

Peta Kendali Demerit Untuk Data Autokorelasi (*Moving Centerline Demerit* dan *Moving Range*)

NURMASYITA NASRUDDIN¹, ERNA TRI HERDIANI², NASRAH SIRAJANG³

^{1, 2, 3}Program Studi Statistika Fakultas MIPA Universitas Hasanuddin, Indonesia
e-mail: nurmasyitav@gmail.com

ABSTRAK

Proses industri seringkali menghasilkan data cacat yang bersifat autokorelasi, hal ini menyebabkan asumsi dasar penggunaan peta kendali tidak terpenuhi. Peta kendali demerit direkomendasikan untuk perusahaan yang terdapat berbagai macam tingkat kesalahan. Peta kendali demerit adalah metode pengendalian kualitas yang mengkategorikan jenis cacat ke dalam beberapa kelas berdasarkan tingkat keseriusannya. Peta kendali demerit sangat berguna dalam situasi di mana terdapat berbagai macam tingkat kesalahan, memungkinkan perusahaan untuk mengidentifikasi dan mengatasi cacat berdasarkan tingkat dampaknya terhadap kualitas produk. Penelitian ini bertujuan untuk memperoleh peta kendali Demerit pada data berautokorelasi dan menerapkan peta kendali Residual Demerit dan peta kendali *Moving Centerline Demerit* sebagai solusi dalam peta kendali Demerit autokorelasi terhadap pengendalian kecacatan produk pada data wadah plastik anti bocor. Metode yang digunakan adalah peta kendali demerit, peta kendali Residual, dan peta kendali *Moving Centerline Demerit* (MCD). Data yang digunakan merupakan data sekunder. Hasil penelitian ini memperlihatkan bahwa peta kendali Residual dan peta kendali *Moving Centerline Demerit* sama unggulnya dalam mengatasi data autokorelasi pada peta kendali Demerit dimana sama-sama terdapat 4 *out of control* atau 4 titik yang mengindikasikan adanya masalah proses produksi yang tidak dapat diatasi oleh perusahaan.

Kata Kunci: Autokorelasi, Peta Kendali Demerit, Peta Kendali *Moving Centerline Demerit*, Peta Kendali Residual.

ABSTRACT

Industrial processes often produce defect data that is autocorrelated, causing the basic assumptions of using control maps to not be met. If there are various levels of errors in the company, then the company is advised to use the Demerit control map. Demerit control map is a quality control method that categorizes defect types into several classes based on their seriousness. Demerit control maps are particularly useful in situations where there is a wide range of error rates, allowing companies to identify and address defects based on their level of impact on product quality. This study aims to derive Demerit control maps on autocorrelated data and apply the Residual Demerit control map and the Moving Centerline Demerit control map as solutions in the autocorrelated Demerit control map to product defect control on leak-proof plastic container data. The methods used are Demerit control map, Residual control map, and Moving Centerline Demerit (MCD) control map. The data used is secondary data. The results of this study indicate that the Residual control map and the Moving Centerline Demerit control map are equally superior in overcoming autocorrelated data on the Demerit control map where there are both 4 out of control or 4 points that indicate a production process problem that cannot be overcome by the company.

Keywords: *Autocorrelation, Demerit Control Chart, Moving Centerline Demerit Control Chart, Residual Control Chart.*

1. PENDAHULUAN

Peta kendali demerit adalah peta kendali dengan jenis cacat yang terbagi menjadi beberapa kategori kelas menurut tingkat keseriusan cacatnya, yaitu cacat sangat serius, cacat serius, cacat cukup serius dan cacat minor (Aksioma, 2019). Data yang saling bebas dan menyebar normal dengan nilai tengah dan ragam tetap adalah asumsi dasar penggunaan peta kendali (Syarifuddin dkk, 2018). Akan tetapi, di dalam perusahaan yang melakukan proses industri

seringkali menghasilkan data cacat yang bersifat autokorelasi karena unit-unit berurutan dan saling terikat dengan unit sebelumnya. Jika data produksi adalah autokorelasi, maka akan meningkatkan deteksi pergeseran dan kesalahan tanda bahaya dan menyebabkan meningkatnya rate *type I error* (Bisri, 2019).

Peta kendali demerit merupakan alat yang efektif untuk memantau dan meningkatkan kualitas produk dengan mengukur demerit (bobot cacat) dari waktu ke waktu. Kelebihanannya terletak pada kemampuannya untuk menggambarkan berbagai jenis cacat dengan bobot, mengidentifikasi cacat dominan, memantau tren cacat, mengkomunikasikan informasi kualitas, dan meningkatkan kualitas produk secara keseluruhan. Oleh karena itu, peta kendali demerit bukan hanya menjadi alat pengendalian kualitas, tetapi juga menjadi alat manajemen strategis yang membantu perusahaan dalam membuat keputusan berdasarkan data, meningkatkan efisiensi operasional, dan menjamin bahwa produk yang dibuat memenuhi standar kualitas yang tinggi (Piter dkk, 2021).

Beberapa penelitian telah dilakukan terkait peta kendali demerit. Ramadhani dkk (2014), menuliskan tentang analisis pengendalian kualitas menggunakan diagram kendali demerit untuk studi kasus produksi air minum dalam kemasan 240 ml di PT TIW. Hasil penelitian yang diperoleh terdapat 18 titik pengamatan yang berada di luar batas pengendali (*out of control*) dan terkendali pada iterasi ketiga yang dilakukan. Aksioma (2019), meneliti tentang penerapan peta kendali demerit dan *fuzzy* demerit pada data Kantong semen di PT industri kemasan semen Gresik. Hasil analisis menunjukkan bahwa peta kendali fuzzy demerit lebih sensitif daripada peta kendali demerit. Ini karena peta kendali fuzzy demerit menangkap lebih banyak titik *out of control* daripada peta kendali demerit. Ylmaz & Yank (2020), meneliti tentang *Design of Demerit Control Charts with Fuzzy C-Means Clustering and an Application in Textile Sector*. Hasil yang didapatkan bahwa Peta kendali Demerit *fuzzy C-Means* lebih sensitif daripada peta kendali Demerit konvensional.

Dalam peta kendali untuk mengatasi autokorelasi, sering digunakan peta kendali residual yang menghitung *Moving Range* pada peta kendali demerit. Selain itu, terdapat perkembangan lainnya yaitu *Moving Centerline Demerits* (MCD), yang merupakan peta kendali menggunakan *Exponentially Weighted Moving Average* (EWMA) MCD sesuai digunakan untuk data yang berautokorelasi otomatis dalam hal ini cocok digunakan untuk proses produksi atau layanan yang memiliki perubahan yang dinamis dan tidak stabil dari waktu ke waktu. Nembard dan Nambard (2000), meneliti peta kendali demerit pada data yang berautokorelasi otomatis dan sesuai digunakan untuk data atribut. Dengan demikian penulis tertarik untuk mengkaji kembali penelitian David dan Harriet (2000) dalam artikel yang berjudul "**Peta Kendali Demerit untuk Data Autokorelasi**".

2. METODE PENELITIAN

2.1 Sumber Data dan Tahapan Analisis

Data yang dipergunakan dalam penelitian ini merupakan data sekunder dari proses industri yang memproduksi berbagai model wadah plastik anti bocor yang dibagi dalam 3 kelas. Data ini diperoleh dari publikasi jurnal yang berjudul *A Demerits Control Chart for Autocorrelated Data* dengan jumlah pengamatan 172, Nembard dan Nambard (2000). Data ini menceritakan tentang investigasi dalam operasi industri dimana cetakan injeksi menghasilkan berbagai macam model wadah plastik anti bocor, setiap wadahnya memiliki tiga segel yaitu segel luar, segel tengah dan segel dalam. Tujuan dari segel adalah untuk menjaga cairan di dalam wadah tersebut agar tidak terjadi kebocoran, wadah dianggap baik selama cairan uji ditampung oleh setidaknya salah satu segel.

Selama 172 hari, dilakukan pengambilan sampel dengan mesin cetakan injeksi yang beroperasi dua kali sehari selama 24 jam. Operasi pertama berlangsung selama 18 jam dengan pengambilan sampel sebanyak 9, sementara operasi kedua berlangsung selama 6 jam dengan pengambilan sampel sebanyak 3. Jumlah total sampel selama dua operasi dalam 24 jam adalah 12. Namun, terkadang jumlah sampel melebihi 12 (pada sampel 36, 69, 114, 123, 126, 130, dan 158) karena kecurigaan terhadap kesalahan operator. Sebaliknya, jika operasi berakhir lebih awal, jumlah sampel akan berkurang (pada sampel 50, 100, 101, 105, 122, 124, 134, 137, 138, 139, 140, 141, 146, 148, 151, 160-163, 167, dan 169).

Pada penelitian ini menggunakan *software* statistik (*Minitab*, *Excel* dan *Rstudio*). Tahapan analisis: 1) Melakukan Uji Autokorelasi; 2) Membuat peta kendali demerit; 3) Melihat kestasioneran data; 4) Mengidentifikasi Model Arima; 5) Membuat peta kendali Residual; 6) Membuat peta kendali MCD.

2.2 Peta Kendali Demerit

Peta kendali demerit merupakan peta kendali yang digunakan untuk mengidentifikasi sambungan yang mengalami kerusakan pada setiap unit. Namun, jenis cacat yang berbeda dapat ditemukan dalam proses tertentu, sehingga tidak semua jenis cacat mempengaruhi produk dengan cara yang sama; dengan kata lain, jenis cacat yang terjadi tidak boleh disamakan atau memiliki berat kerusakan yang sama (Irwanto, 2017). Tergantung pada seberapa serius kecacatan yang berbeda dalam setiap kelas, kemungkinan kecacatan produk biasanya dikategorikan ke dalam tiga kelas berdasarkan prosedur yang digunakan (Piter dkk., 2021).

Jumlah cacat terboboti (d_i), pada masing-masing subgrup (i) ditentukan dengan mengalikan jumlah unit cacat pada obeservasi ke- i dan di kelas j ($c_{i,j}$) dengan bobot sistem (w_i), pembobotan akan meningkat selaras dengan tingkatan cacat demerit, jumlah cacat terboboti dapat dirumuskan seperti pada persamaan berikut (Montgomery, 2020):

$$d_i = w_1 c_{i,1} + w_2 c_{i,2} + w_3 c_{i,3} \quad \dots (1)$$

dan untuk nilai rata-rata cacat per unit (U_i) diperoleh dengan persamaan berikut:

$$U_i = \frac{d_i}{n_i} \quad \dots (2)$$

dengan n_i banyaknya sampel pada observasi ke- i .

Garis tengah peta kendali demerit atau CL diperoleh menggunakan persamaan sebagai berikut:

$$\bar{U} = w_1 \bar{u}_1 + w_2 \bar{u}_2 + w_3 \bar{u}_3 \quad \dots (3)$$

dengan \bar{u}_1, \bar{u}_2 , dan \bar{u}_3 yang memperlihatkan rata-rata cacat per unit untuk kategori atau per kelompok 1, 2 dan 3 yang dapat diperoleh dengan persamaan sebagai berikut:

$$\bar{u}_j = \frac{\sum_{i=1}^m c_{i,j}}{\sum_{i=1}^m n_i} \quad \dots (4)$$

dengan:

$c_{i,j}$: jumlah unit cacat pada obeservasi ke- i dan di kelas j

j : jumlah kelas dimana $j: 1,2$ dan 3

n_i : banyaknya sampel pada obeservasi ke- i

i : $1,2,3, \dots, m$

Nilai dari batas kontrol dapat divisualisasikan sebagai UCL atau batas kendali atas dan LCL atau batas kendali bawah sebagai berikut:

$$\begin{aligned} UCL &= \bar{U} + 3\hat{\sigma}_{U_i} \\ LCL &= \bar{U} - 3\hat{\sigma}_{U_i} \end{aligned} \quad \dots (5)$$

Selanjutnya untuk menghitung nilai standar deviasi $\hat{\sigma}_{U_i}$ adalah:

$$\hat{\sigma}_{U_i} = \sqrt{\frac{(w_1^2 \bar{u}_1 + w_2^2 \bar{u}_2 + w_3^2 \bar{u}_3)}{n_i}} \quad \dots (6)$$

dengan $i : 1,2,3 \dots, m$

2.3 Peta Kendali Demerit

Peta kendali biasanya dibuat dengan asumsi data berdistribusi normal atau kebebasan. Namun, proses autokorelasi terjadi ketika data tidak selalu berdistribusi normal, yang berdampak pada pembuatan peta kendali. Uji Durbin-Watson adalah contoh uji yang mengevaluasi keberadaan autokorelasi (Rismayanti dkk., 2022). Hipotesis berikut digunakan dalam uji Durbin-Watson (Azizah dkk., 2021):

$H_0: \rho = 0$ (Tidak ada autokorelasi)

$H_1: \rho \neq 0$ (Ada Autokorelasi)

Guna mengatasi data yang memiliki autokorelasi, mencari residual dari model peramalan terbaik adalah pendekatan yang efektif. Residual ini memenuhi asumsi yang diperlukan untuk membuat peta kendali. Sebelumnya, data yang digunakan dalam analisis *time series* harus stasioner. Kestasioneran data dapat diverifikasi menggunakan uji unit *root*, seperti uji *Augmented Dicky Fuller* (ADF). Uji ADF adalah alat statistik yang menentukan stasioneritas data deret waktu. Stasioneritas adalah karakteristik penting dalam analisis deret waktu, menunjukkan bahwa data tidak memiliki tren atau musiman yang konsisten seiring waktu. Dengan kata lain, fluktuasi data bersifat "statis" atau tetap sepanjang periode pengamatan (Nursiwan, 2023).

2.4 Peta Kendali I-MR

Alwan dan Roberts (1988) dalam Zhou dkk (2020) mengusulkan untuk memodifikasi teknik pembuatan peta *Statistical Process Control* (SPC) untuk memperbaiki sebagian masalah yang terkait dengan sampel autokorelasi dengan menyesuaikan model deret waktu yang sesuai dengan data dan kemudian menerapkan peta kendali Residual kedalam model.

2.4.1 Pemilihan Model Arima

Alat utama untuk mengidentifikasi dari data yang ingin kita ramalkan dalam metode runtun waktu adalah dengan mempergunakan fungsi autokorelasi dan fungsi autokorelasi parsial. Menurut Montgomery dkk (2015), untuk suatu data deret waktu X_1, X_2, \dots, X_t maka fungsi autokorelasinya seperti pada Persamaan (7) sebagai berikut:

$$\rho_k = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)}\sqrt{\text{Var}(X_{t+k})}} = \frac{E(X_t - \mu)(X_{t+k} - \mu)}{\sqrt{E(X_t - \mu)^2}\sqrt{E(X_{t+k} - \mu)^2}} = \frac{\gamma_k}{\gamma_0} \quad \dots (7)$$

dengan:

μ : rata-rata

γ_k : autokovariansi pada *lag* k

ρ_k : autokorelasi pada *lag* k

t : waktu pengamatan

Nilai *partial autocorrelation function* pada *lag* k adalah

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j} \quad \dots (8)$$

dengan ϕ_{kk} adalah autokorelasi parsial antara X_t dan X_{t-k}

2.4.2 Pembuatan Peta Kendali I-MR

Jika model deret waktu memberikan kecocokan yang baik, maka akan menghilangkan autokorelasi, sehingga dihasilkan residual independen. ACF dan PACF untuk residual dapat dirumuskan sebagai berikut:

$$r_i = \hat{y}_i - y_i \quad \dots (9)$$

dengan:

\hat{y}_i : estimasi parameter y_i

y_i : nilai pada data sebelumnya yaitu U_i

Moving range dapat didefinisikan sebagai:

$$R = |(r_i)(r_{i-1})| \quad \dots (10)$$

Rata-rata *moving range* didefinisikan sebagai berikut:

$$\bar{R} = \frac{\sum_{i=2}^N R_i}{N-1} \quad \dots (11)$$

dengan N adalah jumlah data

Untuk pembuatan peta kendali Residual untuk garis tengah peta kendali Residual adalah pada titik nol. Menentukan batas kontrol atas dan bawah pada peta Residual dengan menggunakan 3-sigma, sehingga nilai batas kontrol dapat digambarkan sebagai berikut:

$$UCL = \bar{r} + \frac{3}{d_2} \bar{R} \quad \dots (12)$$

$$LCL = \bar{r} - \frac{3}{d_2} \bar{R}$$

dengan:

\bar{r} : nilai rata-rata residual

\bar{R} : nilai rata-rata *moving range*

d_2 : 1,128

2.5 Peta Kendali MCD

Alternatif untuk pendekatan di atas adalah dengan menggunakan model EWMA sebagai perkiraan model deret waktu umum yang mempertahankan peta kendali tunggal yang ekuivalen. Pada penelitian Nembhard & Nembhard (2000), untuk membuat peta kendali MCD dengan menghitung nilai rata-rata cacat per unit dengan Persamaan (2). Model EWMA dengan nilai rata-rata cacat yang terkait dengan sampel i sebagai berikut:

$$W_i = \lambda U_i + (1 - \lambda)W_{i-1} \quad \dots (13)$$

dengan:

i : 1,2,3 ..., m

λ : nilai pembobot dengan $0 < \lambda \leq 1$ perkiraan satu langkah kedepan

U_i : nilai rata-rata cacat per unit.

W_0 : rata-rata data awal (U_i)

Jika W_i diramalkan untuk pengamatan pada periode $i + 1$, maka prediksi masa depan ini dilambangkan dengan

$$\hat{W}_{i+1}(i) = W_i \quad \dots (14)$$

Kesalahan prediksi residual satu langkah kedepan mengikuti metode dari Mastrangelo dan Montgomery (1995) dalam Graxinha & Pereira (2023) yaitu $e_i = U_i - \hat{W}_i(i - 1)$, didistribusikan secara independen dan tidak berkorelasi dengan rata-rata nol dan standar deviasi. Peta kendali EWMA dapat diterapkan pada data autokorelasi karena EWMA adalah prediktor satu langkah maju yang optimal untuk kelas tertentu dari model deret waktu. Peta MCD kemudian dirancang dengan menggunakan prediktor satu langkah ke depan sebagai garis tengah untuk periode $i + 1$ dengan tiga sigma pada batas kendali atas dan batas kendali bawah:

$$\begin{aligned} UCL_{i+1} &= W_i + 3\sigma_p \\ LCL_{i+1} &= W_i - 3\sigma_p \end{aligned} \quad \dots (15)$$

Untuk memperkirakan σ_p dengan menggunakan standar deviasi tetap dari satu langkah ke depan dengan akar kuadrat dari jumlah kesalahan prediksi dibagi dengan jumlah pengamatan:

$$\sigma_p = \sqrt{\frac{\sum_{i=1}^N (U_i - \hat{W}_i(i-1))^2}{N}} \quad \dots (16)$$

dengan:

N : Jumlah data

U_i : Nilai rata-rata cacat per unit

\hat{W}_i : Prediksi EWMA

i : 1, 2, 3 ..., m

Batas kendali dihitung, kemudian diplot ke depan untuk perbandingan pada periode berikutnya.

3. HASIL DAN PEMBAHASAN

3.1 Uji Autokorelasi

Berdasarkan *software* Minitab diperoleh nilai Durbin-Watson sebesar 0,0224, dalam kriteria pengambilan keputusan pada DW dengan nilai dL pada Lampiran 3 yaitu $dL = 1,7389$ dengan $\alpha = 5\%$, $n = 172$ dan $k = 1$, maka tolak H_0 . Sehingga, dapat disimpulkan bahwa $0 < 0,0224 < 1,7389$ autokorelasi yang terjadi pada data adalah autokorelasi positif.

3.2 Peta Kendali Demerit

Jumlah ketidaksesuaian yang terdapat dalam data untuk setiap kategori yang diamati adalah 172 sampel, ukuran sampel yang paling sering diambil adalah 12 sampel dalam sehari atau 24 jam, tetapi terkadang sampel yang diambil lebih banyak atau lebih sedikit dari biasanya. Peta kendali biasanya dibuat dengan asumsi data berdistribusi normal atau kebebasan. Namun, faktanya data tidak selalu berdistribusi normal dan terjadi proses autokorelasi.

Kategori kecacatan yang digunakan yaitu tiga kelas kecacatan dimana Kelas 1 yaitu Segel luar, Kelas 2 yaitu Segel tengah dan Kelas 3 yaitu Segel dalam. Penentuan nilai pembobotan telah diputuskan oleh manajemen perusahaan dimana bobot yang digunakan adalah fungsi dari biaya, seperti biaya perbaikan, penggantian, atau pengoperasian berdasarkan tingkat kesesuaian jangka panjang, atau persyaratan pelanggan, untuk bobot wadah dalam penelitian ini adalah $w_1 = 10$, $w_2 = 3$, dan $w_3 = 1$, untuk kebocoran segel luar, segel tengah, dan segel dalam diambil dalam jurnal *A Demerits Control Chart For Autocorrelated*.

Sehingga, jumlah total bobot kerugian, d pada unit inspeksi i dengan menggunakan Persamaan (1) sebagai berikut:

$$d_1 = (10)(0) + (3)(0) + (1)(12) = 12$$

Setelah mendapatkan nilai dari d_i maka rata-rata cacat per unit dapat diperoleh dengan Persamaan (2) sebagai berikut:

$$U_1 = \frac{12}{12} = 1$$

Kemudian untuk menghitung garis tengah perlu menghitung rata-rata cacat per unit untuk kategori 1, 2 dan 3 dengan menggunakan Persamaan (4) sebagai berikut:

- (i) Untuk Kategori 1

$$\bar{u}_1 = \frac{5}{2043} = 0,0024$$

(ii) Untuk Kategori 2

$$\bar{u}_2 = \frac{21}{2043} = 0,0103$$

(iii) Untuk kategori 3:

$$\bar{u}_3 = \frac{1192}{2043} = 0,5835$$

Setelah mendapatkan hasil dari $\bar{u}_1, \bar{u}_2,$ dan \bar{u}_3 dilanjutkan untuk menghitung garis tengah peta kendali Demerit dengan menggunakan Persamaan (3) sebagai berikut:

$$\bar{u} = (10)(0,0024) + (3)(0,0103) + (1)(0,5835) = 0,6388$$

Untuk mendapatkan nilai dari batas kendali atas dan batas kendali bawah perlu mendapatkan nilai standar deviasi setiap unit terlebih dahulu dengan menggunakan Persamaan (6) sebagai berikut:

$$\hat{\sigma}_{u_1} = \sqrt{\frac{((10)^2(0,0024) + (3)^2(0,0103) + (1)^2(0,5835))}{12}} = 0,2770$$

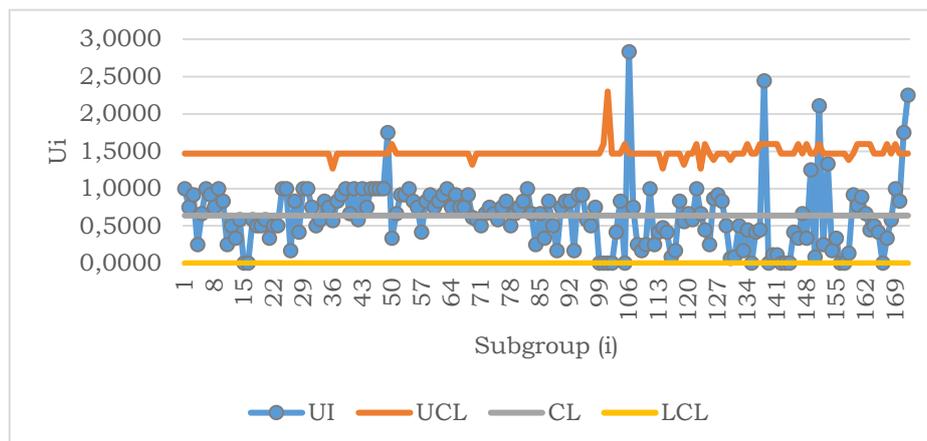
Batas kendali atas dan batas kendali bawah dapat didapatkan dengan Persamaan (5) sebagai berikut:

$$UCL_1 = 0,6388 + (3)(0,2770) = 1,4697$$

$$LCL_1 = 0,6388 - (3)(0,2770) = -0,1922 = 0$$

Batas pengendali bawah (*LCL*) untuk peta kendali Demerit dinyatakan dalam nilai proporsi atau persentase selalu positif, dan juga tidak negatif ($LCL \geq 0$) ini karena jumlah cacat yang terboboti tidak mungkin negatif dan nilai jumlah cacat terboboti paling kecil adalah 0.

Setelah mendapatkan batas atas dan batas bawah dari peta kendali demerit maka diperoleh Peta Kendali Demerit seperti pada Gambar 1 sebagai berikut:



Gambar 1. Peta Kendali Demerit

Gambar 1 menunjukkan bahwa enam titik pengamatan berada di luar batas kendali atau *out of control*, sedangkan 166 titik pengamatan lainnya berada di dalam batas kendali atau *in control*.

3.3 Peta Kendali Demerit Untuk Data Autokorelasi

Syarat pembentukan model analisis deret waktu dengan mengasumsikan data rangkaian waktu, oleh karena itu terlebih dahulu diperlukan untuk memeriksa kestasioneran data U_i sebelum menentukan model. Uji *Augmented Dicky Fuller* (ADF) adalah uji yang dilakukan. Hipotesisnya adalah sebagai berikut:

$H_0: \delta = 0$ (Data tidak stasioner)

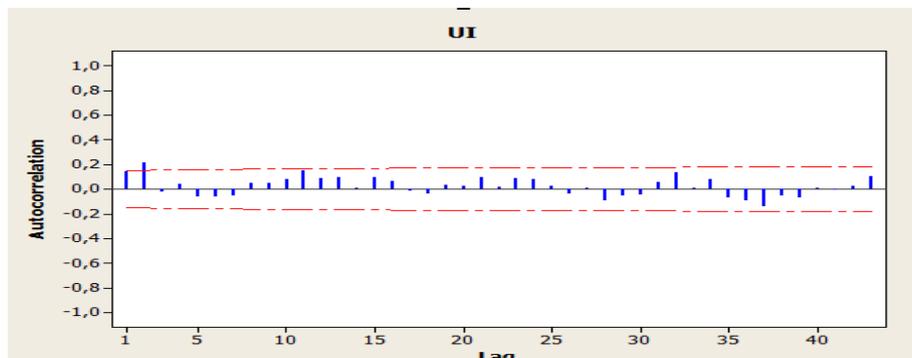
$H_1: \delta \neq 0$ (Data telah stasioner)

Kriteria keputusan, jika $p\text{-value} < \alpha$ atau $|t_{hit}| > t_{\frac{\alpha}{2}, n-1}$, maka H_0 ditolak.

Pada Uji *Augmented Dicky Fuller* berdasarkan *software* R Studio diperoleh hasil uji yaitu *Dickey-Fuller* = -5,9998, *Lag Order* = 1, $p\text{-value}$ = 0,01, dikarenakan nilai $0,01 < 0,05$. Oleh karena itu, dapat disimpulkan H_0 ditolak yang berarti data telah stasioner.

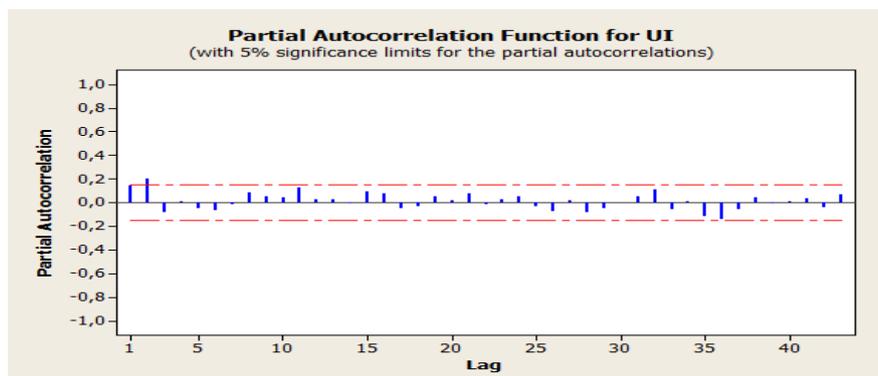
3.3.1 Identifikasi Model

Proses identifikasi model dari data yang ingin diramalkan dalam metode *time-series* dapat menggunakan ACF dan PACF. Model yang ingin diramalkan adalah U_i sebagai nilai rata-rata cacat per unit.



Gambar 2. Fungsi Autokorelasi

Berdasarkan pendekatan ACF dan PACF, Gambar 2 menunjukkan bahwa ACF membentuk gelombang sinus yang menandakan bahwa data mengikuti model autoregressive (AR).

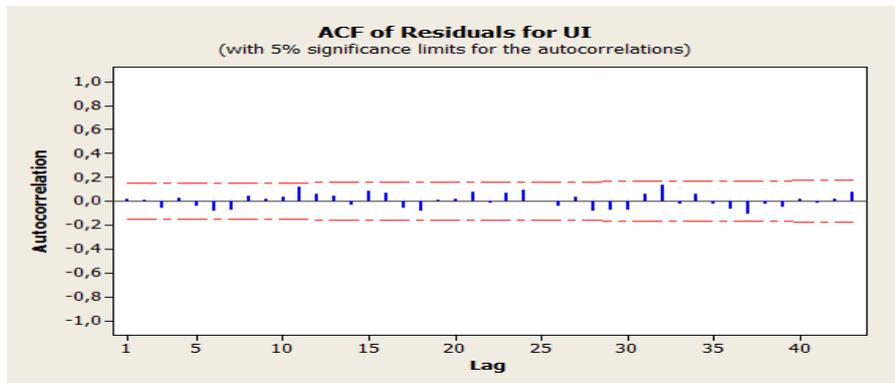


Gambar 3. Fungsi Autokorelasi Parsial

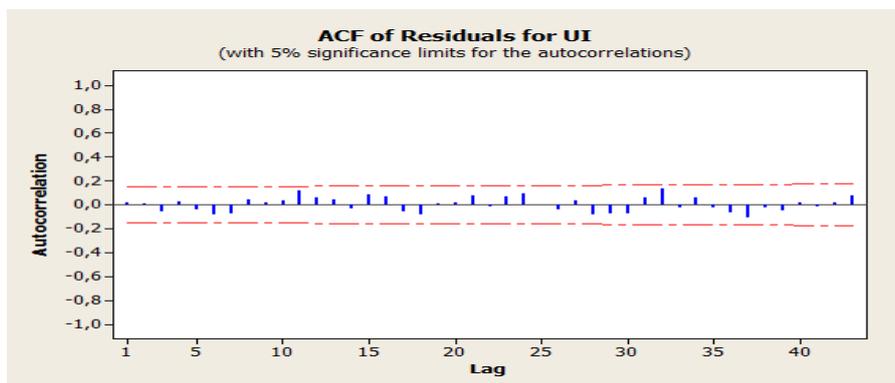
Gambar 3 pada PACF melewati batas taraf kepercayaan pada *lag* 2 yang menyarankan model deret waktu adalah AR(2) untuk proses tersebut. Model AR(2) yang diperoleh sebagai berikut:

$$\hat{y}_i = 0,1325 y_{i-1} + 0,2302 y_{i-2} + 0,41208 \dots \quad (17)$$

Kemudian dilakukan pemeriksaan kelayakan model AR(2) dengan memperhatikan plot ACF dan PACF residual model. Jika plot ACF dan PACF tersebut cenderung memiliki nilai tidak signifikan, maka model layak digunakan. Hal ini ditunjukkan pada Gambar 4 dan 5.



Gambar 4. Fungsi Autokorelasi Untuk Residual



Gambar 5. Fungsi Autokorelasi Parsial Untuk Residual

Gambar 4 dan 5 menunjukkan bahwa model memberikan kecocokan yang memuaskan karena tidak ada yang keluar dari garis putus-putus. ACF dan PACF untuk residual model dapat digunakan.

3.3.2 Peta Kendali Residual

Setelah model deret waktu memberikan kecocokan yang baik, maka akan menghilangkan autokorelasi, sehingga dihasilkan residual independen. Untuk pembuatan peta kendali Residual untuk garis tengah peta kendali residual adalah pada titik nol. Pada ACF dan PACF untuk residual perlu mencari \hat{y}_i dengan Persamaan (17) sebagai berikut:

$$\hat{y}_1 = 0,1325 (0) + 0,2302 (0) + 0,41208 = 0,4121$$

Sedangkan untuk nilai residualnya diperoleh dari Persamaan (9) adalah sebagai berikut:

$$r_1 = 1,0000 - 0,4121 = 0,5879$$

Kemudian menghitung nilai *average moving range* dapat diperoleh menggunakan Persamaan (10) sebagai berikut:

$$R_2 = |(0,2054) - (0,5879)| = 0,3825$$

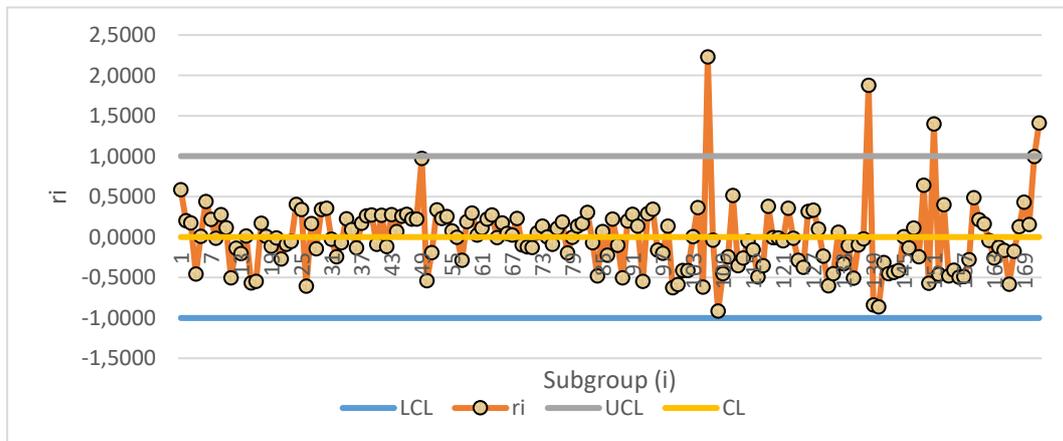
Untuk mendapatkan nilai batas atas dan batas bawahnya perlu menghitung rata-rata dari *average moving range* tersebut menggunakan Persamaan (11) sebagai berikut:

$$\begin{aligned}\bar{R} &= \sum_{i=2}^{172} \frac{R_i}{172 - 1} \\ &= \frac{(0,3825 + 0,0304 + 0,6312 + \dots + 0,4169)}{171} \\ &= 0,3766\end{aligned}$$

Nilai batas kendali atas dan batas kendali bawah dapat diperoleh dari Persamaan (12) sebagai berikut:

$$\begin{aligned}UCL &= 0,0014 + \left(\frac{3}{1,128}\right)(0,3766) = 1,0032 \\ LCL &= 0,0014 - \left(\frac{3}{1,128}\right)(0,3766) = -1,0005\end{aligned}$$

Setelah mendapatkan nilai batas atas dan nilai batas bawah dengan nilai tengah adalah 0, maka gambar peta kendali Residual yang didapatkan adalah:



Gambar 6. Peta Kendali Residual

3.4 Peta Kendali *Moving Centerline Demerit* (MCD)

Proses menghitung jumlah kerugian untuk setiap sampel dengan EWMA sebagai alternatif untuk pendekatan residual dengan nilai rata-rata cacat yang terkait sampel i seperti Persamaan (13) sebagai berikut:

$$W_1 = \lambda U_1 + (1 - \lambda)W_0$$

dengan $\lambda = 0,11$ sebagaimana saran jurnal Montgomery dan Mastrangelo (1991) dan mengikuti saran dari buku Montgomery (2009) maka $W_0 = \bar{U}_i$.

$$W_1 = (0,11)(1,0000) + (0,89)(0,6376) = 0,6775$$

Sebelum menghitung batas kendali atas dan batas kendali bawah, prediksi residual satu langkah kedepan perlu dihitung menggunakan rumus:

$$e_i = U_i - \widehat{W}_i(i - 1)$$

maka untuk $i = 1$ dengan $\widehat{W}_1(1 - 1) = W_0 = \bar{U}_i$.

$$e_1 = 1,0000 - 0,6376 = 0,3624$$

Kemudian standar deviasi diperoleh dari Persamaan (16) sebagai berikut:

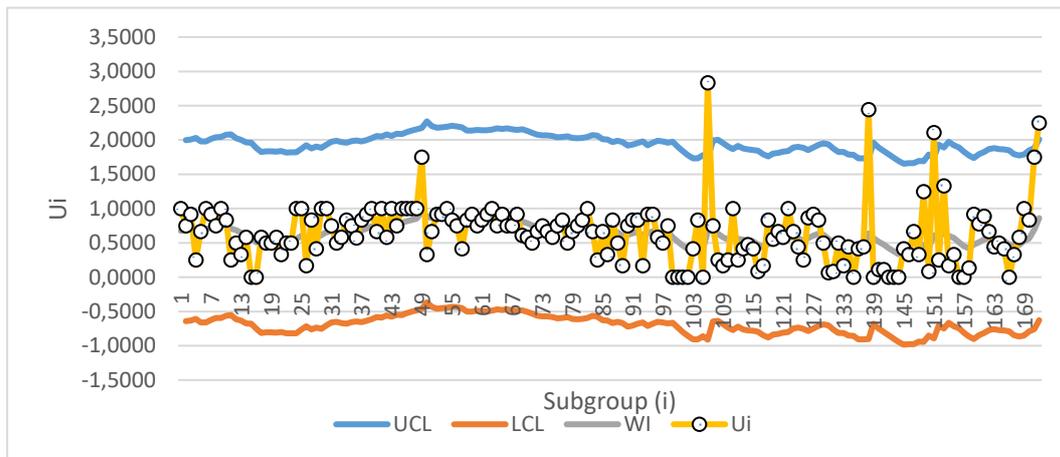
$$\sigma_p = \sqrt{\frac{33,2440}{172}} = 0,4396$$

Batas kendali atas dan batas kendali bawah dapat diperoleh menggunakan Persamaan (15). Hasilnya adalah sebagai berikut:

$$UCL_2 = 0,6775 + (3)(0,4396) = 1,9964$$

$$LCL_2 = 0,6775 - (3)(0,4396) = -0,6402$$

Peta kendali MCD ditunjukkan pada Gambar 7 berikut ini:



Gambar 7. Peta Kendali MCD

Gambar 7 menunjukkan empat titik pengamatan yang berada di luar batas kendali atau *out of control*, dan 168 titik pengamatan lainnya berada di dalam batas kendali atau *in control*. Ada empat titik, 106, 138, 151, dan 172, yang menunjukkan masalah dalam proses produksi yang menyebabkan produksi tidak terkontrol. Akibatnya, produk cacat yang tidak dapat ditoleransi ditemukan.

4. SIMPULAN DAN SARAN

Berdasarkan hasil dan pembahasan, dapat ditarik kesimpulan bahwa Peta kendali demerit untuk data berautokorelasi diperoleh dengan peta kendali residual dari nilai U_i . Dikarenakan data autokorelasi dikumpulkan lebih dekat dalam waktu sehingga peta kendali Residual cocok digunakan untuk peta kendali Demerit pada data Autokorelasi. Peta kendali MCD merupakan pengembangan peta kendali Demerit dengan menggunakan EWMA pada data Autokorelasi, MCD sebagai perkiraan model deret waktu umum. Peta Kendali Residual dan peta kendali MCD

terdapat 4 *out of control* yang menunjukkan terdapat masalah proses produksi yang tidak dapat ditoleransi tingkat keparahannya, hal ini menunjukkan bahwa perusahaan harus memperhatikan proses produksi per 100 hari pada proses produksi wadah plastik anti bocor.

DAFTAR PUSTAKA

- Aksioma, D. F. (2019). Pengendalian Kualitas Kantong Semen di PT. Industri Kemasan Semen Gresik Menggunakan Peta Kendali Demerit dan Fuzzy Demerit. *Jurnal Sains Dan Seni ITS*, 7(2), 156–161.
- Azizah, I. N., Arum, P. R., & Wasono, R. (2021). Model Terbaik Uji Multikolinearitas untuk Analisis Faktor-Faktor yang Mempengaruhi Produksi Padi di Kabupaten Blora Tahun 2020. *Prosiding Seminar Nasional UNIMUS*, 4.
- Bisri, H. (2019). Menghilangkan Autokorelasi Pada Diagram Kontrol *Shewhart* Menggunakan Diagram Kontrol Residual Berdasarkan Model *Extention Support Vector Regression*. Institut Teknologi Sepuluh Nopember.
- Graxinha, A. M. F., & Pereira, J. M. D. (2023). *Real Time Statistical Process Control for Autocorrelated Serial Data: A Simulation Approach*. *International Journal of Computing*, 22(2), 107–116.
- Irwanto, M. A. (2017). Analisis Kapabilitas Proses Pengelasan pada Pembuatan Kapal SSV2 PT. Pal Indonesia. Institut Teknologi Sepuluh September.
- Montgomery, D. C. (2020). *Introduction to Statistical Quality Control* (8 ed.). John Wiley & Sons.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to Time Series Analysis and Forecasting (Second Edition)*. John Wiley & Sons.
- Nembhard, D. A., & Nembhard, H. B. (2000). *A Demerits Control Chart for Autocorrelated Data*. *Quality Engineering*, 13(2), 179–190.
- Nursiwan, A. (2023). Analisis Dampak Suku Bunga dan Inflasi terhadap Profitabilitas Bank Syariah dengan Pendekatan *Time Series*. *Persya: Jurnal Perbankan Syariah*, 1(1), 18–24.
- Piter, F. P., Asdi, Y., & Yozza, H. (2021). Analisis Pengendalian Kualitas Menggunakan Diagram Kendali Demerit Pada Kualitas Produk PT. Sinar Sosro Kpb Ungaran. *Jurnal Matematika UNAND*, 9(4), 366–372.
- Ramadhani, G. S., Wilandari, Y., & Suparti, S. (2014). Analisis Pengendalian Kualitas Menggunakan Diagram Kendali Demerit (Studi Kasus Produksi Air Minum Dalam Kemasan 240 ml di PT TIW). *Jurnal Gaussian*, 3(3), 401–410.
- Rismayanti, R., Lestari, S. P., & Rahwana, K. A. (2022). *The Effect of Raw Material Inventory Control Costs and Direct Labor Costs on Production Volume (Case Study on Al-Yafi embroidery mukena in Tasikmalaya Regency 2018-2021 Period)*. *Journal of Indonesian Management (JIM)*, 2(2), 287–292.
- Syarifuddin, S., Herdiana, E. T., & AF, M. S. (2018). Perbandingan Bagan Kendali Modifikasi *Shewhart* dan Bagan Kendali ARMAST pada ARMA (1, 1). *Jurnal Matematika, Statistika dan Komputasi*, 15(1), 75–87.
- Ylmaz, H., & Yank, S. (2020). *Design of Demerit Control Charts with Fuzzy C-Means Clustering and An Application in Textile Sector*. *Textile and Apparel*, 30(2), 117–125.
- Zhou, P., Lin, D. K. J., Niu, X., & He, Z. (2020). *Performance Evaluation Method for Network Monitoring Based on Separable Temporal Exponential Random Graph Models with Application to The Study of Autocorrelation Effects*. *Computers & Industrial Engineering*, 145, 106507.