

Fitrah_Cornellya_Angela_19102
0700131_Artikel_Tugas_Akhir.d

OCX

by

Submission date: 13-Jul-2023 02:41PM (UTC+0700)

Submission ID: 2130483447

File name: Fitrah_Cornellya_Angela_191020700131_Artikel_Tugas_Akhir.docx (315.58K)

Word count: 6311

Character count: 38097



Forecasting Sales of Clothing Products with a Combination Support Vector Regression and Particle Swarm Optimization Algorithm ²

Peramalan Penjualan Produk Pakaian dengan Kombinasi Metode Support Vector Regression dan Algoritma Particle Swarm Optimization

Fitrah Cornellya Angela^{*1)}, Tedjo Sukmono²⁾

^{1,2)} Program Studi Teknik Industri, Universitas Muhammadiyah Sidoarjo, Indonesia

*Email Penulis Korespondensi: 191020700131@umsida.ac.id

Abstract. One of the new business concepts in e-commerce is the twin date events which result in an increase in product sales so that there is a difference or fluctuation of around 20%, one of them is in the business in the textile sector. This study aims to predict the number of sales of clothing products at the Nara Gallery Collection Boutique using the support vector regression method which is known to have reliable performance in predicting time series data. However, it should be noted that the level of accuracy in forecasting is not necessarily high. Therefore, the parameters in the support vector regression method are optimized using the particle swarm optimization algorithm. From this study, the results of forecasting were obtained with a MAPE value = 8,98% were obtained by entering the optimal parameter value of SVR is the C value was 34,3642, the ϵ value was 0,0110, the σ value was 0,3677, the cLR value was 0,1062, and the λ value was 0,0117.

Keywords – Forecasting; Product Sale; Support Vector Regression; Particle Swarm Optimization

Abstrak. Salah satu konsep bisnis baru pada e-commerce ialah event tanggal kembar yang mengakibatkan peningkatan penjualan produk sehingga terdapat perbedaan atau fluktuasi sekitar 20%, salah satunya pada usaha di bidang tekstil. Penelitian ini bertujuan untuk memprediksi jumlah penjualan produk pakaian pada Butik Nara Gallery Collection menggunakan metode support vector regression yang dikenal memiliki performa handal dalam meramalkan data time series. Namun, perlu diketahui tingkat keakuratan dalam peramalan belum tentu tinggi. Oleh karena itu, parameter pada metode support vector regression dioptimasi dengan menggunakan algoritma particle swarm optimization. Dari penelitian ini didapatkan hasil peramalan dengan nilai MAPE = 8,98% yang dihasilkan dengan memasukkan nilai parameter optimal dari SVR yaitu dengan parameter C bernilai 34,3642, parameter ϵ bernilai 0,0110, parameter σ bernilai 0,3677, parameter cLR bernilai 0,1062, dan parameter λ bernilai 0,0117.

Kata Kunci – Peramalan; Penjualan Produk; Support Vector Regression; Particle Swarm Optimization

I. PENDAHULUAN

Usaha Mikro, Kecil, dan Menengah (UMKM) berperan sangat penting dalam menunjang pertumbuhan perekonomian di Indonesia. UMKM di negara yang berkembang seperti Indonesia memiliki keberlangsungan usaha yang baik, dimana pemberdayaan dan inovasi telah dilakukan secara terus menerus sehingga mampu memberikan kontribusi yang signifikan dalam mensejahterakan pelaku UMKM dan mitranya [1]. Usaha Mikro, Kecil, dan Menengah (UMKM) berperan penting dalam perekonomian di Indonesia. Salah satu UMKM di Indonesia yaitu usaha yang bergerak dalam bidang tekstil, dimana salah satu kebutuhan primer manusia ialah sandang. Oleh karena itu, seiring berjalannya waktu dan kenaikan jumlah penduduk mengakibatkan terjadinya peningkatan permintaan akan kebutuhan sandang yang menyebabkan para UMKM bidang tekstil harus mampu memenuhi kebutuhan tersebut. Nara Gallery Collection merupakan salah satu UMKM yang bergerak pada bidang tekstil yang memproduksi berbagai macam pakaian wanita.

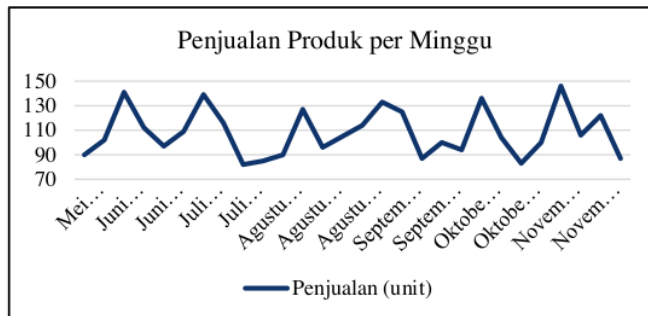
Konveksi merupakan salah satu bidang bisnis yang berkembang di Indonesia. Alasan yang membuat bisnis konveksi mampu berkembang di Indonesia ialah karena pakaian merupakan salah satu hal dasar yang dibutuhkan oleh manusia, oleh karena itu tersedia banyak pasar yang menjualnya. Pengusaha harus mampu terus berinovasi dalam pemanfaatan kebutuhan dasar tersebut. Perkembangan industri konveksi diprediksi akan terus tumbuh mencapai 30%. Selain makanan dan rumah, pakaian juga merupakan salah satu kebutuhan primer sehingga prospek dalam mengembangkan usaha konveksi sangat menjanjikan. Pemenuhan kebutuhan terhadap pakaian ini bersifat mutlak karena sangat diperlukan dalam keberlangsungan hidup. Menurut artikel berjudul Peluang Bisnis Konveksi dari Dinas Koperasi Usaha Mikro Kecil dan Menengah (KUMKM), pangsa pasar dari bisnis konveksi sangat luas, dinamis, dan mampu beradaptasi seiring perkembangan zaman. Permintaan pasar terhadap usaha konveksi sangat besar, maka usaha ini mampu terealisasi dengan melakukan perencanaan terhadap peningkatan modal usaha, jumlah tenaga kerja, jumlah kapasitas produksi, dan distribusi penjualan serta meningkatkan strategi [2].

Nara Gallery Collection tidak hanya memiliki *store* yang bersifat *offline*, namun juga menyediakan *platform* belanja secara *online* melalui Shopee, Instagram, dan Whatsapp. Di era sekarang ini masyarakat Indonesia

menghabiskan cukup banyak waktu dengan ponsel dan media sosial. Tidak heran Nara *Galery Collection* memakai media sosial sebagai media pemasaran. Adanya *platform* belanja *online* memudahkan para pelanggan untuk melakukan pemesanan dari berbagai daerah dan UMKM dapat memiliki pangs pasar yang sangat luas sehingga mampu meningkatkan jumlah pelanggan dan omset penjualan. *E-Commerce* merupakan sebuah sistem yang bersifat online yang digunakan untuk aktivitas jual-beli, artinya seorang pelanggan tidak perlu membeli sebuah barang dengan mendatangi ke toko tersebut. Saat ini *e-commerce* digunakan sebagai salah satu alternatif media informasi pada sebuah perusahaan khususnya dalam bidang wiraswasta agar memudahkan interaksi antara penjual dan pembeli dengan ruang dan waktu yang tak terbatas. Penggunaan *electronic commerce* mampu mengurangi biaya operasional sehingga perusahaan mampu bersaing dalam memberikan pelayanan yang cepat dan akurat terhadap peningkatan permintaan yang terjadi [3].

E-Commerce ialah cara pelanggan dalam melakukan pembelian barang yang diinginkan secara online, artinya penjualan barang dilakukan secara langsung dengan menggunakan internet sebagai media promosi yang ditujukan untuk konsumen (*Business to Consumer*) ataupun bisnis (*Business to Business*). Pelanggan biasanya enggan untuk membeli produk dengan berbelanja langsung ke toko, sehingga hal ini memicu UMKM untuk mampu menjangkau banyak pelanggan dengan menggunakan sistem *e-commerce* (toko *online*) agar memudahkan pelanggan dalam mendapatkan produk [4]. Peningkatan penggunaan fasilitas internet dalam kegiatan jual-beli memberikan dampak positif bagi pertumbuhan perekonomian negara dan para penggunanya. Konsep bisnis baru pada *e-commerce* berisikan gabungan dari semua konsep manajemen bisnis dengan ekonomi sebelumnya. Adanya *e-commerce* memberikan kemudahan seperti penghematan biaya promosi, kemudahan dalam berkomunikasi antar penjual dan pembeli, sistem pembayaran yang dapat dilakukan secara *online*, dan mempermudah penyebaran informasi. Informasi berperan penting dan memiliki manfaat yang dominan untuk kebutuhan penggunanya [5].

Saat permintaan pelanggan meningkat dan persediaan produk sedikit, maka UMKM kehilangan kesempatan untuk meraih keuntungan akibat tidak dapat memenuhi permintaan tersebut. Sedangkan ketika permintaan pelanggan menurun dan persediaan produk banyak, maka UMKM mengalami peningkatan biaya yaitu biaya *inventory*. Karena jumlah penjualan produk setiap minggu bervariasi, maka jumlah produksi pakaian yang dihasilkan setiap minggunya juga bervariasi. Misalnya, Nara *Gallery Collection* mendapat cukup banyak permintaan saat memasuki *event* tanggal kembar. Minggu dimana terjadi *event* tersebut mengakibatkan peningkatan penjualan produk sehingga terdapat perbedaan atau fluktuasi sekitar 20% dengan minggu sebelumnya atau setelahnya seperti yang terlihat pada gambar 1.



Gambar 1. Grafik Penjualan Produk per Minggu

Dalam upaya penyelesaian permasalahan yang terjadi pada Nara *Gallery Collection* dan memenangkan persaingan bisnis yang telah terjadi, maka peramalan penjualan atau memprediksi jumlah penjualan produk pakaian pada periode selanjutnya perlu dilakukan sehingga proses produksi dapat berjalan dengan lancar dan terhindar dari berbagai permasalahan produksi. Akan tetapi sampai saat ini, Butik Nara *Gallery Collection* belum pernah dilakukan peramalan terhadap penjualan produk pakaian.

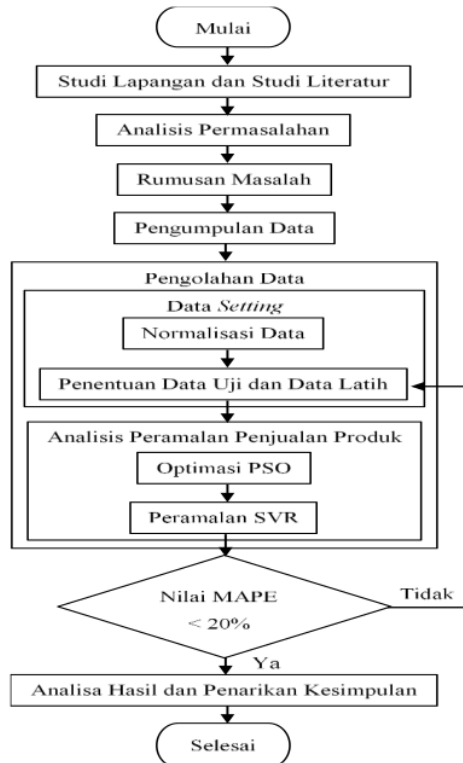
Peramalan yang akurat dapat dikatakan bahwa peramalan tersebut baik. Pengukuran akurasi peramalan dapat ditinjau dari konsistensi pada peramalan tersebut. Hasil peramalan yang terlalu tinggi maupun terlalu rendah dari nilai sebenarnya dikatakan bias. Kesalahan dalam peramalan yang relative kecil menunjukkan hasil peramalan yang konsisten. Apabila akurasi peramalan terlalu rendah maka persediaan akan mengalami kekurangan dan pemenuhan permintaan konsumen tidak dapat dilakukan segera. UMKM mungkin akan mengalami penurunan keuntungan penjualan maupun kehilangan pelanggan [6].

Penelitian ini bertujuan untuk memprediksi jumlah penjualan produk pakaian pada Butik Nara *Gallery Collection* menggunakan metode *support vector regression* yang dikenal memiliki performa handal dalam meramalkan data *time series*. Namun, perlu diketahui tingkat keakuratan dalam peramalan belum tentu tinggi. Oleh karena itu, parameter

pada metode *support vector regression* dioptimasi dengan menggunakan algoritma *particle swarm optimization* sehingga didapatkan hasil peramalan penjualan produk pakaian dengan tingkat akurasi yang tinggi dan nilai kesalahan terendah.

II. METODE

Dalam pelaksanaan penelitian ini terdiri dari beberapa proses yang dimulai dari studi literatur yaitu melakukan pencarian referensi yang bersumber pada buku, jurnal, dan penelitian terdahulu yang sejenis, observasi secara langsung melalui wawancara dengan pemilik UMKM konveksi yaitu *Butik Nara Gallery Collection* di Waru Sidoarjo, identifikasi dan perumusan permasalahan yang ada, pengumpulan data yang diperlukan, pengolahan data, dan analisis data hingga mendapatkan hasil akhir penelitian. Adapun *flow chart* penelitian terlihat pada gambar 2.



Gambar 2. Diagram Alir Penelitian

Peramalan ialah kegiatan dalam meramalkan sesuatu yang terjadi di masa yang akan datang dengan melakukan pengujian yang terjadi di masa lampau. Tujuan dari peramalan yaitu untuk memperkirakan apa yang terjadi di masa yang akan datang dengan memperhatikan pola-pola di masa lampau dan penggunaan kebijakan pada proyeksi-proyeksi terhadap pola-pola di masa lampau. Peramalan adalah ilmu yang digunakan untuk memperkirakan apa yang terjadi di masa yang akan datang dengan menggunakan pengumpulan data pada masa lampau lalu menempatkannya pada suatu bentuk model matematis ke masa yang akan datang [7]. Peramalan (*forecasting*) bertujuan dalam memperoleh hasil prediksi yang akurat. Apabila hasil peramalan terlalu rendah maka akan menyebabkan kekurangan *inventory*. Begitu pula apabila hasil peramalan terlalu tinggi maka akan menyebabkan kelebihan *inventory* dan pengeluaran biaya yang tidak diperlukan sehingga menjadi tidak efektif [8].

Data mining dapat disebut sebagai beberapa proses yang digunakan untuk melakukan eksplorasi dan pencarian nilai berupa informasi dan hubungan kompleks yang telah tersimpan dalam suatu *database*. Penggalan pola informasi dari data yang penting dilakukan untuk memanipulasi data menjadi suatu informasi baru yang lebih berguna dan didapatkan dengan melakukan ekstraksi dan mengetahui pola-pola menarik dari data yang berada pada *database*. *Data*

mining digunakan dalam pengolahan data yang berjumlah besar dan membantu dalam menyimpan data transaksi dan melakukan proses data warehousing sehingga pengguna bisa mengambil informasi yang dibutuhkan [9].

Dalam penelitian ini menggunakan salah satu fungsi dasar pada data mining yaitu fungsi prediksi (prediction) yaitu proses penemuan pola dalam data dengan menggunakan beberapa variabel untuk memprediksi variabel lain yang tidak diketahui jenis atau nilainya [10]. Salah satu metode yang memiliki fungsi prediksi ialah metode support vector regression.

A. Support Vector Regression

Metode pembelajaran support vector regression ialah modifikasi metode support vector machine learning yang digunakan dalam pembangunan hyperlane pada kasus regresi. Dalam penerapan metode SVR dilakukan pencarian fungsi regresi terbaik yang didapatkan dari evaluasi kesalahan seminimal mungkin dengan memaksimalkan margin [11]. Ide dasar yang dimiliki dalam SVR ialah melakukan pembagian set data menjadi data training dan testing. Selanjutnya menentukan suatu fungsi regresi dari data training dengan menggunakan batasan deviasi tertentu sehingga mampu memprediksi dengan hasil yang mendekati dengan nilai sesungguhnya. Konsep SVR berdasarkan pada Structural Risk Minimization (SRM) dimana melakukan estimasi suatu fungsi resiko (risk function) dengan meminimalkan batas atas pada generalization error [12]. SVR bertujuan dalam pembuatan data yang lebih random agar mampu menerima regresi dengan melakukan pemetaan terhadap dimensi yang lebih tinggi [13]. SVR memiliki rumus persamaan yang dijelaskan dalam rumus 3 prediksi deret waktu sebagai berikut.

$$f(x) = \omega\phi(x) + b \dots\dots\dots(1)$$

Rumus di atas menunjukkan ω ialah bobot, $\phi(x)$ ialah fungsi pemetaan fitur x pada dimensi yang lebih tinggi, dan b ialah koefisien. Algoritma sequential learning SVR dapat menyelesaikan masalah non-linear. Sebelum menggunakan algoritma tersebut, terlebih dahulu perlu dilakukan proses normalisasi data yang bertujuan dalam peningkatan akurasi regresi dengan melakukan pengurangan tingkat error dalam komputasi [14]. Proses normalisasi yang dilakukan sebelum melakukan pelatihan menggunakan SVR dirumuskan sebagai berikut.

$$X'_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \dots\dots\dots(2)$$

Rumus di atas menunjukkan X'_i ialah hasil normalisasi data ke-i, X_i ialah nilai data ke-i, X_{min} ialah nilai data minimum dari keseluruhan dan X_{max} ialah nilai data maksimum dari keseluruhan. Hasil akhir dari normalisasi data menghasilkan data yang nilainya hanya dalam rentang 0 hingga 1, maka dari itu perlu dilakukan denormalisasi agar mengetahui data sebenarnya pada hasil akhir tersebut. Denormalisasi merupakan proses dalam mengembalikan data dari nilai hasil akhir proses normalisasi ke data asli [15]. Proses denormalisasi dapat dilakukan dengan menggunakan rumus sebagai berikut.

$$\text{Denormalisasi} = (X'_i (X_{max} - X_{min}) + X_{min}) \dots\dots\dots(3)$$

Berikut ini adalah beberapa tahapan dalam Support Vector Regression (SVR) antara lain [13]:

1. Inisialisasi parameter yang digunakan pada metode SVR antara lain ϵ dan C yang memiliki pengaruh dalam penentuan toleransi kesalahan, cLR sebagai parameter yang berguna untuk menentukan kecepatan pada proses pembelajaran, σ sebagai konstanta yang memiliki pengaruh dalam persebaran dimensi data, dan λ sebagai parameter yang berguna untuk menentukan ukuran skala dimensi dalam pemetaan kernel SVR.
2. Pembentukan matriks hessian menggunakan rumus sebagai berikut dengan $K(x_i, x_j)$ ialah fungsi kernel dan λ^2 ialah variabel skalar.

$$[R]_{ij} = K(x_i, x_j) + \lambda^2 \dots\dots\dots(4)$$

3. Perhitungan nilai kesalahan meliputi menginisialisasikan nilai lagrange multiplier α_i dan α_i^* sebesar 0, lalu perhitungan nilai galat (error), perubahan nilai lagrange multiplier, dan perbaharuan nilai lagrange multiplier.
4. Tahapan ketiga di atas kemudian dilakukan secara berulang (iterasi) hingga satu dari syarat-syarat berikut terpenuhi yaitu batas maksimal dari iterasi yang telah ditetapkan telah tercapai, terjadi konvergensi yang artinya tidak ada perubahan nilai dari lagrange multiplier, atau syarat dari perubahan nilai lagrange multiplier terpenuhi dimana tidak melebihi dari nilai konstanta epsilon ($\max(|\delta\alpha_i|) < \epsilon$ dan $\max(|\delta\alpha_i^*|) < \epsilon$).
5. Nilai hasil peramalan diperoleh setelah mendapatkan hasil perhitungan dengan persamaan regresi yang dirumuskan sebagai berikut dengan $\alpha_j^* - \alpha_j$ ialah nilai lagrange multiplier terkini.

$$f(x) = \sum_{j=1}^n (\alpha_j^* - \alpha_j) (K(x_i, x) + \lambda^2) \dots\dots\dots(5)$$

Metode SVR ini cocok digunakan dalam melakukan peramalan penjualan produk pakaian yang bersifat fluktuatif. Dimana metode SVR merupakan salah satu dari metode data mining yang mampu mengolah data time series yang berjumlah cukup banyak, dimana dalam penelitian ini menggunakan 100 data sehingga pengolahan data dapat dilakukan dengan mudah. Namun, pada metode SVR tidak mudah dalam melakukan penentuan parameter yang optimal sehingga harus dikombinasikan dengan metode lain sebagai optimasi [16].

B. Particle Swarm Optimization

Salah satu metode optimasi yang cocok dikombinasikan dengan metode SVR ialah algoritma PSO, dimana dengan kombinasi tersebut akan menghasilkan nilai parameter yang optimal dan menghasilkan nilai MAPE maupun nilai

error yang rendah. Dengan begitu, hasil peramalan penjualan produk pakaian mampu mendekati dengan nilai aktual di masa yang akan datang.

Particle Swarm Optimization (PSO) digunakan dalam pemecahan masalah optimasi. PSO berdasar pada perilaku dari sekawanan burung atau ikan yang melakukan tiruan terhadap perilaku sosial organisme. *Swarm Intelligence System* menyebarkan kecerdasan yang inovatif dalam menyelesaikan permasalahan optimasi dengan melakukan pengambilan inspirasi terhadap contoh biologis, seperti fenomena kelompok (*swarm*) pada hewan yang mempunyai perilaku individu dalam melakukan tindakan yang sama pada pencapaian tujuan yang sama [17].

Particle Swarm Optimization (PSO) merupakan salah satu alat yang digunakan dalam pemilihan fitur yang memberikan pengaruh pada model prediksi. PSO juga biasa disebut sebagai alat yang digunakan dalam pencarian karakteristik atau masalah optimum dengan menggunakan bantuan optimum *local* dan optimum *global* pada ruang fitur secara iteratif. Setelah itu fitur yang telah dipilih dijadikan sebagai data masukan pada peramalan dengan menggunakan metode *Support Vector Regression* (SVR). SVR ialah salah satu dari metode *supervised learning* yang digunakan dalam penemuan sebuah fungsi (x) sebagai *hyperplane* dalam bentuk fungsi regresi, yang artinya fungsi tersebut harus mempunyai tingkat *error* yang rendah ϵ atau tidak bernilai lebih dari ϵ pada nilai target aktual y_i untuk semua data pelatihan [16].

Proses optimasi PSO-SVR ialah proses optimasi dengan penggunaan algoritma PSO dan SVR yang digunakan sebagai evaluasi terhadap fungsi *fitness*nya, tujuan dari proses optimasi ini adalah menemukan nilai parameter yang paling optimal. Dalam proses optimasi PSO-SVR menggunakan data yang telah dilakukan proses normalisasi. Parameter yang akan dilakukan optimasi antara lain yaitu parameter C , ϵ , σ , cLR , dan λ .

Berikut adalah langkah-langkah yang dilakukan dalam melakukan peramalan dengan menggunakan metode *support vector regression* dan optimasi dengan menggunakan algoritma *particle swarm optimization*.

1. Perhitungan *k-fold cross validation* untuk memprediksi tingkat kesalahan dengan melakukan pengelompokan antara data *training* dan *data testing* pada keseluruhan data. Tahapan yang dilakukan antara lain pengacakan urutan pada hasil proses normalisasi data, pencarian indeks awal dan indeks akhir pada data *testing*, pendefinisian dilakukan sejumlah K pada data *training* dan data *testing*.
2. Inisialisasi posisi partikel dilakukan asumsi dimana sebuah partikel pada setiap dimensinya harus berada pada domain yang biasa disebutkan dengan dua vektor, yaitu x_{min} dan x_{max} . Dimana x_{min} merupakan batas bawah dari setiap dimensi, sedangkan x_{max} merupakan batas atas dari setiap dimensi. Inisialisasi dilakukan dengan rumus sebagai berikut dengan x ialah posisi partikel (merepresentasikan nilai C , ϵ , σ , cLR , λ) dan r_j ialah nilai *random* dalam range $[0,1]$.

$$x(0) = x_{min,j} + r_j (x_{max,j} - x_{min,j}) \dots \dots \dots (6)$$

3. Inisialisasi kecepatan partikel.
4. Evaluasi fungsi *fitness* dilakukan dengan pelatihan metode SVR. Dalam tahapan ini terdiri dari pemilihan fitur yang akan digunakan atas dasar fitur yang telah dipilih, perhitungan *sequential learning*, pengujian model regresi dengan data *testing*, dan perhitungan nilai *error* serta nilai *cost*.
5. Pencarian nilai *pBest* atau posisi terbaik pada pencapaian partikel dengan melakukan perbandingan antara nilai *cost pBest* dengan partikel iterasi saat ini. Jika nilai *cost* dari *pBest* lebih besar terhadap nilai *cost* partikel iterasi saat ini, maka nilai posisi pada *pBest* tergantikan dengan nilai posisi partikel saat ini. Sedangkan jika nilai *cost* dari *pBest* lebih kecil terhadap nilai *cost* partikel iterasi saat ini, maka nilai posisi pada *pBest* tetap.
6. Pencarian nilai *gBest* atau posisi terbaik partikel dan nilai bobot inersia baru dengan melakukan perbandingan antara nilai *cost gBest* dengan *pBest*. Jika nilai *cost* dari *gBest* lebih besar terhadap nilai *cost* dari *pBest*, maka nilai posisi pada *gBest* tergantikan dengan nilai posisi pada *pBest*. Sedangkan jika nilai *cost* dari *gBest* lebih kecil terhadap nilai *cost* dari *pBest*, maka nilai posisi pada *gBest* tetap. Perhitungan nilai bobot inersia dapat menggunakan persamaan berikut dengan w_{max} ialah batas atas bobot inersia, w_{min} ialah batas bawah bobot inersia, t_{max} ialah iterasi maksimal, dan t ialah iterasi saat ini.

$$w = w_{max} - \frac{w_{max} - w_{min}}{t_{max}} \times t \dots \dots \dots (7)$$

7. Pembaruan kecepatan partikel.
8. Pembaruan posisi partikel.
9. Pengulangan langkah 1-8 hingga didapatkan kondisi yang konvergen atau kondisi pada saat maksimal iterasi.
10. Penentuan hasil parameter SVR yang telah optimal dan jumlah fitur pilihan dari nilai *gBest*.

C. Ukuran Akurasi Hasil Peramalan

Dalam peramalan terdapat peluang dimana kesalahan peramalan (*error*) akan terjadi sehingga peralamana tidak ada yang 100% tepat. Oleh karena itu, peramalan yang baik ialah peramalan yang mampu memiliki nilai *error* seminimal mungkin hingga batas yang ditoleransi [18]. Kesalahan peramalan (*forecast error*) merupakan perbedaan pada hasil peramalan terhadap data aktual. Penilaian ketepatan pada peramalan dapat ditinjau dengan melakukan pencarian selisih dari data peramalan terhadap data aktual. Perbandingan dari selisih data tersebut dapat dijadikan sebagai acuan dalam penentuan kebutuhan di masa yang akan datang [19].

Ukuran akurasi hasil peramalan ialah ukuran mengenai tingkat perbedaan yang terjadi pada hasil permintaan terhadap permintaan yang sebenarnya terjadi. Ada beberapa metode yang dapat digunakan dalam menunjukkan kesalahan yang terjadi akibat dari suatu teknik peramalan tertentu. Sebagian ukuran tersebut melakukan perhitungan rata-rata dari beberapa fungsi terhadap perbedaan antara nilai aktual dengan nilai peramalan [20].

Dalam penelitian ini menggunakan nilai MAPE untuk mengetahui tingkat keakuratan dari hasil peramalan penjualan produk pakaian menggunakan metode *support vector regression* dan algoritma *particle swarm optimization*. MAPE ialah ukuran kesalahan relatif. MAPE menyatakan kesalahan berupa persentase dari hasil peramalan dengan permintaan aktual selama periode tertentu dan menginformasikan apakah nilai persentase terlalu tinggi atau rendah. MAPE dapat dihitung dengan persamaan sebagai berikut [21].

$$MAPE = \left(\frac{100}{n} \right) \sum \left| \frac{F_t - A_t}{A_t} \right| \dots \dots \dots (8)$$

Persamaan di atas menunjukkan A_t ialah permintaan aktual pada periode- t , F_t ialah peramalan permintaan (*forecast*) pada periode- t , dan n ialah jumlah periode peramalan. Berikut ini terdapat keterangan pada rentang nilai MAPE yang disajikan pada tabel 1.

Tabel 1. Rentang Nilai MAPE

Nilai MAPE	Keterangan
< 10%	Model peramalan sangat baik
10-20%	Model peramalan baik
20-50%	Model peramalan cukup
> 50%	Model peramalan buruk

Sumber: A. K. Wardhani *et al.*, (2022).

Pada tabel di atas menunjukkan bahwa nilai persentase *error* pada nilai MAPE yang apabila nilai MAPE tidak lebih dari 50% maka model peramalan masih dapat digunakan, dan apabila nilai MAPE sudah lebih dari 50% maka model peramalan tidak dapat digunakan [22].

III. HASIL DAN PEMBAHASAN

Dalam penelitian ini menggunakan *dataset* yang diambil dari *database* UMKM berupa data *time series* jumlah penjualan produk pakaian dengan periode per minggu dalam enam bulan terakhir pada bulan Juni sampai bulan November 2022. Data yang digunakan untuk peramalan dalam penelitian ini ialah jumlah penjualan produk pakaian dengan satuan *unit* pada minggu sebelumnya, yaitu data (T-3) sebagai data tiga minggu sebelumnya, data (T-2) sebagai data dua minggu sebelumnya, data (T-1) sebagai data 1 minggu sebelumnya, dan data aktual atau data yang digunakan saat ini. Sampel yang digunakan dalam perhitungan sebesar 25 data. Sebelum dilakukan perhitungan data terlebih dahulu dilakukan proses normalisasi menggunakan persamaan 2. Berikut adalah hasil dari proses normalisasi data yang dapat dilihat pada tabel 2 dimana untuk kolom F1, F2, dan F3 ialah atribut untuk peramalan, sedangkan kolom aktual ialah jumlah penjualan produk pakaian sebenarnya.

Tabel 2. Hasil Normalisasi Data

Data	Periode	F1	F2	F3	Aktual
1	Juni Minggu ke-3	0,0000	0,3125	0,9219	0,4688
2	Juni Minggu ke-4	0,3125	0,9219	0,4688	0,2344
3	Juni Minggu ke-5	0,9219	0,4688	0,2344	0,4219
..
25	November Minggu ke-5	1,0000	0,3750	0,6250	0,0781

Setelah data dinormalisasi maka dilakukan perhitungan *k-fold cross validation* dengan melakukan pengacakan urutan pada hasil proses normalisasi data, pencarian indeks awal dan indeks akhir pada data *testing* sebanyak K berdasarkan dari hasil pencarian nilai interval data, pendefinisian sebanyak K kali pada data *testing*, dan pendefinisian sebanyak K kali pada data *training*. Berikut adalah skenario hasil pemilihan fitur yang disajikan pada tabel 3 dimana data telah dibagi menjadi 5 *fold* pada proses *k-fold cross validation*.

Tabel 3. Skenario Data *Testing* dan Data *Training*

Skenario	Data <i>Testing</i>	Data <i>Training</i>
K = 1	indeks 0-4	indeks 5-24
K = 2	indeks 5-9	indeks 0-4 dan 10-24
K = 3	indeks 10-14	indeks 0-9 dan 15-24
K = 4	indeks 15-19	indeks 0-14 dan 20-24
K = 5	indeks 20-25	indeks 0-19

Berdasarkan tabel 3, skenario data yang telah dibuat akan digunakan dalam proses pengolahan data. Dimana data *training* ialah data yang digunakan dalam pelatihan SVR sehingga didapatkan nilai yang merupakan hasil peramalan di masa yang akan datang dengan jumlah 80% dari sampel data yang digunakan, sedangkan sisa 20% merupakan data *testing* yaitu data yang digunakan dalam pengujian dimana hasil pengolahan dari data *training* dibandingkan dengan data *testing* sehingga dari hasil perbandingan tersebut didapatkan nilai MAPE.

A. Penetapan Nilai

Dalam proses inialisasi partikel diperlukan penetapan nilai yang telah digunakan pada penelitian Ambarwati, 2020 yang telah memperoleh hasil yang cukup akurat.

1. Jumlah partikel = 3.
2. Jumlah iterasi maksimum = 50.
3. Nilai bobot inersia batas bawah (w_{\min}) = 0,4 dan batas atas (w_{\max}) = 0,8.
4. Nilai konstanta akselerasi (C1 dan C2) = 1.
5. Jumlah *fold cross validation* (K) = 5.
6. Nilai batas bawah dan batas atas ruang pencarian tiap dimensi partikel:
 - a. Dimensi C ($x_{\min, 1}$) = 0,01 dan ($x_{\max, 1}$) = 1000.
 - b. Dimensi ϵ ($x_{\min, 2}$) = 0,01 dan ($x_{\max, 2}$) = 0,09.
 - c. Dimensi σ ($x_{\min, 3}$) = 0,01 dan ($x_{\max, 3}$) = 10.
 - d. Dimensi cLR ($x_{\min, 4}$) = 0,01 dan ($x_{\max, 4}$) = 2.
 - e. Dimensi λ ($x_{\min, 5}$) = 0,01 dan ($x_{\max, 5}$) = 5.

B. Inialisasi Partikel

Pada proses inialisasi partikel menggunakan dimensi kontinu sebanyak 5 dan dimensi biner sebanyak 3. Setiap partikel dengan dimensi C, ϵ , σ , cLR, dan λ diinisialisasi berdasarkan batas atas dan batas bawah dari ruang pencarian tiap dimensi yang telah ditentukan sebanyak jumlah partikel, sedangkan nilai pada dimensi biner diinisialisasikan dengan 0 atau 1. Berikut adalah contoh perhitungan inialisasi menggunakan persamaan sebagai berikut dan hasil dari inialisasi posisi partikel disajikan pada tabel 4.

Tabel 4. Hasil Inialisasi Posisi Partikel

X	C	ϵ	σ	cLR	λ	F1	F2	F3
1	289,5798	0,0278	2,5586	0,1009	2,1111	1	1	0
2	814,6669	0,0418	3,8557	0,4101	0,0923	0	1	1
3	441,3160	0,0525	0,4577	0,2201	2,9125	1	1	0

$$X_{1,C} = X_{\min,C} + r_1(X_{\max,C} - X_{\min,C}) = 0,01 + 0,2896(1000 - 0,01) = 289,5798$$

Pada tabel di atas menunjukkan bahwa pemberian nilai posisi secara acak pada partikel awal menggunakan batas yang telah ditentukan. Setiap nilai dari hasil inialisasi mewakili posisi partikel dari masing-masing dimensi. Lima dimensi kontinu merupakan nilai parameter yang optimal, sedangkan tiga dimensi biner merupakan fitur yang dipilih.

C. Perhitungan Sequential Learning

Langkah pertama yang dilakukan dalam tahapan ini ialah melakukan penentuan fitur yang akan digunakan dalam perhitungan SVR atas dasar fitur yang dipilih, dimana berdasarkan proses inialisasi posisi partikel ke-1 yang telah dilakukan sebelumnya fitur yang dipilih ialah F1 dan F2. Selanjutnya melakukan perhitungan *sequential learning* yang bertujuan untuk mendapatkan nilai yang akan digunakan pada pengujian model regresi. Langkah pertama yang dilakukan ialah inialisasi nilai $\alpha_i = 0$ dan $\alpha_i^* = 0$ dengan indeks $i = 1, \dots, n$. Sebelum pembentukan model regresi maka terlebih dahulu dilakukan pembentukan matriks X. Berikut adalah hasil dari perhitungan partikel ke-1 iterasi ke-0 pada *fold K = 1* yang disajikan pada tabel 5.

Tabel 5. Jarak Data Training

X	1	2	3	4	5	...	20
1	0,0000	0,2549	0,0911	0,3364	0,1770	...	0,0901
2	0,2549	0,0000	0,1233	0,0317	0,7717	...	0,4329
3	0,0911	0,1233	0,0000	0,1125	0,5205	...	0,3379
...
20	0,0901	0,4329	0,3379	0,6213	0,0635	...	0,0000

Pada tabel di atas menunjukkan terbentuknya matriks X yang merupakan matriks berisi hasil dari perhitungan jarak antar data *training* yaitu data *training* ke-1 dan data *training* ke-2 dan hasil dari matriks ini akan digunakan dalam pembentukan matriks kernel yang juga merupakan model regresi yang disajikan pada tabel 6.

Tabel 6. Model Regresi

X	1	2	3	4	5	...	20
1	5,4566	5,4373	5,4497	5,4312	5,4432	...	5,4497
2	5,4373	5,4566	5,4472	5,4542	5,3994	...	5,4241
3	5,4497	5,4472	5,4566	5,4480	5,4176	...	5,4311
...
20	5,4497	5,4241	5,4311	5,4103	5,4518	...	5,4566

Pada tabel di atas menunjukkan hasil pembentukan model regresi yang didapatkan berdasarkan dari perhitungan matriks X sebelumnya pada tabel 5 menggunakan persamaan 4. Selanjutnya melakukan perhitungan *learning rate* menggunakan persamaan sebagai berikut:

$$\begin{aligned} \gamma &= \frac{1}{\text{cLR}} \\ &= \frac{\text{MAX}(\text{diagonal matriks regresi})}{0,1009} \\ &= \frac{\text{MAX}(5,4566, 5,4566, 5,4566, \dots, 5,4566)}{0,1009} \\ &= 0,0185 \end{aligned}$$

Selanjutnya dilakukan perhitungan nilai *error* menggunakan persamaan sebagai berikut dan hasil dari perhitungan partikel ke-1 iterasi ke-0 pada *fold K = 1* disajikan pada tabel 7.

$$\begin{aligned} E_i &= y_i - \sum_{j=1}^n (a_j^* - a_j) R_{ij} \\ &= 0,5313 - (((0-0)*5,4566) + (((0-0)*5,4373) + \dots + (((0-0)*5,4497) \\ &= 0,5313 \end{aligned}$$

Tabel 7. Nilai Error

Data ke-	1	2	3	4	5	...	20
E _i	0,5313	0,0938	0,3594	0,6250	1,0000	...	0,8906

Pada tabel di atas menunjukkan nilai *error* yang didapatkan dari perhitungan nilai aktual dari data *training* yang telah dinormalisasi dan matriks kernel atau model regresi yang didapatkan sebelumnya pada tabel 6 yang selanjutnya hasil dari proses ini digunakan dalam perhitungan nilai $\delta\alpha_1^*$ dan $\delta\alpha_1$ menggunakan persamaan sebagai berikut dan hasil dari perhitungan partikel ke-1 iterasi ke-0 pada *fold K = 1* disajikan pada tabel 8.

$$\begin{aligned} \delta\alpha_1^* &= \min\{\max[\gamma(E_i - \epsilon), -\alpha_1^*], C - \alpha_1^*\} \\ &= \min\{\max[0,0185(0,5313 - 0,0278), -0], 289,5798 - 0\} \\ &= \min\{0,0093, 289,5798 - 0\} = 0,0093 \\ \delta\alpha_1 &= \min\{\max[\gamma(-E_i - \epsilon), -\alpha_1], C - \alpha_1\} \\ &= \min\{\max[0,0185(-0,5313 - 0,0278), -0], 289,5798 - 0\} \\ &= \min\{0, 289,5798 - 0\} = 0 \end{aligned}$$

Tabel 8. Nilai $\delta\alpha_1^*$ dan $\delta\alpha_1$

Data ke-	1	2	3	4	5	...	20
$\delta\alpha_1^*$	0,0093	0,0012	0,0061	0,0110	0,0180	...	0,0160
$\delta\alpha_1$	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000

Berdasarkan pada tabel 8, hasil dari perhitungan nilai $\delta\alpha_1^*$ dan $\delta\alpha_1$ dapat langsung digunakan dalam proses selanjutnya yaitu pembaruan nilai α_1^* dan α_1 menggunakan persamaan sebagai berikut dan hasil dari perhitungan partikel ke-1 iterasi ke-0 pada *fold K = 1* disajikan pada tabel 9.

$$\begin{aligned} \alpha_1^* &= \alpha_1^* + \delta\alpha_1^* = 0 + 0,0093 = 0,0093 \\ \alpha_1 &= \alpha_1 + \delta\alpha_1 = 0 + 0 = 0 \end{aligned}$$

Tabel 9. Pembaruan Nilai α_1^* dan α_1

Data ke-	1	2	3	4	5	...	20
α_1^*	0,0093	0,0012	0,0061	0,0110	0,0180	...	0,0160
α_1	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000

Berdasarkan tabel 9 maka hasil dari tahapan ini diasumsikan bahwa telah mencapai kondisi terminasi yang artinya nilai α_1^* dan α_1 sudah memenuhi untuk menghentikan proses pengulangan dalam pembaruan nilai sehingga tidak terjadi pengulangan tanpa henti yang mengakibatkan proses pengolahan data menjadi lama. Nilai α_1^* dan α_1 tersebut selanjutnya dapat digunakan dalam pengujian model regresi.

D. Pengujian Model Regresi

Langkah pertama yang dilakukan yaitu menghitung jarak antara data *training* dan data *testing*. Berikut adalah hasil dari perhitungan jarak antara data *training* dan data *testing* partikel ke-1 iterasi ke-0 pada *fold K = 1* (data *testing* ke-1 dan data *training* ke-1) yang disajikan pada tabel 10.

Tabel 10. Jarak Data *Testing* dan Data *Training*

<i>Testing/Training</i>	1	2	3	4	5	...	20
1	0,1604	0,8196	0,4316	0,9436	0,0635	...	0,1758
2	0,1958	0,6470	0,5364	0,8838	0,0413	...	0,0237
3	0,3774	0,4771	0,6458	0,7471	0,3577	...	0,1526
4	0,2610	0,5305	0,5688	0,7883	0,1704	...	0,0552
5	0,1802	0,0571	0,0237	0,0332	0,7102	...	0,4504

Pada tabel di atas menunjukkan terbentuknya matriks yang berisikan jarak antara data *testing* ke-1 dan data *training* ke-1 dimana hasil dari pembentukan matriks tersebut digunakan dalam pembentukan matriks kernel seperti pada proses sebelumnya menggunakan persamaan 4 yang disajikan pada tabel 11.

Tabel 11. Matriks Kernel

X	1	2	3	4	5	...	20
1	5,4444	5,3959	5,4242	5,3871	5,4518	...	5,4433
2	5,4418	5,4084	5,4165	5,3913	5,4535	...	5,4548
3	5,4282	5,4208	5,4085	5,4011	5,4297	...	5,4450
4	5,4369	5,4169	5,4141	5,3982	5,4437	...	5,4524
5	5,4429	5,4522	5,4548	5,4541	5,4038	...	5,4228

Berdasarkan tabel 11, hasil pembentukan matriks kernel selanjutnya digunakan untuk perhitungan nilai regresi dan hasil yang didapatkan dilakukan proses denormalisasi menggunakan persamaan 2, dimana tujuan dari proses denormalisasi ialah agar dapat melakukan perhitungan tingkat akurasi dengan membandingkan nilai $f(x)$ dengan data aktual. Berikut adalah hasil dari perhitungan nilai regresi, denormalisasi, dan nilai aktual partikel ke-1 iterasi ke-0 pada *fold K = 1* yang disajikan pada tabel 12.

Tabel 12. Nilai $f(x)$, Denormalisasi, dan Aktual

<i>Testing</i>	$f(x)$	Hasil Denormalisasi	Aktual (A_i)
1	0,8034	133,4169	127
2	0,8037	133,4362	90
3	0,8020	133,3297	100
4	0,8032	133,4023	114
5	0,8027	133,3726	83

Pada tabel di atas menunjukkan nilai $f(x)$ merupakan hasil peramalan yang didapatkan dari perhitungan menggunakan persamaan 5 yang belum didenormalisasi sedangkan nilai aktual merupakan jumlah penjualan produk pakaian secara aktual di periode tersebut. Berdasarkan pada tabel 12 maka dilakukan perhitungan tingkat akurasi menggunakan *Mean Absolute Percentage Error* (MAPE) lalu dilakukan perhitungan nilai *error* yang hasilnya akan digunakan dalam perhitungan *cost* dimana hasil nilai *error* dari semua *fold* dilakukan perhitungan rata-rata. Hasil dari perhitungan nilai *error* dan nilai *cost* partikel ke-1 iterasi ke-0 disajikan pada tabel 13.

Tabel 13. Nilai *Error* dan Nilai *Cost* Partikel 1 Iterasi 0

<i>Fold</i>	<i>Error</i>
1	0,3456
2	0,2284
3	0,3450
4	0,3553
5	0,1931
<i>Cost</i>	0,2935

Berdasarkan tabel 13, nilai *cost* atau nilai rata-rata *error* yang didapatkan 0,2935 atau 29,35% dari perhitungan SVR menggunakan parameter hasil inisialisasi pada awal proses untuk partikel ke-1. Maka selanjutnya akan dilakukan optimasi parameter SVR sehingga didapatkan nilai *cost* yang lebih rendah.

E. Pembaruan Kecepatan dan Posisi Partikel

Langkah pertama yang dilakukan ialah pencarian posisi individu terbaik dan posisi terbaik global. Hasil yang didapatkan disajikan pada tabel 14. Nilai parameter yang disajikan ialah nilai parameter c_2 dari hasil proses inisialisasi partikel yang telah dilakukan sebelumnya dengan nilai *cost* didapatkan dari hasil proses evaluasi fungsi *fitness* dengan menggunakan pelatihan SVR yang telah dilakukan sebelumnya.

Tabel 14. Posisi Individu Terbaik Iterasi 0

pBest	C	ϵ	σ	cLR	λ	F1	F2	F3	Cost
1	289,5798	0,0278	2,5586	0,1009	2,1111	1	1	0	0,2935
2	814,6669	0,0418	3,8557	0,4101	0,0923	0	1	1	1,5559
3	441,3160	0,0525	0,4577	0,2201	2,9125	1	1	0	0,6943

Pada tabel di atas menunjukkan bahwa nilai *cost* paling minimum yang didapatkan dari ketiga partikel sebesar 0,2935, maka didapatkan pencarian posisi terbaik global iterasi 0 yaitu pada partikel ke-1. Selanjutnya dilakukan perhitungan bobot inersia iterasi ke-0 menggunakan persamaan 7 dan didapatkan hasil sebesar 0,8. Dari hasil perhitungan bobot inersia dilakukan pembaruan kecepatan partikel dengan persamaan sebagai berikut dengan pembangkitan nilai *random* r_1 dan r_2 dalam *range* antara 0 sampai 1 yaitu 0,5063 dan 0,4425.

$$V_{1c}(1) = WV_{1c}(0) + c_1r_1(0) [y_{1c}(0) - x_{1c}(0)] + c_2r_2(0) [y_{1c}(0) - x_{1c}(0)]$$

$$= 0,8 \times 0 + 1 \times 0,63 \times [289,5798 - 289,5798] + 1 \times 0,4425 \times [289,5798 - 289,5798] = 0$$

Hasil dari pembaruan kecepatan partikel pada dimensi partikel yang bernilai diskrit yaitu tiga dimensi terakhir akan dilakukan normalisasi. Hasil dari pembaruan kecepatan dimensi partikel disajikan pada tabel 15.

Tabel 15. Kecepatan Baru Dimensi Partikel Iterasi 0

X	C	ϵ	σ	cLR	λ	F1	F2	F3
1	0,0000	0,0000	0,0000	0,0000	0,0000	0,5000	0,5000	0,5000
2	-498,2105	-0,0133	-1,2307	-0,2933	1,9155	0,7311	0,5000	0,2689
3	-143,9695	-0,0234	1,9934	-0,1131	-0,7604	0,5000	0,5000	0,5000

Pada tabel di atas menunjukkan nilai kecepatan baru partikel yang selanjutnya akan digunakan dalam pembaruan posisi partikel dengan memperbarui posisi pada dimensi partikel yang bernilai kontinu dengan menggunakan persamaan sebagai berikut.

$$X_1(1) = X_1(0) + V_1(1) = 289,5798 + 0 = 289,5798$$

Hasil dari posisi baru partikel dilakukan pengecekan apakah masih berada pada ruang pencarian dengan melakukan perbandingan nilai posisi baru partikel dengan nilai batas bawah dan batas atas dimensi partikel yang telah ditentukan pada awal proses. Apabila nilai posisi baru partikel lebih kecil dari nilai batas bawah dan lebih besar dari nilai batas atas, maka posisi baru partikel bernilai sama dengan batas bawah maupun batas atas dimensi partikel. Sedangkan pembaruan pada dimensi partikel bernilai diskrit dilakukan terlebih dahulu pembangkitan nilai *random* sebanyak dimensi partikel yang bernilai diskrit dalam *range* antara 0 sampai 1. Berikut hasil dari pembangkitan nilai *random* yang disajikan pada tabel 16.

Tabel 16. Nilai Random

X	F1	F2	F3
1	0,4050	0,3429	0,6727
2	0,6161	0,8522	0,1116
3	0,0971	0,9894	0,0052

Berdasarkan tabel 16, maka dapat dilakukan penentuan posisi baru pada dimensi partikel yang bernilai diskrit dengan membandingkan nilai kecepatan baru partikel dengan nilai *random* yang telah dibangkitkan sebelumnya. Apabila nilai *random* lebih besar dari nilai kecepatan baru partikel maka nilai posisi baru partikel yaitu 0. Apabila sebaliknya, maka posisi baru partikel yaitu 1. Hasil dari pembaruan posisi pada dimensi partikel disajikan pada tabel 17.

Tabel 17. Posisi Baru Dimensi Partikel Iterasi 0

X	C	ϵ	σ	cLR	λ	F1	F2	F3
1	289,5798	0,0278	2,5586	0,1009	2,1111	1	1	0
2	316,4563	0,0286	2,6250	0,1168	2,0077	1	0	1
3	297,3464	0,0291	2,4511	0,1070	2,1521	1	0	1

Pada tabel di atas menunjukkan hasil pembaruan dari posisi dimensi partikel yang didapatkan dari perhitungan serta ketentuan yang telah ditetapkan. Seluruh tahapan di atas diulang sebanyak jumlah *max* iterasi. Berikut adalah hasil posisi terbaik global pada *max* iterasi yang merupakan solusi dari permasalahan yang disajikan pada tabel 18.

Tabel 18. Posisi Terbaik Global Iterasi 0

gBest	C	ϵ	σ	cLR	λ	F1	F2	F3	Cost
0	289,5798	0,0278	2,5586	0,1009	2,1111	1	1	0	0,2935


Berdasarkan tabel 18, partikel ke-1 merupakan posisi terbaik global yang didapatkan dari seluruh tahapan yang telah dilakukan di atas dan memiliki nilai *cost* paling minimum dibandingkan dengan partikel yang lain. Selanjutnya dalam penyelesaian *gBest* digunakan *software* MATLAB R2015a sebagai skenario pengujian algoritma PSO agar

mendukung terbentuknya nilai *cost* dengan melakukan *input coding* dan akan menghasilkan *output* berupa nilai *cost* dari iterasi 1 sampai 50 yang disajikan pada tabel 19.

Tabel 19. Iterasi dan *Cost*

<i>gBest</i>	<i>Cost</i>
1	15,4243
2	3,5253
3	3,5253
...	...
50	1,4609e ⁻⁰⁵

Berdasarkan tabel 19, dapat diketahui bahwa kombinasi dari parameter SVR yang terbentuk mengalami banyak perubahan. Nilai *cost* yang dihasilkan dari penggunaan optimasi PSO pada iterasi terakhir sebesar 1,4609e⁻⁰⁵. Pada *output* grafik yang disajikan pada gambar 3 terlihat bahwa mulai dari iterasi 0 hingga 20 nilai *cost* mengalami penurunan dan pada pemilihan iterasi 20 sampai 50 mendapatkan hasil nilai *cost* yang stabil. Kondisi nilai *cost* yang mengalami penurunan menunjukkan bahwa proses optimasi dengan algoritma PSO mampu menurunkan nilai *error* pada parameter SVR yang akan digunakan, sedangkan kondisi nilai *cost* yang sudah stabil menunjukkan bahwa iterasi yang dilakukan pada proses optimasi dapat berhenti sehingga parameter yang dihasilkan sudah optimal dan dapat digunakan. Hal ini menunjukkan bahwa model regresi yang telah dibentuk sudah cukup akurat untuk meramalkan penjualan produk pakaian.



Gambar 3. Grafik *Output* PSO - MATLAB

F. Peramalan SVR

Nilai parameter SVR yang optimal dan jumlah fitur pilihan dari nilai *gBest* hasil dari tahap sebelumnya dapat digunakan untuk meramalkan penjualan produk pakaian menggunakan metode *support vector regression*. Fitur yang dipilih ialah F1 dan F2 dengan penentuan data *training* dan data *testing* menggunakan perbandingan 60:40 dari sampel yang digunakan dalam perhitungan yaitu sebesar 25 data yang telah dinormalisasi dan diacak. Berikut adalah data *training* yang digunakan dengan indeks 0-9 dan 20-24 atau *fold* K = 3 dimana yang disajikan pada tabel 20.

Tabel 20. Data *Training* Pengujian

Indeks	F1	F2	Aktual
0	0,0938	0,0469	0,7031
1	0,5313	0,0938	0,1250
2	0,8438	0,3438	0,2813
...
24	0,4688	0,2344	0,8906

Pada tabel di atas menunjukkan data *training* yang akan digunakan dalam pengujian parameter SVR. Indeks yang digunakan sebanyak 15 yang merupakan 60% dari jumlah sampel data yang digunakan, sedangkan data *testing* yang digunakan ialah data dengan indeks 10-19 atau *fold* K = 3 yang disajikan pada tabel 21.

Tabel 21. Data *Testing* Pengujian

Indeks	F1	F2	Aktual
10	0,0000	0,3125	0,4688
11	0,3125	0,9219	0,2344
12	0,2813	0,1875	0,3438
...
19	1,0000	0,3750	0,0781

Pada tabel di atas menunjukkan data *testing* yang didapatkan dari sisa 40% dari jumlah sampel data yang digunakan dan data ini akan dilakukan perbandingan dengan hasil peramalan SVR menggunakan data *training* yang telah ditentukan pada tahap sebelumnya yang disajikan pada tabel 20.

Pada tahapan optimasi parameter SVR dengan PSO menggunakan *software* MATLAB menghasilkan nilai parameter yang optimal yaitu dengan parameter C bernilai 34,3642, parameter ϵ bernilai 0,0110, parameter σ bernilai 0,3677, parameter cLR bernilai 0,1062, dan parameter λ bernilai 0,0117. Dengan parameter tersebut didapatkan perbandingan nilai aktual dan hasil peramalan yang disajikan pada tabel 22.

Tabel 22. Nilai Aktual dan Hasil Peramalan

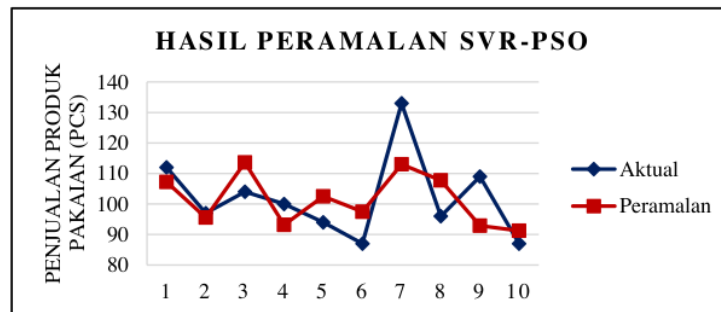
Data	Aktual (Ai)	Regresi (Fi)
1	112	113,0970
2	97	97,9993
3	104	120,0769
...
10	87	91,2348

Berdasarkan tabel 22, nilai regresi (Fi) merupakan hasil peramalan yang telah didenormalisasi yang selanjutnya akan dilakukan perhitungan tingkat akurasi menggunakan *Mean Absolute Percentage Error* (MAPE) dan perhitungan nilai *error* menggunakan persamaan sebagai berikut.

$$\begin{aligned} \text{MAPE} &= \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - f_i}{A_i} \right| \\ &= \frac{1}{10} \times \left[\left| \frac{112 - 113,0970}{112} \right| + \dots + \left| \frac{87 - 91,2348}{87} \right| \right] \\ &= \frac{1}{10} \times 0,8997 = 0,0898 \text{ atau } 8,98\% \end{aligned}$$

$$\begin{aligned} \text{Error} &= (W_A \times \text{MAPE}) + (W_F \times \frac{\sum_{j=1}^3 F_j}{3}) \\ &= (0,95 \times 0,0898) + (0,05 \times \frac{3}{3}) \\ &= 0,1186 \times 100\% = 11,86\% \end{aligned}$$

Dari perhitungan di atas dapat dilihat peramalan penjualan produk pakaian dengan metode SVR menggunakan parameter yang telah dipotimasi dengan algoritma PSO menghasilkan MAPE 8,98% dan nilai *error* sebesar 11,86%. Berikut adalah grafik yang menggambarkan perbandingan data aktual dengan hasil peramalan SVR-PSO yang disajikan pada gambar 4.

**Gambar 4.** Grafik Peramalan SVR-PSO

IV. KESIMPULAN

Dari penelitian ini didapatkan kesimpulan bahwa hasil peramalan penjualan produk pakaian menggunakan metode *Support Vector Regression* (SVR) dengan nilai MAPE = 8,98% dan nilai *error* = 11,86% yang dihasilkan dengan

memasukkan nilai parameter optimal dari SVR yang telah dioptimasi dengan algoritma *Particle Swarm Optimization* yaitu dengan parameter C bernilai 34,3642, parameter ϵ bernilai 0,0110, parameter σ bernilai 0,3677, parameter cLR bernilai 0,1062, dan parameter λ bernilai 0,0117. Dua fitur terpilih yaitu F1 dan F2 pada pengujian 60% data *training* dan 40% data *testing* dari 25 sampel yang digunakan yaitu sebesar 25 data dengan *fold* $K = 3$, dimana indeks 0-9 dan 20-24 untuk data *training* dan indeks 10-19 untuk data *testing*.

Saran yang dapat dilakukan untuk penelitian selanjutnya yaitu perlu mencoba beberapa metode peramalan yang lain dengan metode optimasi yang berbeda sehingga dapat melakukan perbandingan pada nilai MAPE yang dihasilkan dari masing-masing metode tersebut.

UCAPAN TERIMA KASIH

Dalam penyusunan artikel ilmiah ini tidak lepas bantuan dari berbagai pihak, terima kasih kepada pimpinan atau pemilik *Butik Nara Gallery Collection* yang telah memberikan kesempatan untuk melakukan penelitian.

REFERENSI

- [1] N. Ardiansyah and H. C. Wahyuni, "Analisis Kualitas Produk Dengan Menggunakan Metode FMEA Dan Fault Tree Analysis (FTA) Di Exotic UKM Intako," *Prozima*, vol. 2, no. 2, pp. 58–63, 2018.
- [2] M. Farhan, "Perancangan Sistem Inventori Dan Penjualan Pakaian Di Konveksi Aulia Collection," *JRAMI (Jurnal Ris. dan Apl. Mhs. Inform.*, vol. 01, no. 02, pp. 171–176, 2020.
- [3] M. Efriyanti, Garaika, and R. Irviani, "Analisis Implementasi Electronic Commerce Untuk Meningkatkan Omset Penjualan Butik Mery Berbasis Web Mobile," *J. Signal. STMIK Pringsewu*, vol. 7, no. 2, pp. 45–51, 2018.
- [4] F. Alfiah, R. Tarmizi, and A. A. Junidar, "Perancangan Sistem E – Commerce Untuk Penjualan Pakaian Pada Toko A & S," vol. 6, no. 1, pp. 70–81, 2020.
- [5] C. Nurlaila and H. Fitriyah, "Effect of E-Commerce, Use of Accounting Information Systems and Business Capital in Student Decision Making for Entrepreneurship," *Indones. J. Law Econ. Rev.*, vol. 11, pp. 1–13, 2021.
- [6] R. E. Utama, N. A. Gani, Jaharuddin, and A. Priharta, *Manajemen Operasi*, 1st ed. Tangerang Selatan: UM Jakarta Press, 2019.
- [7] H. Prasetya and F. Lukiasuti, *Manajemen Operasi*, 1st ed. Jakarta: MedPress, 2009.
- [8] Rahmawati, R. S. Muminin, I. Denni, and R. Ramdhani, "Implementation Of The Support Vector Regression Algorithm And Particle Swarm Optimization In Sales Forecasting," *J. RISTEC Res. Inf. Syst. Technol.*, vol. 1, no. 1, pp. 1–10, 2021.
- [9] D. P. Utomo and B. Purba, "Penerapan Datamining pada Data Gempa Bumi Terhadap Potensi Tsunami di Indonesia," *Pros. Semin. Nas. Ris. Inf. Sci.*, vol. 1, pp. 846–853, 2019.
- [10] Mulaab, *Data Mining Konsep dan Aplikasi*, 1st ed. Malang: Media Nusa Creative, 2017.
- [11] A. B. Raharjo, Z. Z. Dinanto, D. Sunaryono, and D. Purwitasari, "Prediksi Akumulasi Kasus Terkonfirmasi Covid-19 di Indonesia Menggunakan Support Vector Regression," *Techno.COM*, vol. 20, no. 3, pp. 372–381, 2021.
- [12] D. I. Purnama, "Peramalan Harga Emas Saat Pandemi Covid-19 Menggunakan Model Hybrid Autoregressive Integrated Moving Average - Support Vector Regression," *Jambura J. Math.*, vol. 3, no. 1, pp. 52–65, 2021.
- [13] D. A. Mardhika, B. D. Setiawan, and R. C. Wihandika, "Penerapan Algoritma Support Vector Regression Pada Peramalan Hasil Panen Padi Studi Kasus Kabupaten Malang," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 10, pp. 9402–9412, 2019.
- [14] V. Rusmalawati, M. T. Furqon, and Indriati, "Peramalan Harga Saham Menggunakan Metode Support Vector Regression (SVR) Dengan Particle Swarm Optimization (PSO)," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 5, pp. 1980–1990, 2018.
- [15] M. R. Rifqi, B. D. Setiawan, and F. A. Bachtiar, "Support Vector Regression Untuk Peramalan Permintaan Darah : Studi Kasus Unit Transfusi Darah Cabang – PMI Kota Malang," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 10, pp. 3332–3342, 2018.
- [16] A. Umiyati, D. Dasari, and F. Agustina, "Peramalan Harga Batubara Acuan Menggunakan Metode PSOSVR Dan IPSOSVR," *EurekaMatika*, vol. 9, no. 2, pp. 175–198, 2021.
- [17] K. F. Imanda, A. P. Windarto, and I. S. Damanik, "Optimasi Particle Swarm Optimization Pada Peningkatan Prediksi dengan Metode Backpropagation Menggunakan Software RapidMiner," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 1, pp. 122–130, 2022.
- [18] K. R. P. Irawan and T. Sukmono, "Planning Total Veener Production PT . XYZ," *Procedia Eng. Life Sci.*, vol. 1, no. 2, pp. 1–8, 2021.

- [19] T. D. Anggraeni and L. Wachidah, "Metode Single Exponential Smoothing dan Fuzzy Time Series Pada Peramalan Permintaan Penjualan Pakaian Thrift Shop Garagesaleinaja," *Bandung Conf. Ser. Stat.*, vol. 2, no. 2, pp. 254–265, 2022.
- [20] N. Hudaningsih, S. F. Utami, and W. A. A. Jabbar, "Perbandingan Peramalan Penjualan Produk Aknil PT. Sunthi Sepuri Menggunakan Metode Single Moving Average Dan Single Exponential Smoothing," *J. JINTEKS*, vol. 2, no. 1, pp. 15–22, 2020.
- [21] C. D. Kusmindari, A. Alfian, and S. Hardini, *Production Planning And Inventory Control*, 1st ed. Yogyakarta: Deepublish, 2019.
- [22] A. K. Wardhani *et al.*, *Teknik Peramalan Pada Teknologi Informasi*, 1st ed. Padang: PT Global Eksekutif Teknologi, 2022.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Article History:

Received: 26 June 2018 | Accepted: 08 August 2018 | Published: 30 August 2018

ORIGINALITY REPORT

10%

SIMILARITY INDEX

11%

INTERNET SOURCES

2%

PUBLICATIONS

1%

STUDENT PAPERS

PRIMARY SOURCES

1	repository.ub.ac.id Internet Source	5%
2	repository.upi.edu Internet Source	3%
3	j-ptiik.ub.ac.id Internet Source	1%
4	repository.uncp.ac.id Internet Source	1%

Exclude quotes On

Exclude matches < 1%

Exclude bibliography On