
VEHICLE ROUTING PROBLEM WITH STOCHASTIC DEMANDS DENGAN METODE HIBRID SIMULATED ANNEALING – ALGORITMA GENETIKA

¹Adi Slamet Kusumawardana, ²Irhamah

^{1,2}Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh November,
Surabaya

Alamat e-mail : ¹adislametk@gmail.com

ABSTRAK

Manajemen logistik memiliki peranan penting dalam suatu perusahaan yang bergerak dalam bidang logistik dan ekspedisi. Tujuan manajemen logistik yaitu mengantarkan produk ke konsumen tepat waktu dengan cara yang efektif dan efisien. Salah satu cara untuk mengoptimalkan sistem distribusi adalah dengan pengoptimalan transportasi. Salah satu permasalahan dalam transportasi adalah *Vehicle Routing Problem*. *Vehicle Routing Problem with Stochastic Demands* (VRPSD) merupakan perluasan dari VRP konvensional dengan kondisi permintaan konsumen di setiap lokasi diasumsikan mengikuti distribusi peluang yang telah diketahui. Dalam penelitian ini bertujuan untuk menyelesaikan *Vehicle Routing Problem with Stochastic Demands* menggunakan Hibrid Simulated Annealing – Algoritma Genetika. Simulated annealing adalah salah satu algoritma untuk optimasi, Simulated annealing berasal dari bidang metalurgi yaitu annealing. Algoritma ini digunakan untuk mencari pendekatan terhadap solusi optimum lokal. Algoritma genetika merupakan metode optimisasi yang menggunakan teori evolusi dan seleksi alam di dalam suatu populasi individu. Algoritma genetika menawarkan pemecahan persoalan dengan pendekatan terhadap solusi optimum global. Hibrid simulated annealing – algoritma genetika mencakup beberapa proses dasar, yaitu generate populasi, evaluasi, seleksi elitism, *fitness*, serta seleksi roulette wheel. Pada proses operasi algoritma genetika menggunakan crossover dan mutasi sedangkan operasi pada simulated annealing menggunakan mutasi dan proses annealing. Implementasi metode hibrid simulated annealing – algoritma genetika pada *Vehicle Routing Problem with Stochastic Demands* diharapkan dapat menghasilkan rute pengantaran barang dengan jarak dan biaya transportasi minimum.

Kata Kunci : *Vehicle Routing Problem with Stochastic Demands*, Pengantaran Barang, Simulated Annealing, Algoritma Genetika, Hibrid Simulated Annealing – Algoritma Genetika

PENDAHULUAN

Manajemen logistik memiliki peranan penting dalam suatu perusahaan yang bergerak dalam bidang logistik dan ekspedisi. Manajemen logistik sendiri memiliki tujuan yaitu mengantarkan produk ke konsumen tepat waktu dengan cara efektif dan efisien Suatu perusahaan di bidang logistik harus dapat

mengoptimalkan sistem distribusinya agar dapat bersaing dengan perusahaan sejenis lainnya. Salah satu caranya adalah dengan pengoptimalan transportasi.

Salah satu permasalahan dalam transportasi adalah *Vehicle Routing Problem* (VRP) yaitu merancang m set rute kendaraan dengan biaya terkecil dimana tiap kendaraan berawal dan berakhir di depot, setiap konsumen hanya dilayani sekali oleh sebuah kendaraan,


serta total permintaan yang dibawa tidak melebihi kapasitas kendaraan. Vehicle Routing Problem with Stochastic Demands (VRPSD) merupakan perluasan dari VRP konvensional. VRPSD didasarkan pada kondisi dimana jumlah permintaan konsumen di setiap lokasi tidak diketahui pada saat perancangan perjalanan, tetapi diasumsikan mengikuti distribusi peluang yang telah diketahui. Situasi ini muncul setiap hari dalam praktek pada sebuah perusahaan ketika dihadapkan dengan masalah pengiriman kepada sekumpulan konsumen yang memiliki permintaan acak [2]. Penyelesaian masalah VRPSD diharapkan dapat memberi masukan dalam pengambilan keputusan untuk menentukan urutan rute terpendek dari aktifitas pengantaran barang.

Salah satu metode yang digunakan untuk menyelesaikan VRPSD antara lain adalah dengan pendekatan heuristik dan metaheuristik. Dibandingkan dengan heuristik klasik, metaheuristik menunjukkan pencarian solusi yang lebih baik. Atas dasar itu dipilih metode metaheuristik hibrid simulated annealing – algoritma genetika sebagai metode untuk menyelesaikan VRPSD. Simulated annealing adalah salah satu algoritma untuk optimasi. Algoritma ini digunakan untuk mencari pendekatan terhadap solusi optimum lokal. Nama dan inspirasi dari Simulated annealing berasal dari bidang metalurgi yaitu Annealing, dimana itu adalah suatu teknik yang digunakan dalam mempelajari proses pembentukan kristal dalam suatu materi. Algoritma genetika merupakan metode optimisasi yang menggunakan teori evolusi dan seleksi alam untuk suatu populasi individu – individu yang mempresentasikan solusi potensial masalah.

Pada penelitian ini akan digunakan pendekatan baru untuk menyelesaikan Vehicle Routing Problem with Stochastic Demands dengan metode hibrid

simulated annealing – algoritma genetika. Metode hibrid simulated annealing – algoritma genetika diharapkan akan memberikan solusi yang lebih baik karena mencakup pencarian solusi secara global maupun lokal. Dalam penelitian ini data yang akan digunakan adalah data riil dan data simulasi. Data riil yang digunakan adalah data penjualan milik PT. Sinar Moto Surya periode Oktober 2012 – April 2013, dan data simulasi yang berisi customer PT. Sinar Moto Surya dengan data demand yang menggunakan data bangkitan berupa data berdistribusi normal dan uniform diskrit. Distribusi normal dan uniform diskrit digunakan karena dua distribusi tersebut juga digunakan pada penelitian – penelitian sebelumnya, sehingga bisa dijadikan sebagai pembandingan dan acuan.

Menurut [1], *Vehicle Routing Problem* (VRP) merupakan manajemen distribusi barang yang memperhatikan pelayanan, periode waktu tertentu, sekelompok konsumen dengan sejumlah kendaraan yang berlokasi pada satu atau lebih depot yang dijalankan oleh sekelompok pengemudi, menggunakan *road network* yang sesuai. Solusi dari sebuah VRP yaitu menentukan sejumlah rute, yang masing-masing dilayani oleh suatu kendaraan yang berasal dan berakhir pada depotnya, sehingga kebutuhan pelanggan terpenuhi, semua permasalahan operasional terselesaikan, dan biaya transportasi secara umum diminimalkan.



Gambar 1 VRP dengan 3 rute

Menurut [14], Formulasi matematis secara umum untuk *Vehicle Routing Problem with Stochastic Demands* adalah sebagai berikut:

Pelanggan dan Depot:

VRPSD didefinisikan sebagai graph lengkap $G=(V,A,D)$, dimana $V=\{v_0,v_1,\dots,v_n\}$ adalah satu set himpunan node pelanggan dengan node 0 menunjukkan depot. $A = \{(v_i,v_j):i,j \in \{0,1,2,\dots,n\}; v_i, v_j \in V, v_i \neq v_j\}$ adalah satu set himpunan node yang saling terhubung, dan $D = \{d_{ij} : v_i,v_j \in V, v_i \neq v_j\}$ adalah biaya perjalanan (jarak) antara node.

Permintaan (Demands) :

Permintaan/*demand* pelanggan adalah variabel stokastik $\xi_i, i = 1,\dots,n$ dengan mengikuti fungsi distribusi probabilitas yang diketahui. Diasumsikan bahwa ξ_i tidak melebihi kapasitas kendaraan (Q) dan mengikuti distribusi probabilitas diskrit $p_{ik} = \text{Prob}(\xi_i=k), k = 0,1,2,\dots, K \leq Q$. Diasumsikan lebih lanjut bahwa permintaan pelanggan adalah independen. Permintaan aktual dari setiap pelanggan hanya diketahui saat kendaraan tiba di lokasi pelanggan.

Kendaraan dan kendala kapasitas :

Satu kendaraan dengan kapasitas Q harus mengirimkan barang kepada pelanggan sesuai dengan permintaan/*demand*. Kendaraan mengunjungi pelanggan di urutan rute apriori dan tergantung pada permintaan pelanggan aktual, apakah akan berlanjut ke pelanggan berikutnya atau pulang ke depot untuk isi ulang muatan. Isi ulang muatan terjadi jika permintaan total pelanggan melebihi kapasitas kendaraan.

Rute : Rute A harus mulai dari depot, mengunjungi sejumlah pelanggan dan kembali ke depot. Sebuah solusi layak untuk VRPSD adalah permutasi dari pelanggan $V = \{v_0,v_1,\dots,v_n\}$ mulai dan berakhir di depot, disebut rute apriori.

VRPSD bertujuan untuk menemukan rute apriori yang meminimalkan jarak perjalanan yang diharapkan oleh

kendaraan yang berbasis di depot dengan kapasitas Q . VRPSD dipengaruhi kebijakan isi ulang muatan. Hal itu dibutuhkan untuk menemukan rute kendaraan dan untuk memutuskan apakah perlu atau tidak kembali ke depot untuk isi ulang muatan sebelum mengunjungi pelanggan berikutnya untuk meminimalkan biaya total perkiraan perjalanan. Terkadang pilihan untuk tidak isi ulang muatan adalah pilihan yang terbaik jika kendaraan tidak kosong atau jika kapasitasnya lebih besar dari permintaan yang diharapkan dari pelanggan yang terjadwal berikutnya. Tindakan ini disebut “pencegahan isi ulang muatan”. Total biaya bergantung pada:

- Biaya perjalanan dari satu pelanggan ke pelanggan lain
- Biaya isi ulang muatan (biaya pergi dari pelanggan untuk kembali ke depot)
- Biaya perjalanan dari pelanggan ke depot untuk isi ulang muatan jika permintaan pelanggan melebihi kapasitas kendaraan

Misalkan $V = \{v_0,v_1,\dots,v_n\}$ adalah rute apriori. Misalkan kendaraan memiliki beban sisa q (residual atau kapasitas kendaraan setelah j pelanggan dilayani) dan misalkan $f_i(q)$ adalah panjang rute yang diharapkan dari kendaraan setelah melayani j pelanggan, sehingga biaya yang diharapkan dari rute apriori adalah $f_0(Q)$. Jika H_j merupakan himpunan semua beban yang mungkin bahwa sebuah kendaraan dapat memiliki layanan purna selesai di j pelanggan, maka, $f_i(q)$ untuk $q \in H_j$ memenuhi :

$$f_i(q) = \text{minimum} \begin{cases} f_j^p(q) \\ f_j^r(q) \end{cases} \quad (1)$$

dimana

$$f_j^p(q) = d_{j,j+1} + \sum_{k:k \leq q} f_{j+1}(q-k)p_{j+1,k} + \sum_{k:k \geq q+1} d_{j+1,0} + f_{j+1}(q+1) + Q - kp_{j+1,k} \quad (2)$$

Dan

$$f_j^r(q) = d_{j,0} + d_{0,j+1} + \sum_{k=1}^K f_{j+1}(Q - kp_{j+1,k}) \quad (3)$$

dengan batasan kondisi :

$$f_n(q) = d_{n,0}, q \in H_n \quad (4)$$

Dimana Q adalah kapasitas kendaraan, d_{ij} adalah jarak dari lokasi i ke lokasi j , dan k adalah permintaan pelanggan.

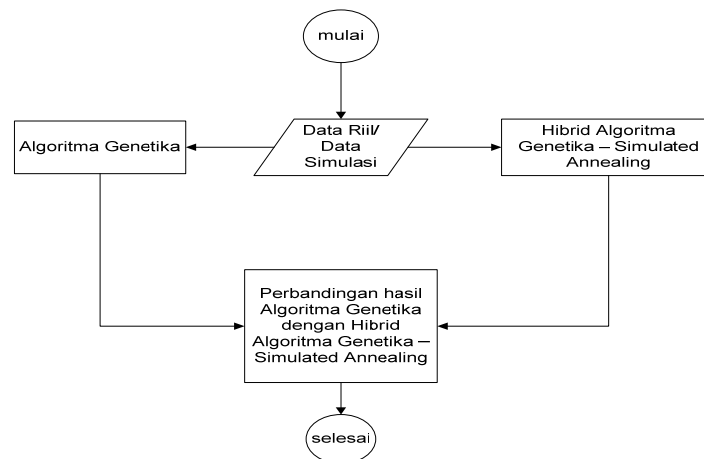
Pada persamaan 2, $f_j^p(q)$, adalah biaya yang diharapkan sesuai dengan pilihan untuk melanjutkan langsung ke pelanggan berikutnya, sementara persamaan 3, $f_j^r(q)$, adalah biaya yang diharapkan dalam kasus ‘pencegahan isi ulang muatan’ yang dipilih. Persamaan ini digunakan secara rekursif untuk menentukan nilai obyektif dari rute kendaraan yang telah direncanakan dan urutan yang optimal keputusan setelah pelanggan dilayani [19].

METODE PENELITIAN

Data yang digunakan dalam penelitian ini adalah data sekunder dari laporan penjualan PT. Sinar Moto Surya selaku distributor ban *Michelin*. Data penjualan yang digunakan adalah data bulanan periode Oktober 2012 – April 2013. Data *demand* masing – masing *customer* dihitung per dua minggu, sehingga jumlah pengamatan data *demand* tersebut dicari distribusinya.

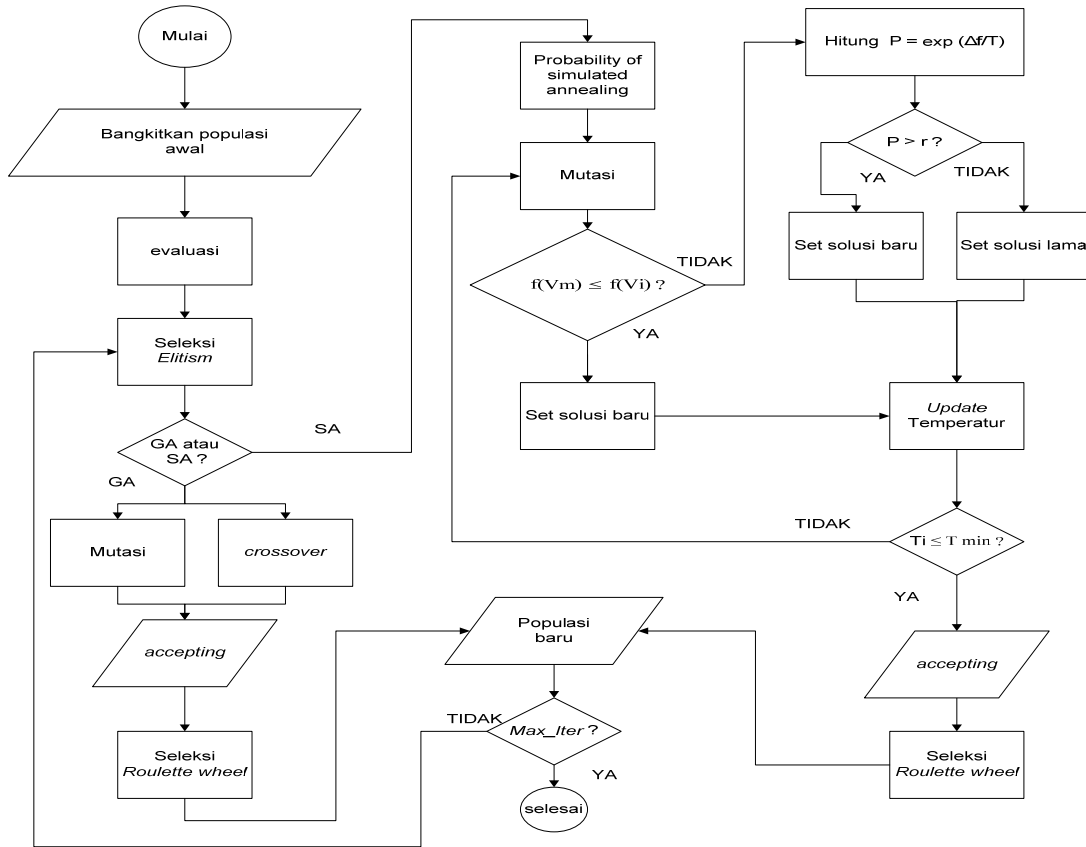
Data *demand* yang digunakan adalah data *demand* riil dan data *demand* hasil simulasi. Data *demand* riil menggunakan data *demand* hasil laporan penjualan PT. Sinar Moto Surya, sedangkan data *demand* simulasi adalah data *demand* hasil bangkitan dari software minitab yang berdistribusi normal dan uniform diskrit. Data lokasi dikodekan dalam bentuk node – node. Data lokasi yang digunakan adalah 11 node/lokasi, dengan 1 depot dan 10 costumer.

Variabel yang digunakan pada VRPSD adalah biaya perjalanan (jarak) dari node i ke j (d_{ij}), kapasitas angkut maksimum kendaraan (Q), kapasitas kendaraan setelah melayani pelanggan (q), biaya yang diharapkan sesuai dengan pilihan untuk melanjutkan langsung ke pelanggan berikutnya ($f_j^p(q)$), dan biaya yang diharapkan dalam kasus ‘pencegahan isi ulang muatan’ yang dipilih ($f_j^r(q)$). Variabel yang digunakan pada Hibrid Simulated Annealing – Algoritma Genetika adalah laju *crossover* GA (P_c), laju mutasi GA (P_m), laju probabilitas SA (P_{SA}) maksimum iterasi (max_iter), temperatur awal SA (T_{now}), temperature akhir SA (T_{min}), faktor penurunan temperatur pada SA (α). langkah penelitian dijelaskan dalam Gambar 1

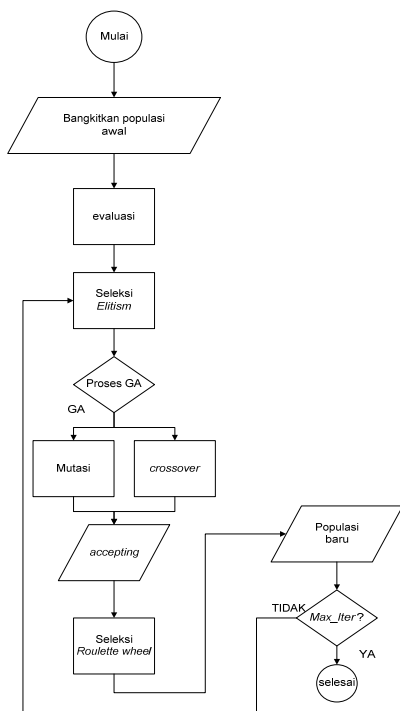


Gambar 2 Bagan Langkah-Langkah Penelitian

Untuk langkah penelitian Hibrid Simulated Annealing – Algoritma Genetika, dijelaskan dalam bagan pada Gambar 2.



Gambar 3 Bagan Langkah – Langkah Metode Hibrid Simulated Annealing – Algoritma Genetika



Gambar 4 Langkah metode Algoritma Genetika

HASIL PENELITIAN

Terdapat 3 jenis data demand yang digunakan pada *Vehicle Routing Problem with Stochastic Demands*, yang pertama data demands riil dari laporan PT. Sinar Moto Surya dan 2 data demand simulasi yang berdistribusi normal dan uniform diskrit. Data demand riil pada awalnya tidak diketahui karakteristik dan distribusinya. Maka tahap pertama terlebih dahulu dicari karakteristik datanya dan distribusinya sebelum digunakan dalam proses Hibrid Simulated Annealing – Algoritma Genetika. Masing – masing node memiliki 14 data demand yang merupakan data per dua minggu dari bulan Oktober 2012 hingga April 2013.

Tabel 1 Statistik Deskriptif Data Demand Riil

| Costumer | N | Mean | St. Dev | Distribusi |
|----------|----|-------|---------|------------|
| 1 | 14 | 0.286 | 0,7953 | Uniform |
| 2 | 14 | 9.571 | 9.6859 | Uniform |
| 3 | 14 | 4.714 | 14,375 | Uniform |
| 4 | 14 | 1.286 | 3.1719 | Uniform |
| 5 | 14 | 9.714 | 13.812 | Uniform |
| 6 | 14 | 106.1 | 58.558 | Uniform |
| 7 | 14 | 7.571 | 12.316 | Uniform |
| 8 | 14 | 1.714 | 4.463 | Uniform |
| 9 | 14 | 1.786 | 2.7563 | Uniform |
| 10 | 14 | 7 | 9.1026 | Uniform |

Hasil pengolahan didapat bahwa data demand riil memenuhi distribusi uniform. Sehingga pada proses pengerjaan Vehicle Routing Problem with Stochastic Demands (VRPSD), variabel P yang digunakan adalah peluang distribusi uniform. Setiap data merupakan inputan program yang dibuat dalam bahasa *Borland C++* untuk menyelesaikan VRPSD dengan metode Hibrid Simulated Annealing – Algoritma Genetika.

Proses Vehicle Routing Problem with Stochastic Demands

Pada proses VRPSD diinputkan demand masing-masing customer, variabel Q, dan variabel biaya perjalanan (jarak) antar node (d_{ij}). Pada proses ini dilakukan iterasi dengan prinsip kerja dynamic programming. Hasil dari proses VRPSD adalah variabel $f_0(Q)$ untuk masing-masing kromosom. Variabel $f_0(Q)$ adalah fungsi tujuan, yang mana itu adalah inputan untuk proses Hibrid Simulated Annealing – Algoritma Genetika. Untuk kromosom dengan $f_0(Q)$ terkecil, diambil untuk digunakan pada populasi baru.

Proses Hibrid Simulated Annealing – Algoritma Genetika

Mengacak nilai 0 atau 1. Jika 0 maka proses Algoritma Genetika (GA) dan jika 1 maka berjalan proses Simulated Annealing (SA). Pada tahap ini digunakan nilai laju crossover (P_c) yang direkomendasikan yaitu antara 0.8 dan 0.95. namun pada banyak persoalan,

crossover dengan $P_c = 0.6$ memiliki hasil yang paling baik. Berlawanan dengan nilai laju crossover (P_c), laju mutasi (P_m) direkomendasikan bernilai kecil, yaitu antara 0.005 dan 0.01 [11]. Hasil dengan menggunakan data demand riil ditunjukkan pada Tabel 2.

Kemudian digunakan 2 data demand simulasi yang berdistribusi normal dan uniform diskrit. Hasil penyelesaian dengan menggunakan data demand hasil simulasi yang berdistribusi normal terdapat pada Tabel 3.

Tabel 2 Hasil data demand riil

| Data No. | P_c | P_m | P_{sa} | T_{now} | T_{min} | A | Hasil SA-GA |
|----------|-------|-------|----------|-----------|-----------|-----|--------------|
| 1 | 0.95 | 0.005 | 0.95 | 1000 | 100 | 0.1 | 421.2 |
| 2 | 0.95 | 0.05 | 0.95 | 1000 | 10 | 0.1 | 421.3 |
| 3 | 0.95 | 0.01 | 0.95 | 1000 | 1 | 0.1 | 408.1 |
| 4 | 0.8 | 0.005 | 0.8 | 1000 | 100 | 0.1 | 419.3 |
| 5 | 0.8 | 0.05 | 0.8 | 1000 | 10 | 0.1 | 408.1 |
| 6 | 0.8 | 0.01 | 0.8 | 1000 | 1 | 0.1 | 408.1 |
| 7 | 0.6 | 0.005 | 0.6 | 1000 | 100 | 0.1 | 408.1 |
| 8 | 0.6 | 0.05 | 0.6 | 1000 | 10 | 0.1 | 408.1 |
| 9 | 0.6 | 0.01 | 0.6 | 1000 | 1 | 0.1 | 408.1 |

Tabel 3 Hasil data demand simulasi distribusi Normal

| Data No. | P_c | P_m | P_{sa} | T_{now} | T_{min} | α | Hasil SA-GA |
|----------|-------|-------|----------|-----------|-----------|----------|--------------|
| 1 | 0.95 | 0.005 | 0.95 | 1000 | 100 | 0.1 | 407.6 |
| 2 | 0.95 | 0.05 | 0.95 | 1000 | 10 | 0.1 | 407.4 |
| 3 | 0.95 | 0.01 | 0.95 | 1000 | 1 | 0.1 | 399.3 |
| 4 | 0.8 | 0.005 | 0.8 | 1000 | 100 | 0.1 | 410.2 |
| 5 | 0.8 | 0.05 | 0.8 | 1000 | 10 | 0.1 | 401.7 |
| 6 | 0.8 | 0.01 | 0.8 | 1000 | 1 | 0.1 | 390.6 |
| 7 | 0.6 | 0.005 | 0.6 | 1000 | 100 | 0.1 | 397.4 |
| 8 | 0.6 | 0.05 | 0.6 | 1000 | 10 | 0.1 | 395.3 |
| 9 | 0.6 | 0.01 | 0.6 | 1000 | 1 | 0.1 | 390.6 |

Tabel 4 Hasil data demand simulasi distribusi uniform

| Data No. | P_c | P_m | P_{sa} | T_{now} | T_{min} | α | Hasil SA-GA |
|----------|-------|-------|----------|-----------|-----------|----------|--------------|
| 1 | 0.95 | 0.005 | 0.95 | 1000 | 100 | 0.1 | 437.3 |
| 2 | 0.95 | 0.05 | 0.95 | 1000 | 10 | 0.1 | 437.3 |
| 3 | 0.95 | 0.01 | 0.95 | 1000 | 1 | 0.1 | 421.2 |
| 4 | 0.8 | 0.005 | 0.8 | 1000 | 100 | 0.1 | 430.4 |
| 5 | 0.8 | 0.05 | 0.8 | 1000 | 10 | 0.1 | 420.1 |
| 6 | 0.8 | 0.01 | 0.8 | 1000 | 1 | 0.1 | 416.5 |
| 7 | 0.6 | 0.005 | 0.6 | 1000 | 100 | 0.1 | 416.5 |
| 8 | 0.6 | 0.05 | 0.6 | 1000 | 10 | 0.1 | 416.5 |
| 9 | 0.6 | 0.01 | 0.6 | 1000 | 1 | 0.1 | 416.5 |

Tabel 5 Perbandingan hasil metode Hibrid Simulated annealing – Algoritma Genetika dengan metode Algoritma Genetika

| No. | Data | Pc | Pm | Psa | Tnow | Tmin | A | SA – GA | GA |
|-----|------------------------------|-----|------|-----|------|------|-----|---------------|--------|
| 1 | Data demand Riil | 0.6 | 0.01 | 0.6 | 1000 | 1 | 0.1 | 408.13 | 531.72 |
| 2 | Data demand Simulasi Normal | 0.6 | 0.01 | 0.6 | 1000 | 1 | 0.1 | 390.62 | 503.31 |
| 3 | Data demand Simulasi Uniform | 0.6 | 0.01 | 0.6 | 1000 | 1 | 0.1 | 416.53 | 511.27 |

Kemudian dilakukan pengerjaan dengan tahap yang sama untuk data demand hasil simulasi yang berdistribusi uniform. Hasil data demand simulasi distribusi uniform terdapat pada Tabel 4.

Setelah didapat hasil, data yang ada digunakan untuk input proses yang menggunakan metode algoritma genetika, hasil yang didapat akan dibandingkan dengan hasil metode Hibrid SA – GA. Dari Tabel 5 nampak bahwa hasil optimasi Hibrid Simulated Annealing (SA) – Algoritma Genetika (GA) lebih baik dibanding ketika menggunakan metode tunggal Algoritma Genetika.

KESIMPULAN DAN SARAN

Kesimpulan

Hasil dengan menggunakan parameter nilai laju mutasi (P_m) = 0.01 dan untuk nilai laju crossover (P_c) dan $P_{sa} = 0.6$ serta $\alpha = 0.1$ di $T_{now} = 1000$ dan $T_{min} = 1$ pada Hibrid Simulated Annealing - Algoritma Genetika memiliki solusi yang paling baik. Penyelesaian Vehicle Routing Problem with Stochastic Demands dengan menggunakan metode Hibrid Simulated annealing – Algoritma Genetika mempunyai solusi yang lebih baik daripada solusi yang dihasilkan dengan menggunakan metode Algoritma Genetika.

Saran

Sebaiknya dilakukan penelitian pada data yang lebih banyak jumlahnya dan digunakan distribusi selain uniform dan

normal untuk menguji lebih dalam keunggulan metode Hibrid Simulated Annealing – Algoritma Genetika. Dan juga data riil yang digunakan mungkin bisa lebih detil pemilihan waktunya, bisa perhari selama beberapa tahun, agar lebih akurat dalam menentukan pola data riil itu berdistribusi apa.

UCAPAN TERIMA KASIH

Ucapan terima kasih ini ditujukan kepada PT. Sinar Moto Surya Jakarta selaku instansi yang bergerak didistribusi ban *Michelin* untuk wilayah JABODETABEK yang telah memberikan kesempatan bagi penulis untuk magang selama periode bulan dan membantu penulis dalam memberikan data dan informasi yang dibutuhkan penulis dalam penyusunan jurnal.

DAFTAR PUSTAKA

- [1] Asteria, C., 2008, *Penentuan Rute Distribusi dengan Algoritma Tabu Search untuk VRP dengan Time Windows (Studi Kasus di PT. X)*, Tesis, Program Studi Teknik Industri, Universitas Indonesia, Jakarta.
- [2] Bertsimas, D.L., 1992, A Vehicle Routing Problem With Stochastic Demand, *Operation Research*, Vol 40, No. 3, hal 574-585.
- [3] Chartrand, G. dan Oellermann, O.R., 1993, *Applied and Algorithmic Graph Theory*, McGraw-Hill, New York.
- [4] Chepuri, K., dan Homem-De-Mello, T., 2005, Solving the Vehicle Routing Problem with Stochastic Demands

- using the Cross-Entropy method, *Annals of Operation Research*, 134, 153-181
- [5] Dereli, T. dan Sena Das, G., 2006, *A Hybrid Simulated Annealing Algorithm for 2D Packing Problems*, Sakarya University, Turkey.
- [6] Fariza, A., 2004, *APenentuan Model Hybrid Algoritma Genetika Simulated Annealing untuk Peramalan Data Time Series*, Tesis, Jurusan Teknik Informatika, FTIf Institut Teknologi Sepuluh November, Surabaya.
- [7] Gen, M. dan Cheng, R., 1997, *Genetic Algorithms and Engineering Design*, John Wiley & Sons, New York
- Obitko, M., 1998, *Genetic Algorithms*, Czech Technical University.
- [8] Ismail, Z. dan Irhamah., 2008, Solving the Vehicle Routing Problem with Stochastic Demands via Hybrid Genetic Algorithm – Tabu Search, *Journal Mathematics and Statistics*, 4(3) : 161-167.
- [9] Kirkpatrick, S., Gelatt, C.D. dan Vecchi, M. P., 1983, Optimization by Simulated Annealing, *Science*, 220, 671-680.
- [10] Michalewicz, Z., 1996, *Genetic Algorithm + Data Structures = Evaluation Programs*, Spinger- Verlag Berlin Heidelberg, New York.
- [11] Obitko, M., 1998, *Genetic Algorithms*, Czech Technical University.
- [12] Oysu, O., dan Bingul, Z., 2009, Application of heuristic and hybrid-GASA algorithm to tool-path optimization problem for minimizing airtime during machining, *Engineering Application of Artificial Intelligence*, 22, 389-396
- [13] Sandikci, B, 2000, *Genetic Algorithms*, Department of Industrial Engineering of Bilkent University, Ankara.
- [14] Shanmugam, G., Ganesan, P., dan Vanathi, Dr. P.T., 2011, *Meta Heuristic Algorithms for Vehicle Routing Problem with Stochastic Demands*, *Journal of Computer Science*, 7(4), 533-542.
- [15] Soke, A., dan Bingul, Z., 2006, Hybrid genetic algorithm and simulated annealing for two-dimensional non-guillotine rectangular packing problems, *Engineering Applications of Artificial Intelligence*, 19, 557-567.
- [16] Taha, Hamdy A, 1996. *Operations Research, an Introduction*, sixth edition, Upper Saddle River, New Jersey, Prentice Hall, Inc.
- [17] Toth, P. dan Vigo, D., 2002, *The Vehicle Routing Problem*, Siam Publisher, Philadelphia
- [18] Yang, W.H., K. Mathur, dan R.H. Ballou, 2000, Stochastic Vehicle Routing Problem with Restocking. *Transport. Sci.*, 34: 99-112
- [19] Yong, P., dan Hai-Ying, Z., 2008, Research on Vehicle Routing Problem with Stochastic Demand and PSO-DP Algorithm with Inver-over Operator, *Syst. Eng. Theory Practice*, 28: 76-81, DOI : 10.1016/j.ejor.2008.02.028
- [20] Yoshikawa M, Hironori Yamauchi and Hidekazu Terai, 2008, *Hybrid Architecture of Genetic Algorithm and Simulated Annealing*, Department of information engineering, Meijo University, 16:3, EL_16_3_11.
- [21] Zomaya, A.Y., 1996, *Parallel and Distributed Computing Handbook*, MacGraw-Hill, New York