

Integrasi *forecasting* pada rantai pasok manufaktur komponen otomotif Jepang di Indonesia dengan penerapan metode klasik dan regresi

(Integrated forecasting in supply chain of a leading Japanese automotive component manufacturer at Indonesia with classic and regression method)

Rio Patria^{1#}, Sumarsono Sudarto²

¹Mahasiswa Magister Teknik Industri, Universitas Mercu Buana, Jakarta

²Program Studi Magister Teknik Industri, Universitas Mercu Buana, Jakarta

#Corresponding author: patria.rio001@gmail.com

Received 10 November 2020, Revised 22 November 2020, Accepted 26 November 2020

Abstrak. Kebutuhan Busi sebagai komponen pengganti pada kendaraan mempunyai permintaan yang cukup besar, khususnya bagi manufaktur busi asal Jepang yang telah berdiri sejak 40 tahun yang lalu di Indonesia. Peramalan penjualan busi yang dilakukan oleh perusahaan pada *aftermarket* memiliki akurasi yang tidak cukup baik. Sehingga permasalahan yang muncul adalah bagaimana meningkatkan akurasi peramalan busi pada *aftermarket* untuk mengurangi rugi-rugi pada proses rantai pasok, yaitu rugi *inventory*, produksi dan transportasi. Pada penelitian ini didapatkan bahwa penggunaan metode ARIMA dan MLR memiliki tingkat akurasi yang lebih tinggi dibandingkan metode peramalan yang dilakukan perusahaan ataupun model peramalan lainnya. Didapatkan peningkatan akurasi peramalan menggunakan ARIMA dan MLR mampu menurunkan biaya operasional sampai dengan 25.05% pertahun pada biaya *overtime* dan 40.21% per tahun pada biaya *inventory* produk jadi. Selain itu menurunkan biaya pengiriman material sampai dengan 24.90% pertahun, serta mengurangi biaya *inventory* supplier sebesar 25.74% pertahun.

Kata kunci: peramalan, ARIMA, MLR, persediaan, rantai pasok.

Abstract. *The need of spark plugs as a replacement component has a potential demand, especially for a Company from Japan which establish in the last 40 year ago as manufacture of spark plugs in Indonesia. Sales forecast of spark plugs that develop by Company for aftermarket class has big error. It makes a question 'how to improve the accuracy of forecasting spark plugs in the aftermarket class to reduce losses in the supply chain process', such as loss due to inventory, production and transportation. In this study, it was found that using ARIMA and MLR methods could increase level of accuracy than current forecasting method by Company. It was found that the increment in forecasting accuracy by using ARIMA and MLR was able to reduce operational costs up to 25.05% per year in overtime costs and 40.21% per year in finished goods inventory costs. In addition, reducing the cost of shipping materials by 24.90% per year, and reducing inventory costs on suppliers by 25.74% per year.*

Keywords: forecasting, ARIMA, MLR, inventory, supply chain.

1. Pendahuluan

Forecasting atau peramalan digunakan untuk mengetahui jumlah permintaan akan barang atau jasa. Menurut Stadler (2005) dalam Pujawan (2017) bahwa semua kegiatan *supply chain* bermula dari permintaan. Permintaan yang fluktuatif dari waktu ke waktu akan membutuhkan sumber daya yang lebih besar untuk memenuhinya. Pada industri manufaktur peramalan penjualan memberikan andil yang sangat besar terhadap kegiatan produksi termasuk di dalamnya persediaan. Perencanaan permintaan dan produksi (S&OP) merupakan hal yang penting guna memenuhi *service level* terhadap pelanggan (Disney & Towil, 2003) (Chopra, 2013).

Busi merupakan salah satu komponen penting pada industri manufaktur otomotif. Kebutuhan busi sebagai komponen pengganti pada kendaraan mempunyai permintaan yang cukup besar, khususnya bagi manufaktur busi asal Jepang yang telah berdiri sejak 40 tahun yang lalu di Indonesia. Perusahaan melakukan penjualan untuk mensuplai komponen kepada manufaktur produsen kendaraan (Principle) atau yang biasa disebut OEM (Original

Equipment Manufacturer) yaitu penjualan yang diperuntukkan sebagai barang setengah jadi dari produk kendaraan oleh Principle (Uhl et al, 2017) (Gaikindo, 2018). Pada penjualan *aftermarket* (AM) menjadi bagian penjualan terpenting. Peramalan penjualan busi yang dilakukan oleh perusahaan pada *aftermarket* memiliki akurasi yang tidak cukup baik. Penjualan AM adalah permintaan busi dimana penjualan dan distribusinya dikendalikan sendiri oleh perusahaan itu sendiri. Dengan menerapkan sistem produksi *Make-to-Stock*, perencanaan produksi untuk AM sangat berpedoman pada peramalan internal perusahaan. Saat ini peramalan perusahaan memiliki eror sebesar 30%, artinya perusahaan memiliki ketidakpastian dalam penjualan dengan nilai yang sama dan mampu berakibat dalam perencanaan produksi dan menimbulkan biaya-biaya pada rantai pasok. Tidak hanya berpengaruh pada meningkatnya biaya secara internal perusahaan, rendahnya akurasi peramalan dapat meningkatkan biaya pada pihak ketiga seperti pemasok bahan baku.

Penelitian ini bertujuan untuk mencari metode peramalan terbaik dengan membandingkan beberapa metode peramalan yaitu metode klasik (*Moving Average, Weighted Moving Average, Exponential Smoothing*) dan juga metode regresi (ARIMA dan *Multiple Linear Regression*). Serta melakukan validasi dengan menggunakan MAD, MAPE dan MSE sebagai alat untuk menghitung akurasi dari peramalan.

2. Kajian Teori

Peramalan, ditujukan untuk meramalkan permintaan dari item-item *independen demand* di masa yang akan datang (Gaspersz, 2005). Semua kegiatan rantai suplai bermula dari permintaan (Stadtler & Kilger, 2005) yang digunakan sebagai perencanaan produksi dan penentuan tingkat persediaan (Chopra & Meindl, 2016). Secara umum dapat diambil kesimpulan bahwa tujuan dilakukan peramalan permintaan sebagai dasar dalam perencanaan bisnis yang di dalamnya yaitu kegiatan operasional bisa dalam bentuk produksi, pengadaan jasa, atau persediaan barang jadi atau material guna mendapatkan keuntungan dari pasar. Manfaat dari peramalan permintaan pada proses produksi adalah untuk mencapai efektivitas dan efisiensi dari manajemen produksi dan *inventory* dalam industri manufaktur (Gaspersz, 2005).

Chopra et al. (2016) menggambarkan karakteristik peramalan sebagai berikut:

1. Peramalan akan selalu tidak akurat dengan demikian peramalan seharusnya memiliki ekspektasi pencapaian (*Expectation Value*) dan memiliki eror peramalan yang terukur (*Forecast Error Measurement*).
2. Peramalan jangka panjang (*Long-term forecast*) memiliki akurasi yang lebih rendah dibandingkan peramalan jangka pendek (*Short-term forecast*). Peramalan jangka panjang akan memiliki standar deviasi yang besar terhadap *relative error* dibandingkan dengan peramalan jangka pendek
3. Peramalan *aggregate* cenderung memiliki akurasi yang lebih baik daripada peramalan *disaggregate*, karena peramalan *aggregate* cenderung memiliki standar deviasi yang kecil terhadap *relative error* rata-rata.
4. Pada rantai suplai yang kompleks, informasi menjadi hal yang sangat penting karena distorsi informasi akan berpengaruh pada proses atau rantai setelahnya atau dikenal dengan *Bullwhip Effect* (Barlas & Gunduz, 2011). *Collaborative Forecasting* pada rantai suplai *end customers* (hulu) sampai dengan *supplier* terkecil (hilir) akan mengurangi eror pada peramalan sepanjang rantai suplai (Fildes et al, 2008).

Moving Average, adalah peramalan dengan menggunakan rata-rata dari permintaan masa lalu yang menunjukkan siklus dari *trend (Trend-cycle)* permintaan dengan cara menghilangkan nilai random dari permintaan dalam periode ke- m (Ali et al, 2017). Penentuan jumlah n didasarkan pada percobaan atau simulasi dengan mempertimbangkan situasi riil dilapangan (Pratiwi & Hasibuan, 2020). Data permintaan terbaru akan menghilangkan ketidakpastian lebih baik daripada data permintaan sebelumnya. Siklus trend didapatkan dengan formulasi $m=2k+1$ dimana k merupakan periode peramalan yang diamati. Oleh sebab itu siklus trend (n) biasanya bernilai ganjil ($m= 3, 5, 7, \dots$, dst). Hal ini bertujuan untuk mendapatkan nilai yang simetris dari data peramalan (Hyndman, 2012).

$$\tilde{T}_t = \frac{1}{m} \sum_{j=-k}^k y_{t+j} \quad (1)$$

Dimana

\check{T}_t = Ramalan permintaan untuk periode t

y_t = Permintaan aktual pada periode t

m = *trend-cycle* period

k = Jumlah data dari permintaan yang diamati, $k = 1, 2, 3, \dots$, dst

Weight Moving Average, Model rata-rata bergerak terbobot lebih responsif terhadap perubahan, karena data dari periode yang baru biasanya diberi bobot yang lebih besar.

$$T_t = \sum_{j=-k}^k a_j y_{t+j} \quad (2)$$

Dimana

\check{T}_t = Ramalan permintaan untuk periode t

y_{t+j} = Permintaan aktual pada periode t

a_j = Bobot yang diberikan pada data periode j

k = Jumlah data dari permintaan yang diamati, $k=1, 2, 3, \dots$, dst

Single Exponential Smoothing, Peramalan permintaan dengan metode *exponential smoothing* yaitu dengan cara memberikan bobot rata-rata yang berbeda pada setiap data aktual permintaan, data aktual pada periode terdekat dengan peramalan akan diberikan pembobotan lebih besar daripada data sebelumnya (Hyndman, 2012). *Single Exponential Smoothing* (SES) merupakan metode peramalan yang cocok digunakan untuk peramalan dengan pola seasonal atau tanpa *trend*, karena pada metode SES memasukkan nilai Δ (delta) antara peramalan t-1 dengan aktual permintaannya.

$$\check{T}_t = T_{t-1} + \alpha(A_{t-1} - T_{t-1}) \quad (3)$$

Dimana

\check{T}_t = Nilai ramalan untuk periode waktu ke t

T_{t-1} = Nilai ramalan waktu ke t-1

A_{t-1} = Nilai aktual pada waktu ke t-1

α = Konstanta *exponential*/ Pemulusan, ($0 < \alpha < 1$) yang ditentukan secara subjektif

Metode HOLT's, merupakan metode yang digunakan ketika permintaan yang dipengaruhi oleh *trend* tetapi tidak dipengaruhi oleh musim. Metode ini memuluskan nilai *trend* dengan parameter yang berbeda dari parameter yang digunakan pada deret aslinya (Hyndman, 2012). Metode ini dilakukan dengan melakukan beberapa kali penghitungan yaitu menentukan *level* estimasi *forecast*, menentukan nilai estimasi dari *trend* data yang baru, dan yang terakhir penentuan ramalan baru pada periode t.

$$l_t = \alpha A_{t-1} + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (4)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (5)$$

$$\check{T}_t = l_t + h \cdot b_t \quad (6)$$

Dimana

\check{T}_t = Nilai ramalan untuk periode waktu ke t

l_t = Estimasi *level* pada waktu ke t

b_t = Estimasi *trend* pada waktu ke t

A_{t-1} = Nilai aktual pada waktu ke t-1

h = Jumlah periode untuk ramalan di masa datang

α = Konstanta *exponential*/ Pemulusan untuk level ($0 < \alpha < 1$)

β = Konstanta *exponential*/ Pemulusan untuk trend ($0 < \beta < 1$)

Winter's model, merupakan metode yang digunakan ketika permintaan yang dipengaruhi oleh *trend* dan dipengaruhi juga oleh musim.

$$s_t = \gamma(A_{t-1} - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad (7)$$

$$\check{T}_t = l_t + h \cdot b_t + s_t \quad (8)$$

Dimana:

s_t = Estimasi musim waktu ke t

γ = Konstanta *exponential*/ Pemulusan untuk musim ($0 \leq \gamma \leq 1$)

m = Panjang musim (jumlah bulan/kuartal dalam 1 tahun/periode)

ARIMA atau Box-Jenkins, mengasumsikan bahwa data *time series* memiliki rata-rata konstan dan varian yang konstan atau stasioner (Lin, 2019). Data dikatakan stasioner apabila tidak terdapat pertumbuhan atau penurunan pada data. Kondisi data yang tidak stasioner harus dilakukan. *Differencing* terus dilakukan sampai dengan data tersebut dikatakan stasioner (Stadtler & Kilger, 2005). Model ARIMA dibagi kedalam 3 kelompok, yaitu model *autoregressive* (AR), model *moving average* (MA) dan model campuran.

Autoregressive (AR) dengan orde p dinotasikan dengan AR(p) dinyatakan pada persamaan berikut

$$Y_t = C + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varepsilon_t \quad (9)$$

Model *moving average* yang berordo q dinotasikan dengan MA(q) atau model ARIMA (0,0,q) yang dinyatakan dengan persamaan:

$$Y_t = C + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (10)$$

Model campuran atau dinotasikan dengan ARIMA (p,0,q). Jika diasumsikan AR(1) dan MA(1) maka model campurannya dinotasikan ARIMA (1,0,1) dengan persamaan sebagai berikut:

$$Y_t = C + \beta_1 Y_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (11)$$

Dimana

Y_t = nilai variabel pada waktu ke t

β_p = koefisien *autoregressive*, p (1, 2, 3, ..., p)

θ_q = koefisien *moving average*, q (1, 2, 3, ..., q)

ε_t = nilai kesalahan pada waktu ke t

p = orde AR

q = orde MA

C = Konstanta

Multiple Linear Regression (MLR), adalah model yang menggambarkan hubungan satu variable tergantung (*dependent variable*) terhadap dua atau lebih variable penduga (*predictor variable*) (Hani et al, 2017). Menurut Gujarati dalam (Laoh, 2019) MLR memiliki asumsi-asumsi dasar yaitu (1) model regresi adalah linier dalam parameter, (2) Nilai rata-rata error adalah nol, (3) Variansi dari error adalah konstan, (4) tidak terjadi autokorelasi pada error, (5) tidak terjadi multikolinieritas pada variable bebas, dan (6) eror berdistribusi normal.

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{i,p-1} + \varepsilon_i \quad (12)$$

Dimana:

Y_i = Variabel *dependent* untuk pengamatan ke-i untuk $i = 1, 2, \dots, n$

X_{i1} = Variabel *independent*

β_0 = Parameter yang mempengaruhi variable *independent*

ε_i = variabel residu pada pengamatan ke-i

Akurasi Peramalan, Tingkat akurasi ramalan akan meningkat semakin mendekati periode yang diramalkan karena informasi order dari pelanggan, situasi pasar dan sebagainya menjadi lebih jelas (Pujawan & Mahendrawahti, 2017). Sebuah ramalan yang lebih halus bisa mengurangi bullwhip effect (Fildes et al, 2008) (Buchmeister et al, 2014). Perhitungan eror peramalan digunakan pada dua jenis keputusan. Keputusan pertama adalah untuk membandingkan akurasi dan memilih metode peramalan yang paling optimal diantara metode-metode peramalan yang ada. Keputusan kedua adalah untuk mengevaluasi seberapa mendekati kenyataan (Pratiwi & Hasibuan, 2020).

MAD adalah nilai total absolut dari eror suatu forecast dibagi dengan data atau rata-rata kesalahan mutlak selama periode tertentu tanpa melihat hasil peramalan lebih besar atau lebih kecil dibandingkan aktual. MAD dinotasikan dengan persamaan berikut:

$$MAD = \sum \left| \frac{A_t - F_t}{n} \right| \quad (13)$$

Dimana:

A_t = Nilai aktual permintaan pada periode ke-t

F_t = Nilai peramalan permintaan pada periode ke-t

n = Jumlah periode peramalan

MAPE merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui persentase penyimpangan hasil peramalan. Secara umum MAPE dinotasikan dengan persamaan sebagai berikut:

$$MAPE = \left(\frac{100}{n} \right) \sum \left| A_t - \frac{F_t}{A_t} \right| \quad (14)$$

Dimana:

A_t = Nilai aktual permintaan pada periode ke-t

F_t = Nilai peramalan permintaan pada periode ke-t

n = Jumlah periode peramalan

MSE dihitung dengan menjumlahkan kuadrat semua kesalahan peramalan pada setiap periode dan membaginya dengan jumlah periode peramalan. MSE memperkuat pengaruh angka-angka kesalahan besar, tetapi memperkecil angka kesalahan prakiraan yang lebih kecil dari satu unit.

$$MSE = \sum \frac{(A_t - F_t)^2}{n} \quad (15)$$

Dimana:

A_t = Nilai aktual permintaan pada periode ke-t

F_t = Nilai peramalan permintaan pada periode ke-t

n = Jumlah periode peramalan

Tracking Signal (TS). Menurut (Gaspersz, 2005), ukuran baik atau buruknya ramalan adalah yang mampu memperkirakan nilai-nilai aktual suatu ramalan. Tracking signal dihitung sebagai running sum of the forecast errors (RSFE) dibagi dengan mean absolute deviation (MAD).

$$TS = \frac{RSFE}{MAD} = \frac{\sum(A_i - F_i)}{\sum \left| \frac{A_i - F_i}{n} \right|} \quad (16)$$

Dimana:

A_t = Nilai aktual permintaan pada periode ke-t

F_t = Nilai peramalan permintaan pada periode ke-t

n = Jumlah periode peramalan

Tracking signal yang positif menunjukkan bahwa nilai aktual permintaan lebih besar daripada ramalan. Sebaliknya TS yang negative berarti nilai aktual permintaan lebih kecil daripada ramalan. Tracking signal yang telah dihitung dapat dibuat peta kontrol untuk melihat kelayakan data dalam batas kontrol atas (UCL) dan batas kontrol bawah (LCL)

Moving range diperuntukkan untuk membandingkan nilai-nilai observasi atau data aktual dengan nilai peramalan dari kebutuhan yang sama. MR adalah peta kontrol statistik seperti yang digunakan pada pengendalian kualitas. Jika ada sebuah titik atau data yang berada di luar batas tersebut maka ada beberapa data yang harus dihilangkan atau mencari metode peramalan lain.

$$MR_i = |(F_{i-1} - A_{i-1}) - (F_i - A_i)| \tag{17}$$

Maka,

$$\overline{MR} = \frac{\sum MR}{n - 1} \tag{18}$$

$$UCL = 2,66 \times \overline{MR} \tag{19}$$

$$LCL = -2,66 \times \overline{MR} \tag{20}$$

Dimana:

MR = Moving Range

\overline{MR} = Rata-rata Moving Range

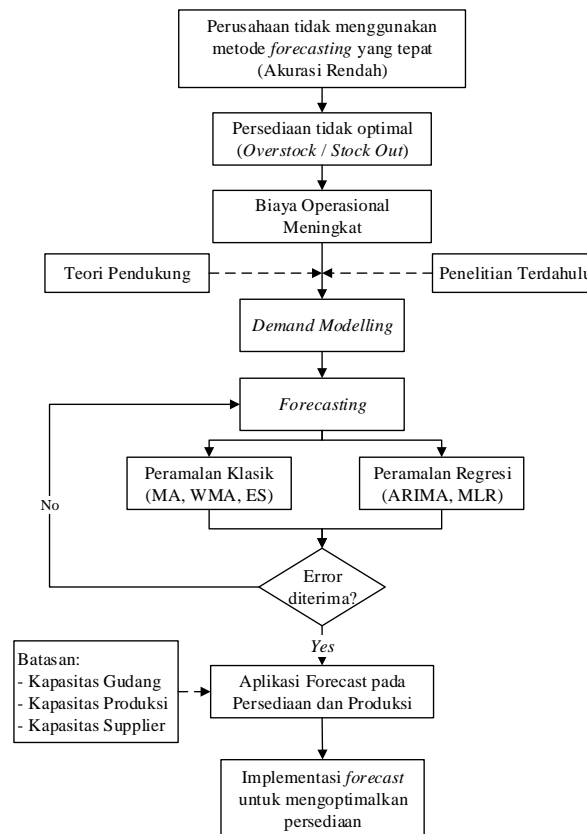
A_i = Nilai aktual permintaan pada periode ke-t

F_i = Nilai peramalan permintaan pada periode ke-t

n = Jumlah periode peramalan

UCL = Batas atas range

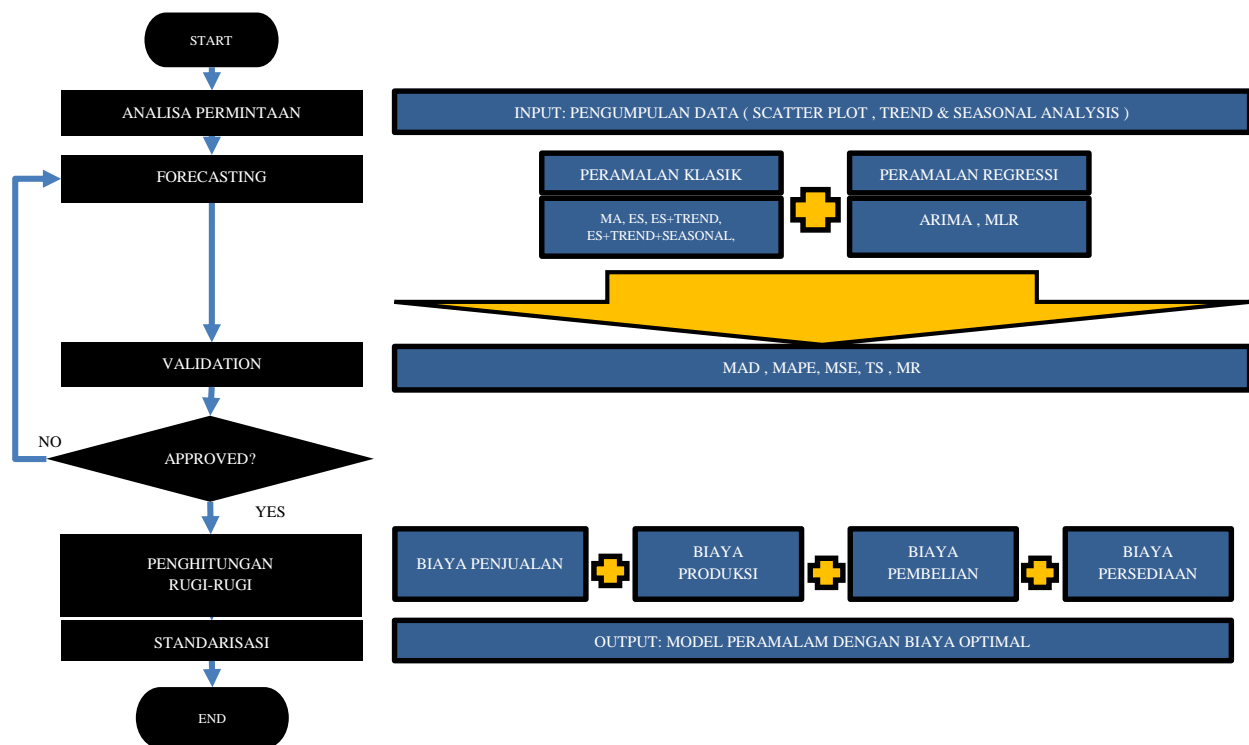
LCL = Batas bawah range



Gambar 1 Kerangka pemikiran penelitian.

3. Metode

Data yang digunakan merupakan data aktual penjualan pada periode sebelumnya. Dengan menggunakan metode ABC didapatkan 4 tipe yang mewakili pola data dengan memiliki pengaruh terbesar pada penjualan perusahaan. Langkah yang dilakukan sebelum melakukan peramalan yaitu mendeskripsikan pola data pada scatter diagram guna mengetahui pola data dan model peramalan yang cocok dengan data. Setelah mendapatkan pola dari data, dilakukan peramalan dengan menggunakan aplikasi MS. Excel untuk peramalan *moving average* dan *weight moving average*. Pada peramalan *single exponential smoothing*, Holt's model dan Winter's model digunakan *tools* tambahan pada MS. Excel yaitu *Solver*. *Tools Solver* digunakan untuk mendapatkan nilai konstanta pemulusan yang memberikan eror peramalan terkecil. Peramalan *multiple linear regression* menggunakan *tools Data Analysis* yang terdapat pada MS. Excel untuk mendapatkan nilai koefisien dari masing-masing variabel yang digunakan. Pada peramalan ARIMA menggunakan aplikasi Minitab 16 dalam pengerjaannya. Metode validasi yang digunakan yaitu *Mean Absolute Deviation (MAD)*, *Mean Absolute Percentage Error (MAPE)* dan *Mean Square Error (MSE)*. Lalu dalam melakukan kontrol terhadap keandalan dari peramalan digunakan metode *Tracking Signal (TS)* dan *Moving Range (MR)*.




Gambar 2 Tahapan Penelitian.

4. Hasil dan Pembahasan

Berdasarkan hasil penghitungan dengan menggunakan MS. Excel dan Minitab maka peramalan dengan menggunakan model MLR dan ARIMA menghasilkan total rata-rata eror per-tahun yang lebih kecil dibandingkan dengan model peramalan lainnya (Gambar 3). Peramalan dengan menggunakan MLR mendapatkan nilai MAD dan MSE secara total terkecil dibandingkan yang lainnya yaitu sebesar 336,757 pcs dan 18,440 juta. Model ARIMA memiliki nilai MAPE secara total terkecil diantara model peramalan lainnya yaitu sebesar 17,8%.

Jika dijabarkan pada setiap tipe yang di teliti berdasarkan kategori A untuk model ARIMA dan MLR diperoleh untuk tipe C7HSA dan BP7HS memiliki nilai MAD dan MAPE terkecil dengan menggunakan model peramalan MLR,

sedangkan pada tipe CPR6EA-9 dan BP5ES yang memiliki nilai MAD dan MAPE terkecil adalah model peramalan ARIMA (lihat Tabel 1).



Gambar 3 Perolehan nilai error MAD, MAPE dan MSE pada setiap model peramalan.

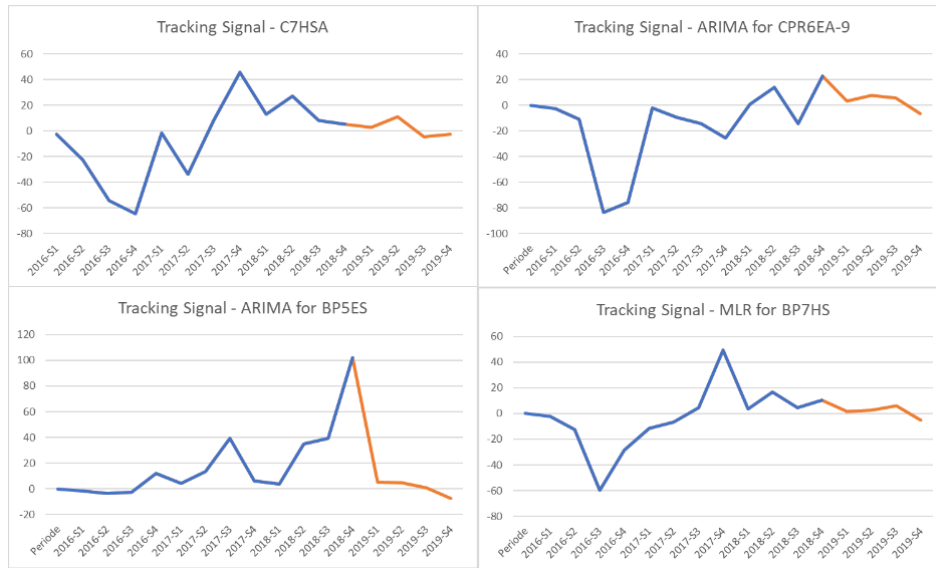
Tabel 1 Perolehan nilai MAD, MAPE dan MSE model peramalan terpilih

Type	C7HSA			CPR6EA-9			BP5ES			BP7HS		
Forecast Model	MAD	MAPE	MSE (in million)	MAD	MAPE	MSE (in million)	MAD	MAPE	MSE (in million)	MAD	MAPE	MSE (in million)
ARIMA	249,811	18.70%	102,670	51,202	16.01%	5,088	20,640	19.35%	821	28,687	17.00%	1,419
MLR	215,615	15.68%	64,339	68,521	21.90%	7,171	24,154	22.15%	935	28,466	16.00%	1,317

Berdasarkan hasil penghitungan tersebut, diputuskan bahwa model peramalan yang akan digunakan oleh perusahaan adalah metode kombinasi antara MLR dan ARIMA. Metode kombinasi ini selanjutnya digunakan untuk memproyeksikan ramalan data penjualan di periode yang akan datang. Untuk memastikan bahwa peramalan yang dilakukan masih layak untuk dipercaya untuk menanggapi perubahan pasar, maka dibutuhkan *tools* untuk memonitor kelayakan model peramalan tersebut. *Tracking Signal* (TS) dan *Moving Range* (MR) dapat dijadikan *tools* untuk memonitor kelayakan dari model peramalan.

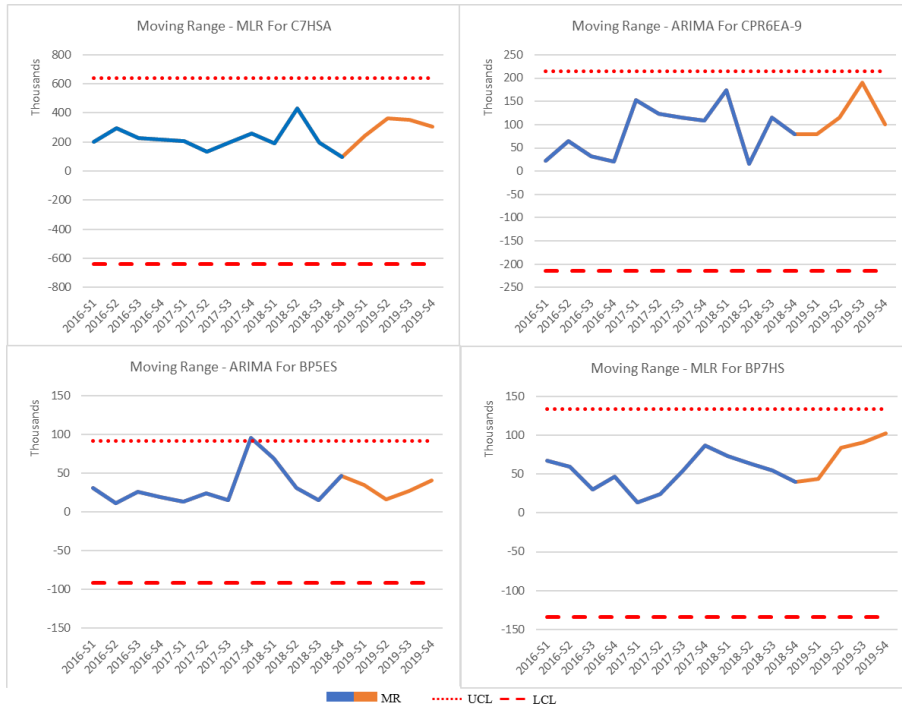
Pada umumnya, peramalan yang memiliki akurasi yang baik akan memiliki nilai TS yang mendekati nilai 0 (nol). Sebaliknya apabila nilai TS menjauhi nilai 0 (nol) mengindikasikan akurasi dari peramalan akan semakin buruk. TS yang bernilai negatif (-) mempunyai arti *overforecasting* atau nilai peramalan lebih tinggi dibandingkan nilai aktualnya. Sedangkan TS yang bernilai positif (+) mempunyai arti *underforecasting* atau nilai peramalan lebih rendah dibandingkan nilai aktual. Pada Gambar 4 dapat diperhatikan bahwa dengan menambahkan data penjualan tahun 2019, terlihat pada masing-masing tipe memiliki TS yang mendekati nilai 0 (nol) yang artinya peramalan yang digunakan memiliki keandalan yang cukup baik dan dapat merefleksikan penjualan dari masing-masing tipe.

Pada tipe BP5ES terdapat nilai *underforecasting* yang cukup signifikan pada 3 periode terakhir penghitungan. Untuk mengetahui apakah keadaan peramalan ini masih didalam ambang normal atau tidak diperlukan analisa lanjutan. Salah satunya dengan melihat kondisi peramalan pada kontrol *Moving range*.



Gambar 4 Perolehan nilai *Tracking Signal* pada model peramalan ARIMA dan MLR.

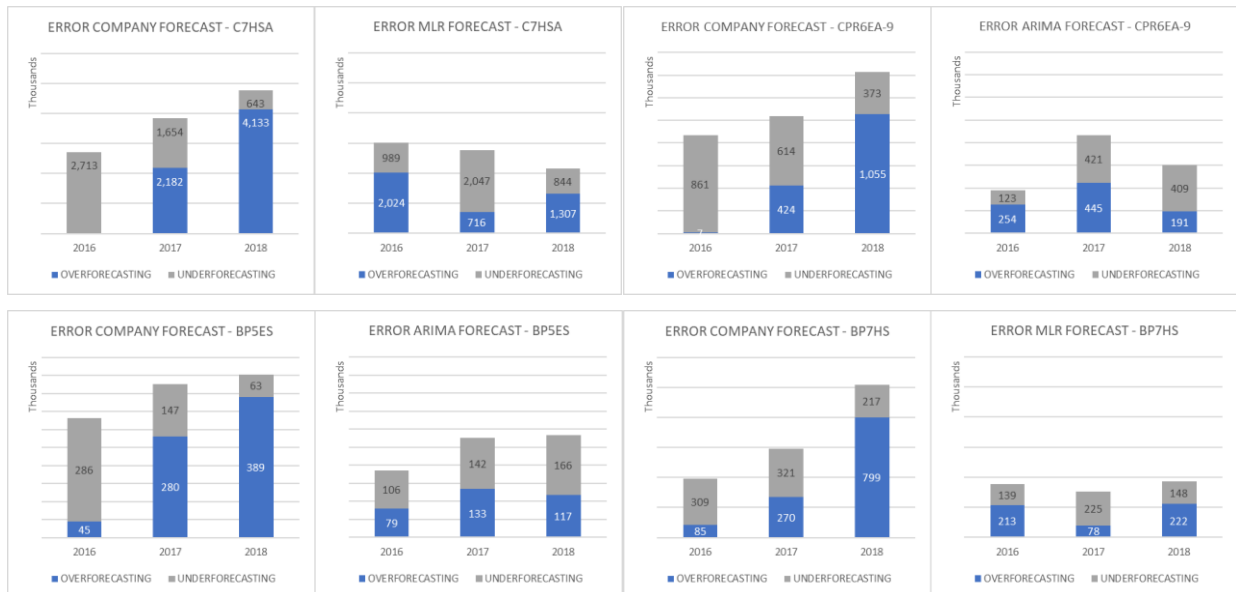
Nilai *underforecasting* pada tipe BP5ES setelah digambarkan dalam tools MR, ada nilai yang di luar dari batas kontrol atas dari MR seperti dapat dilihat pada Gambar 5. Hal ini dikarenakan adanya permintaan abnormal yang terjadi pada awal musim pertama di tahun 2018. Permintaan *abnormal* ini bisa terjadi karena adanya program perusahaan seperti diskon awal tahun atau *campaign* perusahaan guna menaikan penjualan produk. Dan pada periode setelahnya MR pada tipe BP5ES kembali normal atau masih berada dalam batas dari UCL dan LCL. Dengan kata lain model peramalan ARIMA pada tipe BP5ES masih layak untuk digunakan untuk meramalkan penjualan di periode setelahnya.



Gambar 5 Perolehan nilai *Moving Range* pada model peramalan ARIMA dan MLR.

Analisa

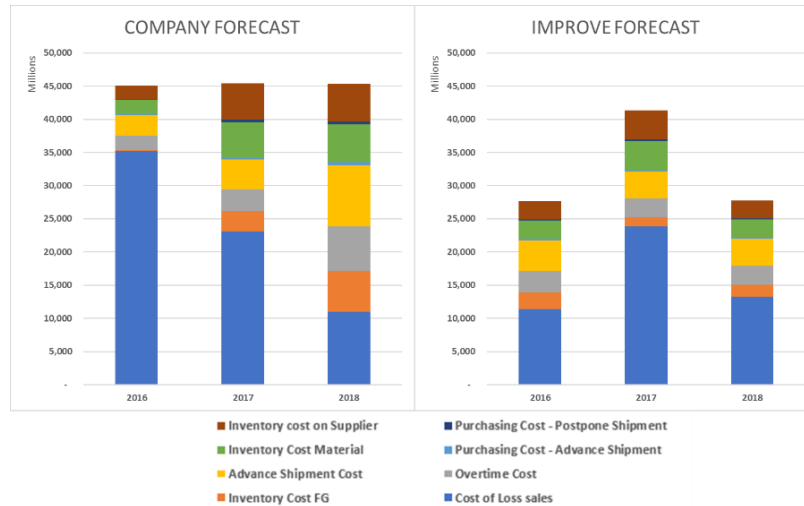
Dengan memakai metode peramalan ARIMA dan MLR didapatkan perbandingan penurunan error dari peramalan yang selama ini perusahaan lakukan dengan model peramalan yang dilakukan peneliti seperti disajikan pada Gambar 6.



Gambar 6 Perbandingan MAD forecast perusahaan vs. model ARIMA & MLR.

Berdasarkan pengolahan data, terdapat temuan bahwa peramalan yang baik akan menurunkan biaya produksi. Mulai dari biaya *overtime* produksi, *inventory*, biaya pengiriman dan biaya *inventory* di sisi supplier. Peramalan *underforecasting* atau peramalan lebih kecil dari aktual penjualan menyebabkan rugi atas kehilangan peluang untuk

menjual produk. Sebaliknya kondisi peramalan *overforecasting* atau peramalan lebih besar dari aktual penjualan menyebabkan rugi akibat meningkatnya biaya *inventory* produk dan material. Hasil temuan dapat dilihat pada Gambar 7 dimana terlihat bahwa model peramalan yang dilakukan oleh perusahaan memiliki tingkat eror terhadap aktual lebih tinggi. Jika dibandingkan nilai MAD dari peramalan yang dilakukan perusahaan dengan model peramalan terpilih dari masing-masing tipe (Gambar 6), terlihat bahwa penurunan eror peramalan cukup signifikan. Hal ini memberikan efek baik pada proses produksi dan rantai pasok yang dapat dilihat pada Gambar 7.



Gambar 7 Perbandingan biaya forecast perusahaan vs model ARIMA & MLR.

5. Kesimpulan dan Saran

Kesimpulan

1. Peramalan MLR dan ARIMA memberikan nilai akurasi paling baik dibandingkan peramalan yang digunakan sebelumnya. Meningkatnya akurasi ini memberikan efek yang signifikan pada proses rantai suplai yaitu dengan menurunnya biaya produksi dan pembelian material serta biaya-biaya lainnya pada sisi *supplier*. Akurasi peramalan meningkat sebesar 17.92% pada tipe yang menggunakan peramalan MLR dan peningkatan akurasi sebesar 11.21% pada tipe yang menggunakan peramalan ARIMA.
2. Menggunakan model peramalan MLR dan ARIMA perusahaan dapat menghemat biaya operasional sampai dengan 25.05% pertahun pada biaya *overtime* dan 40.21% per tahun pada biaya *inventory* produk jadi. Selain itu menurunkan biaya pengiriman material sampai dengan 24.90% pertahun, serta mengurangi biaya *inventory supplier* sebesar 25.74% pertahun.

Saran

Penelitian ini juga diharapkan dapat dijadikan landasan dasar untuk pengembangan penelitian selanjutnya. Adapun beberapa penelitian yang disarankan berdasarkan keterbatasan penelitian ini adalah:

1. Penelitian ini dilakukan pada kategori produk dengan perputaran *inventory* yang cepat (*fast moving*), dimana risiko rugi atas *inventory* yang berlebih lebih kecil dibandingkan kategori produk dengan perputaran *inventory* yang lambat (*slow moving*). Kategori ini dapat menjadi pertimbangan perusahaan untuk penelitian selanjutnya.
2. Penelitian selanjutnya dapat dilakukan dengan mempertimbangkan faktor keadaan sosial, ekonomi dan budaya

Referensi

- Ali, M. M., Zied, M., Boylan, J. E., & Syntetos, A. A. (2017). Supply chain forecasting when information is not shared, 260, 984–994. <https://doi.org/10.1016/j.ejor.2016.11.046>
- Barlas, Y., & Gunduz, B. (2011). Demand forecasting and sharing strategies to reduce fluctuations and the bullwhip effect in supply chains, 62(3), 458–473. <https://doi.org/10.1057/jors.2010.188>

- Buchmeister, B., Friscic, D., & Palcic, I. (2014). Bullwhip Effect Study in a Constrained Supply Chain. *Procedia Engineering*, 69, 63–71. <https://doi.org/10.1016/j.proeng.2014.02.204>
- Chopra, S. (2013). *Supply Chain Management Strategy, Planning and Operation*. (S. Yagan, Ed.) (Fifth Edit). Pearson Education Limited.
- Chopra, S., & Meindl, P. (2016). *Supply Chain Management Strategy, Planning and Operation*. (D. Tylman, Ed.) (Sixth Edit). Harlow, England: Pearson Education Limited. Retrieved from www.pearsonglobaleditions.com
- Disney, S. M., & Towil, D. R. (2003). Vendor-managed inventory and bullwhip reduction in a two-level supply chain.
- Fildes, R., Nikolopoulos, K., Crone, S. F., & Syntetos, A. A. (2008). Forecasting and operational research : a review, 1150–1173. <https://doi.org/10.1057/palgrave.jors.2602597>
- Gaikindo. (2018). Indonesian Automobile Industry Data. Retrieved from <https://www.gaikindo.or.id/indonesian-automobile-industry-data/>
- Gaspersz, V. (2005). *PPIC Berdasarkan Pendekatan Sistem Terintegrasi MRP II dan JIT Menuju Manufaktur 21* (Fifth Edit). Jakarta: Gramedia Pustaka Utama.
- Hani, F., Salleh, M., Zainudin, S., & Arif, S. M. (2017). Multiple Linear Regression for Reconstruction of Gene Regulatory Networks in Solving Cascade Error Problems, 2017.
- Hyndman, R. J. (2012). *Forecasting : principles and practice*.
- Laoh, L. C. (2019). Dividend Payout Forecast : Multiple Linear Regression vs Genetic Algorithm-Neural Network. *Cogito Smart Journal*, 5(2).
- Lin, M. (2019). Forecasting Supply and Demand of the Wooden Furniture Industry in China, 69(19), 228–238. <https://doi.org/10.13073/FPJ-D-19-00011>
- Pratiwi, F., & Hasibuan, S. (2020). Perencanaan persediaan bahan baku amoxicillin menggunakan metode material requirement planning : studi kasus perusahaan Farmasi (Amoxicillin raw material inventory planning using material requirement planning method : pharmacy company case study), 12(3), 344–354.
- Pujawan, I. N., & Mahendrawahti. (2017). *Supply Chain Management*. (Maya, Ed.) (3rd Editio). Yogyakarta: ANDI Yogyakarta.
- Stadtler, H., & Kilger, C. (2005). *Supply Chain Management and Advanced Planning: Concepts, Models, Software and Case Studies* (Third Edit). Heidelberg, Germany: Springer Berlin Heidelberg. Retrieved from springeronline.com
- Uhl, C., Nabhani, F., Kauf, F., Shokri, A., & Hughes, D. (2017). Purchasing Management : The Optimisation of Product Variance. *Procedia Manufacturing*, 11(June), 1366–1374. <https://doi.org/10.1016/j.promfg.2017.07.266>