

BAB II

KAJIAN LITERATUR

2.1 Profil Perusahaan

PT United Tractors Tbk (UNTR) merupakan anak perusahaan dari PT Astra International Tbk yang merupakan salah satu kelompok usaha terbesar di Indonesia dengan pengalaman luas dalam berbagai sektor industri. Sejak 19 September 1989, perusahaan telah menjadi perusahaan publik dengan mencatatkan sahamnya di Bursa Efek Indonesia. Saat ini, sebagian besar saham perusahaan dimiliki oleh Astra, sementara sisanya dimiliki oleh publik. United Tractors berperan sebagai salah satu pelaku utama di berbagai sektor industri melalui lima pilar bisnis utama, yaitu mesin konstruksi, kontraktor pertambangan, pertambangan, industri konstruksi, dan energi [9].

Salah satu anak perusahaan dari PT United Tractors Tbk adalah PT United Tractors Pandu Engineering yang bergerak di bidang manufaktur alat berat dan rekayasa teknik. Perusahaan ini didirikan pada 8 Februari 1983 dengan mayoritas saham dimiliki oleh PT United Tractors Tbk. Dalam operasionalnya, perusahaan memiliki keunggulan dalam menyesuaikan Item berdasarkan kebutuhan pelanggan sehingga mampu menjadi mitra strategis di berbagai sektor industri. Selain itu, perusahaan berkomitmen untuk memberikan solusi yang komprehensif mulai dari tahap perencanaan hingga implementasi di lapangan, serta didukung oleh layanan purna jual untuk meningkatkan Itemtivitas dan kepuasan pelanggan [10].

UNTR memiliki visi menjadi perusahaan kelas dunia berbasis solusi di bidang alat berat, pertambangan, dan energi untuk menciptakan manfaat bagi para pemangku kepentingan. Misinya meliputi menjadi mitra terpercaya bagi pelanggan melalui Item dan layanan bernilai tambah berkelanjutan, menciptakan peluang bagi insan perusahaan untuk meningkatkan status sosial dan aktualisasi diri, menghasilkan nilai tambah berkelanjutan bagi pemangku kepentingan melalui keseimbangan aspek ekonomi, sosial, dan lingkungan, serta memberikan kontribusi bagi kesejahteraan bangsa melalui program tanggung jawab sosial perusahaan (CSR) [11].

Layanan tersebut yang ditawarkan bertujuan untuk memastikan kinerja alat berat pelanggan tetap optimal dan efisien. Beberapa program yang disediakan antara lain Program Pemeriksaan Undercarriage (PPU) dan Program Analisa Pelumas (PAP), serta

program penjualan seperti bundling dan bulky order untuk mendukung kebutuhan pelanggan dalam pengadaan suku cadang. Pada PT United Tractors Tbk Cabang Medan, aktivitas utama difokuskan pada penjualan dan distribusi suku cadang serta pengelolaan permintaan pelanggan, khususnya dari sektor pertambangan dan kontraktor. Hal ini menjadikan perencanaan kebutuhan suku cadang sebagai aspek penting dalam menjaga ketersediaan barang dan mendukung operasional pelanggan [12].

PT United Tractors Tbk merupakan perusahaan yang bergerak di bidang distribusi alat berat, penyediaan layanan, serta penjualan suku cadang asli untuk berbagai merek seperti Komatsu, Scania, UD Trucks, Tadano, dan Bomag. Penjualan suku cadang asli berperan penting dalam menjaga kinerja alat berat agar tetap produktif dan efisien. Selain itu, perusahaan juga menyediakan layanan purna jual yang bertujuan untuk memastikan kondisi unit pelanggan tetap optimal setelah pembelian. Layanan purna jual yang ditawarkan oleh perusahaan juga sangat bermanfaat karena memberikan ketenangan pikiran kepada pelanggan mengenai kondisi unit dan suku cadang yang dibeli dalam jangka panjang [12].

2.2 Pengelolaan Suku Cadang

Suku cadang merupakan komponen penting dalam suatu mesin yang digunakan untuk menggantikan bagian yang mengalami kerusakan. Ketersediaan suku cadang menjadi faktor penting dalam menjaga keandalan mesin dan kelangsungan operasional produksi, karena tanpa ketersediaan yang memadai dapat menyebabkan terhentinya proses produksi dan menimbulkan kerugian bagi perusahaan [13].

Pengelolaan suku cadang merupakan hal yang sangat penting dalam perusahaan karena dapat mempengaruhi sistem pengendalian suku cadang dan sebaliknya. Perencanaan pengelolaan yang tidak baik dapat menyebabkan fluktuasi permintaan suku cadang, sehingga menyulitkan perusahaan dalam menentukan jumlah persediaan yang optimal [13].

Kelebihan persediaan suku cadang dapat menyebabkan penumpukan stok yang berdampak pada meningkatnya biaya penyimpanan, sebaliknya kekurangan suku cadang dapat menghambat proses perawatan mesin dan operasional produksi. Selain itu, permintaan suku cadang yang bersifat fluktuasi dan tidak pasti juga menyulitkan perusahaan dalam menentukan jumlah persediaan yang optimal, sehingga diperlukan perencanaan yang baik dalam pengelolaan suku cadang [13].

2.3 Peramalan

Peramalan merupakan proses untuk memperkirakan nilai suatu variabel di masa yang akan datang berdasarkan data historis sebagai dasar analisis. Dalam konteks data deret waktu, proses ini memanfaatkan pola seperti tren dan musiman. Berbagai metode dapat digunakan, baik pendekatan statistik seperti ARIMA maupun metode modern seperti Prophet [14].

Peramalan data deret waktu dilakukan dengan memanfaatkan pola yang terdapat dalam data historis, seperti tren dan musiman. Tren menunjukkan arah pergerakan data dalam jangka panjang, sedangkan pola musiman menggambarkan fluktuasi yang terjadi secara periodik. Pemahaman terhadap pola-pola tersebut sangat penting dalam membangun model peramalan yang mampu menghasilkan prediksi yang lebih akurat [14].

Metode peramalan dapat dilakukan menggunakan berbagai pendekatan statistik, seperti Autoregressive Integrated Moving Average (ARIMA) dan metode modern seperti Prophet. Pemilihan metode yang tepat sangat bergantung pada karakteristik data yang digunakan. Oleh karena itu, diperlukan evaluasi model untuk menentukan metode yang paling sesuai serta menghasilkan tingkat kesalahan yang paling rendah [14].

2.4 Machine Learning

Machine learning merupakan bagian dari kecerdasan buatan yang berfokus pada pembelajaran dari data untuk menghasilkan prediksi. Machine learning juga merupakan studi berkelanjutan yang mempelajari konsep pembelajaran komputasi dalam kecerdasan buatan [15].

Dalam analisis data, pendekatan ini digunakan untuk mendukung proses pengambilan keputusan berbasis data dengan menghasilkan insight yang bersifat prediktif. Model machine learning dibangun melalui tahapan data preparation dan data modelling yang memungkinkan sistem berjalan secara otomatis dalam mengolah data [15].

Penerapan machine learning dilakukan dengan menggunakan berbagai algoritma klasifikasi untuk memprediksi berdasarkan data yang tersedia. Algoritma tersebut digunakan untuk mengolah data dan menghasilkan prediksi yang dapat membantu dalam proses pengambilan keputusan [15].

2.5 Metode ARIMA

ARIMA (Autoregressive Integrated Moving Average) merupakan salah satu metode statistik yang luas digunakan dalam analisis dan peramalan data time series. Metode ini

bekerja dengan memanfaatkan hubungan antara nilai data saat ini dengan nilai data sebelumnya. ARIMA sangat efektif digunakan pada data yang memiliki pola tertentu dan dapat dibuat menjadi stasioner melalui proses diferensiasi [16].

Model ARIMA terdiri dari tiga komponen utama, yaitu Autoregressive (AR), Integrated (I), dan Moving Average (MA). Komponen AR digunakan untuk menggambarkan hubungan antara nilai saat ini dengan nilai sebelumnya, sedangkan komponen I digunakan untuk menghilangkan tren agar data menjadi stasioner. Komponen MA digunakan untuk memodelkan kesalahan (error) dari periode sebelumnya yang mempengaruhi nilai saat ini [16].

Dalam penerapannya, model ARIMA dinyatakan dalam bentuk $ARIMA(p,d,q)$, dimana p menunjukkan jumlah lag pada komponen AR, d menunjukkan tingkat diferensiasi, dan q menunjukkan jumlah lag pada komponen MA. Penentuan parameter yang tepat sangat penting untuk menghasilkan model yang optimal, sehingga biasanya dilakukan melalui proses identifikasi, estimasi, dan pengujian model [16].

Bentuk umum ARIMA dinyatakan sebagai:

$$ARIMA(p, d, q) \dots\dots\dots (2.1)$$

Dimana:

- p = orde Autoregressive (AR)
- d = tingkat diferensiasi (differencing)
- q = orde Moving Average (MA)

Persamaan matematis ARIMA adalah:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \dots\dots\dots (2.2)$$

Dimana:

- y_t = nilai data pada waktu ke- t
- c = konstanta
- ϕ_i = koefisien autoregressive
- y_{t-i} = nilai data pada waktu sebelumnya (lag ke- i)
- θ_j = koefisien moving average
- ε_{t-j} = error pada periode sebelumnya
- ε_t = error pada waktu ke- t

Sebelum membangun model ARIMA, dilakukan pengujian stasioneritas data menggunakan Augmented Dickey-Fuller (ADF) Test. Stasioneritas merupakan asumsi penting dalam model ARIMA, di mana data dikatakan stasioner apabila memiliki nilai rata-rata dan variansi yang konstan sepanjang waktu. Hipotesis pada uji ADF adalah H_0 yaitu data memiliki unit root sehingga bersifat non-stasioner dan H_1 yaitu data tidak memiliki unit root sehingga bersifat stasioner. Kriteria pengambilan keputusan pada uji ADF adalah apabila nilai $p\text{-value} < 0,05$ maka H_0 ditolak sehingga data dinyatakan stasioner. Sebaliknya, apabila $p\text{-value} \geq 0,05$ maka H_0 tidak dapat ditolak sehingga data dinyatakan non-stasioner dan diperlukan proses differencing [17].

Dalam uji ADF, model dibentuk dalam bentuk regresi diferensiasi data time series, dimana perubahan data saat ini dipengaruhi oleh nilai data sebelumnya. Parameter dalam model ini diestimasi menggunakan metode Ordinary Least Squares (OLS), yaitu metode yang meminimalkan jumlah kuadrat error untuk memperoleh estimasi parameter yang optimal [17].

Model regresi pada uji ADF dapat dituliskan sebagai berikut:

$$\Delta Y_t = \gamma Y_{t-1} + c + \epsilon_t \dots\dots\dots (2.3)$$

Dimana:

ΔY_t = perubahan data

Y_{t-1} = data pada periode sebelumnya

γ = koefisien yang diuji

c = konstanta

ϵ_t = error

Setelah data mencapai kondisi stasioner, dilakukan analisis menggunakan grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) untuk mengidentifikasi model deret waktu yang sesuai. ACF digunakan untuk mengukur hubungan antara observasi pada waktu ke- t dengan waktu sebelumnya, sedangkan PACF digunakan untuk mengukur korelasi parsial dengan mengabaikan pengaruh lag perantara sehingga model ditentukan berdasarkan pola kedua grafik tersebut [18].

Akaike Information Critermion (AIC) merupakan suatu kriteria informasi yang digunakan untuk memilih model terbaik di antara beberapa model statistik atau

ekonometrika. AIC diperkenalkan oleh Akaike (1973, 1974) dan didasarkan pada nilai likelihood dari model [19].

$$AIC=2k-2\ln(L).....(2.4)$$

Dimana:

k = jumlah parameter dalam model

L = nilai likelihood maksimum

$\ln(L)$ = logaritma natural dari nilai likelihood

2.6 Metode Prophet

Prophet merupakan model machine learning yang digunakan untuk peramalan data time series. Model ini menggunakan pendekatan decomposable time series yang memisahkan komponen data menjadi beberapa bagian, yaitu tren, musiman, dan efek hari libur [20].

Salah satu keunggulan model Prophet adalah kemudahannya untuk dikembangkan dan disesuaikan dengan karakteristik data time series. Model ini juga dapat menghasilkan prediksi yang akurat, terutama ketika dilakukan penyetelan hyperparameter dan menggunakan dataset dalam jumlah yang cukup [20].

Dalam penggunaannya, model Prophet relatif mudah digunakan dan tidak memerlukan keterampilan yang tinggi dalam pengembangannya. Oleh karena itu, model ini dapat digunakan sebagai alternatif metode lain seperti ARIMA dalam melakukan peramalan data time series [20].

Persamaan umum model Prophet adalah:

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t (2.5)$$

Dimana:

$g(t)$ = tren

$s(t)$ = musiman

$h(t)$ = efek hari libur

ϵ_t = error

Komponen tren dalam model Prophet dimodelkan menggunakan pendekatan piecewise linear, yaitu tren yang dapat berubah pada titik-titik tertentu yang disebut changepoints. Model ini memungkinkan perubahan laju pertumbuhan sehingga lebih fleksibel dalam menangkap perubahan pola data [21].

Rumus:

$$g(t) = (k + a(t)^T \delta) t + (m + a(t)^T \gamma) \dots \dots \dots (2.6)$$

Dimana:

k = laju pertumbuhan awal

δ = perubahan laju pertumbuhan

m = offset

$a(t)$ = fungsi indikator changepoint

Komponen musiman dimodelkan menggunakan deret fourier untuk menangkap pola berulang dalam periode tertentu seperti tahunan atau mingguan [17].

Rumus:

$$s(t) = \sum [a_n \cos(2\pi n t / P) + b_n \sin(2\pi n t / P)] \dots \dots \dots (2.7)$$

Dimana:

p = periode (misalnya 365 hari)

a_n, b_n = parameter fourier

n = jumlah komponen

2.7 Evaluasi Model

Evaluasi model peramalan merupakan tahap penting yang bertujuan untuk mengukur tingkat akurasi hasil prediksi. Proses ini dilakukan dengan membandingkan nilai hasil peramalan dengan data aktual. Dalam penelitian peramalan di Indonesia, evaluasi model umumnya menggunakan beberapa metrik kesalahan untuk mendapatkan hasil yang lebih objektif [22].

Beberapa metrik evaluasi yang sering digunakan adalah Mean Absolute Error (MAE), dan Mean Absolute Scaled Error (MASE). MAE digunakan untuk mengukur rata-

rata kesalahan absolut memberikan penalti lebih besar terhadap error yang besar, sedangkan MASE digunakan untuk membandingkan model dengan metode sederhana [23].

2.7.1 MAE (Mean Absolute Error)

Metrik evaluasi yang digunakan untuk mengukur seberapa dekat prediksi model dengan nilai sebenarnya dalam suatu dataset. Metrik ini memberikan ukuran rata-rata dari selisih absolut antara nilai yang diobservasi dan nilai yang diprediksi oleh model. MAE memberikan ukuran rata-rata dari besarnya kesalahan prediksi dalam satuan yang sama dengan variabel yang diukur. Semakin kecil nilai MAE, semakin baik model dapat memprediksi nilai yang diobservasi [24].

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (2.8)$$

Dimana:

y_t = nilai aktual

y^t = nilai prediksi

n = jumlah data

2.7.2 MASE (Mean Absolute Scaled Error)

Mengukur besarnya kesalahan dibandingkan dengan besarnya kesalahan ramalan satu langkah ke depan yang naif sebagai sebuah rasio. Ramalan algoritma berasumsi bahwa berapapun nilainya hari ini akan sama nilainya besok. Jadi, MASE sebesar 0,5 berarti perkiraan Anda kemungkinan besar memiliki kesalahan setengah dari perkiraan naif, yang lebih baik daripada MASE 1,0, yang tidak lebih baik dari perkiraan naif [24].

$$MASE = \frac{\left\{ \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \right\}}{\left\{ \frac{1}{n-1} \sum_{t=2}^n |Y_t - Y_{t-1}| \right\}} \quad \dots (2.10)$$

Dimana:

y_t = nilai aktual

y^t = nilai prediksi

n = jumlah data

y_{t-1} = nilai aktual periode sebelumnya