

BAB 2

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Dalam penyusunan proyek akhir ini, kajian terhadap penelitian-penelitian terdahulu digunakan sebagai sumber masukan dan ide yang relevan dengan penelitian yang akan dilakukan. Terdapat 4 penelitian yang digunakan sebagai perbandingan dalam proyek akhir ini.

Penelitian pertama oleh Auditya, A. G. B., & Michael, B. (2016), Penelitian dengan judul “Analisis Peramalan Penerimaan Pajak Kendaraan Bermotor dengan Metode *Autoregressive Integrated Moving Average* (ARIMA)” Studi ini berhasil memperkirakan pendapatan pajak kendaraan untuk periode Mei 2015 hingga Agustus 2015. Hasilnya menunjukkan peningkatan pendapatan pajak yang signifikan selama jangka waktu ini, menunjukkan efektivitas model ARIMA dalam memprediksi pendapatan pajak di masa depan. Penelitian menyimpulkan bahwa model ARIMA (1,1,1) (1,0,0) 12 paling cocok untuk memperkirakan pendapatan pajak di Provinsi Jawa Tengah untuk empat periode berikutnya.

Penelitian kedua oleh Khairunnisa, Q. A., Haryadi, N. D., & Audyna, N. (2022), Penelitian dengan judul “Aplikasi Metode ARIMA dalam Meramalkan Rata-Rata harga beras di tingkat Perdagangan Besar(Grosir) Indonesia” Penelitian ini menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) untuk analisis data. Data yang digunakan adalah rata-rata harga beras grosir dari Januari 2017 hingga Oktober 2021, yang diperoleh dari Badan Pusat Statistik (BPS). Model terbaik yang diperoleh dari penelitian ini adalah ARIMA(1,1,2), yang menunjukkan bahwa model ini memiliki nilai *Akaike Information Criterion* (AIC) terendah dan signifikan secara statistik. Hasil peramalan diharapkan dapat membantu pemerintah dalam menjaga stabilitas harga dan cadangan beras di Indonesia, mengingat pentingnya komoditas ini bagi masyarakat.

Penelitian ketiga oleh Sinaga, S. A. (2017), penelitian dengan judul “Implementasi Metode ARIMA Untuk Prediksi Penjualan Mobil” Studi ini menerapkan model ARIMA, yang merupakan kombinasi dari tiga komponen:

Autoregressive (AR), *Integrated (I)*, dan *Moving Average (MA)*. Metode ini memproses data penjualan historis untuk membuat prediksi masa depan.

Penelitian keempat oleh Herwanto, P., Marliani, N., Rosida, R., & Herdyansyah, R. (2023), Penelitian dengan judul “Sistem Analisis Laporan Keuangan Dan Prediksi Kinerja Keuangan PT Astra International Tbk Dengan Model ARIMA” Studi ini menyimpulkan bahwa sementara model ARIMA memberikan prediksi yang cukup akurat untuk beberapa rasio keuangan, itu menunjukkan akurasi yang kurang untuk ROA. Temuan keseluruhan menunjukkan bahwa PT Astra International Tbk memiliki area untuk perbaikan dalam kinerja keuangannya, terutama dalam profitabilitas dan pemanfaatan aset. Penelitian lebih lanjut dapat meningkatkan akurasi prediksi dengan mengeksplorasi model lain atau menggabungkan beberapa pendekatan.

Berdasarkan penelitian sebelumnya, akan dibangun Perhitungan Proyeksi Pajak Kendaraan Bermotor yang akan di Proyeksikan menggunakan metode ARIMA. Bukan hanya itu, pada perhitungan ini akan membantu pihak BAPENDA selaku yang akan menggunakan sistem ini dapat memperhitungkan prediksi pendapatan secara akurat dan dapat memperkirakan pengambilan keputusan yang baik untuk kedepannya. Untuk perbandingan yang lebih spesifik, dapat dilihat pada Tabel di bawah ini.

Tabel 2. 1 Perbandingan Penelitian Terdahulu

Kategori	(Auditya & Michael, 2016)	(Khairunnisa dkk., 2022)	(Sinaga, 2017)	(Herwanto dkk., 2023)
Judul	Analisis Peramalan Penerimaan Pajak Kendaraan Bermotor dengan Metode Autoregressive Integrated Moving Average (ARIMA)	Aplikasi Metode ARIMA dalam Meramalkan Rata-Rata Harga Beras di Tingkat Perdagangan Besar (Grosir) Indonesia	Implementasi Metode ARIMA Untuk Prediksi Penjualan Mobil	Sistem Analisis Laporan Keuangan Dan Prediksi Kinerja Keuangan PT Astra International Tbk Dengan Model ARIMA
Dataset	Data historis pendapatan pajak kendaraan di Provinsi Jawa Tengah	Dataset yang digunakan dalam penelitian ini terdiri dari harga rata-rata beras pada tingkat perdagangan grosir di	Data penjualan mobil	Laporan keuangan PT Astra International Tbk yang dikumpulkan dari tahun 2012 hingga 2021

Kategori	(Auditya & Michael, 2016)	(Khairunnisa dkk., 2022)	(Sinaga, 2017)	(Herwanto dkk., 2023)
		Indonesia yang bersumber dari Badan Pusat Statistik (BPS)		
Algoritma	Autoregressive Integrated Moving Average (ARIMA)	Autoregressive Integrated Moving Average (ARIMA)	Autoregressive Integrated Moving Average (ARIMA)	ARIMA (Autoregressive Integrated Moving Average), MAE, RMSE, MAPE
Kontribusi	Model ini menggunakan data historis untuk memprediksi pendapatan pajak, efektif dalam menganalisis tren dan pola musiman	Studi ini mengidentifikasi ARIMA (1,1,2) sebagai model terbaik dengan akurasi tinggi dalam memprediksi harga beras	Studi ini menggunakan ARIMA untuk menganalisis data penjualan historis dan memprediksi tren masa depan	Studi ini menerapkan ARIMA untuk memprediksi kinerja keuangan dan membantu perusahaan menganalisis data mereka
Pengembangan	Analisis awal dilakukan dengan plot dan korelogram (ACF, PACF) serta transformasi log untuk menstabilkan varians	Analisis menggunakan ACF dan PACF untuk menentukan parameter optimal, diikuti pemasangan model dan pemeriksaan diagnostik	Tes diagnostik memastikan akurasi model termasuk pemeriksaan keacakan residu	Model dikembangkan dengan membagi data menjadi set pelatihan dan pengujian untuk validasi
Hasil	Model ARIMA (1,1,1)(1,0,0) ₁₂ terbukti paling efektif dalam meramalkan pendapatan pajak kendaraan di Jawa Tengah untuk empat periode ke depan	Hasil menunjukkan harga beras stabil dengan puncak pada Desember 2021 sesuai tren historis	ARIMA efektif dalam meramalkan penjualan mobil dan membantu showroom mengelola inventaris	Hasil menunjukkan DER 70,44% dalam kondisi baik, namun ROA dan TATO masih di bawah standar industri

Berdasarkan kajian terhadap beberapa penelitian terdahulu pada Tabel 2.1, diketahui bahwa penelitian-penelitian tersebut telah menerapkan metode ARIMA pada berbagai bidang, seperti peramalan penerimaan pajak kendaraan bermotor, peramalan harga beras, prediksi penjualan mobil, dan prediksi kinerja keuangan perusahaan. Hasil dari penelitian-penelitian tersebut menunjukkan bahwa metode ARIMA mampu menghasilkan prediksi yang cukup baik dalam menganalisis data deret waktu (*time series*). Namun, objek penelitian tersebut berbeda dan belum berfokus pada proyeksi pendapatan Pajak Kendaraan Bermotor di Provinsi Riau.

Penelitian saat ini memiliki beberapa perbedaan dibandingkan dengan penelitian sebelumnya. Penelitian ini menggunakan data historis Pendapatan PKB Provinsi Riau sebagai objek penelitian untuk menghasilkan proyeksi pendapatan pada periode mendatang menggunakan metode ARIMA. Selain itu, hasil proyeksi yang diperoleh akan disajikan dalam bentuk dashboard berbasis web sehingga memudahkan pengguna dalam melihat informasi pendapatan PKB, tren pendapatan, serta hasil prediksi yang dihasilkan oleh model. Kinerja model yang digunakan juga dievaluasi menggunakan metrik *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) untuk mengetahui tingkat akurasi hasil prediksi.

Dengan adanya penelitian ini, diharapkan dapat membantu Badan Pendapatan Daerah (BAPENDA) Provinsi Riau dalam memperoleh gambaran mengenai proyeksi pendapatan Pajak Kendaraan Bermotor pada periode mendatang, sehingga dapat mendukung proses perencanaan dan pengambilan keputusan yang lebih baik berdasarkan hasil prediksi yang dihasilkan.

2.2 Landasan Teori

Landasan teori merupakan bagian yang berisi teori-teori pendukung yang digunakan sebagai dasar dalam pembuatan sistem pada proyek akhir ini. Teori-teori tersebut diperlukan agar proses perancangan dan pengembangan sistem memiliki acuan yang jelas serta sesuai dengan konsep yang digunakan. Pada proyek akhir ini, landasan teori yang dibahas meliputi Pajak Kendaraan Bermotor, *Machine Learning*, metode ARIMA, *Use Case Diagram*, *wireframe*, *Laravel*, *Dashboard* dan *User Acceptance Testing*. Seluruh teori tersebut digunakan untuk mendukung proses pembangunan sistem yang mampu melakukan proyeksi pendapatan Pajak Kendaraan Bermotor yang akan dibuat.

2.2.1 Machine Learning

Machine Learning (ML) merupakan salah satu cabang dari *Artificial Intelligence* (AI) yang memungkinkan sistem komputer mempelajari pola dari data historis untuk menghasilkan prediksi atau keputusan tanpa diprogram secara eksplisit (Nurhidayat et al., 2021). Algoritma Machine Learning memanfaatkan data sebagai dasar pembelajaran sehingga mampu mengenali pola dan

menghasilkan prediksi terhadap data baru. Dalam penelitian ini, ML digunakan untuk memproyeksikan pendapatan PKB berdasarkan data historis penerimaan.

Berdasarkan metode pembelajarannya, penelitian ini menggunakan pendekatan Supervised Learning, yaitu metode pembelajaran yang memanfaatkan data berlabel (labeled data) sebagai data latih. Pada pendekatan ini, model mempelajari hubungan antara data masukan (input) dan data keluaran (output) sehingga dapat menghasilkan prediksi terhadap data baru yang memiliki karakteristik serupa. Menurut (Wardhana, dkk., 2023), supervised learning banyak digunakan dalam berbagai permasalahan prediksi dan peramalan karena mampu mempelajari pola dari data historis untuk memperkirakan nilai pada periode berikutnya.

Dalam konteks penelitian ini, data historis penerimaan PKB digunakan sebagai data latih untuk mempelajari pola perubahan pendapatan dari waktu ke waktu. Model kemudian memanfaatkan pola tersebut untuk menghasilkan proyeksi pendapatan pada periode mendatang. Oleh karena itu, pendekatan supervised learning dinilai sesuai karena penelitian ini berfokus pada permasalahan prediksi (*forecasting*) berdasarkan data historis yang telah tersedia.

2.2.2 Metode ARIMA

AutoRegressive Integrated Moving Average (ARIMA) adalah model statistik yang digunakan untuk analisis deret waktu. Model ini menggabungkan tiga komponen utama:

- 1) *Autoregressive* (AR): Menggunakan nilai-nilai masa lalu dari variabel yang sama untuk memprediksi nilai saat ini. Komponen ini menangkap hubungan antara pengamatan saat ini dan pengamatan sebelumnya (Box et al., 2015).
- 2) *Integrated* (I): Mengacu pada diferensiasi data untuk membuatnya stasioner. Proses ini diperlukan karena banyak data deret waktu menunjukkan tren atau musiman yang perlu dihilangkan agar model dapat memberikan hasil yang akurat (Hyndman & Athanasopoulos, 2021).
- 3) *Moving Average* (MA): Menggunakan kesalahan masa lalu untuk memperbaiki prediksi. Komponen ini membantu dalam menangkap fluktuasi acak dalam data (Brockwell & Davis, 2016).

Model ini terdiri dari tiga komponen utama yang masing-masing direpresentasikan oleh parameter p , d , dan q . Berikut adalah penjelasan dari masing-masing parameter tersebut:

1) p – *Autoregressive (AR) Order*

Parameter p menunjukkan banyaknya lag (keterlambatan) dari nilai variabel itu sendiri yang digunakan dalam model. Komponen *autoregressive* mengasumsikan bahwa nilai saat ini X_t bergantung secara linear terhadap sejumlah nilai sebelumnya

$X_{t-1}, X_{t-2}, \dots, X_{t-p}$. Estimasi nilai p biasanya ditentukan berdasarkan plot *Partial Autocorrelation Function (PACF)*.

2) d – *Degree of Differencing (Integrasi)*

Parameter d menunjukkan berapa kali data perlu didiferensiasi untuk menjadi stasioner (yaitu memiliki rata-rata dan varians yang konstan sepanjang waktu). Proses integrasi ini bertujuan untuk menghilangkan tren atau pola musiman dari data agar memenuhi asumsi stasioner. Nilai d biasanya 0, 1, atau 2, tergantung pada tingkat kestasioneran data.

3) q – *Moving Average (MA) Order*

Parameter q menunjukkan banyaknya lag dari komponen kesalahan acak yang dimasukkan ke dalam model. Komponen *moving average* mengasumsikan bahwa nilai sekarang dipengaruhi oleh kesalahan pada masa lalu, yaitu $et-1, et-2, \dots, et-q$. Nilai q biasanya ditentukan berdasarkan plot *Autocorrelation Function (ACF)*.

Model ARIMA sangat cocok untuk data deret waktu yang menunjukkan pola musiman dan tren, sehingga sering digunakan dalam proyeksi pendapatan pajak (Gujarati & Porter, 2009). Dalam konteks pajak kendaraan bermotor di Provinsi Riau, model ARIMA dapat digunakan untuk menganalisis dan memprediksi penerimaan pajak berdasarkan data historis. Penetapan estimasi metode ARIMA (p,d,q) yang dapat ditentukan dengan cara melihat perilaku dari plot *Autocorrelation Function (ACF)* dan plot *Partial Autocorrelation Function (PACF)* dari deret data berkala. Setelah mendapatkan nilai p,d,q maka bisa melakukan perhitungan peramalan ARIMA.

Autocorrelation Function (ACF), adalah kolerasi antara pengamatan deret waktu yang diatur pada plot di setiap lag. Koefisien autokorelasi dapat dihitung menggunakan rumus berikut ini:

$$\rho_k = \frac{\sum_{t=k+1}^n (X_t - \bar{X})(X_{t-k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad 2 - 1$$

Dimana,

ρ_k : Koefisien autokorelasi

X_t : Data *time series* pada periode t

X_{t+k} : nilai periode x pada periode t+k

$\bar{X}$: nilai rata-rata variabel X

N: banyaknya data

Partial Autocorrelation Function (PACF) adalah kolerasi antar deret observasi dalam lag-lag observasi yang mengukur kedekatan antar observasi dalam periodik. Koefisien autokorelasi dapat dihitung menggunakan rumus berikut ini:

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad 2 - 2$$

Dimana,

ρ_k : Koefisien ACF

j: 1, 2, ..., k

ϕ_{kk} : Koefisien PACF

Model *Autoregressive Integrated Moving Average* (ARIMA) adalah pengembangan dari model ARMA dengan penambahan komponen integrasi (I), yang digunakan untuk menangani data deret waktu yang tidak stasioner. Integrasi mengacu pada proses diferensiasi data untuk menghilangkan tren atau ketidakstabilan dalam data. Berikut adalah bentuk umum dari model ARIMA:

$$\Delta^d X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad 2 - 3$$

Dimana,

X_t : Data ke-t (nilai yang diamati pada waktu t).

μ : Nilai konstan (jika ada).

ϕ_1 : Parameter autoregresif ke-1 untuk model AR.

e_t : Nilai error pada waktu t (juga disebut noise atau residual).

θ_1 : Parameter moving average ke-1 untuk model MA.

d : Tingkat differencing atau integrasi yang diperlukan untuk membuat data stasioner.

Δ^d : Operator differencing untuk membuat data stasioner (differencing sebanyak d kali).

Musiman didefinisikan sebagai suatu pola yang berulang-ulang dalam selang waktu yang tetap. Untuk data yang stasioner, faktor musiman dapat ditentukan dengan mengidentifikasi koefisien autokorelasi pada dua atau tiga time-lag yang berbeda nyata dari nol. Untuk menangani musiman, bentuk umum yang singkat adalah:

$$\text{ARIMA}(p,d,q)(P,D,Q)^M$$

Dimana,

(p,d,q) : bagian yang tidak musiman dari model

(P,D,Q) : bagian musiman dari model

M : jumlah periode per musim

Perhitungan Error dengan menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) adalah dua metrik yang digunakan untuk mengevaluasi kinerja model prediksi. MAE mengukur rata-rata selisih absolut antara nilai yang diprediksi dan nilai aktual, sehingga memberikan gambaran seberapa besar kesalahan rata-rata yang terjadi. Metrik ini mudah dipahami karena menggunakan satuan yang sama dengan data asli. Sementara itu, RMSE mengukur akar kuadrat dari rata-rata kuadrat selisih antara nilai prediksi dan aktual, yang lebih sensitif terhadap kesalahan besar karena memberikan bobot lebih pada kesalahan yang lebih besar. Berikut ini merupakan rumus MAE dan RMSE:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad 2 - 4$$

Dimana, y_i = nilai riil

$\hat{y}_i$ = Hasil Prediksi

n = jumlah total data (jumlah bulan atau periode pengamatan).

$|y_i - \hat{y}_i|$ = menunjukkan besar kesalahan (error) antara nilai riil dan prediksi tanpa memperhatikan arah selisih (positif atau negatif).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad 2 - 5$$

Dimana, n : jumlah data

y_i : nilai aktual ke- i

$\hat{y}_i$: nilai
prediksi ke- i

Dimana, $(y_i - \hat{y}_i)^2$ = menunjukkan kesalahan kuadrat dari tiap prediksi.

Karena nilai error dikuadratkan, RMSE memberikan penalti lebih besar terhadap kesalahan besar, sehingga metrik ini sensitif terhadap outlier. Semakin kecil nilai RMSE, semakin baik kinerja model dalam memprediksi.

2.2.3 Dashboard

Dashboard merupakan media visualisasi informasi yang dirancang untuk menyajikan data dalam bentuk yang ringkas, mudah dipahami, dan interaktif sehingga memudahkan pengguna dalam melakukan pemantauan terhadap suatu kondisi atau kinerja. Dashboard mengintegrasikan berbagai data ke dalam satu tampilan yang berisi grafik, diagram, tabel, indikator, maupun metrik penting sehingga pengguna dapat memperoleh informasi secara cepat tanpa harus melakukan analisis data secara manual. Dashboard banyak digunakan pada berbagai bidang, seperti pemerintahan, pendidikan, kesehatan, maupun dunia bisnis, sebagai alat pendukung dalam proses monitoring dan pengambilan keputusan.

Menurut Mantik (2021), dashboard merupakan alat bantu yang digunakan untuk menyajikan informasi penting secara ringkas sehingga pengguna dapat melakukan pemantauan (*monitoring*) terhadap kondisi organisasi dan mendukung proses pengambilan keputusan secara lebih cepat. Dashboard yang baik tidak hanya

menampilkan data, tetapi juga mampu menyajikan informasi yang relevan, mudah dipahami, dan sesuai dengan kebutuhan pengguna.

Muliandari dan Setiaji (2021) menjelaskan bahwa seiring berkembangnya teknologi informasi, dashboard berbasis web menjadi salah satu solusi yang banyak diterapkan karena dapat diakses melalui berbagai perangkat tanpa memerlukan instalasi aplikasi tambahan. Dashboard berbasis web juga memungkinkan proses pembaruan data dilakukan secara lebih cepat sehingga informasi yang ditampilkan selalu sesuai dengan kondisi terkini. Selain itu, penggunaan visualisasi seperti bar chart, line chart, pie chart, kartu indikator (*summary card*), dan tabel interaktif membantu pengguna dalam mengidentifikasi pola, tren, maupun perubahan data secara lebih mudah.

Secara umum, sebuah dashboard memiliki beberapa karakteristik, yaitu:

- 1) Menyajikan informasi penting dalam satu halaman (*single screen*) sehingga mudah dipantau.
- 2) Menggunakan visualisasi data seperti grafik, diagram, tabel, dan indikator untuk mempermudah pemahaman informasi.
- 3) Menampilkan informasi secara ringkas tanpa mengurangi makna dari data yang disajikan.
- 4) Memudahkan pengguna dalam melakukan monitoring terhadap indikator-indikator penting.
- 5) Mendukung proses analisis serta pengambilan keputusan berdasarkan data yang disajikan.

Penerapan dashboard memberikan berbagai manfaat bagi organisasi, di antaranya meningkatkan kecepatan dalam memperoleh informasi, mempermudah proses monitoring terhadap indikator kinerja, membantu menemukan pola maupun tren data, serta mendukung pengambilan keputusan yang lebih efektif. Dashboard juga mampu mengurangi proses penyusunan laporan secara manual karena informasi telah disajikan secara otomatis dalam bentuk visual yang mudah dipahami oleh pengguna.

Pada penelitian ini, dashboard digunakan sebagai media visualisasi data historis dan hasil proyeksi pendapatan Pajak Kendaraan Bermotor (PKB) di Provinsi Riau. Dashboard dikembangkan berbasis web sehingga dapat menyajikan

informasi mengenai total penerimaan PKB, tren pendapatan, distribusi penerimaan berdasarkan wilayah dan jenis kendaraan, serta hasil proyeksi pendapatan. Dengan adanya dashboard tersebut, BAPENDA Provinsi Riau diharapkan dapat melakukan pemantauan terhadap perkembangan pendapatan PKB secara lebih mudah serta memperoleh informasi yang dapat mendukung proses perencanaan dan pengambilan keputusan.

2.2.4 *Black Box Testing*

Black Box Testing merupakan metode pengujian perangkat lunak yang berfokus pada pemeriksaan fungsi sistem berdasarkan masukan (*input*) dan keluaran (*output*) yang dihasilkan tanpa memperhatikan struktur internal maupun kode program. Pengujian dilakukan dengan memberikan berbagai kondisi masukan kemudian mengamati apakah keluaran yang dihasilkan sistem telah sesuai dengan kebutuhan dan spesifikasi yang telah ditentukan. Dengan demikian, Black Box Testing dapat digunakan untuk mengetahui apakah fungsi-fungsi yang terdapat pada sistem telah berjalan sebagaimana mestinya serta menemukan kesalahan yang terjadi pada saat sistem digunakan. Widia et al. (2021) menerapkan Black Box Testing untuk memvalidasi keluaran sistem berdasarkan data masukan, dengan penyusunan *test case* menggunakan pendekatan *use case*. Beberapa teknik yang umum digunakan dalam *black box testing* antara lain sebagai berikut:

1) *Equivalence Partitioning*

Teknik *Equivalence Partitioning* dilakukan dengan membagi ruang masukan (*input*) ke dalam beberapa kelompok atau kelas berdasarkan karakteristik tertentu. Setiap kelompok dianggap memiliki perilaku pemrosesan yang sama sehingga pengujian dapat dilakukan menggunakan nilai perwakilan dari masing-masing kelompok. Teknik ini dapat mengurangi jumlah kasus pengujian dengan tetap memberikan cakupan pengujian terhadap kelas masukan yang berbeda. Taufikurrohman dan Nuryasin (2024) menggunakan *Equivalence Partitioning* untuk menguji masukan pengguna pada aplikasi, sedangkan *State Transition* digunakan untuk menguji alur perpindahan sistem.

2) *Boundary Value Analysis*

Boundary Value Analysis merupakan teknik pengujian yang berfokus pada nilai-nilai yang berada di sekitar batas suatu rentang masukan. Pengujian dilakukan terhadap nilai pada batas minimum, nilai di bawah batas, nilai di atas batas, serta batas maksimum sesuai dengan kondisi yang ditentukan. Teknik ini digunakan karena kesalahan pada perangkat lunak sering kali muncul pada nilai yang berada di sekitar batas suatu kondisi. Rahmawati et al. (2023) menunjukkan bahwa *Boundary Value Analysis* sesuai digunakan untuk menguji fitur yang memiliki rentang nilai, sedangkan *Equivalence Partitioning* lebih sesuai untuk fitur masukan, pilihan, dan tombol.

3) *Decision Table Testing*

Teknik ini memanfaatkan tabel keputusan untuk menggambarkan berbagai kombinasi kondisi dan tindakan yang mungkin terjadi dalam sistem. Dengan menggunakan tabel tersebut, penguji dapat memastikan bahwa setiap kombinasi kondisi telah diuji dan menghasilkan respons yang sesuai.

4) *Use Case Testing*

Teknik ini berorientasi pada skenario penggunaan sistem oleh pengguna. Pengujian dilakukan berdasarkan use case yang menggambarkan langkah-langkah interaksi pengguna dengan sistem dalam mencapai tujuan tertentu. Dengan demikian, fungsi sistem dapat dievaluasi berdasarkan kondisi penggunaan yang nyata.

5) *State Transition Testing*

Teknik ini digunakan pada sistem yang memiliki beberapa keadaan (state) dan perpindahan antar keadaan tersebut. Pengujian dilakukan untuk memastikan bahwa perubahan status terjadi sesuai dengan aturan dan spesifikasi yang telah ditentukan, serta sistem memberikan respons yang benar pada setiap transisi yang terjadi.

2.2.5 *User Acceptance Testing (UAT)*

User Acceptance Testing (UAT) adalah tahap pengujian akhir dalam pengembangan perangkat lunak yang dilakukan oleh pengguna akhir untuk memastikan bahwa sistem yang dikembangkan memenuhi kebutuhan dan harapan mereka. UAT bertujuan untuk memverifikasi bahwa fungsi-fungsi dalam sistem berjalan sesuai dengan spesifikasi yang telah ditetapkan dan dapat digunakan dalam lingkungan operasional nyata. Pengujian ini dilakukan dengan menggunakan skenario uji yang disusun berdasarkan kebutuhan pengguna dan melibatkan feedback langsung dari pengguna untuk memastikan sistem siap diterapkan. Metode pengujian yang sering digunakan dalam UAT adalah black box testing, di mana pengujian dilakukan tanpa memperhatikan struktur internal sistem. UAT memiliki peran penting dalam memastikan bahwa sistem yang dikembangkan tidak hanya berfungsi secara teknis, tetapi juga dapat diterima oleh pengguna dan memenuhi harapan mereka (Perry, 2006).