB 1 PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	2
1.3 Tujuan .....	2
1.3.1 Tujuan Umum.....	2
1.3.2 Tujuan Khusus .....	3
1.4 Manfaat .....	3
1.4.1 Manfaat Bagi Mahasiswa .....	3
1.4.2 Manfaat Bagi Perguruan Tinggi .....	3
1.4.3 Manfaat Bagi Instansi .....	3
<b>BAB 2 GAMBARAN UMUM TEMPAT KERJA PRAKTIK.....</b>	<b>5</b>
2.1 Profil Badan Pendapatan Daerah Provinsi Jawa Timur.....	5
2.2 Sejarah Badan Pendapatan Daerah Provinsi Jawa Timur.....	5
2.3 Visi dan Misi Badan Pendapatan Daerah Provinsi Jawa Timur .....	6
2.3.1 Visi.....	6
2.3.2 Misi.....	6
2.4 Struktur Organisasi Badan Pendapatan Daerah Provinsi Jawa Timur.....	6
2.5 Tugas Pokok, Fungsi, dan Wewenang Badan Pendapatan Daerah Provinsi Jawa Timur .....	8
2.5.1 Tugas Pokok .....	9
2.5.2 Fungsi .....	9
2.5.3 Wewenang .....	9
<b>BAB 3 PELAKSANAAN KERJA PRAKTIK.....</b>	<b>10</b>
3.1 Waktu dan Tempat Pelaksanaan Kerja Praktik .....	10

3.2	Ruang Lingkup Kerja Praktik.....	10
3.2.1	Analisa Data Pajak Kendaraan Bermotor (PKB) .....	11
3.2.2	Traveling Salesman Problem (TSP) dan Vehicle Routing Problem (VRP) .	11
3.2.3	Clustering Pajak Kendaraan Bermotor (PKB).....	12
3.3	Metodologi Penyelesaian Tugas Khusus .....	12
3.3.1	Sumber Data .....	12
3.3.2	Metode Analisis .....	13
3.3.2.1	Statistika Deskriptif .....	13
3.3.2.2	Data Preprocessing .....	13
3.3.2.3	Traveling Salesman Problem .....	13
3.3.2.4	Vehicle Routing Problem.....	14
3.3.2.5	Clustering .....	14
3.3.2.6	K-Means .....	15
3.3.2.7	Manhattan Distance .....	16
3.3.2.8	Particle Swarm Optimization.....	16
3.3.3	Langkah Analisis .....	17
3.3.3.1	Analisis Data Pajak Kendaraan Bermotor .....	17
3.3.3.2	Pengembangan TSP dan VRP .....	18
3.3.3.2.1	Traveling Salesman Problem.....	19
3.3.3.2.2	Vehicle Routing Problem.....	20
3.3.3.3	Analisis Clustering .....	21
<b>BAB 4</b>	<b>HASIL KERJA PRAKTIK.....</b>	<b>22</b>
4.1	Hasil Analisis Data Pajak Kendaraan Bermotor.....	22
4.1.1	Hasil Preprocessing Data.....	22
4.1.2	Hasil Analisis Distribusi Geografis .....	23
4.1.3	Hasil Analisis Keterlambatan Pembayaran Pajak .....	24
4.2	Hasil Implementasi TSP dan VRP.....	25
4.2.1	Hasil Implementasi dan Analisis TSP .....	25
4.2.2	Hasil Implementasi dan Analisis VRP .....	27
4.3	Hasil Analisis Clustering PKB .....	31
4.3.1	Hasil Analisis Permasalahan PKB.....	31
4.3.2	Pemilihan Fitur .....	31
4.3.3	Hasil Implementasi Elbow Method .....	32

4.3.4	Hasil Implementasi K-Means Clustering .....	33
4.3.5	Hasil Implementasi Label Encoding Euclidian Distance .....	35
4.3.6	Hasil Implementasi Frequency Encoding Manhattan Distance.....	36
4.4	Hasil Analisis Strategi Baru untuk PKB.....	38
4.4.1	Hasil Analisis Strategi Baru dengan Pemberian Diskon .....	38
4.4.1.1	Strategi 1: Subtraksi Sama Rata.....	39
4.4.1.2	Strategi 2: Subtraksi Bertingkat.....	39
<b>BAB 5</b>	<b>KESIMPULAN DAN SARAN.....</b>	<b>41</b>
5.1	Kesimpulan .....	41
5.2	Saran .....	41
	<b>DAFTAR PUSTAKA.....</b>	<b>42</b>
	<b>BIODATA PENULIS .....</b>	<b>44</b>

## DAFTAR GAMBAR

Gambar 2.1 Struktur Organisasi Badan Pendapatan Daerah Provinsi Jawa Timur .....	8
Gambar 3.1 Contoh Clustering (Jain, 2009) .....	15
Gambar 3.2 Flowchart Analisis Data PKB .....	18
Gambar 3.3 Flowchart Traveling Salesman Problem .....	19
Gambar 3.4 Flowchart Vehicle Routing Problem.....	20
Gambar 3.5 Flowchart Clustering Menggunakan K-Means .....	21
Gambar 4.1 Contoh Baris Data dengan Missing Values .....	23
Gambar 4.2 Distribusi Kecamatan pada Data PKB .....	23
Gambar 4.3 Distribusi Keterlambatan Pembayaran PKB.....	24
Gambar 4.4 Hasil Visualisasi TSP .....	27
Gambar 4.5 Hasil Visualisasi VRP .....	30
Gambar 4.6 Matriks Korelasi Antar Fitur .....	32
Gambar 4.7 Hasil Implementasi Elbow Method.....	33
Gambar 4.8 Hasil Visualisasi Kluster Menggunakan K-Means Clustering .....	35
Gambar 4.9 Hasil Visualisasi Kluster Menggunakan Euclidian Distance.....	36
Gambar 4.10 Hasil Visualisasi Kluster Menggunakan Manhattan Distance .....	38
Gambar 4.11 Hasil dari Strategi 1 .....	39
Gambar 4.12 Hasil dari Strategi 2.....	40

## DAFTAR TABEL

Tabel 3.1 Jadwal Kegiatan Kerja Praktik .....	10
Tabel 3.2 Contoh Data PKB .....	12

## DAFTAR PERSAMAAN

Persamaan (3.1) Formula Matematis TSP .....	14
Persamaan (3.2) Formula Objektif TSP .....	14
Persamaan (3.3) Formula Matematis VRP .....	14
Persamaan (3.4) Formula Objektif VRP .....	14
Persamaan (3.5) Centroid Baru .....	16
Persamaan (3.6) Manhattan Distance .....	16
Persamaan (3.7) Menghitung Kecepatan pada PSO .....	17
Persamaan (3.8) Menghitung Posisi pada PSO.....	17

## DAFTAR KODE SUMBER

Kode Sumber 4.1 Fungsi Perhitungan Matriks Jarak .....	25
Kode Sumber 4.2 Implementasi Algoritma TSP .....	26
Kode Sumber 4.3 Implementasi Visualisasi Rute TSP.....	27
Kode Sumber 4.4 Fungsi Perhitungan Matriks Jarak dengan Nilai Rate .....	28
Kode Sumber 4.5 Konversi Menjadi Format Numerik.....	28
Kode Sumber 4.6 Implementasi Pembagian Lokasi untuk Beberapa Kendaraan .....	29
Kode Sumber 4.7 Implementasi Pencarian Rute Optimal .....	29
Kode Sumber 4.8 Implementasi Pencarian Jalur Berkendara.....	30
Kode Sumber 4.9 Implementasi Elbow Method.....	33
Kode Sumber 4.10 Implementasi K-Means Clustering .....	34
Kode Sumber 4.11 Penghapusan Outliers Menggunakan IQR.....	34
Kode Sumber 4.12 Implementasi Label Encoding Euclidian Distance .....	36
Kode Sumber 4.13 Implementasi Frequency Encoding Manhattan Distance .....	37

**LEMBAR PENGESAHAN  
KERJA PRAKTIK**

**Penerapan Algoritma Traveling Salesman Problem, Vehicle Routing Problem,  
dan Clustering dalam Meningkatkan Efisiensi Pengelolaan Pajak Kendaraan  
Bermotor di Badan Pendapatan Daerah Provinsi Jawa Timur**

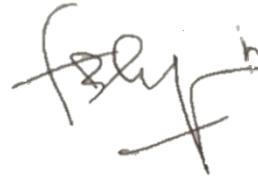
Oleh:

Anggara Saputra

5025211241

Disetujui oleh Pembimbing Kerja Praktik:

1. Fajar Baskoro, S.Kom., M.T.  
NIP. 197404031999031002



(Pembimbing Departemen)

2. Irfanur Ilham Febriansyah



(Pembimbing Lapangan)

*[Halaman ini sengaja dikosongkan]*

## **Penerapan Algoritma Traveling Salesman Problem, Vehicle Routing Problem, dan Clustering dalam Meningkatkan Efisiensi Pengelolaan Pajak Kendaraan Bermotor di Badan Pendapatan Daerah Provinsi Jawa Timur**

Nama Mahasiswa : Anggara Saputra  
NRP : 5025211241  
Departemen : Teknik Informatika FTEIC-ITS  
Pembimbing Departemen : Fajar Baskoro S.Kom., M.T.  
Pembimbing Lapangan : Irfanur Ilham Febriansyah

### **ABSTRAK**

Kerja praktik ini bertujuan untuk memberikan solusi terhadap permasalahan yang dihadapi oleh Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur dalam pengelolaan Pajak Kendaraan Bermotor (PKB). Dalam analisis data PKB, ditemukan bahwa 48,8% pembayaran dilakukan terlambat, yang menunjukkan adanya tingkat keterlambatan yang signifikan dalam pembayaran pajak kendaraan. Selain itu, distribusi kontribusi PKB antar kecamatan di wilayah UPT menunjukkan ketimpangan, di mana Kecamatan Tambaksari memberikan kontribusi terbesar sebesar 27%, sementara kecamatan seperti Gunung Anyar hanya menyumbang 8,1%. Untuk mengatasi permasalahan ini, dilakukan implementasi model optimasi rute seperti *Traveling Salesman Problem* (TSP) dan *Vehicle Routing Problem* (VRP) untuk meningkatkan efisiensi pengumpulan pajak, serta penerapan teknik *clustering* untuk segmentasi wajib pajak berdasarkan keterlambatan pembayaran dan nilai PKB. Hasil analisis *clustering* menunjukkan bahwa pengelompokan wajib pajak berdasarkan karakteristik tertentu memungkinkan penetapan kebijakan yang lebih tepat sasaran, dengan total lima kluster optimal yang dapat menjadi target prioritas dalam penagihan pajak. Selain itu, strategi pemberian diskon berdasarkan segmentasi kluster juga diusulkan untuk mendorong kepatuhan wajib pajak dengan skema pemberian diskon yang lebih besar bagi wajib pajak dengan total PKB tinggi. Hasil kerja praktik ini berhasil memberikan wawasan yang mendalam tentang strategi pengelolaan PKB yang lebih efisien, dengan kontribusi berupa solusi berbasis data yang dapat diimplementasikan di Bapenda untuk meningkatkan kepatuhan dan efisiensi pengumpulan pajak kendaraan bermotor.

***Kata Kunci : Bapenda, Pajak Kendaraan Bermotor, Traveling Salesman Problem, Vehicle Routing Problem, K-Means Clustering***

*[Halaman ini sengaja dikosongkan]*

## KATA PENGANTAR

Puji syukur kita panjatkan kepada Allah SWT atas berkah dan karunianya, sehingga penulis dapat menyelesaikan serangkaian kerja praktik di Badan Pendapatan Daerah (BAPENDA) Provinsi Jawa Timur dengan judul “Penerapan Algoritma Traveling Salesman Problem, Vehicle Routing Problem, dan Clustering dalam Meningkatkan Efisiensi Pengelolaan Pajak Kendaraan Bermotor di Badan Pendapatan Daerah Provinsi Jawa Timur”, yang merupakan kewajiban penulis sebagai mahasiswa Departemen Teknik Informatika Fakultas Teknologi Elektro dan Informatika Cerdas Institut Teknologi Sepuluh Nopember Surabaya.

Penulis juga ingin mengucapkan terima kasih kepada seluruh pihak yang telah membantu penulis dalam menyelesaikan kewajiban kerja praktik secara langsung maupun tidak langsung, antara lain :

1. Orang tua penulis yang selalu memberikan dukungan tanpa henti.
2. Bapak Ary Mazharuddin S.Kom., M.Comp.Sc. selaku koordinator Kerja Praktik Departemen Teknik Informatika.
3. Bapak Fajar Baskoro S.Kom., M.T. selaku dosen pembimbing departemen yang telah membantu dan membina penulis selama masa kerja praktik.
4. Bapak Irfanur Ilham Febriansyah selaku pembimbing lapangan dari Badan Pendapatan Daerah (BAPENDA) Provinsi Jawa Timur yang sudah membimbing, mengarahkan dan mengevaluasi penulis selama melakukan kerja praktik
5. Seluruh teman-teman penulis yang senantiasa memberikan semangat kepada penulis.

Sebagai penyusun, penulis sadar akan adanya kekurangan dalam buku laporan kerja praktik ini, baik dari segi penyajian data maupun aspek teknis lainnya. Oleh karena itu, penulis menerima setiap saran dan kritik yang bersifat membangun dari pembaca dengan tulus, sebagai bahan perbaikan di masa depan.



Surabaya, 10 November 2024

Anggara Saputra

# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang

Kerja praktik merupakan salah satu kegiatan penting dalam dunia pendidikan tinggi yang bertujuan memberikan pengalaman langsung kepada mahasiswa untuk memahami penerapan ilmu di dunia kerja. Di tengah era digitalisasi, teknologi telah menjadi tulang punggung berbagai sektor, termasuk sektor publik dan pemerintahan. Di Indonesia, perkembangan teknologi telah memengaruhi berbagai aspek kehidupan, mulai dari sistem informasi hingga pengelolaan data dalam skala besar (Mukhlis, 2024). Tantangan besar yang dihadapi adalah bagaimana mengintegrasikan teknologi secara efektif dalam proses pengambilan keputusan yang berbasis data. Oleh karena itu, kerja praktik ini tidak hanya memberikan peluang untuk mengaplikasikan ilmu, tetapi juga membantu menghadirkan solusi terhadap permasalahan yang dihadapi oleh institusi dalam memanfaatkan teknologi.

Badan Pendapatan Daerah (Bapenda) merupakan lembaga pemerintah yang mengelola dan mengoptimalkan penerimaan pajak daerah untuk mendukung pembangunan dan pelayanan publik. Bapenda bertanggung jawab atas pengumpulan berbagai jenis pajak, termasuk pajak kendaraan bermotor, pajak hotel, restoran, dan hiburan. Selain itu, Bapenda juga berperan dalam meningkatkan kesadaran masyarakat tentang kewajiban perpajakan melalui berbagai program edukasi dan sosialisasi. Dalam menjalankan tugasnya, Bapenda menggunakan berbagai teknologi informasi untuk mempermudah proses administrasi dan pengelolaan data pajak, serta melakukan pengawasan terhadap implementasi kebijakan pajak. Bapenda berfokus pada optimalisasi potensi pajak daerah untuk meningkatkan pendapatan daerah, yang kemudian digunakan untuk membiayai berbagai program pembangunan dan meningkatkan kesejahteraan masyarakat (Bapenda, 2024).

Di Indonesia, pajak kendaraan bermotor (PKB) yang dikelola oleh Bapenda berperan dalam mendukung keuangan daerah dan pembiayaan pembangunan infrastruktur, pelayanan publik, dan sektor lainnya. Sebagai pajak yang bersifat progresif, pemungutan dan pengelolaan pajak kendaraan bermotor memiliki tantangan tersendiri, baik dalam hal data, teknologi, maupun pemanfaatannya untuk kepentingan pelayanan publik. Tantangan besar muncul dalam pengelolaan data yang kompleks, terutama terkait dengan volume data yang besar, inkonsistensi informasi, serta kebutuhan akan analisis yang cepat dan akurat (Cai & Zhu, 2015). Selain itu, isu seperti keterbatasan metode distribusi sumber daya dan pengawasan lapangan juga memerlukan perhatian lebih. Permasalahan yang kompleks tersebut menunjukkan bahwa penggunaan teknologi dan pendekatan analitik yang lebih modern menjadi kebutuhan untuk menghadirkan solusi yang lebih efektif.

Sebagai bagian dari kerja praktik, analisis data PKB menjadi salah satu fokus utama untuk memberikan wawasan mendalam terkait tren pajak kendaraan, distribusi potensi pajak, dan identifikasi pola yang relevan. Pengembangan *Traveling Salesman Problem* (TSP) dan *Vehicle Routing Problem* (VRP) adalah dua metode populer dapat meningkatkan efisiensi operasional (Laporte, 2010). Dengan menggunakan TSP dan VRP diharapkan dapat meminimalkan total jarak tempuh serta mengoptimasi pengaturan rute kendaraan untuk memenuhi kebutuhan pengantaran dengan mempertimbangkan berbagai. Selain itu, penerapan metode *clustering*

digunakan untuk menyegmentasi data berdasarkan karakteristik tertentu, sehingga memungkinkan rekomendasi kebijakan yang lebih tepat sasaran (Faizan et al., 2020). Melalui teknik *clustering*, data dapat dikelompokkan dalam kategori yang relevan sehingga membantu dalam memahami pola atau tren dan memungkinkan analisis yang lebih mendalam terhadap variabel-variabel yang mempengaruhi suatu peristiwa. Dengan demikian, kegiatan kerja praktik ini mencakup berbagai tahapan, mulai dari pengumpulan data, analisis dengan pendekatan berbasis data, hingga evaluasi terhadap hasil yang diperoleh untuk memberikan solusi yang optimal.

Melalui kerja praktik ini diharapkan dapat memberikan kontribusi positif baik dalam hal peningkatan efisiensi pengelolaan data di Bapenda maupun pemanfaatan teknologi dalam analisis data skala besar. Kegiatan ini juga menjadi sarana untuk mengembangkan kemampuan teknis dan analitis sesuai kebutuhan dunia kerja. Selain itu, diharapkan hasil kerja praktik ini mampu memberikan rekomendasi strategis yang bermanfaat bagi instansi terkait dalam mendukung perencanaan berbasis data. Dengan demikian, kerja praktik ini tidak hanya menjadi pengalaman belajar yang berharga, tetapi juga langkah nyata dalam mendukung inovasi teknologi untuk memecahkan permasalahan nyata di sektor publik.

## 1.2 Rumusan Masalah

Dalam pelaksanaan kerja praktik di Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur, rumusan masalah yang dapat diangkat sebagai berikut:

1. Bagaimana cara mengoptimalkan analisis data pajak kendaraan bermotor (PKB) di Provinsi Jawa Timur dengan menggunakan metode statistik?
2. Apa saja faktor-faktor yang mempengaruhi efisiensi distribusi dan pengawasan kendaraan bermotor yang dioptimalkan dengan metode *Traveling Salesman Problem* (TSP) dan *Vehicle Routing Problem* (VRP)?
3. Bagaimana metode *clustering* dapat digunakan untuk mengidentifikasi pola-pola dalam data pajak kendaraan bermotor (PKB)?
4. Apa dampak dari penerapan solusi teknologi ini terhadap pengelolaan data dan kebijakan pajak kendaraan bermotor di Bapenda Jawa Timur?

## 1.3 Tujuan

Secara garis besar tujuan dilaksanakannya kerja praktik ini adalah untuk membentuk mahasiswa sarjana yang memiliki keahlian dalam dunia kerja yang nyata dengan keterampilan dan kemampuan yang kreatif, inovatif, dan mandiri. Tujuan kerja praktik ini meliputi tujuan umum dan tujuan khusus yang dijabarkan sebagai berikut.

### 1.3.1 Tujuan Umum

Tujuan umum yang ingin dicapai dari pelaksanaan kerja praktik ini adalah sebagai berikut:

1. Meningkatkan keterampilan teknis dan pengetahuan dalam penerapan metode analitik dan teknologi informasi dalam pengelolaan data.
2. Memperoleh pengalaman praktis dalam menghadapi tantangan dunia kerja, khususnya dalam sektor publik dan pengolahan data.
3. Mempersiapkan mahasiswa untuk berkontribusi secara profesional dalam analisis data di instansi pemerintah dan sektor lainnya.

4. Memperkuat hubungan antara dunia akademik dan dunia industri dengan memberikan kesempatan kepada mahasiswa untuk mengaplikasikan teori yang dipelajari di perkuliahan.
5. Meningkatkan reputasi perguruan tinggi dalam menghasilkan lulusan yang siap pakai dan memiliki keterampilan yang relevan dengan kebutuhan dunia kerja.

### **1.3.2 Tujuan Khusus**

Adapun tujuan khusus yang ingin dicapai dari pelaksanaan kerja praktik ini adalah sebagai berikut:

1. Mengoptimalkan analisis data PKB di Provinsi Jawa Timur dengan menggunakan metode statistik dan teknologi yang tepat.
2. Meningkatkan efisiensi operasional dalam distribusi dan pengawasan kendaraan bermotor melalui penerapan metode *Traveling Salesman Problem (TSP)* dan *Vehicle Routing Problem (VRP)*.
3. Menerapkan metode *clustering* untuk menyegmentasi data PKB dan mengidentifikasi pola-pola yang dapat digunakan dalam perumusan kebijakan yang lebih tepat sasaran.
4. Memberikan rekomendasi dan solusi berbasis teknologi untuk meningkatkan pengelolaan data dan kebijakan pajak kendaraan bermotor di Bapenda Jawa Timur.

## **1.4 Manfaat**

Manfaat dari pelaksanaan kerja praktik ini dijabarkan sebagai berikut.

### **1.4.1 Manfaat Bagi Mahasiswa**

1. Mahasiswa dapat mengaplikasikan pengetahuan yang diperoleh selama perkuliahan dalam situasi nyata di dunia kerja.
2. Mahasiswa dapat mengembangkan keterampilan teknis, seperti pengolahan data, penggunaan metode statistik, serta pengambilan keputusan.
3. Mahasiswa mendapatkan pengalaman langsung bekerja di lembaga pemerintah, yang dapat menjadi nilai tambah dalam pengembangan karir di masa depan.
4. Mahasiswa dilatih untuk memecahkan masalah yang kompleks, mengidentifikasi kendala, dan memberikan solusi berbasis data yang tepat.

### **1.4.2 Manfaat Bagi Perguruan Tinggi**

1. Perguruan tinggi dapat memperoleh wawasan tentang kebutuhan praktis dunia industri dan pemerintahan yang dapat dijadikan bahan evaluasi untuk pengembangan kurikulum yang lebih relevan.
2. Perguruan tinggi dapat meningkatkan reputasinya dalam menghasilkan lulusan yang siap pakai karena keberhasilan kerja praktik.
3. Perguruan tinggi dan instansi pemerintah dapat mempererat hubungan dengan membuka peluang kolaborasi dalam pengembangan riset dan penerapan teknologi.

### **1.4.3 Manfaat Bagi Instansi**

1. Bapenda Jawa Timur dapat meningkatkan efisiensi pengelolaan data dan pengawasan kendaraan bermotor, sehingga mempermudah pengambilan keputusan.
2. Bapenda Jawa Timur dapat menghasilkan informasi yang lebih tepat dan relevan untuk merumuskan kebijakan pajak kendaraan bermotor yang lebih tepat sasaran dengan analisis data yang lebih mendalam.

3. Bapenda Jawa Timur dapat mengintegrasikan teknologi terbaru dalam proses pengelolaan dan analisis data, sehingga dapat meningkatkan kualitas dan kecepatan pengolahan data.
4. Bapenda Jawa Timur Hasil dapat memberikan rekomendasi strategis terkait pengelolaan data dan kebijakan yang lebih efisien dari hasil kerja praktik.

## **BAB 2**

### **GAMBARAN UMUM TEMPAT KERJA PRAKTIK**

#### **2.1 Profil Badan Pendapatan Daerah Provinsi Jawa Timur**

Badan Pendapatan Daerah (Bapenda) adalah lembaga yang bertanggung jawab atas pengelolaan dan pengoptimalan penerimaan pajak daerah guna mendukung pembangunan dan pelayanan publik di wilayah Provinsi Jawa Timur. Sebagai pengelola pajak daerah, Bapenda memiliki peran penting dalam meningkatkan Pendapatan Asli Daerah (PAD), yang digunakan untuk membiayai berbagai program pemerintah, termasuk pembangunan infrastruktur dan pelayanan sosial. Bapenda bertugas untuk mengumpulkan berbagai jenis pajak, seperti pajak kendaraan bermotor, pajak hotel, restoran, dan hiburan, serta meningkatkan kesadaran masyarakat tentang kewajiban perpajakan. Selain itu, Bapenda juga berfokus pada penerapan teknologi informasi dalam sistem administrasi pajak untuk memastikan kelancaran dan transparansi proses pemungutan pajak.

Badan Pendapatan Daerah Provinsi Jawa Timur merupakan organisasi perangkat daerah pelaksana fungsi penunjang urusan pemerintahan bidang keuangan yang diberikan kewenangan oleh Kepala Daerah, yaitu Gubernur Jawa Timur untuk melaksanakan pemungutan Pendapatan Asli Daerah (PAD) di Provinsi Jawa Timur. Bapenda Provinsi Jawa Timur dibentuk melalui Peraturan Daerah Provinsi Jawa Timur Nomor 18 Tahun 2016 tentang Perangkat Daerah dan Peraturan Gubernur Jawa Timur Nomor 67 Tahun 2016 tentang Kedudukan, Susunan Organisasi, Uraian Tugas dan Fungsi Serta Tata Kerja Badan Pendapatan Daerah Provinsi Jawa Timur.

#### **2.2 Sejarah Badan Pendapatan Daerah Provinsi Jawa Timur**

Sejarah Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur dimulai pada tanggal 28 November 1960 dengan pendirian Unit Urusan Pajak di Bagian Penghasilan Daerah Sekretariat Daerah Tingkat I Jawa Timur, yang ditetapkan melalui Surat Keputusan Gubernur Jawa Timur Nomor P/361/A/Drh. Pada 1 Oktober 1962, Unit Urusan Pajak ini resmi menjadi Dinas Pajak Daerah Jawa Timur melalui Surat Keputusan Gubernur Jawa Timur Nomor Des/1205/G/110/Drh. Peringatan hari jadi Dinas Pajak Daerah Jawa Timur dirayakan berdasarkan tanggal tersebut. Seiring dengan perkembangan kebutuhan tata kelola pemerintahan, pada tahun 2014 terjadi transformasi besar di Bapenda yang menjadikannya sebagai organ pendukung dalam tata kelola baru pemerintahan, dengan fokus pada pengelolaan pendapatan daerah yang lebih responsif dan aman. Proses transformasi ini semakin signifikan dengan diberlakukannya Peraturan Pemerintah Nomor 18 Tahun 2016 dan Peraturan Daerah Nomor 11 Tahun 2016, yang membawa perubahan bentuk organisasi menjadi Badan Pendapatan Daerah Provinsi Jawa Timur pada tahun 2016-2017 untuk lebih meningkatkan efektivitas dalam pengelolaan pendapatan daerah.

## **2.3 Visi dan Misi Badan Pendapatan Daerah Provinsi Jawa Timur**

### **2.3.1 Visi**

Visi Bapenda adalah “Mewujudkan Jawa Timur Lebih Sejahtera dan Berahlak Melalui Kemandirian Fiskal dan Pelayanan Publik Yang Berkualitas”. Visi Bapenda untuk mewujudkan Jawa Timur yang lebih sejahtera dan berahlak mencerminkan komitmen lembaga dalam meningkatkan kesejahteraan masyarakat melalui pengelolaan pajak yang transparan dan efisien. Dengan fokus pada kemandirian fiskal, Bapenda berusaha mengoptimalkan potensi pajak daerah untuk mendukung pembangunan yang berkelanjutan serta memberikan pelayanan publik yang berkualitas untuk meningkatkan kepercayaan masyarakat terhadap sistem perpajakan daerah (Bapenda, 2024).

### **2.3.2 Misi**

Dalam rangka mewujudkan visi Bapenda, maka diperlukan perumusan misi dengan memperhatikan tugas pokok dan fungsi Bapenda dengan uraian sebagai berikut (Bapenda, 2024):

1. Meningkatkan Pendapatan Asli Daerah.
2. Meningkatkan Kualitas Pelayanan Publik.

## **2.4 Struktur Organisasi Badan Pendapatan Daerah Provinsi Jawa Timur**

Struktur organisasi Bapenda Jawa Timur dibentuk dan diatur berdasarkan sejumlah dasar hukum yang mendasari kewenangannya dalam pengelolaan pajak daerah dan retribusi daerah. Berdasarkan Undang-Undang Nomor 28 Tahun 2009 tentang Pajak Daerah dan Retribusi Daerah, Bapenda memiliki peran penting dalam mengelola dan memungut pajak untuk mendukung pembangunan daerah. Selain itu, Undang-Undang Nomor 23 Tahun 2014 tentang Pemerintahan Daerah, yang diubah melalui Undang-Undang Nomor 9 Tahun 2015, memberikan dasar hukum bagi pembentukan perangkat daerah yang lebih efisien, termasuk Bapenda, dalam menjalankan tugas-tugas pemerintahan di tingkat provinsi. Peraturan Daerah Provinsi Jawa Timur Nomor 3 Tahun 2018 tentang Perubahan Atas Peraturan Daerah Provinsi Jawa Timur Nomor 11 Tahun 2016 mengatur tentang pembentukan dan susunan perangkat daerah, yang juga mencakup Badan Pendapatan Daerah. Sebagai landasan operasional, Peraturan Gubernur Jawa Timur Nomor 78 Tahun 2021 menetapkan kedudukan, susunan organisasi, uraian tugas, fungsi, dan tata kerja Bapenda, yang mencerminkan struktur yang terorganisir secara hierarkis untuk menjalankan fungsi pengelolaan pendapatan daerah secara efektif dan efisien. Struktur ini mendukung Bapenda dalam melaksanakan tugasnya untuk mencapai kemandirian fiskal serta meningkatkan pelayanan publik yang berkualitas. Berikut penjabaran terkait struktur organisasi Bapenda Jawa Timur (Bapenda, 2024):

1. Kepala Badan

Kepala Badan adalah pejabat tertinggi yang memimpin dan bertanggung jawab atas seluruh kegiatan operasional di Bapenda Jawa Timur. Tugas utamanya meliputi perencanaan, pelaksanaan, dan pengawasan terhadap kebijakan dan program kerja yang ditetapkan, serta memastikan bahwa pengelolaan pajak dan retribusi daerah berjalan efektif dan efisien.

2. Sekretariat

Sekretariat Bapenda bertugas untuk mendukung kelancaran administrasi dan operasional di seluruh jajaran Bapenda. Bagian ini meliputi pengelolaan tata usaha,

perlengkapan, dan keuangan yang memastikan kegiatan Bapenda dapat berjalan dengan lancar dan sesuai dengan peraturan yang berlaku. Subbagian di bawah sekretariat memiliki tanggung jawab yang mencakup pengelolaan administrasi umum, pengadaan sarana dan prasarana yang diperlukan, serta pengelolaan anggaran dan keuangan Bapenda agar terkelola dengan transparan dan akuntabel.

3. Kelompok Jabatan Fungsional

Kelompok ini terdiri dari tenaga ahli yang memiliki spesialisasi dan kompetensi dalam bidang tertentu. Kelompok ini bertugas untuk memberikan dukungan teknis dan konsultasi dalam penyelesaian tugas-tugas fungsional yang ada di Bapenda, seperti analisis data, penelitian, dan pengembangan sistem yang berhubungan dengan pendapatan daerah.

4. Bidang Perencanaan dan Pengembangan

Bidang ini bertanggung jawab dalam merancang dan mengembangkan kebijakan serta sistem yang mendukung pengelolaan pajak dan retribusi daerah. Tugas dari bidang ini meliputi perencanaan program kerja jangka panjang dan pendek, serta pengembangan teknologi informasi yang mendukung efisiensi dan efektivitas pemungutan pajak. Bidang ini juga melakukan analisis terhadap data pendapatan daerah dan menyusun laporan yang digunakan sebagai dasar evaluasi dan perbaikan kebijakan.

5. Bidang Pajak Daerah

Bidang ini berperan dalam pengelolaan pajak kendaraan bermotor, pajak restoran, pajak hotel, dan jenis pajak daerah lainnya. Tugas dari bidang ini adalah untuk mengoptimalkan pemungutan pajak daerah melalui pengawasan dan pelayanan yang baik kepada wajib pajak. Bidang Pajak Daerah memiliki subbidang yang fokus pada pengelolaan pajak kendaraan bermotor (PKB), bea balik nama kendaraan bermotor (BBNKB), serta pajak daerah lainnya, yang bertujuan untuk meningkatkan Pendapatan Asli Daerah (PAD) secara berkelanjutan.

6. Bidang Retribusi dan Pendapatan Lain-Lain

Bidang ini bertugas untuk mengelola pendapatan daerah yang berasal dari retribusi dan sumber pendapatan lainnya yang tidak termasuk pajak. Tugas bidang ini meliputi pemungutan retribusi, pengelolaan pendapatan bagi hasil pajak, serta pendapatan lain-lain yang dapat meningkatkan PAD. Subbidang dalam bidang ini memiliki kewenangan untuk mengatur dan mengelola berbagai jenis retribusi daerah, seperti retribusi pasar, kebersihan, dan lainnya, serta memastikan pendapatan daerah tersebut terkelola dengan baik.

7. Bidang Pengendalian & Pembinaan

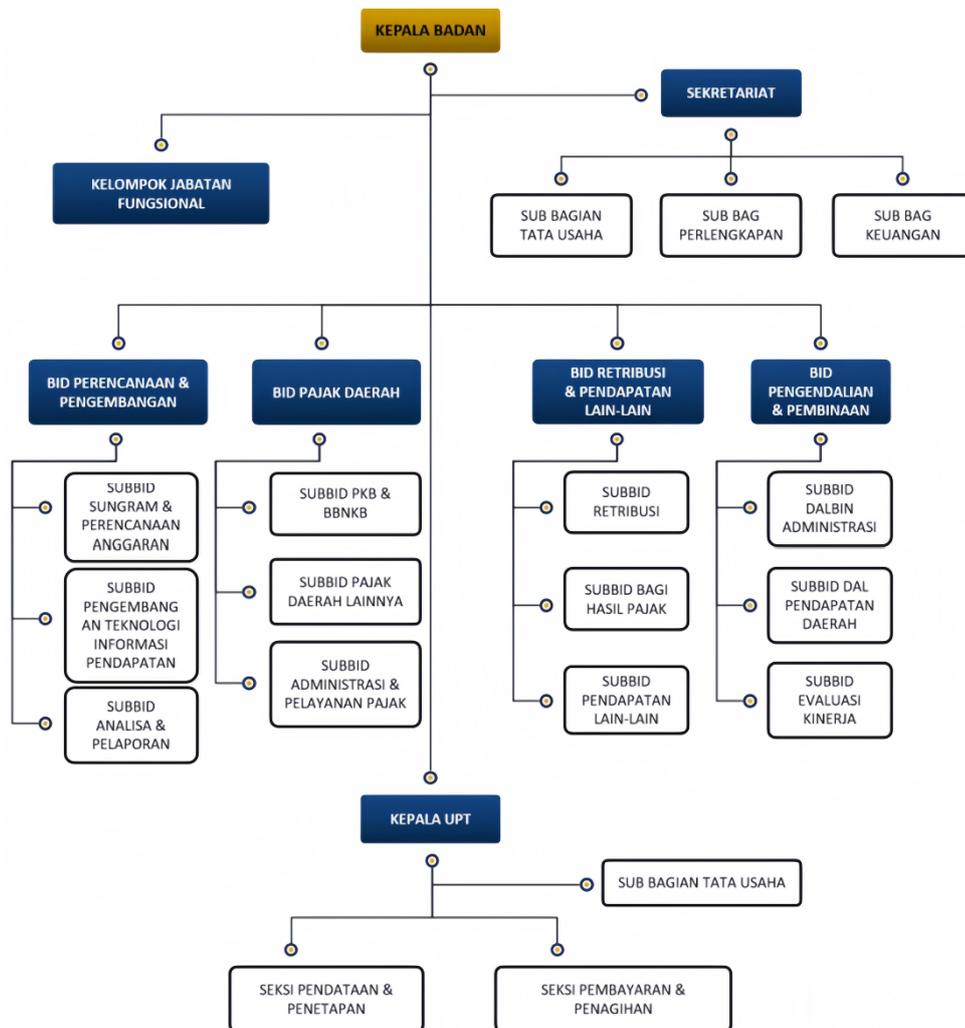
Bidang ini bertugas untuk melakukan pengawasan, pengendalian, dan evaluasi terhadap seluruh kegiatan yang terkait dengan pendapatan daerah. Tugas utama bidang ini adalah memastikan bahwa semua kebijakan dan prosedur yang diterapkan di Bapenda dilaksanakan dengan sesuai dan efisien. Selain itu, bidang ini juga melakukan pembinaan terhadap unit dan subbidang di bawahnya agar dapat meningkatkan kinerja dan hasil yang optimal, serta mengevaluasi kinerja secara rutin untuk mencapai target yang telah ditetapkan.

8. Kepala UPT (Unit Pelaksana Teknis)

Kepala UPT bertanggung jawab atas pelaksanaan operasional yang berhubungan langsung dengan pelayanan pajak di daerah. UPT merupakan unit yang bertugas melaksanakan kegiatan teknis dan operasional yang berkaitan dengan pemungutan pajak,

retribusi, dan pendapatan daerah lainnya di wilayah tertentu. Kepala UPT memiliki wewenang dalam mengelola seluruh kegiatan yang ada di bawah koordinasi UPT serta memastikan pelayanan kepada masyarakat berjalan dengan baik dan sesuai dengan peraturan yang berlaku. Kepala UPT mengkoordinasikan subbidang tata usaha, seksi pendataan dan penetapan, serta seksi pembayaran dan penagihan.

Struktur organisasi Bapenda Provinsi Jawa Timur dapat dilihat pada Gambar 2.1.



Gambar 2.1 Struktur Organisasi Badan Pendapatan Daerah Provinsi Jawa Timur

## 2.5 Tugas Pokok, Fungsi, dan Wewenang Badan Pendapatan Daerah Provinsi Jawa Timur

Tugas pokok, fungsi, dan wewenang Bapenda telah ditetapkan berdasarkan Peraturan Gubernur Jawa Timur Nomor 67 Tahun 2016 tentang Kedudukan, Susunan Organisasi, Uraian Tugas dan Fungsi Serta Tata Kerja Badan Pendapatan Daerah Provinsi Jawa Timur, untuk melaksanakan tugas sebagaimana dimaksud, Badan Pendapatan Daerah Provinsi Jawa Timur. Berikut adalah penjabaran dari tugas pokok dan fungsi Bapenda Jawa Timur (Bapenda, 2024):

### **2.5.1 Tugas Pokok**

Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur memiliki tugas membantu Gubernur melaksanakan fungsi penunjang urusan pemerintahan yang menjadi kewenangan pemerintah provinsi di bidang keuangan.

### **2.5.2 Fungsi**

1. Penyusunan kebijakan teknis di bidang keuangan;
2. Pelaksanaan tugas dukungan teknis di bidang keuangan;
3. Pemantauan, evaluasi dan pelaporan pelaksanaan tugas dukungan teknis di bidang keuangan;
4. Pembinaan teknis penyelenggaraan fungsi penunjang urusan pemerintahan daerah di bidang keuangan;
5. Pelaksanaan administrasi badan di bidang keuangan;
6. Pelaksanaan fungsi lain yang diberikan oleh Gubernur sesuai dengan tugas dan fungsinya.

### **2.5.3 Wewenang**

1. Peraturan Daerah Provinsi Jawa Timur Nomor 18 Tahun 2016 tentang Perangkat Daerah:
  - a. Pemungutan Pendapatan Asli Daerah (PAD): Mengumpulkan pajak daerah dan retribusi daerah.
  - b. Pelaksanaan Tugas Dukungan Teknis: Melaksanakan tugas teknis keuangan di lingkungan Pemerintah Provinsi Jawa Timur.
  - c. Pemantauan, Evaluasi, dan Pelaporan: Bertanggung jawab atas pemantauan dan evaluasi pelaksanaan kebijakan keuangan serta melaporkan hasilnya.
  - d. Pelaksanaan Administrasi Badan: Mengelola administrasi internal untuk mendukung operasional dan kegiatan keuangan.
2. Peraturan Gubernur Jawa Timur Nomor 67 Tahun 2016 tentang Kedudukan, Susunan Organisasi, Uraian Tugas dan Fungsi serta Tata Kerja Badan Pendapatan Daerah Provinsi Jawa Timur:
  - a. Perumusan Kebijakan Teknis di Bidang Keuangan: Mengembangkan kebijakan yang mendukung pengelolaan keuangan daerah.
  - b. Pembinaan Teknis Penyelenggaraan Fungsi Penunjang Urusan Pemerintahan Daerah: Menyediakan pembinaan teknis untuk meningkatkan kualitas pelaksanaan fungsi yang mendukung urusan pemerintahan daerah.
  - c. Pelaksanaan Fungsi Lain yang Diberikan oleh Gubernur: Mengeksekusi tugas dan fungsi tambahan yang diberikan oleh Gubernur sesuai dengan kebutuhan.
3. Undang-Undang Nomor 23 Tahun 2014 tentang Pemerintah Daerah:
  - a. Pembinaan Teknis Penyelenggaraan Fungsi Penunjang Urusan Pemerintahan Daerah: Menyediakan pembinaan teknis untuk meningkatkan kualitas pelaksanaan fungsi yang mendukung urusan pemerintahan daerah.

## BAB 3 PELAKSANAAN KERJA PRAKTIK

### 3.1 Waktu dan Tempat Pelaksanaan Kerja Praktik

Pelaksanaan kerja praktik didasari dari kebutuhan mata kuliah kerja praktik dengan bobot 2 SKS. Kerja praktik dirancang untuk memberikan pengalaman langsung di. Pelaksanaan kerja praktik berlangsung dari 8 Agustus 2024 hingga 8 November 2024 di Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur. Lokasi kerja praktik bertempat di Jl. Manyar Kertoarjo No. 1 Surabaya, 601166.

Kerja praktik dilakukan pada hari kerja (Senin hingga Jumat) dengan sistem *hybrid* yang sebagian berlangsung secara *work form office* (WFO) dan *work from home* (WFH). Komunikasi dengan tim pembimbing dilakukan secara daring menggunakan *platform* seperti *Zoom* dan pesan *WhatsApp* untuk memastikan kelancaran pelaksanaan tugas. Rincian kegiatan kerja praktik yang dilaksanakan dapat dilihat pada Tabel 3.1.

Tabel 3.1 Jadwal Kegiatan Kerja Praktik

No	Tanggal	Kegiatan
1	13 Agustus 2024	Memanfaatkan data dari <i>web</i> Bapenda untuk memprediksi hasil pajak dengan metode statistik prediktif.
2	22 Agustus 2024	Membahas dan menganalisis hasil implementasi metode <i>Particle Swarm Optimization</i> (PSO).
3	3 September 2024	Melakukan analisis data pajak kendaraan bermotor wilayah Surabaya Timur menggunakan <i>Python</i> .
4	3 September 2024	Menyusun presentasi visual yang menjelaskan hasil analisis data pajak kendaraan di Surabaya Timur.
5	11 September 2024	Mengembangkan solusi <i>Traveling Salesman Problem</i> (TSP) untuk optimalisasi rute kendaraan.
6	18 September 2024	Melanjutkan pengembangan solusi <i>Vehicle Routing Problem</i> (VRP) berbasis algoritma pemrograman <i>Python</i> .
7	9 Oktober 2024	Mengimplementasikan metode <i>clustering</i> untuk pengelompokan data PKB Surabaya Timur.
8	18 Oktober 2024	Membuat presentasi tentang hasil analisis <i>clustering</i> data PKB wilayah Surabaya Timur.
9	26 Oktober 2024	Mengembangkan metode <i>clustering</i> sebelumnya dengan menggunakan <i>dataset</i> yang berbeda.
10	1 November 2024	Melakukan uji coba penambahan metode <i>Manhattan</i> dan frekuensi relatif untuk <i>clustering dataset mushroom</i> .
11	8 November 2024	Mengevaluasi dan membandingkan metode <i>clustering</i> sebelumnya pada <i>dataset</i> PKB.

### 3.2 Ruang Lingkup Kerja Praktik

Kerja praktik di Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur melibatkan berbagai tanggung jawab yang mencakup analisis data, pengembangan algoritma optimasi, dan segmentasi data berbasis teknik statistik. Ruang lingkup tugas dirancang untuk mendukung

pengambilan keputusan berbasis data di tingkat provinsi, khususnya dalam pengelolaan Pajak Kendaraan Bermotor (PKB). Tugas-tugas utama yang dilaksanakan meliputi:

### **3.2.1 Analisa Data Pajak Kendaraan Bermotor (PKB)**

Pemerintah Daerah Jawa Timur dalam pelaksanaan penghimpunan pajak daerah dan retribusi daerah sebagaimana ditetapkannya Undang-undang Nomor 32 Tahun 1956 tentang Perimbangan Keuangan Pusat dan Daerah dan Undang-undang Darurat Nomor 11 Tahun 1957 tentang Peraturan Umum Pajak Daerah dan Peraturan Umum Retribusi Daerah, Jenis-jenis penerimaan baik dari Pajak Daerah maupun Retribusi Daerah yang dikelola oleh Badan Pendapatan Provinsi Jawa Timur seperti salah satunya adalah Pajak Kendaraan Bermotor (PKB).

Analisis data PKB berfokus pada pengelolaan dan evaluasi data sebagai langkah untuk optimalisasi pendapatan daerah dari sektor pajak. Tugas ini diawali dengan pengumpulan data dari berbagai sumber resmi, seperti Sistem Administrasi Manunggal Satu Atap (SAMSAT) dan Dinas Pendapatan Daerah. Data yang terkumpul melalui proses penyaringan, pembersihan, dan transformasi menggunakan metode statistik untuk memastikan validitas dan reliabilitas. Hasil pengolahan data ini digunakan untuk mengidentifikasi pola pembayaran, kepatuhan wajib pajak, dan pengaruh variabel-variabel tertentu terhadap jumlah pendapatan pajak (Wijaya et al., 2021) (Siregar, 2022).

Selanjutnya, analisis lebih lanjut dilakukan untuk mengevaluasi dampak kebijakan pajak yang ada serta mengidentifikasi potensi pengembangan kebijakan yang lebih adaptif. Analisis ini mencakup studi longitudinal mengenai tren pembayaran PKB dan pemetaan wilayah dengan tingkat kepatuhan rendah. Dengan ini pemerintah daerah dapat merancang strategi komunikasi yang lebih efektif untuk meningkatkan kesadaran masyarakat akan pentingnya pembayaran pajak. Selain itu, hasil analisis dapat digunakan sebagai dasar untuk meningkatkan layanan publik melalui pemanfaatan pendapatan yang lebih tepat sasaran (Sudiartana & Mendra, 2017).

### **3.2.2 Traveling Salesman Problem (TSP) dan Vehicle Routing Problem (VRP)**

Pengembangan *Traveling Salesman Problem (TSP)* dan *Vehicle Routing Problem (VRP)* bertujuan untuk mengoptimalkan rute dalam pengumpulan data atau distribusi layanan, sehingga efisiensi operasional dapat ditingkatkan. TSP bertujuan menemukan rute terpendek yang mengunjungi sejumlah titik dan kembali ke titik awal, sementara VRP mengoptimalkan rute beberapa kendaraan dengan batasan tertentu seperti kapasitas muatan. Penggunaan algoritma seperti *Simulated Annealing* atau *Genetic Algorithm* sering diterapkan untuk menyelesaikan permasalahan ini, menghasilkan solusi optimal yang hemat waktu dan biaya (Laporte, 2010).

Implementasi metode ini tidak hanya diterapkan pada distribusi barang tetapi juga pada pengelolaan data statistik. Misalnya, dalam konteks pengumpulan data survei, TSP digunakan untuk merancang rute petugas survei agar dapat mencakup lebih banyak wilayah dengan waktu minimal. Di sisi lain, VRP membantu mengelola sumber daya kendaraan, seperti pembagian tugas rute berdasarkan lokasi dan kapasitas kendaraan, sehingga biaya operasional dapat ditekan.

### 3.2.3 Clustering Pajak Kendaraan Bermotor (PKB)

*Clustering* pada data PKB digunakan untuk menyegmentasi wajib pajak berdasarkan karakteristik tertentu, seperti jenis kendaraan, wilayah geografis, atau pola pembayaran. Teknik *clustering* seperti *K-Means*, *DBSCAN*, atau *Hierarchical Clustering* diterapkan untuk mengelompokkan data sehingga pemerintah daerah dapat lebih mudah memahami pola-pola yang ada. Misalnya, *clustering* dapat membantu mengidentifikasi wilayah dengan tingkat kepatuhan rendah atau kelompok kendaraan yang memiliki risiko tinggi untuk menunggak pajak. Hasil segmentasi ini memungkinkan pengambilan kebijakan yang lebih efektif dan terarah (Faizan et al., 2020). Melalui *clustering*, strategi pengawasan dan kampanye kesadaran masyarakat dapat disesuaikan dengan karakteristik kelompok tertentu. Contohnya, wilayah dengan tingkat kepatuhan rendah dapat menjadi fokus dalam program penyuluhan. Dengan ini, pemerintah dapat memanfaatkan hasil analisis *clustering* untuk mengalokasikan sumber daya lebih efisien, meningkatkan kepatuhan pajak, dan mendongkrak pendapatan daerah.

### 3.3 Metodologi Penyelesaian Tugas Khusus

Pada bagian ini dijelaskan mengenai metodologi yang digunakan untuk menyelesaikan tugas khusus dalam kerja praktik. Berikut penjabaran metodologi untuk penyelesaian tugas khusus.

#### 3.3.1 Sumber Data

Sumber data yang digunakan dalam tugas khusus ini terdiri dari *dataset* untuk analisis pajak kendaraan bermotor dan optimasi rute. Dataset utama diperoleh dari Badan Pendapatan Daerah Jawa Timur (Bapenda) Provinsi Jawa Timur dan bidang terkait seperti UPT yang mencakup informasi PKB tentang kendaraan bermotor, jenis pajak, serta distribusi geografis wajib pajak. Data PKB pada UPT Surabaya Timur mencakup 208.157 baris dengan 35 kolom yang menunjukkan distribusi kendaraan yang terdaftar di wilayah UPT, meliputi berbagai jenis kendaraan seperti mikrolet, sedan, dan minibus. Mayoritas kendaraan menggunakan bahan bakar bensin dengan tahun pembuatan bervariasi, mulai dari tahun 1994 hingga 2014, dan jenis pembayaran pajak dilakukan secara tunai atau melalui EDC. Data juga mencatat bahwa sebagian besar pelanggan merasa sangat puas dengan layanan pembayaran pajak, meskipun terdapat beberapa kendaraan dengan keterlambatan pembayaran yang dikenai sanksi PKB. Contoh dari data PKB yang digunakan ditunjukkan pada Tabel 3.2.

Tabel 3.2 Contoh Data PKB

UPT	Kecamatan	Tanggal Bayar	Tanggal Masa STNK	Golongan	PKB	Tanggal Mutasi
Surabaya Timur	Sukolio	21/09/2021	18/09/2026	Minibus	378000	12/12/1899
Surabaya Timur	Rungkut	08/10/2021	26/10/2020	Sedan	1363300	12/12/1899
Surabaya Timur	Rungkut	08/10/2021	26/10/2020	Sedan	1363300	12/12/1899
Surabaya Timur	Tambaksari	07/12/2021	14/13/2026	Minibus	378000	12/12/1899
Surabaya Timur	Tambaksari	07/12/2021	14/12/2026	Minibus	378000	12/12/1899

Seperti yang terlihat pada Tabel 3.2 data PKB di wilayah UPT Surabaya Timur menunjukkan informasi terkait lokasi UPT dan kecamatan, waktu pembayaran pajak, serta masa berlaku STNK. Jenis kendaraan tercatat dalam berbagai golongan, dengan nominal PKB yang beragam sesuai dengan kategori kendaraan. Selain itu, data juga mencatat tanggal mutasi kendaraan untuk keperluan administrasi.

### 3.3.2 Metode Analisis

Metode analisis yang digunakan pada kerja praktik di Bapenda Jawa Timur didasarkan pada pengelompokan data wilayah provinsi Jawa Timur dengan fitur-fitur yang terdapat pada data PKB. Berikut penjabaran dari metode-metode yang digunakan.

#### 3.3.2.1 Statistika Deskriptif

Statistika deskriptif adalah cabang statistik yang bertujuan untuk meringkas dan menyajikan data agar lebih mudah dipahami. Dalam analisis data, statistika deskriptif mencakup langkah-langkah seperti penghitungan ukuran pemusatan (*mean*, *median*, *modus*) dan ukuran penyebaran (*range*, variansi, standar deviasi). Teknik ini merupakan analisis awal terhadap pola data dan anomali yang ada, sehingga dapat memberikan pemahaman awal sebelum analisis lebih kompleks dilakukan. Selain itu, statistika deskriptif juga menjadi dasar penting dalam pengambilan keputusan berdasarkan data. Memahami distribusi data menggunakan statistika deskriptif membantu menentukan metode analisis selanjutnya. Dengan visualisasi yang mendukung, statistika deskriptif memudahkan para pengambil keputusan memahami karakteristik utama dari *dataset* (Kaur et al., 2018).

#### 3.3.2.2 Data Preprocessing

Data *preprocessing* adalah tahap awal dalam analisis data yang bertujuan untuk membersihkan dan mempersiapkan *dataset* agar dapat digunakan. Proses ini melibatkan berbagai teknik seperti pengisian nilai hilang (*missing values*), penghapusan duplikasi, transformasi data, dan normalisasi. Data yang tidak diproses dengan baik dapat menghasilkan model analisis yang bias atau kurang akurat. Oleh karena itu, data *preprocessing* menjadi langkah krusial untuk memastikan integritas *dataset* sebelum analisis lebih lanjut dilakukan. *Preprocessing* yang baik meningkatkan kualitas model prediktif dan pengambilan keputusan (Cetin & Yildiz, 2022).

#### 3.3.2.3 Traveling Salesman Problem

*Traveling Salesman Problem* (TSP) adalah salah satu masalah optimasi klasik yang bertujuan untuk menentukan rute perjalanan paling efisien yang mengunjungi setiap kota sekali dan kembali ke kota asal. Masalah ini memiliki relevansi yang luas, mulai dari logistik hingga perencanaan jaringan. TSP termasuk dalam kelas masalah dimana waktu penyelesaian akan meningkat secara eksponensial seiring bertambahnya jumlah kota. Dalam penerapannya, TSP digunakan untuk mengoptimalkan rute dalam aplikasi sehari-hari, seperti pengiriman barang dan manajemen inventaris. Misalnya, perusahaan logistik dapat mengurangi biaya operasional dengan meminimalkan jarak tempuh kendaraan menggunakan solusi TSP. Algoritma yang dirancang untuk TSP juga telah diadaptasi dalam berbagai konteks lain, termasuk penjadwalan produksi dan pemetaan geografis (Matai et al., 2010).

Dalam penerapannya, misalkan permasalahan TSP yang melibatkan kota-kota  $1, 2, 3, \dots, n$ , dan misalkan  $K_{ab}$  adalah jarak dari kota  $a$  ke kota  $b$ . Sehingga ditentukan bahwa formula matematis (Smith, 1996):

$$X_{ab} \begin{cases} 1, & \text{jika ruas jalan menghubungkan kota } a \text{ dan kota } b \\ 0, & \text{jika tidak} \end{cases} \quad (3.1)$$

TSP adalah masalah optimasi yang bertujuan untuk menemukan rute dengan jarak minimum yang mengunjungi semua kota satu kali dan kembali ke kota asal. Persamaan objektif untuk TSP dapat dituliskan sebagai berikut:

$$\min \sum_{a=1}^n \sum_{b=1, b \neq a}^n K_{ab} X_{ab} \quad (3.2)$$

Dimana,  $n$  merupakan jumlah kota,  $K_{ab}$  adalah jarak dari kota  $a$  ke kota  $b$ , sedangkan  $X_{ab}$  merupakan variabel keputusan berdasarkan persamaan (3.1).

### 3.3.2.4 Vehicle Routing Problem

*Vehicle Routing Problem* (VRP) adalah pengembangan dari TSP yang mempertimbangkan pembatasan tambahan seperti kapasitas kendaraan, waktu pengiriman, dan jumlah permintaan di setiap lokasi. Tujuan dari VRP adalah untuk menentukan rute optimal bagi beberapa kendaraan yang melayani sejumlah pelanggan dengan batasan-batasan tersebut. VRP memiliki aplikasi penting dalam pengelolaan logistik dan distribusi. Metode penyelesaian VRP mencakup algoritma metaheuristik seperti *Particle Swarm Optimization*. Keunggulan utama VRP adalah kemampuannya untuk menghemat biaya operasional melalui perencanaan rute yang lebih baik. Selain itu, VRP sering dikombinasikan dengan data geospasial untuk meningkatkan akurasi solusi (Toth & Vigo, 2014).

Dalam penerapannya, berikut ini adalah formulasi matematis dari VRP (Kristina et al., 2021):

$$X_{abz} \begin{cases} 1, & \text{jika kendaraan } z \text{ bergerak dari kota } a \text{ dan kota } b \\ 0, & \text{jika tidak} \end{cases} \quad (3.3)$$

VRP adalah generalisasi TSP yang mempertimbangkan beberapa kendaraan dengan kapasitas terbatas untuk melayani pelanggan. Tujuan utama adalah meminimalkan jarak atau biaya total perjalanan sambil memenuhi kebutuhan pelanggan. Sehingga persamaan objektif dapat dirumuskan sebagai berikut:

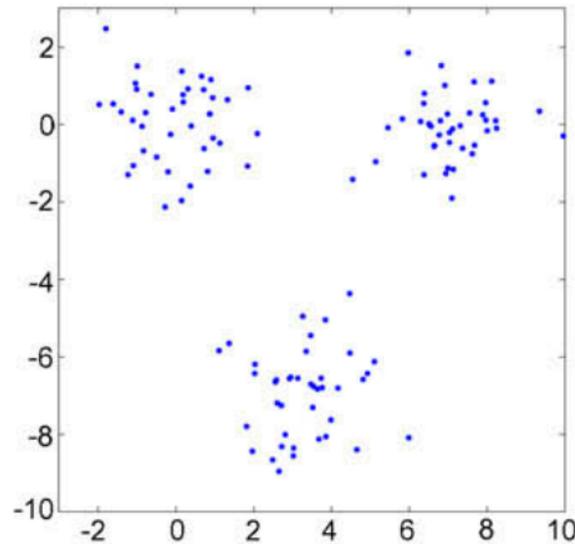
$$\min \sum_{z=1}^z \sum_{a=1}^n \sum_{b=1, b \neq a}^n K_{ab} X_{abz} \quad (3.4)$$

Dimana,  $z$  merupakan jumlah kendaraan,  $n$  merupakan jumlah kota,  $K_{ab}$  adalah jarak dari kota  $a$  ke kota  $b$ , sedangkan  $X_{abz}$  merupakan variabel keputusan berdasarkan persamaan (3.3).

### 3.3.2.5 Clustering

*Clustering* adalah metode analisis data yang bertujuan untuk mengelompokkan data berdasarkan kemiripan atau kedekatan karakteristik. Teknik ini tidak memerlukan label data (*unsupervised learning*), sehingga sangat berguna dalam eksplorasi data yang tidak memiliki

informasi kategori. Hasil *clustering* membantu dalam mengidentifikasi pola atau struktur yang tersembunyi dalam dataset. Algoritma *clustering* yang populer adalah seperti *K-Means*, *Hierarchical Clustering*, dan *DBSCAN* (Jain, 2009).



Gambar 3.1 Contoh *Clustering* (Jain, 2009)

Gambar 3.1 menunjukkan contoh hasil *clustering* dengan tiga kelompok data yang jelas terpisah berdasarkan posisi spasialnya. Setiap *cluster* terlihat memiliki distribusi data yang relatif kompak, dengan jarak yang signifikan antar *cluster*, mencerminkan tingkat pemisahan yang baik. *Clustering* membantu memahami struktur data, menciptakan klasifikasi, dan merangkum data secara efisien. Dengan banyaknya dimensi data yang sulit dianalisis secara manual, *clustering* menjadi penting untuk aplikasi yang beragam.

### 3.3.2.6 K-Means

*K-Means* adalah algoritma *clustering* yang membagi data ke dalam  $K$  kelompok berdasarkan *centroid* yang mewakili pusat dari setiap *cluster*. Algoritma ini bekerja secara iteratif untuk meminimalkan jarak antara data dengan *centroid* masing-masing *cluster*. *K-Means* sangat efisien dalam mengelola *dataset* yang besar. Penerapan *K-Means* sangat luas, termasuk analisis perilaku pelanggan, pengelompokan, dan deteksi anomali. Salah satu tantangan utama dalam *K-Means* adalah menentukan jumlah optimal  $k$ , yang biasanya diidentifikasi melalui metode seperti *Elbow Method* atau *Silhouette Score*. Dalam implementasinya, *K-Means* sering digunakan bersama teknik *preprocessing* untuk memastikan data berada dalam skala yang konsisten (Di Giuseppe et al., 2013).

Pada metode *K-Means*, proses iterasi diawali dengan pemilihan *centroid* untuk setiap *cluster* secara acak. Setiap data akan ditentukan keanggotaannya pada *cluster* tertentu berdasarkan jarak terdekatnya dengan *centroid* tersebut. Data yang memiliki jarak paling kecil ke *centroid cluster ke-K* dibandingkan dengan *centroid cluster* lain akan masuk ke dalam cluster ke- $K$ . Tahapan pengelompokan data dengan metode *K-Means* yang pertama adalah ditentukannya jumlah *cluster* yang akan dibentuk beserta posisi awal *centroid*. Selanjutnya, jarak antara data dan *centroid* dihitung menggunakan metrik jarak. Data kemudian dikelompokkan ke dalam *cluster* dengan jarak terdekat ke *centroid* yang telah ditentukan.

Setelah itu, nilai *centroid* baru untuk masing-masing *cluster* dihitung menggunakan rata-rata posisi anggota *cluster*, sesuai dengan rumus (Wardhani, 2016):

$$\mu = \frac{1}{p} \sum_{i=1}^p x_{ik} \quad (3.5)$$

Di mana  $p$  adalah jumlah anggota dalam cluster ke- $K$ . Proses ini diulangi hingga tidak ada data yang berpindah ke *cluster* lain, yang menandakan konvergensi algoritma. Dengan pendekatan iteratif ini, metode *k-means* memastikan bahwa *cluster* yang terbentuk memiliki anggota yang paling mirip secara jarak terhadap *centroid* masing-masing.

### 3.3.2.7 Manhattan Distance

*Manhattan Distance* adalah metode perhitungan jarak yang mengukur total jarak antara dua titik berdasarkan dimensi horizontal dan vertikal. Berbeda dengan *Euclidean Distance*, *Manhattan Distance* tidak mempertimbangkan diagonal, sehingga lebih cocok untuk lingkungan seperti *grid* atau kota dengan pola jalan berbentuk persegi panjang. Formula ini digunakan dalam berbagai algoritma seperti *clustering* untuk menghitung kedekatan antar data. Kelebihan *Manhattan Distance* adalah kesederhanaannya dan relevansinya dalam analisis data berbasis *grid* atau data kategorikal. Metode ini sering digunakan dalam perencanaan rute transportasi di lingkungan perkotaan atau analisis gambar berbasis piksel (Shekhar & Xiong, 2007).

Metode *Manhattan Distance* digunakan untuk mengukur jarak antara dua objek data berdasarkan jumlah total perbedaan absolut pada atribut-atributnya. Penghitungan jarak ini dilakukan dengan menjumlahkan nilai mutlak selisih antara masing-masing atribut data ke- $i$  dengan atribut pusat *cluster* ke- $i$ , sebagaimana dijelaskan melalui rumus (Nishom, 2019):

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (3.6)$$

Dalam persamaan (3.6),  $d(x, y)$  merepresentasikan jarak antara objek data  $x$  dan  $y$ , di mana  $x_i$  adalah atribut dari data ke- $i$ , dan  $y_i$  merupakan atribut dari pusat *cluster* ke- $i$ .

### 3.3.2.8 Particle Swarm Optimization

*Particle Swarm Optimization* (PSO) adalah salah satu metode optimasi berbasis populasi yang terinspirasi oleh perilaku sosial hewan, seperti kawanan burung atau gerombolan ikan, dalam mencari sumber makanan. Algoritma ini pertama kali diperkenalkan oleh Kennedy dan Eberhart pada tahun 1995, dengan prinsip utama berupa interaksi antara partikel-partikel dalam ruang pencarian untuk menemukan solusi optimal secara kolektif. Algoritma PSO terinspirasi dari sifat alami beberapa hewan tersebut, khususnya kebiasaan mereka dalam kehidupan sehari-hari serta interaksi antar-individu dalam suatu populasi. Istilah partikel dalam algoritma ini mengacu pada individu, seperti seekor burung dalam kawanan. Setiap individu dalam populasi memiliki kecerdasan tersendiri dan secara bersamaan dipengaruhi oleh perilaku kelompoknya. Jadi, ketika salah satu partikel menemukan jalur yang lebih efisien atau lebih pendek menuju sumber makanan, individu lain cenderung mengikuti jalur tersebut, meskipun posisi awal

mereka berada jauh dari partikel yang menemukan jalur tersebut (Cholissodin & Riyandani, 2016).

PSO bekerja dengan menggunakan sekumpulan partikel yang merepresentasikan kandidat solusi dalam ruang pencarian. Setiap partikel memiliki posisi ( $x$ ) dan kecepatan ( $v$ ), serta menyimpan informasi tentang posisi terbaik yang pernah dicapai oleh partikel tersebut ( $p_{best}$ ) dan posisi terbaik di antara seluruh partikel ( $g_{best}$ ). Dalam setiap iterasi, partikel diperbarui berdasarkan kecepatan yang dapat dilihat pada persamaan (3.7) dan posisinya yang dapat dilihat pada persamaan (3.8). Kecepatan partikel dihitung dengan mempertimbangkan tiga komponen utama: inersia kecepatan sebelumnya ( $w \cdot v$ ), daya tarik terhadap posisi terbaik individu ( $p_{best}$ ), dan daya tarik terhadap posisi terbaik global ( $g_{best}$ ). Koefisien pembelajaran ( $c_1$  dan  $c_2$ ) digunakan untuk mengatur pengaruh masing-masing komponen tersebut, sementara bilangan acak ( $r_1$  dan  $r_2$ ) memberikan elemen eksplorasi. Setelah kecepatan diperbarui, posisi partikel diperoleh dengan menambahkan kecepatan baru ke posisi saat ini. Proses ini berlangsung iteratif hingga kondisi penghentian terpenuhi, seperti jumlah iterasi maksimum atau ketika konvergensi solusi tercapai. Dalam setiap iterasi, kecepatan dan posisi partikel diperbarui menggunakan rumus berikut (Cholissodin & Riyandani, 2016):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_{best,i} - x_i(t)) + c_2 \cdot r_2 \cdot (g_{best,i} - x_i(t)) \quad (3.7)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3.8)$$

### 3.3.3 Langkah Analisis

Langkah analisis yang dilakukan pada kerja praktik di Bapenda Jawa Timur dijabarkan sebagai berikut.

#### 3.3.3.1 Analisis Data Pajak Kendaraan Bermotor

Pajak adalah iuran yang wajib dibayarkan oleh rakyat kepada negara dan berfungsi untuk membiayai berbagai kegiatan pemerintah. Selain itu, pajak juga digunakan untuk pembiayaan pembangunan infrastruktur dan layanan publik. Pajak kendaraan bermotor (PKB) merupakan salah satu jenis pajak yang dikenakan kepada pemilik kendaraan bermotor, dan pengelolannya menjadi salah satu fokus penting dalam upaya meningkatkan pendapatan daerah.

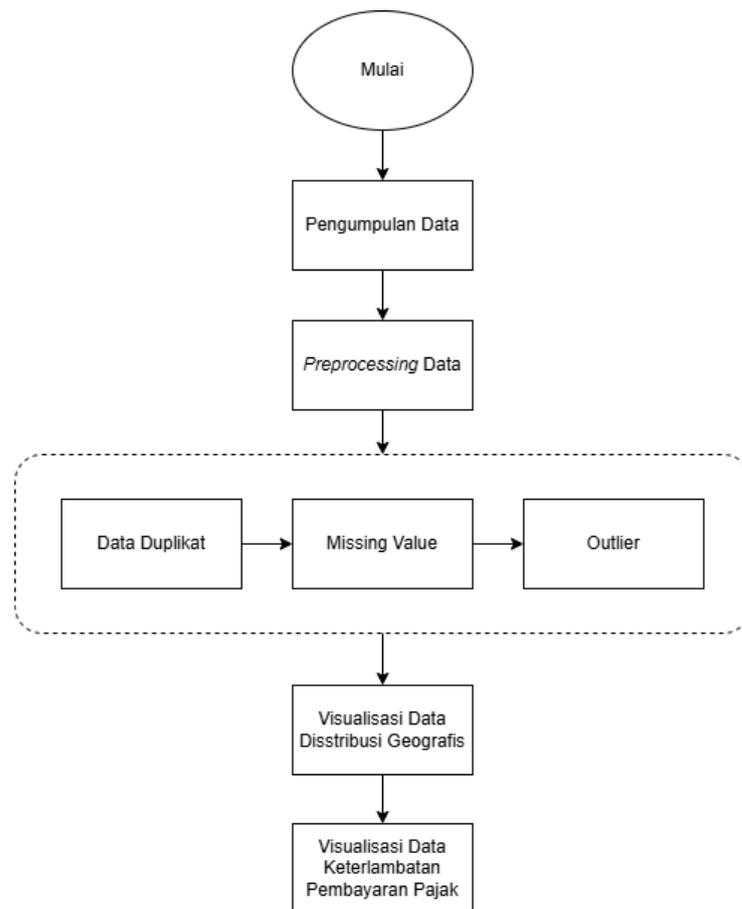
Pajak yang telah ditetapkan terkadang tidak dipatuhi oleh beberapa masyarakat. Pemerintahan harus memikirkan cara dan program khusus yang dapat menarik kembali minat masyarakat untuk membayar pajak. Data PKB dianalisis untuk mengetahui pola pembayaran, distribusi kendaraan, dan faktor-faktor yang mempengaruhi tingkat kepatuhan wajib pajak. Analisis ini melibatkan pengumpulan data yang lengkap tentang kendaraan, seperti jenis kendaraan, golongan, lokasi pembayaran, dan tanggal kedaluwarsa STNK.

Proses analisis data PKB bertujuan untuk mengidentifikasi pola pembayaran yang kurang optimal, menganalisis keterlambatan pembayaran pajak, dan membantu dalam merencanakan kebijakan atau keputusan yang lebih tepat. Selain itu, analisis ini dapat membantu pemerintah dalam menentukan prioritas wilayah yang memerlukan pengawasan lebih ketat atau insentif untuk mendorong pembayaran tepat waktu. Data keterlambatan juga dapat digunakan untuk mengevaluasi efektivitas kebijakan perpajakan yang sudah ada, seperti denda keterlambatan atau penghapusan sanksi administratif. Dengan memahami pola keterlambatan ini, upaya

peningkatan kepatuhan pajak dapat dilakukan secara lebih tepat sasaran. Proses ini menggunakan metode analisis statistik dengan tahapan sebagai berikut:

1. *Preprocessing* data untuk melihat data duplikat, *missing value*, dan *outlier*.
2. Menganalisis data untuk melihat distribusi geografis berdasarkan kecamatan dalam UPT wilayah.
3. Mengidentifikasi jumlah dari keterlambatan pembayaran pajak yang dihitung dengan mengurangi tanggal pembayaran dengan tanggal masa berlaku STNK.

Tahapan diatas dapat juga diilustrasikan dalam *flowchart* yang ditunjukkan pada Gambar 3.2.



Gambar 3.2 *Flowchart* Analisis Data PKB

### 3.3.3.2 Pengembangan TSP dan VRP

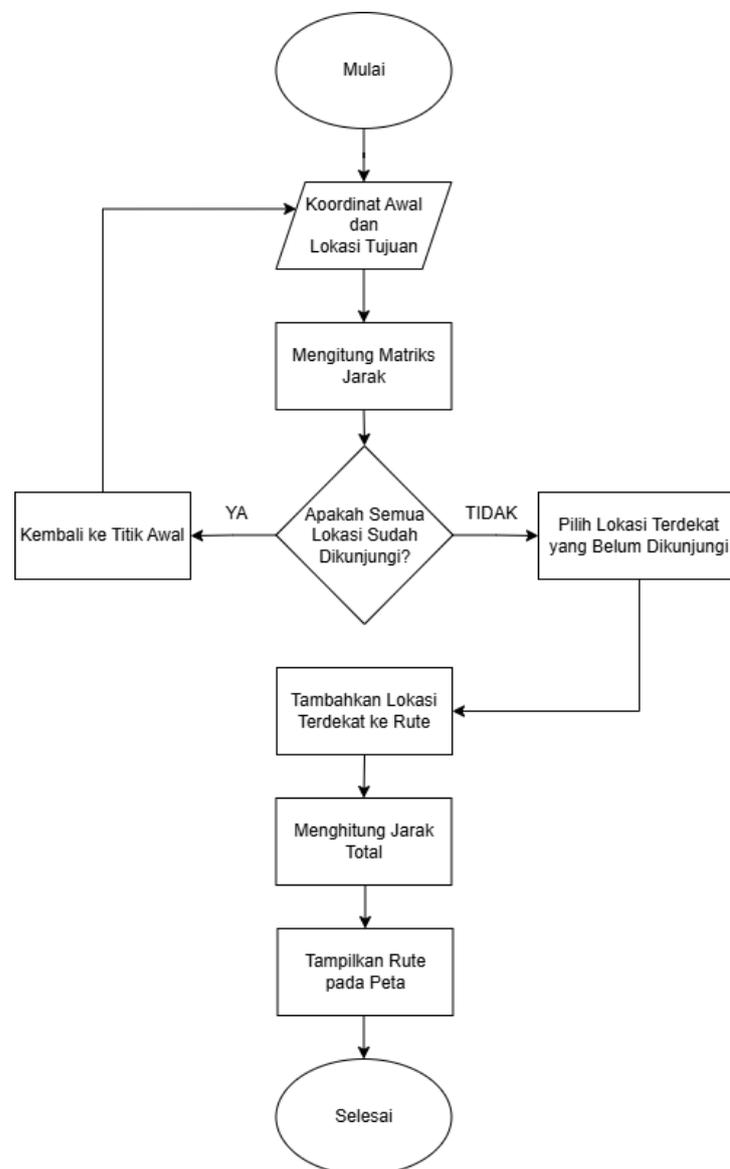
Pengembangan TSP (*Traveling Salesman Problem*) dan VRP (*Vehicle Routing Problem*) dilakukan untuk pengelolaan data dan distribusi. Dalam pengelolaan data PKB, pengembangan TSP dan VRP bertujuan untuk mengoptimalkan rute pengumpulan pajak kendaraan dan pengantaran surat pemberitahuan (SPTPD). TSP diterapkan untuk mencari rute terpendek bagi petugas yang harus mengunjungi setiap lokasi pengumpulan pajak kendaraan secara efisien, sementara VRP digunakan untuk mengelola jadwal dan rute kendaraan yang mengantar SPTPD ke wajib pajak.

### 3.3.3.2.1 Traveling Salesman Problem

*Traveling Salesman Problem* (TSP) diimplementasikan menggunakan *Python*, dengan tujuan mencari rute terpendek yang mengunjungi berbagai lokasi dan kembali ke titik awal. Hasil dari perhitungan rute TSP kemudian divisualisasikan menggunakan sebuah peta interaktif. Berikut ini adalah tahapan dari TSP:

1. Mendefinisikan koordinat titik awal dan lokasi tujuan.
2. Menghitung jarak antara setiap pasangan lokasi dengan menggunakan *geodesic*.
3. Penerapan algoritma TSP untuk mencari rute terpendek yang mengunjungi setiap lokasi dan kembali ke titik awal.
4. Menentukan rute untuk mendapatkan arah perjalanan antara dua titik menggunakan Google Maps API.
5. Memvisualisasikan rute pada peta.

Tahapan diatas dapat juga diilustrasikan dalam *flowchart* yang ditunjukkan pada Gambar 3.3.



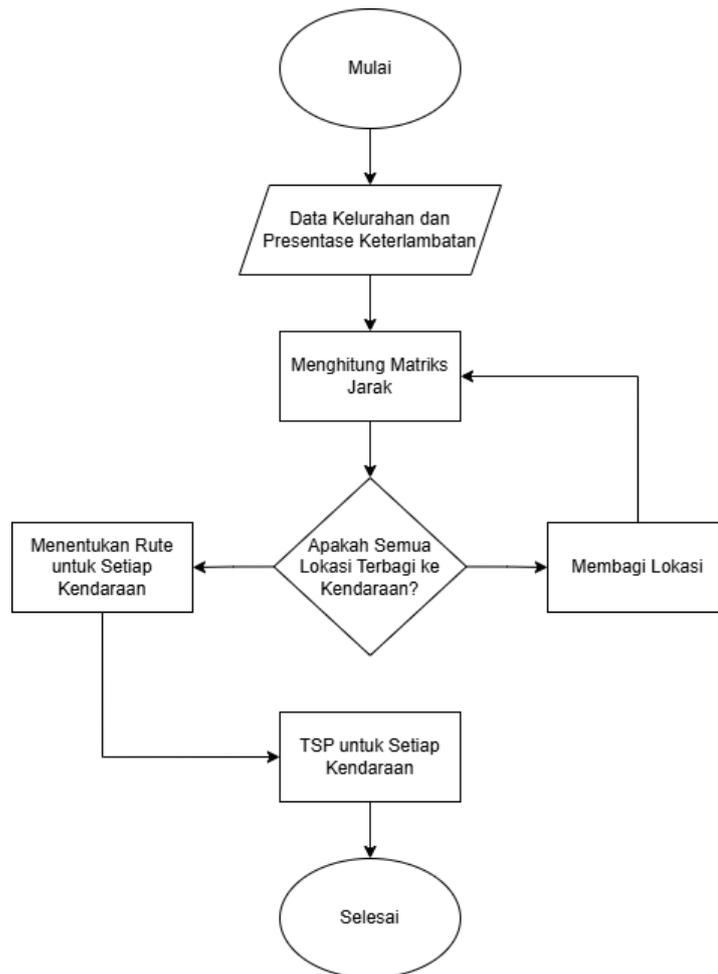
Gambar 3.3 *Flowchart Traveling Salesman Problem*

### 3.3.3.2 Vehicle Routing Problem

*Vehicle Routing Problem* (VRP) diimplementasikan menggunakan *Python*, dengan membagi rute perjalanan antar lokasi menggunakan beberapa kendaraan. Hasil proses ini adalah rute optimal untuk masing-masing kendaraan dan juga memberikan representasi visual yang mudah dimengerti tentang perjalanan yang diambil oleh setiap kendaraan. Berikut ini adalah tahapan dari VRP:

1. Memetakan setiap kelurahan ke persentase keterlambatan.
2. Menghitung matriks jarak antara titik-titik lokasi yang ingin dikunjungi.
3. Matriks jarak dihitung untuk semua lokasi, dan kemudian lokasi-lokasi tersebut dibagi di antara beberapa kendaraan.
4. Penerapan algoritma VRP, dimana diterapkan juga algoritma TSP untuk setiap kendaraan dengan memilih lokasi yang paling dekat untuk dikunjungi secara berurutan.
5. Kendaraan akan mengunjungi semua lokasi yang ditugaskan, kemudian kembali ke titik awal.
6. Mengambil petunjuk arah antara dua lokasi menggunakan *Google Maps API*.
7. Memvisualisasikan rute pada peta.

Tahapan diatas dapat juga diilustrasikan dalam *flowchart* yang ditunjukkan pada Gambar 3.4.



Gambar 3.4 *Flowchart Vehicle Routing Problem*

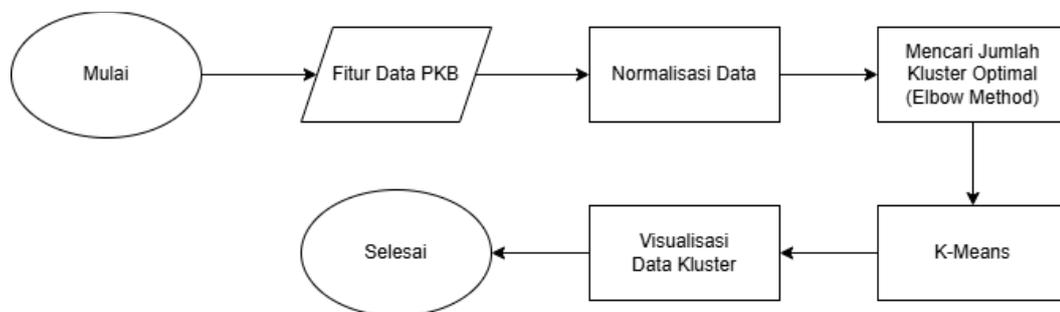
### 3.3.3.3 Analisis Clustering

*Clustering* adalah teknik dalam analisis data yang digunakan untuk mengelompokkan objek atau data yang memiliki kemiripan ke dalam kelompok atau kluster. Setiap kluster berisi objek yang memiliki karakteristik yang serupa, sementara objek yang berada di kluster yang berbeda memiliki perbedaan yang signifikan. Ada berbagai metode dalam *clustering*, namun yang paling sering digunakan adalah *K-Means*. *K-Means* bekerja dengan cara mengelompokkan data ke dalam jumlah kluster yang telah ditentukan sebelumnya dengan melibatkan penentuan *centroid*, penugasan setiap titik data ke kluster terdekat, dan pembaruan posisi *centroid* hingga stabil.

Pembayaran PKB sering tidak teratur dan bervariasi antara individu, tergantung pada kebiasaan atau kesadaran membayar pajak. Identifikasi kelompok kendaraan yang sering terlambat membayar pajak sulit dilakukan tanpa adanya pengelompokan yang jelas. Selain itu, tanpa pemahaman yang jelas tentang pola pembayaran pajak, sulit bagi pemerintah daerah untuk menargetkan kendaraan dengan potensi keterlambatan tinggi atau kendaraan yang perlu diberi perhatian khusus. Dengan *clustering*, kelompok-kelompok ini dapat diidentifikasi dan diberikan perhatian lebih. Berikut ini adalah tahapan dari *clustering* menggunakan *K-Means*:

1. Pemilihan fitur pada data PKB seperti tahun buat, tanggal, dan keterlambatan.
2. Menormalisasikan data untuk menyeragamkan skala tiap fitur.
3. Menentukan jumlah kluster optimal dengan *elbow method*.
4. Penerapan algoritma *K-Means Clustering* dengan nilai kluster optimal.
5. Memvisualisasikan kluster.

Tahapan diatas dapat juga diilustrasikan dalam *flowchart* yang ditunjukkan pada Gambar 3.5.



Gambar 3.5 *Flowchart Clustering Menggunakan K-Means*

## **BAB 4**

### **HASIL KERJA PRAKTIK**

Pada bab ini dipaparkan hasil dari kegiatan kerja praktik Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur yang telah dilakukan. Pemaparan dalam bab ini mencakup implementasi metode, analisis data, hingga penyelesaian permasalahan yang dihadapi selama proses kerja praktik. Penjabaran dalam bab ini mencakup pemaparan hasil pengolahan data, penerapan metode yang telah dijelaskan pada bab sebelumnya, serta interpretasi hasil yang mendukung tujuan khusus kerja praktik. Berikut merupakan hasil kerja praktik yang telah dilakukan.

#### **4.1 Hasil Analisis Data Pajak Kendaraan Bermotor**

Berikut merupakan hasil analisis data pajak kendaraan bermotor (PKB) untuk wilayah UPT Surabaya Timur.

##### **4.1.1 Hasil Preprocessing Data**

Pada tahap awal dilakukan *preprocessing* data untuk memastikan kualitas dan konsistensi data yang digunakan. Proses ini melibatkan identifikasi dan penanganan duplikat dan *missing values* dalam *dataset*. Duplikat data dapat mengganggu akurasi analisis, sementara *missing values* dapat mempengaruhi hasil analisis, sehingga perlu penanganan yang tepat seperti imputasi atau penghapusan data yang tidak valid. Oleh karena itu, *preprocessing* perlu ditangani dengan hati-hati. Pada proses ini, data yang terdapat duplikasi sepenuhnya dihapus. Terdapat setidaknya 38.607 baris data duplikat. Setelah dihapus, data PKB menjadi sebanyak 169.550 baris. Selanjutnya untuk *missing values* dilakukan pengisian data. Pengisian data hilang pada kolom “TGL\_MASASTNK” dari kolom “TGL\_MASALAKU”, dan pengisian data hilang pada kolom “RT” atau “RW” dengan menyesuaikan kecamatan dan Kelurahan data sebelumnya. Selain itu, pada penanganan *missing values* juga dilakukan penghapusan baris yang memiliki data yang tidak lengkap. Ditemukan adanya *missing values* yang terletak pada kolom “TUJUAN” seperti contoh baris data yang terlihat pada Gambar 4.1.

```

UPT SURABAYA TIMUR
KECAMATAN MULYOUREJO
KELURAHAN KEL MULYOUREJO
RW 3.0
RT 5.0
ASALMERK JEPANG
MERKNAMA YAMAHA
MERKTYPE VEGA R-110 4D7
PLAT HITAM
BBM BENSIN
WARNA BIRU
TGL_DAFTAR 20/11/2021
TGL_TETAP 20/11/2021
TGL_BAYAR 20/11/2021
TGL_MASALAKU 20/11/2022
TGL_MASASTNK 20/11/2023
TAHUNBUAT 2008
GOLONGAN SEPEDA MOTOR R2
JENIS SEPEDA MOTOR
BESARCC 110
BBNKB 0
PKB 120000
PROGRESIF 0
NOMILIK 1.0
JENISBAYAR TUNAI
JENISPROSES PENUL
KODEKASIR 2301
THKOHIR 2021
KEPUASAN SANGAT PUAS
PEMBEBASAN INSENTIF PKB
TGL_MUTASI 12/12/1899
TUJUAN NaN
TGL_INFO 12/12/1899
TGL_TAGIH 12/12/1899
LOSS 0
Name: 168978, dtype: object

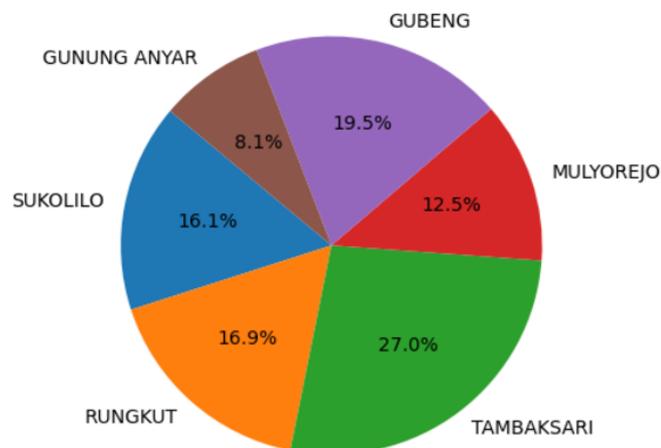
```

Gambar 4.1 Contoh Baris Data dengan *Missing Values*

Kolom “TUJUAN” pada data PKB hampir sepenuhnya memiliki *missing values*. Oleh karena itu, *missing values* perlu ditangani dengan hati-hati melalui penghapusan kolom tersebut. Dengan melakukan langkah-langkah ini, *dataset* yang bersih dan konsisten dapat diperoleh, yang nantinya akan mendukung proses analisis lebih lanjut dan pengambilan keputusan yang lebih tepat.

#### 4.1.2 Hasil Analisis Distribusi Geografis

Setelah data dibersihkan, langkah selanjutnya adalah menganalisis distribusi geografis kendaraan bermotor berdasarkan kecamatan dalam UPT wilayah. Analisis ini bertujuan untuk memahami pola penyebaran kendaraan di tiap wilayah, yang dapat memberikan wawasan mengenai konsentrasi kendaraan dan potensi pendapatan pajak pada masing-masing daerah. Distribusi kecamatan pada data PKB setelah *preprocessing* data ditunjukkan pada Gambar 4.2.

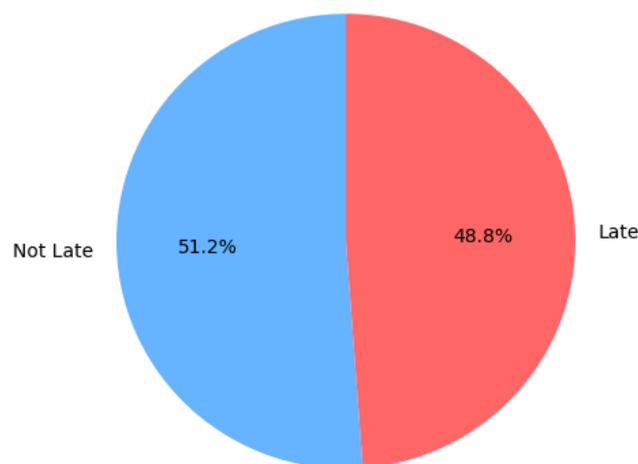


Gambar 4.2 Distribusi Kecamatan pada Data PKB

Diagram lingkaran pada Gambar 4.2 menunjukkan distribusi kontribusi PKB di wilayah UPT Jawa Timur berdasarkan kecamatan, dengan Tambaksari memberikan kontribusi tertinggi sebesar 27%, diikuti oleh Gubeng sebesar 19,5%, Rungkut 16,9%, dan Sukolilo 16,1%. Sementara itu, Mulyorejo (12,5%) dan Gunung Anyar (8,1%) memiliki kontribusi lebih kecil, yang mungkin mencerminkan jumlah kendaraan terdaftar atau aktivitas ekonomi yang lebih rendah. Wilayah seperti kecamatan Tambaksari dan Gubeng merupakan daerah strategis dengan potensi tinggi untuk meningkatkan pendapatan PKB karena tingginya kontribusi. Sedangkan, untuk kecamatan dengan persentase lebih rendah seperti Gunung Anyar, perlu dilakukan tinjauan dan analisis lebih lanjut, misalnya, potensi peningkatan jumlah kendaraan terdaftar atau optimalisasi pengumpulan pajak di daerah tersebut.

#### 4.1.3 Hasil Analisis Keterlambatan Pembayaran Pajak

Selanjutnya, dilakukan identifikasi dan analisis keterlambatan pembayaran pajak pada data PKB. Proses ini dilakukan dengan menghitung selisih antara tanggal pembayaran dan tanggal masa berlaku STNK. Dengan mengurangi kedua tanggal ini, diperoleh informasi mengenai berapa lama keterlambatan pembayaran yang terjadi pada setiap kendaraan. Analisis ini sangat penting untuk mengidentifikasi daerah atau kelompok kendaraan yang memiliki kecenderungan terlambat untuk membayar pajak, yang dapat digunakan sebagai dasar untuk strategi penagihan atau program edukasi untuk meningkatkan kesadaran masyarakat tentang kewajiban perpajakan.



Gambar 4.3 Distribusi Keterlambatan Pembayaran PKB

Diagram pada Gambar 4.3 menunjukkan distribusi pembayaran PKB antara yang terlambat dan yang tepat waktu. Data mengungkapkan bahwa 48,8% pembayaran dilakukan terlambat, sementara 51,2% pembayaran tepat waktu. Meskipun mayoritas pembayaran dilakukan sesuai jadwal, persentase keterlambatan yang hampir setara menunjukkan adanya masalah kepatuhan pajak yang signifikan di kalangan wajib pajak. Hal ini dapat disebabkan oleh kurangnya kesadaran masyarakat, keterbatasan akses terhadap informasi atau layanan pembayaran, atau pengaruh faktor ekonomi yang membuat pembayaran pajak menjadi prioritas rendah. Dengan memahami pola keterlambatan ini, strategi penagihan yang lebih terfokus dapat diterapkan untuk mengurangi tingkat keterlambatan di masa mendatang.

## 4.2 Hasil Implementasi TSP dan VRP

Berikut merupakan hasil implementasi TSP dan VRP pada data pajak kendaraan bermotor (PKB) untuk wilayah UPT Surabaya Timur.

### 4.2.1 Hasil Implementasi dan Analisis TSP

Implementasi *Traveling Salesman Problem* (TSP) digunakan untuk memetakan rute optimal dalam mengunjungi sejumlah lokasi tertentu dengan titik awal dan akhir di lokasi yang sama (*closed loop*). Implementasi ini dirancang untuk meminimalkan total jarak tempuh antara lokasi-lokasi yang dikunjungi. Algoritma ini tidak hanya menghasilkan rute terpendek, tetapi juga divisualisasikan dalam bentuk peta interaktif menggunakan *Folium*, sehingga mempermudah analisis dan validasi hasil.

Pertama, fungsi `calculate_distance_matrix` pada Kode Sumber 4.1 digunakan untuk menghitung jarak antar lokasi dalam bentuk matriks menggunakan fungsi `geodesic` dari *library geopy*. Matriks ini berisi jarak antar setiap pasangan lokasi, serta jarak dari setiap lokasi ke titik awal (`start_coords`). Fungsi ini memastikan bahwa setiap kombinasi lokasi memiliki nilai jarak, yang akan digunakan dalam algoritma TSP. Struktur data matriks jarak disusun sebagai berikut:

- Kunci utama adalah nama lokasi.
- Sub-kunci berisi nama lokasi lainnya beserta jarak ke lokasi tersebut.
- Penambahan data jarak dari dan ke titik awal (`start`) mempermudah kalkulasi rute TSP.

```
def calculate_distance_matrix(start_coords, locations):
    distance_matrix = {}
    for loc1_name, loc1_coords in locations.items():
        distance_matrix[loc1_name] = {}
        for loc2_name, loc2_coords in locations.items():
            if loc1_name != loc2_name:
                distance_matrix[loc1_name][loc2_name] = geodesic(loc1_coords, loc2_coords).km
                distance_matrix[loc1_name]['Start'] = geodesic(loc1_coords, start_coords).km

    distance_matrix['Start'] = {}
    for loc_name, loc_coords in locations.items():
        distance_matrix['Start'][loc_name] = geodesic(start_coords, loc_coords).km
    return distance_matrix
```

Kode Sumber 4.1 Fungsi Perhitungan Matriks Jarak

Kemudian algoritma TSP diimplementasikan melalui fungsi `closed_loop_tsp` seperti yang terlihat pada Kode Sumber 4.2. Algoritma ini bekerja dengan cara berikut:

- Lokasi yang belum dikunjungi disimpan dalam set *unvisited*.
- Algoritma dimulai dari lokasi awal (`start`) dan secara iteratif memilih lokasi terdekat yang belum dikunjungi.
- Setelah mengunjungi semua lokasi, algoritma kembali ke lokasi awal untuk menyelesaikan siklus (*closed loop*).
- Variabel `path` menyimpan urutan lokasi yang dikunjungi, sedangkan `total_distance` mengakumulasi total jarak tempuh.

```

def closed_loop_tsp(start_coords, locations):
    distance_matrix = calculate_distance_matrix(start_coords, locations)

    unvisited = set(locations.keys())
    path = []
    total_distance = 0

    current_location = 'start'

    while unvisited:
        nearest_location = min(unvisited, key=lambda loc: distance_matrix[current_location][loc])
        path.append(current_location)
        total_distance += distance_matrix[current_location][nearest_location]
        current_location = nearest_location
        unvisited.remove(nearest_location)
        # Return to start
        path.append(current_location)
        total_distance += distance_matrix[current_location]['start']
        current_location = 'start'

    path.append('start')
    return path, total_distance

```

#### Kode Sumber 4.2 Implementasi Algoritma TSP

Selanjutnya, peta rute interaktif dibuat menggunakan *library Folium*. Lokasi awal (*start*) dan lokasi lainnya ditampilkan dengan *marker*, dilengkapi *tooltip* untuk informasi tambahan. Fungsi *get\_route* pada Kode Sumber 4.3 menggunakan *Google Maps API* untuk mendapatkan data rute antar lokasi, termasuk detail langkah perjalanan. Pola garis lintasan (warna merah untuk titik awal dan biru untuk lokasi lainnya) digambarkan dengan *folium.PolyLine*, menambahkan visualisasi rute di peta seperti yang terlihat pada Gambar 4.4. Berikut adalah langkah-langkahnya:

- Fungsi *get\_route* menggunakan metode *gmaps.directions* untuk mendapatkan rute dari lokasi sebelumnya ke lokasi saat ini.
- Setiap langkah dalam rute digambarkan sebagai garis pada peta.
- Lokasi yang dikunjungi diberi *marker*, yang menampilkan nama lokasi saat di klik.

```

def get_route(start, end):
    now = datetime.now()
    directions_result = gmaps.directions(start, end, mode="driving", departure_time=now)
    return directions_result

previous_location_coords = start_coords
for idx, loc_name in enumerate(tsp_path):
    if loc_name == 'Start':
        loc_coords = start_coords
    else:
        loc_coords = kelurahan[loc_name]

    route = get_route(previous_location_coords, loc_coords)

    for step in route[0]['legs'][0]['steps']:
        start_lat = step['start_location']['lat']
        start_lng = step['start_location']['lng']
        end_lat = step['end_location']['lat']
        end_lng = step['end_location']['lng']

        line_color = "red" if loc_name == 'Start' else "blue"

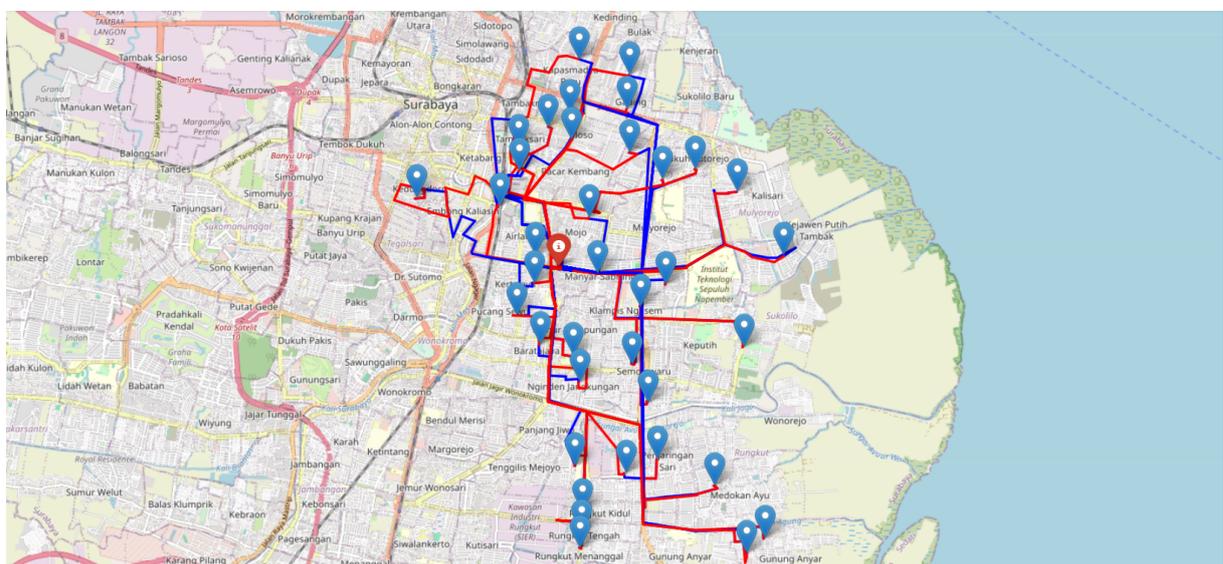
        folium.PolyLine(
            locations=[(start_lat, start_lng), (end_lat, end_lng)],
            color=line_color,
            tooltip=f"Step {idx}: Route to {loc_name}"
        ).add_to(route_map)

    if loc_name != 'Start':
        folium.Marker(loc_coords, popup=f"{idx}: {loc_name}").add_to(route_map)

    previous_location_coords = loc_coords

```

Kode Sumber 4.3 Implementasi Visualisasi Rute TSP



Gambar 4.4 Hasil Visualisasi TSP

#### 4.2.2 Hasil Implementasi dan Analisis VRP

Implementasi *Vehicle Routing Problem* (VRP) bertujuan untuk merancang rute optimal bagi sejumlah kendaraan yang harus mengunjungi beberapa lokasi berdasarkan matriks jarak. VRP memberikan solusi yang efektif dalam pengelolaan logistik dan distribusi dengan mempertimbangkan efisiensi jarak dan waktu tempuh. Dalam hasil implementasi, sistem

mampu membagi lokasi di antara beberapa kendaraan dan menentukan jalur yang optimal untuk setiap kendaraan. Rute yang dihasilkan divisualisasikan pada peta dengan kode warna untuk membedakan jalur antar kendaraan, memudahkan interpretasi dan analisis efisiensi.

Fungsi `calculate_distance_matrix__add_rate` pada Kode Sumber 4.4 digunakan untuk membuat matriks jarak berbasis koordinat lokasi dan faktor tambahan berupa *rate* dengan bobot yang diatur oleh parameter *alpha* dan *beta*. Berikut adalah ketentuannya:

- Matriks jarak dihitung dengan menggunakan fungsi *geodesic* untuk menentukan jarak antara dua titik koordinat.
- Nilai *rate* memberikan pengaruh negatif pada jarak dengan bobot *beta*, yang berarti lokasi dengan nilai *rate* lebih tinggi dianggap lebih menarik untuk dikunjungi terlebih dahulu.

Fungsi ini membangun struktur data berupa *nested dictionary* yang memuat jarak dari setiap lokasi ke lokasi lainnya serta ke lokasi awal (*start*). Langkah penting lainnya adalah memastikan semua lokasi memiliki koneksi ke titik awal, sehingga mempermudah perhitungan TSP.

```
def calculate_distance_matrix__add_rate(start_coords, locations, rate, alpha, beta):
    distance_matrix = {}
    for loc1_name, loc1_coords in locations.items():
        distance_matrix[loc1_name] = {}
        for loc2_name, loc2_coords in locations.items():
            if loc1_name != loc2_name:
                distance_matrix[loc1_name][loc2_name] = alpha * geodesic(loc1_coords, loc2_coords).km - beta * rate[loc2_name]
            distance_matrix[loc1_name]['Start'] = alpha * geodesic(loc1_coords, start_coords).km - beta * rate.get(loc2_name, 0)

    distance_matrix['Start'] = {}
    for loc_name, loc_coords in locations.items():
        distance_matrix['Start'][loc_name] = alpha * geodesic(start_coords, loc_coords).km - beta * rate[loc_name]
    return distance_matrix
```

Kode Sumber 4.4 Fungsi Perhitungan Matriks Jarak dengan Nilai *Rate*

Berikutnya dilakukan perubahan kunci dari matriks jarak ke format numerik menggunakan *LabelEncoder*, seperti yang terlihat pada Kode Sumber 4.5. Semua kunci lokasi dikonversi agar proses pengolahan data lebih efisien dan kompatibel dengan algoritma yang membutuhkan data numerik. Konversi ini membantu menghindari kesalahan dalam pengolahan kunci berbasis *string* yang kompleks.

```
all_keys = set(distance_matrix.keys()).union(*(d.keys() for d in distance_matrix.values()))

le = LabelEncoder()
le.fit(list(all_keys))

numeric_distance_matrix = {le.transform([outer_key])[0]: {le.transform([inner_key])[0]: value
                                                            for inner_key, value in inner_dict.items()}}
                        for outer_key, inner_dict in distance_matrix.items()}}
```

Kode Sumber 4.5 Konversi Menjadi Format Numerik

Selanjutnya fungsi `closed_loop_tsp_multi_vehicle` pada Kode Sumber 4.6 menangani pembagian lokasi untuk beberapa kendaraan dan penyelesaian TSP untuk masing-masing kendaraan. Langkah pertama, membagi lokasi secara merata berdasarkan jumlah kendaraan (*num\_vehicles*).

```

def closed_loop_tsp_multi_vehicle(start_coords, locations, num_vehicles):
    # Calculate the distance matrix once
    distance_matrix = calculate_distance_matrix__add_rate(start_coords, locations, summ_dict, 1, -100)

    # Split the locations among the vehicles
    location_keys = list(locations.keys())
    locations_per_vehicle = len(location_keys) // num_vehicles
    vehicle_paths = []
    vehicle_distances = []

    for vehicle in range(num_vehicles):
        # Assign locations to the current vehicle
        start_idx = vehicle * locations_per_vehicle
        end_idx = (vehicle + 1) * locations_per_vehicle if vehicle != num_vehicles - 1 else len(location_keys)
        vehicle_locations = {k: locations[k] for k in location_keys[start_idx:end_idx]}

        # Solve TSP for this vehicle
        path, distance = solve_tsp_for_vehicle(distance_matrix, vehicle_locations)

        vehicle_paths.append(path)
        vehicle_distances.append(distance)

    return vehicle_paths, vehicle_distances

```

Kode Sumber 4.6 Implementasi Pembagian Lokasi untuk Beberapa Kendaraan

Untuk setiap kendaraan, subset lokasi dipilih, dan fungsi *solve\_tsp\_for\_vehicle* pada Kode Sumber 4.7 digunakan untuk mencari rute optimal bagi subset tersebut. Fungsi ini memanfaatkan matriks jarak untuk menemukan lokasi terdekat dari titik awal, membangun jalur kunjungan hingga semua lokasi dalam *subset* selesai dikunjungi, dan akhirnya kembali ke titik awal.

```

def solve_tsp_for_vehicle(distance_matrix, vehicle_locations):
    unvisited = set(vehicle_locations.keys())
    path = []
    total_distance = 0
    current_location = 'Start'

    while unvisited:
        nearest_location = min(unvisited, key=lambda loc: distance_matrix[current_location][loc])
        path.append(current_location)
        total_distance += distance_matrix[current_location][nearest_location]
        current_location = nearest_location
        unvisited.remove(nearest_location)

        # Return to start if all locations are visited
        path.append(current_location)
        total_distance += distance_matrix[current_location]['Start']
        current_location = 'Start'

    path.append('Start')
    return path, total_distance

```

Kode Sumber 4.7 Implementasi Pencarian Rute Optimal

Fungsi *get\_route* memanfaatkan *Google Maps API* untuk mendapatkan jalur berkendara antara dua titik. Terlihat pada Kode Sumber 4.8, jalur tersebut divisualisasikan menggunakan library *folium*, di mana setiap langkah perjalanan ditampilkan dengan warna spesifik sesuai kendaraan. Penanda lokasi (marker) juga ditambahkan untuk setiap titik tujuan, sehingga memberikan informasi detail pada peta.

```

def get_route(start, end):
    now = datetime.now()
    directions_result = gmaps.directions(start, end, mode="driving", departure_time=now)
    return directions_result

color = ['green', 'blue', 'black', 'red']

previous_location_coords = start_coords
for i, paths in enumerate(vrp_paths):
    print(paths)
    for idx, loc_name in enumerate(paths):
        if loc_name == 'Start':
            loc_coords = start_coords
        else:
            loc_coords = kelurahan[loc_name]

        route = get_route(previous_location_coords, loc_coords)

        for step in route[0]['legs'][0]['steps']:
            start_lat = step['start_location']['lat']
            start_lng = step['start_location']['lng']
            end_lat = step['end_location']['lat']
            end_lng = step['end_location']['lng']

            # line_color = "red" if loc_name == 'Start' else "blue"
            line_color = color[i]

            folium.PolyLine(
                locations=[(start_lat, start_lng), (end_lat, end_lng)],
                color=line_color,
                tooltip=f"Step {idx}: Route to {loc_name}"
            ).add_to(route_map)

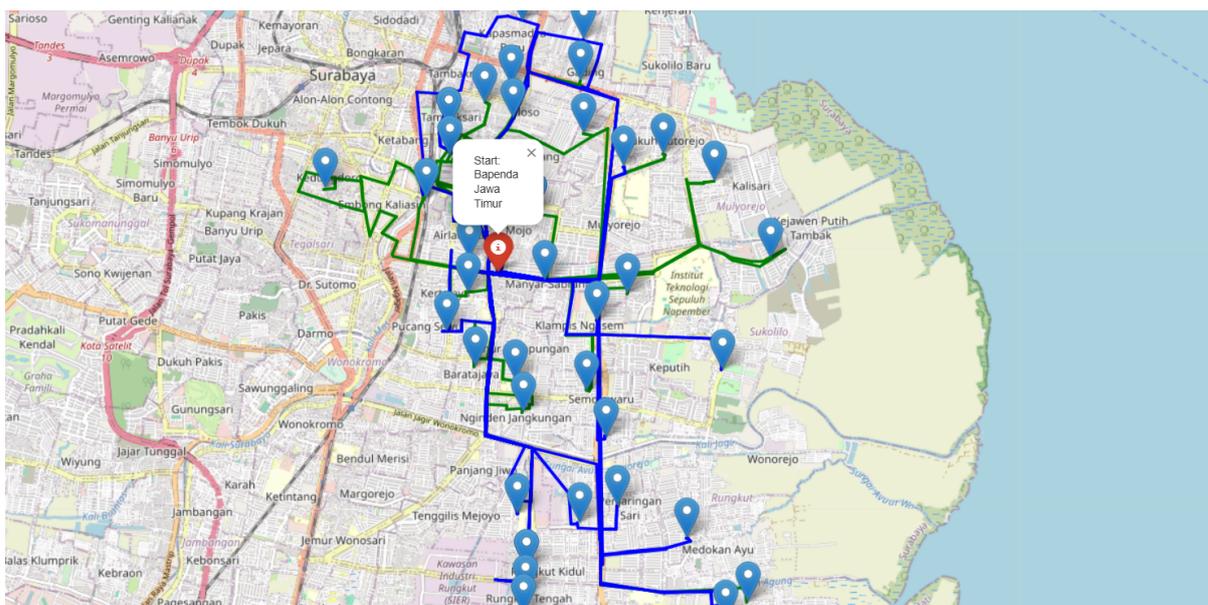
        if loc_name != 'Start':
            folium.Marker(loc_coords, popup=f"{idx}: {loc_name}").add_to(route_map)

        previous_location_coords = loc_coords

```

Kode Sumber 4.8 Implementasi Pencarian Jalur Berkendara

Kemudian peta hasil rute divisualisasikan pada Gambar 4.5 menggunakan *folium.PolyLine* untuk menampilkan garis perjalanan dengan warna berbeda sesuai kendaraan. *Marker* di lokasi awal (*start*) ditambahkan untuk memberikan konteks visual mengenai posisi awal kendaraan. Kombinasi penggunaan matriks jarak, optimasi TSP, dan visualisasi jalur ini memberikan solusi VRP yang efisien dan mudah dipahami.



Gambar 4.5 Hasil Visualisasi VRP

### **4.3 Hasil Analisis Clustering PKB**

Penerapan teknik *clustering* pada data Pajak Kendaraan Bermotor (PKB) menggunakan metode *K-Means*. Data PKB dikelompokkan ke dalam sejumlah klaster untuk mengidentifikasi pola atau kelompok tertentu yang memiliki karakteristik serupa. Hasil *clustering* menunjukkan adanya segmen-segmen yang dapat dibedakan berdasarkan parameter seperti besar CC, keterlambatan pembayaran, dan total PKB yang terutang. Masing-masing klaster mewakili kelompok wajib pajak dengan perilaku pembayaran atau karakteristik yang serupa, yang dapat memberikan wawasan berharga terkait pola pembayaran dan distribusi pajak kendaraan bermotor. Berikut merupakan hasil *clustering* data pajak kendaraan bermotor (PKB) untuk wilayah UPT Surabaya Timur.

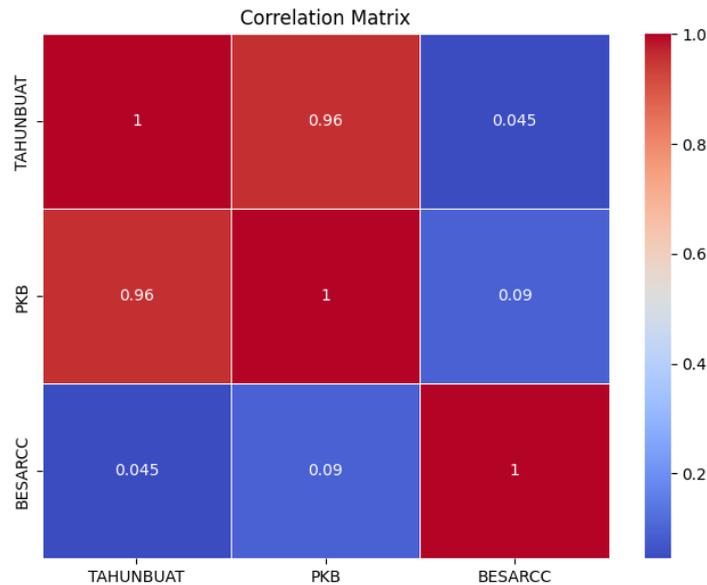
#### **4.3.1 Hasil Analisis Permasalahan PKB**

Pajak yang telah ditetapkan terkadang tidak dipatuhi oleh beberapa masyarakat. Pemerintahan harus memikirkan cara dan program khusus yang dapat menarik kembali minat masyarakat untuk membayar pajak. Pemutihan pajak kendaraan adalah program yang diselenggarakan oleh pemerintah daerah untuk memberikan keringanan atau pembebasan sanksi atas pajak kendaraan yang belum dibayar. Program ini dapat dijadikan sebagai penarik untuk masyarakat dalam membayar pajak.

Penerapan pemutihan pajak (kendaraan) di provinsi Jawa Timur saat ini terbagi menjadi 2, 5% untuk motor dan 10% untuk mobil. Total pendapatan yang didapat berdasarkan data pajak Surabaya Timur tahun 2021 adalah Rp.164.849.609.050 dengan kehilangan untuk pemutihan sebesar Rp.15.515.040.702,50 yang merupakan 9,4% dari total pendapatan. Nilai Rp.15.515.040.702,50 didapatkan dari gabungan 5% pajak kendaraan motor sebesar Rp.969.920.202,50 dari total Rp.19.398.404.050 dan 10% pajak kendaraan mobil sebesar Rp.14.545.120.500 dari total Rp.145.451.205.000.

#### **4.3.2 Pemilihan Fitur**

Sebelum melakukan penerapan ulang dengan strategi baru pada pemutihan pajak, *clustering* diperlukan untuk membagi masyarakat menjadi beberapa segmen berdasarkan kepatuhan/keterlambatan. Fitur yang diambil sebagai pertimbangan terdiri dari “PKB”, “TAHUNBUAT”, “BESARCC”, dan “KETERLAMBATAN”. Penentu keterlambatan individu disesuaikan dengan aturan yang telah ditetapkan, dimana tanggal masa laku harus berjarak minimal 1 tahun atau 365 hari dari tanggal bayar.



Gambar 4.6 Matriks Korelasi Antar Fitur

Matriks korelasi pada Gambar 4.6 menggambarkan hubungan antara tiga fitur. Berikut analisisnya:

- Hubungan “TAHUNBUAT” dan “PKB” (0.96)  
Terdapat korelasi positif yang sangat kuat antara tahun pembuatan kendaraan dengan PKB yang mengindikasikan bahwa kendaraan yang lebih baru cenderung memiliki nilai PKB yang lebih tinggi.
- Hubungan “TAHUNBUAT” dan “BESARCC” (0.045)  
Korelasi sangat lemah antara tahun pembuatan kendaraan dengan kapasitas mesin yang menunjukkan bahwa besarnya kapasitas mesin tidak dipengaruhi secara signifikan oleh tahun pembuatan kendaraan.
- Hubungan “PKB” dan “BESARCC” (0.09)  
Korelasi yang lemah juga ditemukan antara PKB dan kapasitas mesin kendaraan yang menandakan bahwa besaran pajak kendaraan tidak banyak dipengaruhi oleh kapasitas mesin.

### 4.3.3 Hasil Implementasi Elbow Method

Proses dimulai dengan memilih fitur-fitur yang relevan dari *dataset* untuk membentuk matriks data  $X$ . Data ini kemudian distandarisasi menggunakan *StandardScaler* agar setiap fitur memiliki skala yang sama, mencegah dominasi fitur dengan rentang nilai besar. Selanjutnya, *Elbow Method* digunakan untuk menentukan jumlah *cluster* yang optimal ( $K$ ). Dalam metode ini, jumlah *cluster* bervariasi dari 1 hingga 10, dan untuk setiap nilai  $K$ , algoritma *KMeans* diinisialisasi dan di-fit pada data. Nilai *inertia* (total jarak kuadrat dari data ke *centroid cluster*) dihitung untuk setiap  $K$ . Kurva *Elbow* diplot, menunjukkan hubungan antara jumlah *cluster* dan nilai *inertia*. Titik *elbow* pada grafik (titik di mana penurunan inertia mulai melambat) digunakan untuk menentukan jumlah *cluster* optimal, menunjukkan kompromi antara kompleksitas model dan interpretabilitas. Implementasi *elbow method* dapat dilihat pada Kode Sumber 4.9.

```

# Patokan awal PKB, berapa fitur yang berhubungan dengan PKB
features = ['TAHUNBUAT', 'BESARCC', 'PKB', 'KETERLAMBATAN', 'KETERLAMBATAN_BOOLEAN']
X = data[features]

scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

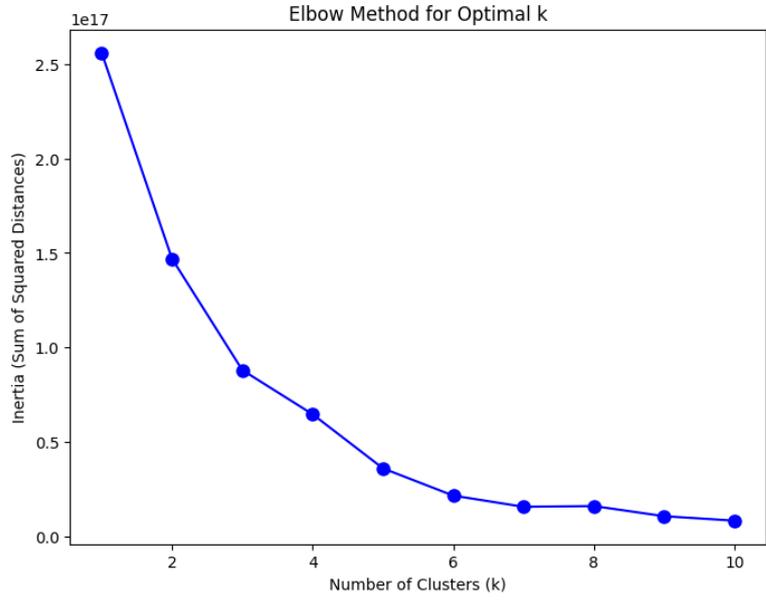
inertia = []

K_range = range(1, 11)
for k in K_range:
    kmeans = KMeans(n_clusters=k, random_state=42)
    kmeans.fit(X)
    inertia.append(kmeans.inertia_) # Append the sum of squared distances

```

Kode Sumber 4.9 Implementasi *Elbow Method*

Nilai optimal untuk jumlah cluster ( $K$ ) ditentukan pada titik di mana kurva mulai melandai, menunjukkan pengurangan yang signifikan dalam *inertia* dengan menambah *cluster*. Dari hasil yang ditunjukkan pada Gambar 4.7, titik optimal terjadi pada  $K = 6$ , yang merepresentasikan keseimbangan antara meminimalkan jarak antar data dalam cluster dan kompleksitas model. Sebelum  $K = 6$ , *inertia* menurun tajam dengan setiap penambahan *cluster*, menunjukkan bahwa setiap *cluster* tambahan memberikan kontribusi signifikan terhadap pengurangan kesalahan. Namun, setelahnya, penurunan *inertia* menjadi lebih lambat, menandakan bahwa penambahan *cluster* selanjutnya tidak memberikan pengurangan yang signifikan terhadap kesalahan, sehingga meningkatkan risiko *overfitting* dan mengurangi interpretabilitas model. Oleh karena itu,  $K = 6$  dipilih sebagai jumlah *cluster* optimal.



Gambar 4.7 Hasil Implementasi Elbow Method

**4.3.4 Hasil Implementasi K-Means Clustering**

Setelah menentukan jumlah *cluster* optimal, algoritma *K-Means* diinisialisasi dan di-fit pada data yang telah distandarisasi. Label *cluster* yang dihasilkan ditambahkan ke *dataset* asli dalam kolom baru *cluster*, sehingga setiap baris data dapat diidentifikasi sebagai anggota dari salah satu *cluster*. Berikut implementasinya yang dapat dilihat pada KODE

```

features = ['TAHUNBUAT', 'BESARCC', 'PKB', 'KETERLAMBATAN', 'KETERLAMBATAN_BOOLEAN']
X = data[features]

scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

kmeans = KMeans(n_clusters=6, random_state=42)

# Fit the model to the scaled data
kmeans.fit(X_scaled)

# Add the cluster labels to the dataframe
data['cluster'] = kmeans.labels_

```

Kode Sumber 4.10 Implementasi *K-Means Clustering*

Kemudian, untuk memastikan analisis lebih akurat, data *outlier* dihapus menggunakan metode *Interquartile Range* (IQR). Nilai kuartil pertama (Q1) dan ketiga (Q3) dihitung, serta rentang antar-kuartil (IQR). Data yang berada di luar batas (lebih kecil dari  $Q1 - 1.5 \times IQR$  atau lebih besar dari  $Q3 + 1.5 \times IQR$ ) dihapus dari *dataset*.

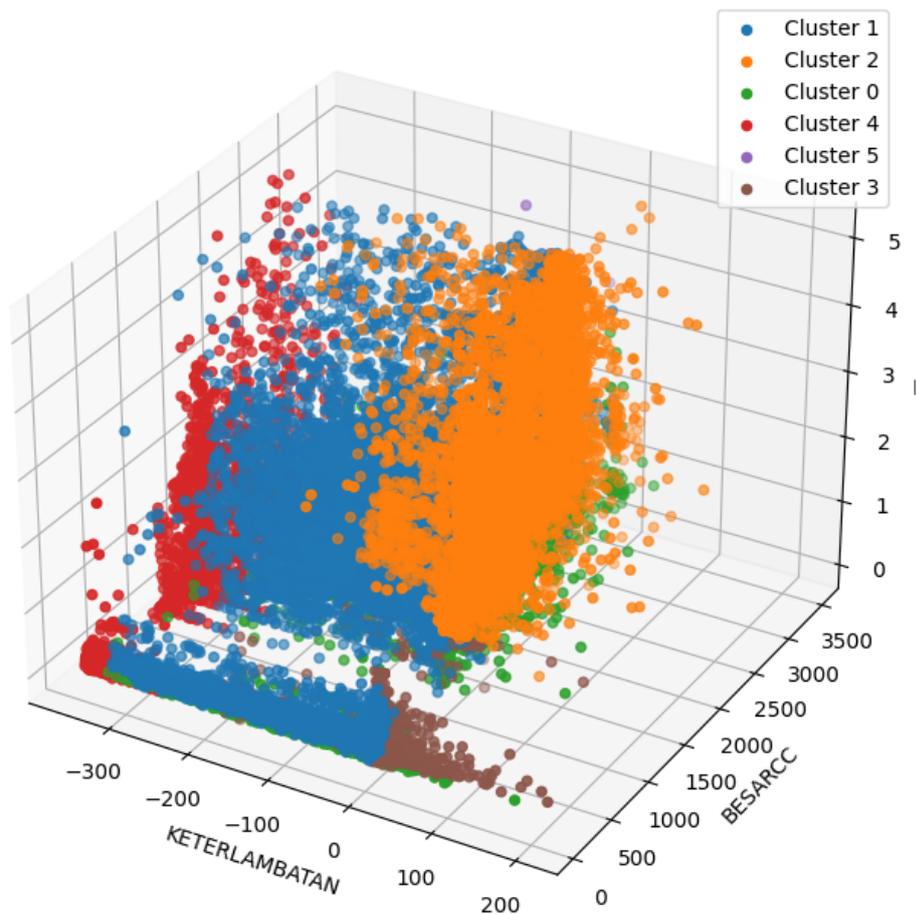
```

# Remove outliers (e.g., using IQR)
Q1 = data[features].quantile(0.25)
Q3 = data[features].quantile(0.75)
IQR = Q3 - Q1
data_filtered = data[~((data[features] < (Q1 - 1.5 * IQR)) | (data[features] > (Q3 + 1.5 * IQR))).any(axis=1)]

```

Kode Sumber 4.11 Penghapusan *Outliers* Menggunakan IQR

Selanjutnya untuk memvisualisasikan hasil *clustering*, fitur-fitur utama (“KETERLAMBATAN”, “BESARCC”, dan “PKB”) digunakan untuk membuat plot 3D. Menggunakan modul *matplotlib* dengan *Axes3D*, data dari setiap *cluster* diplot dalam ruang tiga dimensi dengan warna berbeda untuk setiap *cluster*. Hasil visualisasi ini melengkapi analisis *clustering*, memperkuat interpretasi mengenai struktur data dan distribusi *cluster* dalam *dataset*.



Gambar 4.8 Hasil Visualisasi Kluster Menggunakan *K-Means Clustering*

Gambar 4.8 menunjukkan distribusi data berdasarkan tiga fitur, dimana terlihat bahwa *cluster* memiliki distribusi yang cukup terpisah dengan beberapa tumpang tindih, yang dapat mengindikasikan variasi data yang saling mendekati antar *cluster*. *Cluster* oranye terlihat dominan di area tengah dengan rentang nilai “BESARCC yang tinggi”, sedangkan *cluster* biru menguasai area dengan nilai “KETERLAMBATAN” yang lebih luas. *Cluster* merah cenderung berada di sisi kiri grafik, menunjukkan data dengan nilai “KETERLAMBATAN” rendah.

#### 4.3.5 Hasil Implementasi Label Encoding Euclidian Distance

Hasil implementasi metode *Label Encoding* dengan pengukuran jarak *Euclidean* berfokus pada pengelompokan data berbasis representasi numerik dari fitur kategori. Prosesnya adalah mengubah *string* menjadi angka *numeric sequential* (1, 2, 3, ..) dan menggunakan normal *K-Means*. Proses ini dimulai dengan mengonversi nilai kategori menjadi nilai numerik melalui teknik *Label Encoding*, diikuti oleh penerapan *K-Means clustering* untuk mengidentifikasi kelompok data berdasarkan jarak *Euclidean*. Tahapan ini bertujuan untuk menemukan pola tersembunyi dalam data yang telah diskalakan, dengan menggunakan *Elbow method* untuk menentukan jumlah optimal *K*. Tahapan tersebut diimplementasikan seperti yang terlihat pada Kode Sumber 4.12.

```

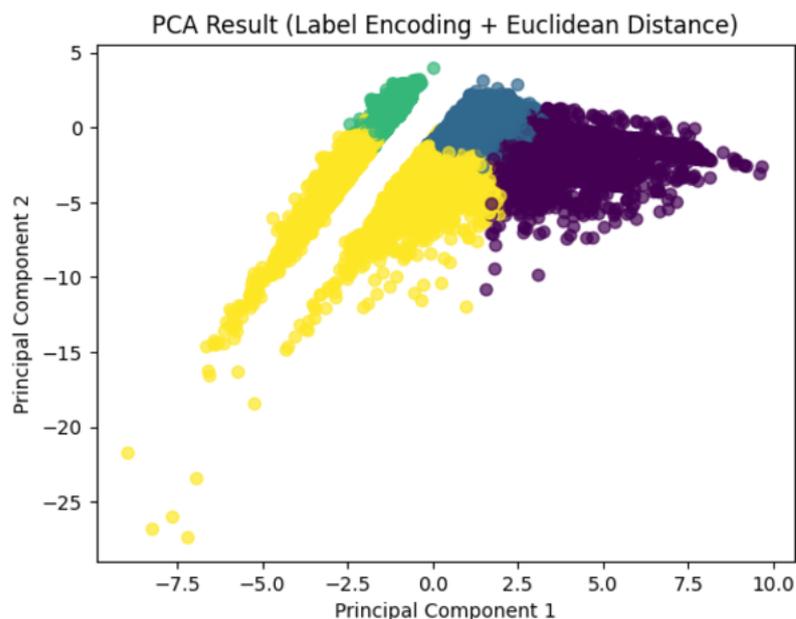
# Elbow Method for Label Encoding
optimal_k_label = plot_elbow(X_label_scaled, "Label Encoding")

# K-Means with Euclidean Distance
kmeans_label = KMeans(n_clusters=optimal_k_label, random_state=42, n_init=10, max_iter=300)
kmeans_label.fit(X_label_scaled)
normal_encoding['cluster'] = kmeans_label.labels_

```

Kode Sumber 4.12 Implementasi *Label Encoding Euclidian Distance*

Pada Gambar 4.9, setelah melakukan *Label Encoding* dan menghitung jarak antar data menggunakan *Euclidean Distance*, hasilnya membagi data ke dalam 5 kluster yang berbeda. Setiap kluster menunjukkan kelompok kendaraan dengan karakteristik yang serupa berdasarkan faktor yang mempengaruhinya. Dengan menggunakan *Euclidean Distance*, setiap titik data dalam kluster tersebut diposisikan berdasarkan kedekatannya terhadap titik data lain yang memiliki nilai fitur serupa. Grafik tersebut memberikan wawasan untuk merancang kebijakan pemungutan pajak yang lebih efisien dengan memperhitungkan segmen-segmen spesifik dalam populasi kendaraan, serta menentukan prioritas untuk pemungutan pajak berdasarkan kluster-kluster yang terbentuk.



Gambar 4.9 Hasil Visualisasi Kluster Menggunakan *Euclidian Distance*

#### 4.3.6 Hasil Implementasi Frequency Encoding Manhattan Distance

Pada implementasi ini, *Frequency Encoding* digunakan untuk mengubah fitur kategori menjadi representasi numerik berdasarkan frekuensi kemunculannya, yang kemudian digunakan dalam algoritma *clustering* berbasis jarak *Manhattan*. Jarak *Manhattan* lebih sensitif terhadap perubahan data pada satu dimensi, menjadikannya cocok untuk *dataset* dengan fitur yang memiliki skala berbeda. Proses *clustering* dimulai dengan penentuan jumlah optimal *K* menggunakan metode *Elbow*, diikuti oleh penerapan *K-Means clustering* yang telah dimodifikasi untuk menghitung jarak *Manhattan*. Tahapan tersebut diimplementasikan seperti yang terlihat pada Kode Sumber 4.13.

```

# K-Means with Manhattan Distance
def manhattan_distance(X, centroids):
    return cdist(X, centroids, metric='cityblock')

class KMeansManhattan:
    def __init__(self, n_clusters=3, max_iter=300, n_init=10, random_state=42):
        self.n_clusters = n_clusters
        self.max_iter = max_iter
        self.n_init = n_init
        self.random_state = random_state

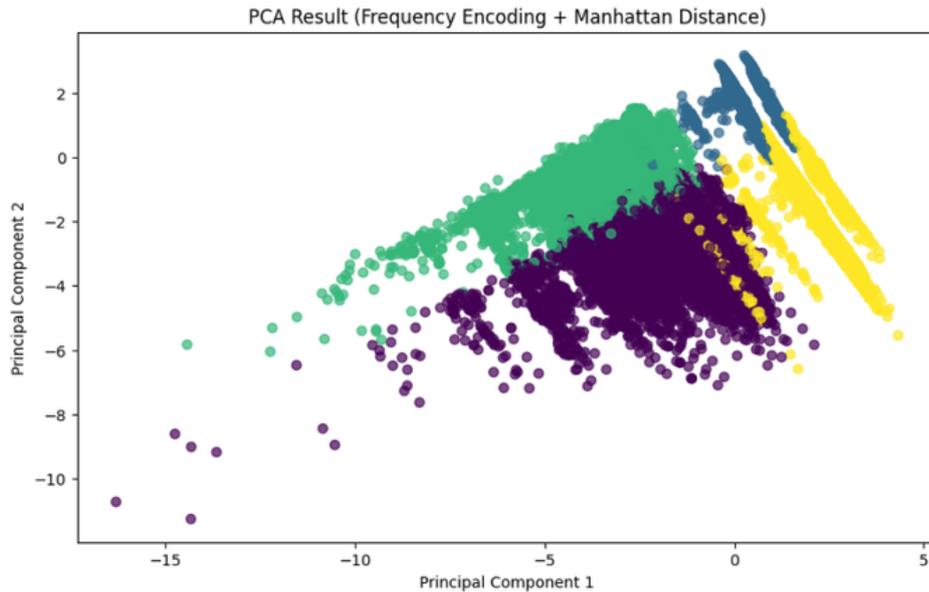
    def fit(self, X):
        best_inertia = float('inf')
        np.random.seed(self.random_state)
        for _ in range(self.n_init):
            centroids = X[np.random.choice(X.shape[0], self.n_clusters, replace=False)]
            for _ in range(self.max_iter):
                distances = manhattan_distance(X, centroids)
                labels = np.argmin(distances, axis=1)
                new_centroids = np.array([X[labels == k].mean(axis=0) for k in range(self.n_clusters)])
                if np.all(centroids == new_centroids):
                    break
                centroids = new_centroids
            inertia = distances[np.arange(X.shape[0]), labels].sum()
            if inertia < best_inertia:
                best_inertia = inertia
                self.centroids = centroids
                self.labels_ = labels
        return self

# K-Means with Manhattan Distance
kmeans_manhattan = KMeansManhattan(n_clusters=optimal_k_freq, max_iter=300, n_init=10, random_state=42)
kmeans_manhattan.fit(X_freq_scaled)
frequency_encoding['cluster'] = kmeans_manhattan.labels_

```

Kode Sumber 4.13 Implementasi *Frequency Encoding Manhattan Distance*

Pada Gambar 4.10, hasilnya menunjukkan bagaimana pengelompokan data berdasarkan kedekatan antar titik data dihitung menggunakan jarak *Manhattan*. *Frequency Encoding* digunakan untuk mengubah kategori-kategori jenis kendaraan dan daerah pembayaran menjadi representasi numerik berdasarkan frekuensi kemunculannya dalam data PKB. Hal ini mempengaruhi cara perhitungan jarak antar titik data, di mana *Manhattan Distance* digunakan untuk mengukur kedekatan antar kendaraan dalam data yang telah diencode. Hasil visualisasi menunjukkan kluster-kluster (sebanyak 5) yang terbentuk berdasarkan karakteristik yang lebih jelas. Kluster-kluster ini mencerminkan pola-pola seperti kendaraan yang sering terlambat membayar pajak. Penggunaan *Manhattan Distance* memungkinkan pemetaan hubungan antar kendaraan berdasarkan jarak numerik yang lebih sesuai dengan distribusi kategori yang ada, memberikan wawasan penting untuk kebijakan penagihan dan pemetaan strategi pemungutan pajak yang lebih tepat sasaran.



Gambar 4.10 Hasil Visualisasi Kluster Menggunakan *Manhattan Distance*

#### 4.4 Hasil Analisis Strategi Baru untuk PKB

Pada bagian ini, analisis dilakukan untuk mengidentifikasi strategi baru dalam meningkatkan efektivitas dan efisiensi pengelolaan PKB (Pajak Kendaraan Bermotor). Proses analisis mencakup pengelompokan data berdasarkan fitur utama yang memengaruhi PKB, seperti keterlambatan pembayaran, besaran nilai PKB, dan karakteristik wajib pajak. Strategi ini diarahkan pada peningkatan kepatuhan wajib pajak dan pengelolaan PKB yang lebih efisien, dengan tujuan meningkatkan pendapatan daerah secara berkelanjutan.

Analisis terhadap data yang dihasilkan dari proses sebelumnya, memberikan informasi yang sangat relevan untuk pengambilan keputusan di Badan Pendapatan Daerah (Bapenda). Klaster yang terdiri dari wajib pajak dengan keterlambatan tinggi dan total PKB yang besar dapat dijadikan target prioritas dalam penagihan pajak atau penerapan kebijakan insentif dan sanksi. Dengan memahami karakteristik setiap klaster, Bapenda dapat merancang strategi yang lebih terarah dan efisien dalam penanganan wajib pajak, seperti penawaran diskon atau pengingat pembayaran untuk kelompok yang cenderung lebih lambat dalam melakukan pembayaran. Hasil analisis juga memungkinkan Bapenda untuk memetakan daerah-daerah dengan jumlah tunggakan pajak yang tinggi, yang bisa dioptimalkan lebih lanjut melalui kebijakan berbasis data. Berikut adalah strategi yang dapat diusulkan dari hasil analisis yang telah dilakukan sebelumnya.

##### 4.4.1 Hasil Analisis Strategi Baru dengan Pemberian Diskon

Sebagai bagian dari upaya meningkatkan kesadaran dan kepatuhan wajib pajak dalam pembayaran Pajak Kendaraan Bermotor (PKB), analisis dilakukan dengan merancang strategi baru berupa pemberian diskon berdasarkan segmentasi kluster. Strategi ini bertujuan untuk mendorong wajib pajak agar melakukan pembayaran tepat waktu sekaligus mengurangi risiko keterlambatan.

Dalam pemberian diskon untuk biaya PKB, berbagai strategi dapat diterapkan untuk mencapai tujuan yang diinginkan. Pada kasus ini, pendekatan yang lebih terukur dapat dilakukan dengan terlebih dahulu menentukan batas maksimal kerugian atau pengeluaran yang

dapat ditoleransi (*maximal loss*). Dengan menetapkan nilai maksimal *loss* ini, diskon dapat dihitung secara proporsional di setiap kluster berdasarkan strategi atau metode penghitungan yang sesuai. Langkah ini memastikan bahwa pemberian diskon tetap terkendali dalam kerangka batas anggaran, sambil mempertimbangkan efektivitas masing-masing metode dalam mendorong pembayaran tepat waktu. Dalam analisis ini, dua pendekatan utama untuk pemberian diskon diimplementasikan sebagai berikut.

#### 4.4.1.1 Strategi 1: Subtraksi Sama Rata

Pada strategi ini, setiap kluster wajib pajak diberi jumlah diskon yang sama tanpa memperhatikan besarnya total PKB dalam kluster tersebut. Pendekatan ini menekankan keadilan absolut antar-kluster, di mana seluruh kelompok diperlakukan setara terlepas dari perbedaan karakteristik seperti nilai PKB atau jumlah wajib pajak dalam kluster. Oleh karena itu pada strategi ini dihitung pembagian pengurangan biaya yang sama di setiap *cluster* dan menentukan diskon proporsional berdasarkan PKB, lalu mengurutkannya sesuai nilai PKB pada tiap *cluster*. Hasil dari strategi ini yang dapat dilihat pada Gambar 4.11 menunjukkan bahwa subtraksi yang merata cenderung memberikan dampak yang stabil terhadap seluruh kluster, namun kurang efektif dalam mendorong peningkatan kepatuhan di kluster-kluster dengan nilai PKB tinggi atau keterlambatan pembayaran yang dominan.

	cluster	PKB	count	discount
4	4	5.593209e+09	9856	0.178788
0	0	8.728998e+09	15069	0.114561
3	3	1.568715e+10	34677	0.063746
1	1	2.173895e+10	51528	0.046000
2	2	6.371980e+10	16418	0.015694

Gambar 4.11 Hasil dari Strategi 1

#### 4.4.1.2 Strategi 2: Subtraksi Bertingkat

Berbeda dengan strategi pertama, strategi kedua menggunakan skema pemberian diskon yang diurutkan berdasarkan total PKB per kluster, dari yang terendah hingga tertinggi. Kluster dengan total PKB terendah mendapatkan diskon yang paling kecil, sementara kluster dengan total PKB tertinggi mendapatkan subtraksi yang lebih besar. Program ini membagi pengurangan biaya pada setiap *cluster* secara bertahap dengan peningkatan bertahap pada setiap iterasi, lalu menghitung diskon proporsional berdasarkan PKB untuk setiap *cluster*, dan mengurutkan hasilnya berdasarkan nilai PKB tiap *cluster*. Strategi ini dirancang untuk memberikan insentif yang lebih signifikan kepada kelompok wajib pajak yang berkontribusi besar terhadap pendapatan daerah. Berdasarkan Gambar 4.12 menunjukkan bahwa pendekatan ini lebih efektif dalam memotivasi wajib pajak pada kluster dengan nilai PKB tinggi untuk membayar tepat waktu, sekaligus mendorong peningkatan kepatuhan secara keseluruhan. Namun, strategi ini memerlukan pengelolaan yang lebih kompleks untuk memastikan keadilan relatif antar-kluster, sehingga implementasinya membutuhkan koordinasi kebijakan yang matang.

	<b>cluster</b>	<b>PKB</b>	<b>count</b>	<b>discount</b>
<b>4</b>	4	5.593209e+09	9856	0.026156
<b>0</b>	0	8.728998e+09	15069	0.059596
<b>3</b>	3	1.568715e+10	34677	0.061334
<b>1</b>	1	2.173895e+10	51528	0.076374
<b>2</b>	2	6.371980e+10	16418	0.063746

Gambar 4.12 Hasil dari Strategi 2

## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Hasil kerja praktik ini menunjukkan bahwa analisis data pajak kendaraan bermotor (PKB) di Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur berhasil mengidentifikasi sejumlah permasalahan yang menghambat pengelolaan pajak. Proses analisis distribusi geografis mengungkapkan bahwa kecamatan Tambaksari memberikan kontribusi pajak terbesar sebesar 27%, diikuti oleh Gubeng dengan kontribusi 19,5%, yang menunjukkan potensi besar untuk peningkatan pendapatan dari wilayah-wilayah ini. Implementasi algoritma *Traveling Salesman Problem (TSP)* dan *Vehicle Routing Problem (VRP)* menghasilkan rute yang lebih efisien, mengurangi jarak tempuh dan biaya operasional pengumpulan pajak, meskipun data menunjukkan bahwa hampir 49% pembayaran dilakukan terlambat. Hasil *clustering* PKB membagi data menjadi 5 kluster, yang menunjukkan kelompok wajib pajak dengan karakteristik serupa dan memberikan wawasan dalam pengelolaan pajak. Temuan ini juga mengindikasikan bahwa pemberian diskon berdasarkan kluster memiliki dampak signifikan pada peningkatan kepatuhan, khususnya di kluster dengan PKB tinggi, yang berkontribusi besar terhadap total pendapatan sebesar Rp 164.849.609.050. Oleh karena itu, Bapenda perlu mempertimbangkan kebijakan pemberian diskon bertahap, di mana kluster dengan keterlambatan tinggi dan kontribusi PKB besar menjadi prioritas utama. Dengan strategi berbasis data yang lebih terstruktur, diharapkan pendapatan daerah dapat meningkat secara signifikan dan berkelanjutan.

#### **5.2 Saran**

Berdasarkan hasil analisis dan pembahasan maka dapat diberikan saran sebagai berikut:

1. Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur perlu mengimplementasikan sistem pengelolaan data pajak kendaraan (PKB) yang lebih terintegrasi, mengurangi ketergantungan pada data manual dan meningkatkan akurasi informasi yang tersedia.
2. Untuk meningkatkan efisiensi lebih lanjut, disarankan untuk memperluas penggunaan algoritma TSP dan VRP dalam aspek logistik lainnya, seperti distribusi barang atau layanan lainnya yang dikelola Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur. Penggunaan algoritma seperti metaheuristik dapat meningkatkan hasil optimalisasi rute dengan mempertimbangkan faktor-faktor dinamis yang berubah seiring waktu.
3. Badan Pendapatan Daerah (Bapenda) Provinsi Jawa Timur harus mempertimbangkan penerapan kebijakan insentif dan penalti yang disesuaikan dengan karakteristik masing-masing kluster wajib pajak. Kebijakan diskon yang bertahap berdasarkan hasil *clustering* PKB akan lebih efektif dalam meningkatkan kepatuhan, terutama bagi wajib pajak yang berisiko tinggi, sekaligus meminimalkan kerugian pendapatan akibat keterlambatan pembayaran.

## DAFTAR PUSTAKA

- BAPENDA. (2024). Badan Pendapatan Daerah (Bapenda) Jawa Timur. <https://bapenda.jatimprov.go.id/>.
- Cai, L., & Zhu, Y. (2015). The challenges of data quality and data quality assessment in the big data era. *Data Science Journal*, 14(0), 2. <https://doi.org/10.5334/dsj-2015-002>.
- Çetin, V., & Yıldız, O. (2022). A comprehensive review on data preprocessing techniques in data analysis. *Pamukkale University Journal of Engineering Sciences*, 28(2), 299–312. <https://doi.org/10.5505/pajes.2021.62687>.
- Cholissodin, I., & Riyandani, E. (2016). SWARM INTELLIGENCE (Teori & Case Study). *Malang: Fakultas Ilmu Komputer, Universitas Brawijaya*.
- Di Giuseppe, M. G., Troiano, A., Troise, C., & De Natale, G. (2013). k-Means clustering as tool for multivariate geophysical data analysis. An application to shallow fault zone imaging. *Journal of Applied Geophysics*, 101, 108–115. <https://doi.org/10.1016/j.jappgeo.2013.12.004>
- Faizan, M., F, M., Ismail, S., & Sultan, S. (2020). Applications of Clustering Techniques in Data Mining: A Comparative study. *International Journal of Advanced Computer Science and Applications*, 11(12). <https://doi.org/10.14569/ijacsa.2020.0111218>.
- Jain, A. K. (2009). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666. <https://doi.org/10.1016/j.patrec.2009.09.011>.
- Kaur, P., Stoltzfus, J., & Yellapu, V. (2018). Descriptive statistics. *International Journal of Academic Medicine*, 4(1), 60. [https://doi.org/10.4103/ijam.ijam\\_7\\_18](https://doi.org/10.4103/ijam.ijam_7_18).
- Kristina, S., Sianturi, R. D., & Husnadi, R. (2021). Penerapan Model Capacitated Vehicle Routing Problem (CVRP) Menggunakan Google OR-Tools untuk Penentuan Rute Pengantaran Obat pada Perusahaan Pedagang Besar Farmasi (PBF), 15(2), 101–106. <https://doi.org/10.61769/telematika.v15i2.359>
- Laporte, G. (2010). The traveling salesman problem, the vehicle routing problem, and their impact on combinatorial optimization. *International Journal of Strategic Decision Sciences*, 1(2), 82–92. <https://doi.org/10.4018/jsds.2010040104>
- MacQueen, J. B. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical*, 1, 281–297. [http://digitalassets.lib.berkeley.edu/math/ucb/text/math\\_s5\\_v1\\_article-17.pdf](http://digitalassets.lib.berkeley.edu/math/ucb/text/math_s5_v1_article-17.pdf)
- Matai, R., Singh, S., & Lal, M. (2010). Traveling Salesman Problem: an Overview of Applications, Formulations, and Solution Approaches. *In InTech eBooks*. <https://doi.org/10.5772/12909>.
- Mukhlis, I. R. (2024). SISTEM INFORMASI (Teori dan Implementasi Sistem Informasi di berbagai Bidang). *PT. Sonpedia Publishing Indonesia*.
- Shekhar, S., & Xiong, H. (2007). Encyclopedia of GIS. *In Springer eBooks*. <http://ci.nii.ac.jp/ncid/BA84678963>

- Siregar, M. P. (2022). Pengaruh Sistem Informasi manajemen dan Pelayanan publik terhadap kinerja Pegawai Penerima Pendapatan dikantor Sistem Administrasi Manunggal Satu Atap (SAMSAT) AEK Kanopan. *Journal Economy and Currency Study (JECS)*, 4(1), 1–13. <https://doi.org/10.51178/jecs.v4i1.357>.
- Smith, K. (1996). An argument for abandoning the travelling salesman problem as a neural-network benchmark. *IEEE Transactions on Neural Networks*, 7(6), 1542–1544. <https://doi.org/10.1109/72.548187>.
- Sudiartana, I. M., & Mendra, N. P. Y. (2017). Faktor – faktor yang mempengaruhi kepatuhan wajib pajak. *Proceeding TEAM*, 2, 184. <https://doi.org/10.23887/team.vol2.2017.170>.
- Toth, P., & Vigo, D. (2014). *Vehicle Routing: Problems, Methods, and Applications*, second edition. <https://ci.nii.ac.jp/ncid/BB18183626>.
- Wijaya, S., Ningrum, S., Myrna, R., & Karlina, N. (2021). Analisis Kepatuhan Wajib Pajak Dalam Membayar Tunggakan Pajak Kendaraan Bermotor Di Provinsi Banten Selama Pandemi COVID-19. *Aliansi : Jurnal Politik, Keamanan Dan Hubungan Internasional*, 197–206(2829–1794).

## **BIODATA PENULIS**

Nama : Anggara Saputra  
Tempat, Tanggal Lahir : Tanjung Enim, 6 Agustus 2003  
Jenis Kelamin : Laki-Laki  
Telepon : +6281260129930  
Email : 5025211241@student.its.ac.id

### **AKADEMIS**

Kuliah : Departemen Teknik Informatika – FTEIC , ITS  
Angkatan : 2021  
Semester : 7 (Tujuh)