

e-ISSN 2774-7832  
Vol. 44, No. 2, 2021

# Indonesian Journal of Mathematics and Natural Sciences



9 772774 783007

**Indonesian Journal of Mathematics and Natural Sciences**

Terbit dua kali setahun bulan April dan Oktober

**DEWAN REDAKSI**

**Penanggung Jawab**

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Negeri Semarang

**Ketua Tim Editor**

R. Susanti

**Tim Editor** Ella

Kusumastuti Siti

Wahyuni

Muhammad Kharis

Mohammad Taufiq

Zaenal Abidin

**Tim Layout** Muhammad

Ghozian Kafi Ahsan Taufan Giri

Ramdani

**Lembaga Penerbit**

Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Negeri Semarang

**Alamat Redaksi/Penerbit**

Gd. D12 Kampus Sekaran Gunungpati Semarang-50229  
Telp. +62248508112/+62248508005 Fax. +62248508005  
Email: [mipa@mail.unnes.ac.id](mailto:mipa@mail.unnes.ac.id)

**Indonesian Journal of Mathematics and Natural Sciences**

Terbit dua kali setahun bulan April dan Oktober

Penyelesaian Resource Constrained Project Scheduling Problem (RCPS) Menggunakan Algoritma Cat Swarm Optimization

Eka Retna Fitriyani, Isnaini Rosyida, Mashuri Mashuri

48-60

Peningkatan Ketepatan Klasifikasi Model Regresi Logistik Biner dengan Metode Bagging (Bootstrap Aggregating)

Dwi Liana Wella Putri, Scolastika Mariani, Sunarmi Sunarmi

61-72

Analisis Perbandingan Akurasi Metode Fuzzy Tsukamoto dan Fuzzy Sugeno Dalam Prediksi Penentuan Harga Mobil Bekas

Reynaldi Reynaldi, Wahyu Syafrizal, M. Faris Al Hakim

73-80

Analisis Citra Hasil Scanning Electron Microscopy Energy Dispersive X-Ray (SEM EDX) Komposit Resin Timbal dengan Metode Contrast to Noise Ratio (CNR)

Alvin Fachrully Septiano, Susilo Susilo, Natalia Erna Setyaningsih

81-85

Uji Toksisitas Ekstrak Daun Cassava Terhadap Larva Artemia salina Leach dengan Metode Brine Shrimp Lethality Test

Rizki Budiyo Putri, WH Nugrahaningsih, Nur Kusuma Dewi

86-91

**Penyelesaian *Resource Constrained Project Scheduling Problem* (RCPSP)  
Menggunakan Algoritma Cat Swarm Optimization**

**Eka Retna Fitriyani\*, Isnaini Rosyida, Mashuri**

Jurusan Matematika, FMIPA, Universitas Negeri Semarang, Indonesia  
Gedung D7 Lt. 1, Kampus Sekaran Gunungpati, Semarang 50229  
E-mail: fitriyaniekaretna@gmail.com

Diterima 2 Februari 2021

Disetujui 1 September 2021

Dipublikasikan 31 Oktober 2021

**Abstrak**

*Resource-Constrained Project Scheduling Problem* (RCPSP) adalah masalah penjadwalan proyek yang harus memenuhi *Precedence Constraint* dan *Resource constraint*. Tujuan penelitian ini adalah mengetahui penerapan penggunaan Algoritma *Cat Swarm Optimization* (CSO) untuk penjadwalan proyek dan simulasi penjadwalan proyek yang optimal pada beberapa kasus RCPSP. Penelitian ini menggunakan CSO dalam menyelesaikan permasalahan dengan bantuan *software* Matlab. Hasil penelitian menunjukkan bahwa penerapan Algoritma CSO yang diawali dengan membuat solusi RCPSP yang valid dan dihitung *maskepan*nya. Bangkitkan sebanyak  $N$  kucing, termasuk kucing dengan solusi valid. Evaluasi kucing sesuai dengan posisi tiap kegiatan. Berdasarkan  $N$  kucing yang diperoleh hitung nilai *maskepan*nya. Selanjutnya, pindahkan kucing sesuai dengan MR dalam *seeking mode* dan *tracing mode*. Evaluasi kembali posisi setiap kucing untuk menyimpan kucing dengan nilai *fitness* terkecil. Akhiri algoritma dengan mengambil solusi yang memiliki *fitness* terkecil. Kasus RCPSP dengan solusi valid yang memiliki nilai *maskepan* yang masih jauh dari nilai *maskepan* terkecil yang bisa diperoleh menghasilkan solusi yang berbeda-beda setiap kali program dijalankan sehingga diperlukan beberapa kali simulasi untuk memastikan solusi yang didapatkan benar-benar memiliki *maskepan* terkecil. Bila solusi valid yang dibuat memiliki *maskepan* yang telah mendekati *maskepan* terkecil yang bisa diperoleh, maka program akan menghasilkan solusi yang sama setiap program dijalankan.

Kata kunci: RCPSP, CSO, penjadwalan proyek.

**Abstract**

*Resource-Constrained Project Scheduling Problem* (RCPSP) was the problem of project scheduling that must satisfy the *Precedence Constraint* and *Resource Constraint*. The objective of this research was to know the application of using *Cat Swarm Optimization* algorithm for optimal project scheduling and simulation of optimal project scheduling in some RCPSP cases. The method by using *Cat Swarm Optimization* (CSO) algorithm was to solve the problem with Matlab software's help. The results show that the application of the CSO Algorithm begins with creating a valid RCPSP solution and calculating the mask. Form as much as  $N$  cat, included the valid solution cat. Evaluate the cat appropriate with the position in every activity. Count the *maskepan* value according to  $N$  cat which gotten. Then, move the cat appropriate with MR in the *seeking mode* and *tracing mode*. Re-evaluate the position of every cat for save the cat with the smallest *fitness* value. Finish the algorithm with take the solution which had the smallest *fitness*. 2) RCPSP case with valid solution had *maskepan* value, that far from the smallest *maskepan* value, gave different solutions in every run program. In this case needed several times of simulation to make sure that the solution gotten was the correct smallest its *maskepan*. If the valid solution had *maskepan* which was closer to the smallest *maskepan*, then the program will produce the same solution in every run program.

Keywords: RCPSP, CSO, project scheduling

**How to cite:**

Fitriyani, E.R., Rosyida, I., & Mashuri. (2020). Penyelesaian Resource Constrained Project Scheduling Problem (RCPSP) Menggunakan Algoritma Cat Swarm Optimization. *Indonesian Journal of Mathematics and Natural Science*, 44(2), 48-60

## PENDAHULUAN

Proyek merupakan kegiatan yang berlangsung dalam jangka waktu yang terbatas dengan mengalokasikan sumber daya tertentu dan dimaksudkan untuk menghasilkan produk atau *deliverable* yang kriteria mutunya telah digariskan dengan jelas (Soeharto, 1999). Sebelum proyek dilaksanakan ada beberapa tahap pengelompokan yang meliputi perencanaan, penjadwalan, dan pengkoordinasian. Dari ketiga tahap tersebut tahap penjadwalan dan perencanaan merupakan tahapan yang menentukan berhasil tidaknya suatu proyek karena penjadwalan adalah tahap ketergantungan antar aktivitas yang membangun proyek secara keseluruhan (Arifudin, 2012). Pemecahan masalah penjadwalan yang baik merupakan salah satu faktor keberhasilan pelaksanaan sebuah proyek tepat pada waktunya yang merupakan tujuan yang penting baik bagi pemilik proyek maupun kontraktor.

Masalah penjadwalan aktivitas-aktivitas pada proyek dengan kendala sumber daya terbatas sering disebut dengan *Resource Constrained Project Scheduling Problem* (RCPSP). Setiap aktivitas memiliki durasi aktivitas dan jumlah kebutuhan sumber daya masing-masing. Penjadwalan proyek dengan ketersediaan sumber daya terbatas adalah penjadwalan proyek yang harus memenuhi urutan pengerjaan kegiatan (*precedence constraint*) dan mempertimbangkan sumber daya yang digunakan pada setiap kegiatan agar tidak melebihi kapasitas sumber daya yang tersedia (*resource constraints*).

Metode analitis algoritma B&B (*Branch and Bound*) pada optimalisasi penjadwalan proyek tidak efisien sehingga berdampak pada keterlambatan penyelesaian proyek pembangunan Mega Tower (Widyawati *et al.*, 2014). Penggunaan metode metaheuristik untuk menyelesaikan RCPSP seperti algoritma *Harmony Search* (Imansyah, 2013), algoritma *Cross Entropy* (Krisnawati, 2014), algoritma Genetika (Chan *et al.*, 1996), dan algoritma *Particle Swarm Optimization* (Zhang *et al.*, 2006). Algoritma *Harmony Search* harus dilakukan dengan tujuh langkah yaitu inialisasi masalah, memasukan data RCPSP, inialisasi parameter algoritma *Harmony Search*, inialisasi *harmony memory*, membangkitkan vektor solusi baru, meng-update *harmony memory*, dan mengecek criteria pemberhentian. Dibandingkan dengan Algoritma CPM, solusi algoritma *Harmony Search* tidak selalu merupakan solusi terbaik, karena pencarian solusi dilakukan secara random, sehingga solusi yang diperoleh sangat beragam dan memerlukan waktu lebih lama yang bergantung pada kriteria pemberhentian yang dipilih. Algoritma *Cross Entropy* melibatkan prosedur iterasi, dimana tiap iterasi dapat dipecahkan menjadi dua fase yaitu pembangkitan sampel random dan pembaharuan parameter. Penggunaan jumlah aktivitas proyek 30-60 memperlihatkan bahwa algoritma *Cross Entropy* mempunyai performansi yang sama dengan penyelesaian menggunakan algoritma *Differential Evolution*. Algoritma Genetika melakukan pencarian solusi yang optimal dari kromosom-kromosom yang merepresentasikan jadwal dimana kromosom-kromosom tersebut diproduksi melalui *cross-over* dan *mutation*. Mekanisme *updating* kromosom membuat algoritma Genetika mampu keluar dari solusi yang bersifat lokal optimal. Oleh karena itu, algoritma Genetika lebih unggul dari pada metode analitis dan metode heuristik. Namun demikian, terdapat kekurangan dalam performansi Algoritma Genetika yaitu proses konvergensi yang lambat. Performansi *Particle Swarm Optimization* menunjukkan kemampuan untuk mencari optimum global dan lebih efisien dari pada Algoritma Genetika karena fiturnya (Zhang *et al.*, 2006).

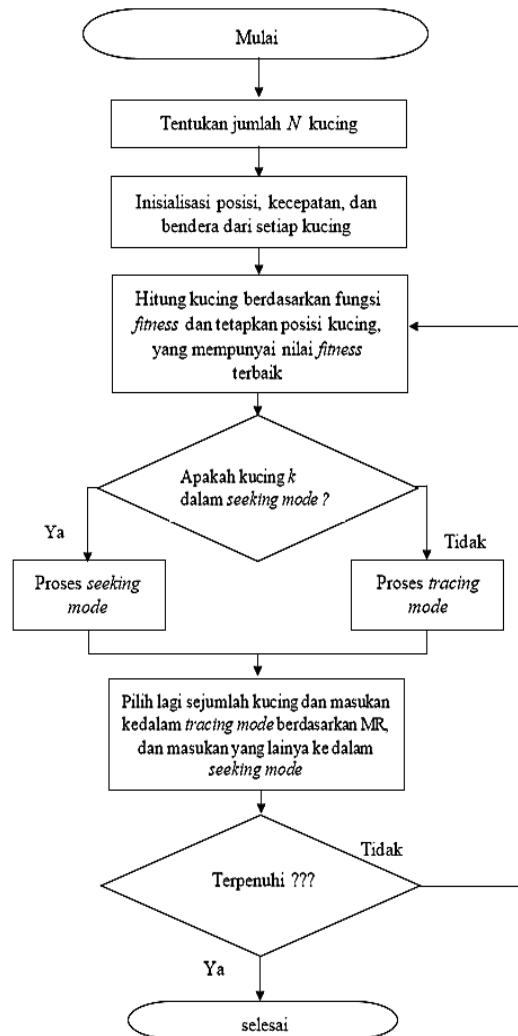
Dari enam tes yang dilakukan oleh Chu dan Tsai (2006), menunjukkan kinerja Algoritma *Cat Swarm Optimization* lebih efektif dibandingkan dengan Algoritma *Particle Swarm Optimization* dan Algoritma *Particle Swarm Optimization with weighting*. Algoritma *Cat Swarm Optimization* (CSO) dapat menghasilkan klasifikasi yang lebih baik dalam hal jumlah iterasi yang dibutuhkan untuk mencapai titik optimal dan memiliki tingkat akurasi yang lebih baik (Dhanasaputra & Santosa, 2010).

CSO merupakan salah satu algoritma metaheuristik untuk masalah optimasi kombinatorial. Algoritma CSO pertama kali diperkenalkan oleh Shu-Chuan Chu dan Pei-Wei Tsai (Taiwan) pada tahun 2006 (Chu & Tsai, 2006). Algoritma CSO terbagi menjadi 2 langkah dalam menyelesaikan masalah optimasi, yaitu *Seeking Mode* (SM) yang menggambarkan kucing saat istirahat, melihat sekeliling, menyusun strategi selanjutnya dan *Tracing Mode* (TM) yang menggambarkan kucing saat mengikuti mangsa buruan. Dua sub model *Seeking Mode* dan *Tracing Mode* dikombinasikan dalam satu algoritma melalui *Mixture Ratio* (MR). Tujuan penelitian ini adalah mengetahui penerapan penggunaan algoritma CSO untuk penjadwalan proyek dan mengetahui susunan penjadwalan yang optimal pada beberapa kasus RCPSP.

## METODE

Penelitian ini menggunakan metode penelitian studi pustaka untuk mempelajari teori-teori yang berhubungan dengan algoritma CSO untuk menyelesaikan masalah yang dikaji. *Software* yang digunakan adalah Matlab. Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Merkel *et al.* (2002) dan Zhang *et al.* (2006). Data 1 terdiri dari 6 kegiatan dengan kapasitas sumber daya 4 unit, data 2 terdiri dari 7 kegiatan dengan kapasitas sumber daya 5 unit, dan data 3 terdiri dari 25 kegiatan 3 jenis sumber daya dengan kapasitas sumber daya 6 unit.

Langkah-langkah Algoritma CSO diberikan pada Gambar 1.



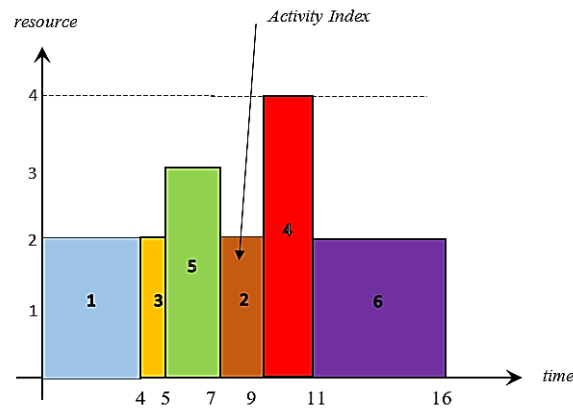
Gambar 1. Flowchart Algoritma

## HASIL DAN PEMBAHASAN

Pembuatan solusi RCPSP yang valid merupakan langkah awal sebelum menerapkan Algoritma CSO pada masalah RCPSP. Solusi RCPSP dikatakan valid apabila jadwal yang dihasilkan memenuhi *precedence constraint* dan *resource constraint* yang telah ditetapkan. Setiap solusi RCPSP yang valid memiliki waktu penyelesaian proyek (*maskepan*). Solusi RCPSP awal yang valid diterapkan pada Algoritma CSO sebagai salah satu kucing, tujuannya untuk mendapatkan solusi yang lebih optimal dengan *maskepan* minimum. Solusi valid pada kasus RCPSP ini diperoleh solusi valid yang paling sederhana dengan mengurutkan kegiatan yang ada pada gambar visualisasi kasus tersebut. Terdapat beberapa kemungkinan solusi valid pada data ke-1, yaitu 1 – 3 – 5 – 2 – 4 – 6, 1 – 2 – 3 – 4 – 5 – 6, 1 – 3 – 2 – 4 – 5 – 6, dan 2 – 4 – 6 – 1 – 3 – 5. Perhitungan manual menggunakan solusi valid 1 – 3 – 5 – 2 – 4 – 6, solusi valid yang lain dicoba pada program simulasi. *Maskepan* dari solusi valid data ke-1 adalah 16 satuan waktu seperti pada Gambar 2.

Tahap penting dari algoritma CSO yaitu menentukan berapa banyak kucing yang digunakan dalam menyelesaikan masalah. Setiap kucing tersebut mewakili himpunan solusi acak awal, yaitu urutan acak dari kegiatan  $J_1$  sampai dengan kegiatan  $J_{n+1}$ . Solusi acak awal adalah solusi yang dibuat secara sembarang tanpa mempertimbangkan batasan yang telah ditetapkan, sehingga kucing yang dibuat dapat berupa solusi yang valid maupun yang tidak valid (Apriana *et al.*, 2016).

Banyaknya kucing yang digunakan dalam data ke-1 adalah 5 tanpa iterasi dalam perhitungan manual. Dimensi merupakan penggambaran dari setiap kegiatan. Kucing data ke-1 memiliki susunan posisi 6 dimensi. Inisialisasi posisi dari setiap kucing dilakukan secara random. Sedangkan kecepatan kucing pada inisialisasi awal = 0 untuk setiap dimensi. Inisialisasi ruang kucing juga dilakukan secara random, sehingga kucing bebas akan masuk ke *seeking mode* atau *tracing mode*. Hanya jumlah kucing yang ditentukan dalam memasuki tiap *mode*.



Gambar 2. Visualisasi Bentuk Jadwal Solusi Valid Data ke-1

Setiap kucing akan dievaluasi berdasarkan posisi tiap kegiatan, dimana setiap posisi harus memenuhi urutan pengerjaan kegiatan dan mempertimbangkan sumber daya yang digunakan agar tidak melebihi kapasitas sumber daya yang tersedia. Kucing yang memenuhi setiap batasan dapat dihitung nilai *fitness*-nya dan begitu sebaliknya. Evaluasi kucing berguna untuk mempercepat perhitungan nilai *fitness*. Jika ada kucing yang melanggar 1 batasan saja maka kucing tidak dapat dihitung nilai *fitness*-nya

Lebih jelas penerapan algoritma CSO dalam *Resource Constrained Project Scheduling Problem*, berikut perhitungan manual dengan data kasus yang kecil, karena apabila menggunakan data yang cukup besar perhitungannya akan rumit dan sangat panjang. Pada penerapan ini data yang digunakan adalah data ke-1 dan data ke-2.

Langkah 1 : Membuat solusi RCPSP awal yang valid. Langkah ini dalam perhitungan manual dapat dihilangkan karena umumnya dapat diketahui secara langsung apabila solusi yang dibuat valid atau tidak. Berbeda bila program yang menjalankan karena inisialisasi posisinya random kemungkinan program dapat membangkitkan semua kucing dengan solusi yang tidak valid. Solusi validnya diperoleh 1 – 3 – 5 – 2 – 4 – 6.

Langkah 2 : Menghitung nilai *fitness* dari solusi valid. Diperoleh nilai *fitness*-nya adalah 16 satuan waktu.

Langkah 3 : Membangkitkan sejumlah N kucing dalam proses. Setiap kucing mewakili himpunan solusi acak awal, yaitu urutan acak dari aktivitas  $J_1$  sampai dengan aktivitas  $J_{n+1}$ . Pada kasus ini akan dibangkitkan 5 kucing termasuk kucing dengan solusi valid. Diperoleh kucing sebagai berikut:

- i. Kucing ke-1: 1 – 3 – 5 – 2 – 4 – 6
- ii. Kucing ke-2: 1 – 3 – 2 – 5 – 4 – 6
- iii. Kucing ke-3: 2 – 4 – 1 – 3 – 5 – 6
- iv. Kucing ke-4: 1 – 2 – 4 – 3 – 5 – 6
- v. Kucing ke-5: 1 – 3 – 4 – 2 – 5 – 6

Langkah 4 : Inisialisasi posisi, kecepatan, dan ruang kucing. Kecepatan awal = 0.



Langkah 5 : Evaluasi semua kucing sesuai dengan posisi setiap kegiatan. Kucing ke-1,2,3, dan 4 memenuhi *precedence constraint* sedangkan kucing k-5 tidak memenuhi artinya kucing ke-5 merupakan solusi yang tidak valid.

Langkah 6 : Hitung semua nilai *fitness* dari N kucing, dan didapat satu kucing dengan nilai *fitness* terbaik.

- i. Kucing ke-1 : 1 – 3 – 5 – 2 – 4 – 6 nilai *fitness* kucing adalah 16  
Menghitung nilai *fitness* dapat dengan mudah diperoleh menggunakan Gambar 1.
- ii. Kucing ke-2 : 1 – 3 – 2 – 5 – 4 – 6 nilai *fitness* kucing adalah 15
- iii. Kucing ke-3: 2 – 4 – 1 – 3 – 5 – 6 nilai *fitness* kucing adalah 16
- iv. Kucing ke-4 : 1 – 2 – 4 – 3 – 5 – 6 nilai *fitness* kucing adalah 14
- v. Kucing ke-5: (1 – 3 – 4 – 2 – 5 – 6) jika kegiatan 4 mendahului kegiatan 2 maka kegiatan 4 tidak dapat terlaksana karena kegiatan 2 belum dikerjakan sehingga tidak dapat dihitung nilai *fitness*nya.

Langkah 7 : Pindahkan kucing sesuai MR (*mixture ratio*). Jika kucing berada dalam *seeking mode* perlakukan kucing sesuai *seeking mode*, dan begitu juga sebaliknya. Nilai MR dan parameter lain seperti SRD, CDC, C diambil dari kombinasi penelitian Apriana et al. (2016) dan Chu & Tsai (2006) sedangkan nilai parameter SMP diambil 2 agar perhitungannya lebih cepat dan dapat melakukan proses *seeking* dengan baik. Pengambilan parameter tanpa melakukan pengujian parameter terlebih dahulu seperti pada Tabel 1.

Tabel 1. Kombinasi Parameter yang Digunakan untuk Perhitungan Manual

Nama Parameter	Nilai
MR	0.5
SMP	2
SRD	0.2/20%
CDC	0.6/60%
C1	2
R	[0,1] random 0 – 1
W	[0.4,0.9] random 0.4 – 0.9

$$\begin{aligned}
 JT &= MR \times JK \\
 &= 0.5 \times 5 = 2.5 \text{ dibulatkan ke bawah menjadi 2 karena jumlah } \textit{tracing} \text{ harus lebih kecil dari pada} \\
 &\text{jumlah } \textit{seeking} \\
 JS &= JK - JT \\
 &= 5 - 2 = 3
 \end{aligned}$$

Langkah 8 : Pilih sejumlah kucing dan masukan kedalam *tracing mode* sesuai MR dan sisanya masukan ke dalam *seeking mode*.

8.1. Misalkan kucing ke-2 dan 3 masuk ke *tracing mode*

8.1.1. Proses *tracing* kucing ke-2 (1 – 3 – 2 – 5 – 4 – 6)

8.1.1.1. Langkah *tracing* 1: Perbarui nilai kecepatan untuk setiap dimensi ( $V_{k,d}$ ) berdasarkan persamaan  $V'_{k,d} = w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d})$  dimana  $C_1 = 2$ ,  $r_1 = [0,1]$  random dari  $0 - 1$ ,  $w = [0.4,0.9]$  random dari  $0.4 - 0.9$ , dan kucing terbaik adalah kucing ke-4 yaitu 1 – 2 – 4 – 3 – 5 – 6 karena memiliki nilai *fitness* terkecil, diperoleh kecepatan terbaru sebagai berikut :

Kecepatan dimensi ke-1

$$\begin{aligned}
 V'_{k,d} &= w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d}) \\
 V'_{3,1} &= 0.4 \times 0 + 0.8 \times 2 (1 - 1) \\
 &= 0 + 0.8 \times 2 (0) = 0
 \end{aligned}$$

Kecepatan dimensi ke-2

$$\begin{aligned}
 V'_{k,d} &= w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d}) \\
 V'_{3,2} &= 0.5 \times 0 + 0.5 \times 2 (2 - 3) \\
 &= 0 + 0.5 \times 2 (-1) = -1
 \end{aligned}$$

Kecepatan dimensi ke-3

$$V'_{k,d} = w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d})$$

$$V'_{3,3} = 0.6 \times 0 + 0.23 \times 2 (4 - 2)$$

$$= 0,92 \text{ dibulatkan menjadi } 1$$

Kecepatan dimensi ke-4

$$V'_{k,d} = w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d})$$

$$V'_{3,4} = 0.7 \times 0 + 0.25 \times 2 (3 - 5)$$

$$= 0 + 0.25 \times 2 (-2) = -1$$

Kecepatan dimensi ke-5

$$V'_{k,d} = w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d})$$

$$V'_{3,5} = 0.8 \times 0 + 37 \times 2 (5 - 4)$$

$$= 0.74 \text{ dibulatkan menjadi } 1$$

Kecepatan dimensi ke-6

$$V'_{k,d} = w \times V_{k,d} + r_1 \times C_1(X_{best,d} - X_{k,d})$$

$$V'_{3,6} = 0.9 \times 0 + 0.77 \times 2 (6 - 6)$$

$$= 0 + 0.77 \times 2 (0) = 0$$

8.1.1.2. Langkah *tracing* 2: Periksa apakah kecepatan berada dalam rentang kecepatan maksimum. Jika kecepatan yang baru melebihi rentang, tetapkan nilai sama dengan batas. Tidak ada kecepatan baru yang melebihi rentang kecepatan.

8.1.1.3. Langkah *tracing* 3: Perbarui posisi kucing ke- $k$  dengan persamaan  $X'_{k,d} = X_{k,d} + V'_{k,d}$ .

Perbaharuan posisi :

$$\text{Dimensi ke-1 } X'_{3,1} = 1 + 0 = 1$$

$$\text{Dimensi ke-2 } X'_{3,2} = 3 - 1 = 2$$

$$\text{Dimensi ke-3 } X'_{3,3} = 2 + 1 = 3$$

$$\text{Dimensi ke-4 } X'_{3,4} = 5 - 1 = 4$$

$$\text{Dimensi ke-5 } X'_{3,5} = 4 + 1 = 5$$

$$\text{Dimensi ke-6 } X'_{3,6} = 6 + 0 = 6$$

Diperoleh posisi kucing terbaru 1 - 2 - 3 - 4 - 5 - 6 dengan nilai *fitness* 14.

8.1.2. Proses *tracing* kucing ke-3 (2 - 4 - 1 - 3 - 5 - 6)

Dengan proses yang sama pada proses *tracing* kucing ke -2 diperoleh posisi kucing baru yaitu 1 - 3 - 2 - 3 - 5 - 6, karena kegiatan 3 berlangsung 2 kali maka nilai *fitness* tidak dapat dihitung.

8.2. Misalkan kucing ke 1,4 dan ke-5 masuk *keseeking mode*.

8.2.1. Proses *seeking* kucing ke-1 (1 - 3 - 5 - 2 - 4 - 6)

8.2.1.1. Langkah *seeking* 1: Bangkitkan  $j$  tiruan dari posisi kucing ke- $k$ , dengan  $j = SMP$ . Jika nilai SPC benar, maka  $j = (SMP - 1)$ , kemudian pertahankan posisi saat ini sebagai salah satu kandidat.

Pada kucing ke-1 membangkitkan kucing tiruan sebanyak 2 ( $SMP = 2$ ) dan SPC bernilai benar maka  $j = 2 - 1 = 1$ .

8.2.1.2. Langkah *seeking* 2 : Untuk setiap tiruan, disesuaikan dengan CDC, tambahkan atau kurangkan SRD persen dari nilai saat ini secara acak dan gantikan nilai yang sebelumnya.

$$\text{Jumlah modifikasi} = 0.6 \times 6$$

$$= 3.6 (4 \text{ dimensi})$$

Yang akan dimodifikasi dimensi ke-1, 3, 4 dan dimensi ke-5. Posisi kucing menjadi 2 - 3 - 4 - 3 - 5 - 6 .

8.2.1.3. Langkah *seeking* 3 : Hitung nilai *fitness* (FS) untuk semua titik kandidat. *Fitness* merupakan nilai *maskepan* dari setiap kucing.

Nilai *fitness* kucing tiruan tidak dapat dihitung karena kegiatan 3 terlaksana dua kali sedangkan kegiatan 1 tidak terlaksana. Sehingga kucing yang dipilih kucing ke-1.

8.2.2. Proses *seeking* kucing ke-4 (1 - 2 - 4 - 3 - 5 - 6)

Dengan proses yang sama pada proses *seeking* kucing ke-1 diperoleh posisi kucing tiruan menjadi 2 - 1 - 4 - 3 - 6 - 5 . Nilai *fitness* kucing tiruannya 13 satuan waktu.

Peluang terpilihnya kucing ke-1

$$P_h = \frac{|F S_h - F S_b|}{F S_{max} - F S_{min}} = \frac{|14 - 14|}{14 - 13} = \frac{0}{1}$$

Peluang terpilihnya kucing tiruan

$$P_h = \frac{|F S_h - F S_b|}{F S_{max} - F S_{min}} = \frac{|13 - 14|}{14 - 13} = 1$$

Pilih kucing dengan nilai peluang = 1, terpilih kucing tiruan dari kucing ke-1 dengan nilai *fitness* 13 satuan waktu.

8.2.3. Proses *seeking* kucing ke-5 (1 – 3 – 4 – 2 – 5 – 6)

Dengan proses yang sama pada proses *seeking* kucing ke-1 diperoleh posisi kucing tiruan ke-1 menjadi 1 – 2 – 4 – 3 – 6 – 5 dan posisi kucing tiruan ke-2 menjadi 2 – 3 – 5 – 1 – 4 – 6. Nilai *fitness* kucing tiruan ke-1 dari kucing ke 5 adalah 13, sedangkan nilai *fitness* kucing tiruan ke-2 tidak dapat dihitung karena kegiatan 3 dan 5 mendahului kegiatan 1 sehingga kegiatan 3 dan 5 tidak dapat terlaksana. Dipilih kucing tiruan ke-1 dari kucing ke-5 karena kucing ke-5 dan kucing tiruan ke-2 tidak ada nilai *fitnessnya*.

Langkah 9 : Evaluasi kembali posisi kegiatan dari semua kucing. Dilihat apakah semua kucing dan kucing tiruannya sesuai dengan *precedence* dan *resource constraint*. Evaluasi ini berguna untuk menyimpan kucing dan kucing tiruan yang dapat dihitung nilai *fitnessnya*.

Langkah 10: Perhatikan kondisi akhir algoritma. Jika memuaskan (*fitness* bernilai kecil), maka hentikan program. Apabila belum ulangi langkah 6 sampai langkah 9. Pada perhitungan manual tidak dicoba dengan melakukan iterasi untuk nilai random [0,1] lainnya karena akan sangat rumit.

Langkah 11: Akhir pada algoritma yang digunakan berupa *fitness* terkecil, kucing yang terpilih sebagai solusi terbaik adalah kucing yang dapat memenuhi semua batasan yang ada dengan *fitness* terkecil. Terpilih kucing dari proses *seeking* kucing tiruan dari kucing ke-4 (2 – 1 – 4 – 3 – 6 – 5) dan kucing tiruan ke-1 dari kucing 5 dengan nilai *fitness* yang sama yaitu 13 satuan waktu.

Penerapan Algoritma Cat Swarm Optimization pada data ke-2 menghasilkan *maskepan* terkecilnya adalah 15 satuan waktu yang sama dengan solusi valid yang dibuat. Perhitungan manual data ke-2 dilakukan dengan kombinasi parameter yang sama pada perhitungan manual data ke-1. Solusinya adalah 2 – 1 – 3 – 5 – 4 – 6 – 7 pada kucing dari proses *tracing* kucing ke-4 dan 5, kucing ke-1, dan kucing tiruan dari kucing ke-1.

**Simulasi Penjadwalan Proyek yang Optimal Pada Beberapa Kasus RCPSP Menggunakan Software Matlab**

Solusi valid dari data ke-2 yaitu 1 – 2 – 3 – 4 – 5 – 6 – 7, sedangkan data ke-3 yang dipisahkan menjadi tiga jenis data sama yaitu 1 – 2 – 3 – 4 – 5 – 6 – 7 – 8 – 9 – 10 – 11 – 12 – 13 – 14 – 15 – 16 – 17 – 18 – 19 – 20 – 21 – 22 – 23 – 24 – 25. *Maskepan* dari data ke-2 adalah 15 satuan waktu. *Maskepan* dari data 3.1 adalah 63 satuan waktu, *maskepan* dari data 3.2 adalah 63 satuan waktu, dan *maskepan* dari data 3.3 adalah 52 satuan waktu.

Pada data ke-1, 2 dan ke-3 simulasi program digunakan 30 dan 50 kucing dengan masing-masing kucing beriterasi sebanyak 10 dan 20. Tujuan untuk mengetahui apakah ada perubahan jumlah kucing dan iterasi dapat mempengaruhi hasil dari Algoritma Cat Swarm Optimization dalam menyelesaikan kasus RCPSP.

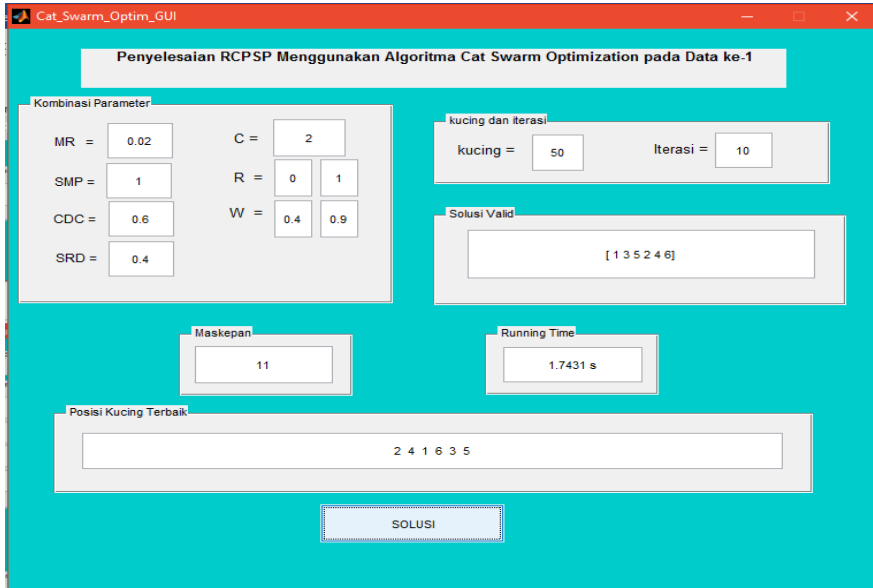
Data ke-2 memiliki susunan posisi 7 dimensi sedangkan data ke-3 memiliki susunan posisi 25 dimensi yang berisikan kegiatan dari kegiatan awal sampai akhir. Kecepatan kucing pada inisialisasi awal = 0 untuk setiap dimensi. Setiap kucing yang dibangkitkan dihitung nilai *fitnessnya*. Perhitungan nilai *fitness* ini bertujuan untuk mengetahui kucing terbaik dari semua kucing yang dibangkitkan. Kucing terbaik akan digunakan pada perhitungan *tracing mode*.

Parameter terbaik dengan rata-rata *maskepan* yang terkecil yaitu 12.6 kombinasi parameter yang tepat diperoleh pada Tabel 2.

Tabel 2 Hasil Kombinasi Parameter Terbaik untuk Simulasi


Nama Parameter	Nilai
MR	0.02
SMP	1
SRD	40%/0.4
CDC	60%/0.6
C1	2
R	[0,1] random 0 – 1
W	[0.4,0.9] random 0.4 – 0.9

Hasil simulasi algoritma CSO pada permasalahan RCPSP dari data ke-1 dengan solusi valid 1 – 3 – 5 – 2 – 4 – 6 menggunakan kombinasi parameter yang tepat dan 2 kali simulasi ternyata dapat diperoleh nilai *maskepan* yang lebih kecil yaitu 11 satuan waktu dengan *running time* 1.7431 s pada simulasi 1 seperti Gambar 3 dengan rangkuman menyeluruh pada Tabel 3 dan 4, sehingga dapat disimpulkan bahwa program yang dibuat valid dan dapat diimplementasikan ke kasus RCPSP yang lebih besar.



Gambar 3. Hasil Simulasi Data 1 pada Program

Set solusi dengan *maskepan* terbaik dari program disajikan pada Gambar 4. Hasil simulasi 1 pada data ke-1 pada Tabel 3 dan hasil simulasi 2 pada data ke-1 pada Tabel 4.



Gambar 4. Visualisasi Bentuk Jadwal Hasil Simulasi Data 1

Tabel 3. Hasil Simulasi 1 Algoritma CSO pada Data ke-1

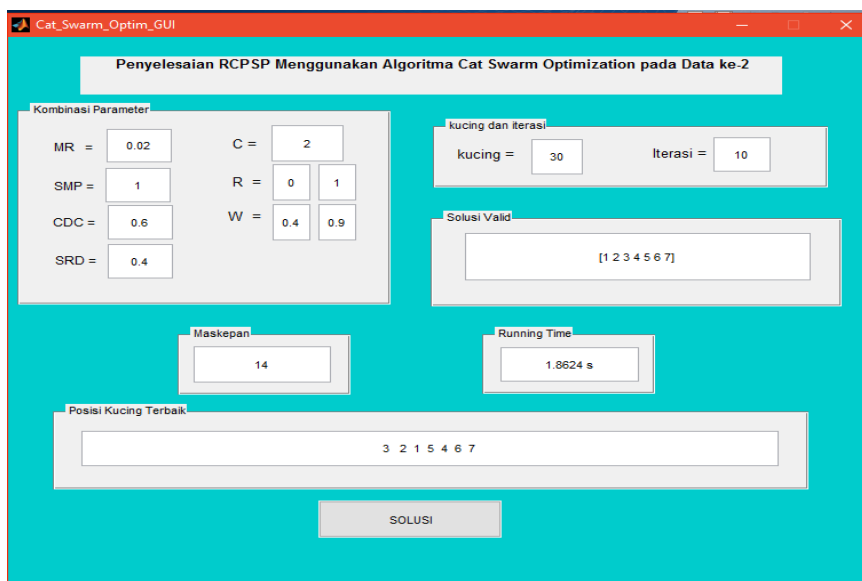
Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	16	1.0548 s	1-3-5-2-4-6
	20	14	2.0041 s	1-2-3-4-5-6
N kucing =50	10	11	1.7431 s	2-4-1-6-3-5
	20	12	2.8931 s	2-4-1-6-3-5

Tabel 4 . Hasil Simulasi 2 Algoritma CSO pada Data ke-1

Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	15	1.1071 s	1-3-2-4-6-5
	20	14	1.9937 s	1-2-3-4-5-6
N kucing =50	10	14	1.5527 s	1-2-3-4-5-6
	20	11	3.0872 s	2-4-6-1-3-5

Simulasi program dengan solusi valid yang lain menghasilkan hasil yang sama yaitu 2 – 4 – 1 – 6 – 3 – 5 dengan *maskepan* 11 satuan waktu. Penggunaan solusi valid yang berbeda hanya berpengaruh pada banyak sedikitnya simulasi yang menghasilkan *maskepan* terkecil.

Dari data ke-2 apabila dilakukan perhitungan menggunakan program dengan kombinasi parameter yang tepat dan 2 kali simulasi ternyata dapat diperoleh nilai *maskepan* yang lebih kecil yaitu 14 satuan waktu dengan *running time* 1.8624 s pada simulasi 2 seperti pada Gambar 5 dengan rangkuman menyeluruh pada Tabel 5 dan Tabel 6.



Gambar 5 Hasil. Simulasi Data 2 pada Program

Simulasi dilakukan 2 kali dengan banyaknya kucing 30, dan 50 dengan masing-masing beriterasi sebanyak 10 dan 20.

Tabel 5. Hasil Simulasi 1 Algoritma CSO pada Data ke-2


Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	14	1.8935 s	2-1-5-4-3-6-7
	20	14	3.6837 s	3-2-1-5-4-6-7
N kucing =50	10	14	2.9383 s	2-1-5-3-4-6-7
	20	14	4.8995 s	2-1-5-3-4-6-7

Tabel 6. Hasil Simulasi 2 Algoritma CSO pada Data ke-2

Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	14	1.8624 s	3-2-1-5-4-6-7
	20	14	3.4141 s	2-1-5-4-3-6-7
N kucing =50	10	14	2.4777 s	2-1-5-4-3-6-7
	20	14	5.4535 s	2-1-5-4-3-6-7

Dari Tabel 5 dan Tabel 6 terlihat bahwa simulasi dengan jumlah kucing dan jumlah iterasi yang berbeda menghasilkan *maskepan* yang sama, sedangkan dari *running time* terlihat bahwa semakin bertambah jumlah kucing dan jumlah iterasi yang digunakan semakin lama *running time* yang

diperlukan. Pemilihan dilakukan dengan memilih *running time* terkecil yaitu pada pembangkitan 30 kucing dengan iterasi 10 disimulasi 2 karena *maskepan* yang dihasilkan sama kecilnya. *Maskepan* dari hasil simulasi adalah 14 satuan waktu dengan solusi penjadwalan 3 – 2 – 1 – 5 – 4 – 6 – 7. Set solusi dengan *maskepan* terbaik dari program disajikan pada Gambar 6.




Gambar 6. Visualisasi Bentuk Jadwal Hasil Simulasi Data Ke-2.

Kombinasi parameter yang tepat juga diterapkan pada algoritma CSO data ke-3. Simulasi dilakukan hanya sekali dengan banyaknya kucing 30, dan 50 dengan masing-masing kucing beriterasi sebanyak 10 dan 20. Hasil simulasi dari tiap data dari data 3 dapat dilihat pada Tabel 7, Tabel 8, dan Tabel 9.

Tabel 7 Hasil Simulasi Algoritma CSO pada Data ke-3.1

Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	60	61.3712 s	1-2-3-4-5-6-7-9-8-10-11-12-14-13-15-16-17-18-19-22-21-23-24-25
	20	60	108.1825 s	1-2-3-4-5-6-7-9-8-10-11-12-14-13-15-16-17-18-19-22-21-23-24-25
N kucing =50	10	60	97.6568 s	1-2-3-4-5-6-7-9-8-10-11-12-14-13-15-16-17-18-19-22-21-23-24-25
	20	60	171.7426 s	1-2-3-4-5-6-7-9-8-10-11-12-14-13-15-16-17-18-19-22-21-23-24-25

Dari Tabel 7 terlihat bahwa simulasi dengan jumlah kucing dan jumlah iterasi yang berbeda menghasilkan *maskepan* yang sama, sedangkan dari *running time* terlihat bahwa semakin bertambah jumlah kucing dan jumlah iterasi yang digunakan semakin lama *running time* yang diperlukan. Pemilihan dilakukan dengan memilih *running time* terkecil yaitu pada pembangkitan 30 kucing dengan iterasi 10 karena *maskepan* yang dihasilkan sama kecilnya. *Maskepan* dari hasil simulasi adalah 60 satuan waktu dengan solusi penjadwalan 1 – 2 – 3 – 4 – 5 – 6 – 7 – 9 – 8 – 10 – 11 – 12 – 14 – 13 – 15 – 16 – 17 – 18 – 19 – 22 – 21 – 23 – 24 – 25 , seperti diperlihatkan pada visualisasi RCPSP di Gambar 6.




Gambar 6. Visualisasi Bentuk Jadwal Hasil Simulasi Data Ke-3.1.

Tabel 8. Hasil Simulasi Algoritma CSO pada Data ke-3.2

Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	56	82.4107 s	1-2-3-4-5-6-7-11-8-10-9-12-13-16-14-20-15-17-19-18-21-22-23-24
	20	56	163.1321 s	1-2-3-4-5-6-7-11-8-10-9-12-13-16-14-20-15-17-19-18-21-22-23-24
N kucing =50	10	56	119.2665 s	1-2-3-4-5-6-7-11-8-10-9-12-13-16-14-20-15-17-19-18-21-22-23-24
	20	56	221.3662 s	1-2-3-4-5-6-7-11-8-10-9-12-13-16-14-20-15-17-19-18-21-22-23-24

Dari Tabel 8 terlihat *maskepan* hasil simulasi adalah 56 satuan waktu dengan solusi penjadwalan 1 – 2 – 3 – 4 – 5 – 6 – 7 – 11 – 8 – 10 – 9 – 12 – 13 – 16 – 14 – 20 – 15 – 17 – 19 – 18 – 21 – 22 – 23 – 24, seperti diperlihatkan pada visualisasi RCPSP di Gambar 7.




Gambar 7. Visualisasi RCPSP Hasil Simulasi Data Ke-3.2

Tabel 9. Hasil Simulasi Algoritma CSO pada Data ke-3.3

Jumlah Kucing	Iterasi	Maskepan	Running Time	Posisi kucing
N kucing = 30	10	52	31.2025 s	1-2-3-4-5-6-7-8-9-10-11-12-13-14-15-16-17-18-19-20-21-22-23-24-25
	20	52	67.4615 s	1-2-3-4-5-6-7-8-9-10-11-12-13-14-15-16-17-18-19-20-21-22-23-24-25
N kucing =50	10	52	69.6197 s	1-2-3-4-5-6-7-8-9-10-11-12-13-14-15-16-17-18-19-20-21-22-23-24-25
	20	52	133.4227 s	1-2-3-4-5-6-7-8-9-10-11-12-13-14-15-16-17-18-19-20-21-22-23-24-25

Dari Tabel 9 terlihat *maskepan* dari hasil simulasi adalah 52 satuan waktu dengan solusi penjadwalan 1 – 2 – 3 – 4 – 5 – 6 – 7 – 9 – 8 – 10 – 11 – 12 – 14 – 13 – 15 – 16 – 17 – 18 – 19 – 20 – 22 – 22 – 23 – 24 – 25, seperti diperlihatkan pada visualisasi RCPSP di Gambar 8. Solusi penjadwalan yang dihasilkan sama dengan solusi valid yang dibangun, artinya solusi valid yang dibuat sudah merupakan solusi yang optimal.



Gambar 8. Visualisasi RCPSP Hasil Simulasi Data Ke-3.3

Pada data ke-1 setiap dijalankan simulasi dengan menggunakan *software* Matlab diperoleh hasil yang berbeda-beda sedangkan pada data ke-2 dan ke-3 menghasilkan *maskepan* yang sama hanya *running timenya* yang berbeda. Hal tersebut terjadi karena pada data ke-1 memiliki solusi valid yang *maskepannya* masih jauh dari *maskepan* terkecil yang bisa didapatkan, sedangkan data ke-2 dan ke-3 *maskepan* solusi valid yang dibuat ternyata sudah mendekati *maskepan* terkecil yang bisa didapatkan. Bentuk visualisasi RCPSP juga berpengaruh akan hasil yang akan didapatkan. Banyak sedikitnya batasan *precedence constraint* dapat mempengaruhi solusi valid yang bisa dibuat. Apabila solusi valid yang bisa dibuat banyak maka solusi yang dihasilkan dapat bermacam-macam, begitupun sebaliknya. Pada data ke-1 memiliki bentuk *serial stucture* sehingga kendala *precedence constraintnya* sedikit sehingga hasil yang diperoleh bisa bermacam-macam. Pada data ke-2 memiliki bentuk visualisasi semi *serial structure* namun karena *maskepan* solusi valid yang dibuat sudah mendekati *maskepan* terkecil yang bisa diperoleh maka hasil tiap simulasinya sama. Pada data ke-3 bentuk visualisasinya *general structure* sehingga hasil yang diperoleh semuanya sama.

## SIMPULAN

Penerapan Algoritma Cat Swarm Optimization diawali dengan membuat solusi RCPSP yang valid dan dihitung *maskepannya*. Bangkitkan sebanyak N kucing, termasuk kucing dengan solusi valid. Evaluasi kucing sesuai dengan posisi tiap kegiatan untuk mempercepat perhitungan nilai *fitness*. Berdasarkan N kucing yang diperoleh hitung nilai *maskepannya*. Selanjutnya, pindahkan kucing sesuai dengan MR dalam *seeking mode* dan *tracing mode*. Evaluasi kembali posisi setiap kucing untuk



menyimpan kucing dengan nilai *fitness* terkecil. Akhiri algoritma dengan mengambil solusi yang memiliki *fitness* terkecil. Algoritma Cat Swarm Optimization dengan bantuan *software* Matlab telah diterapkan pada 2 kasus RCPSP, yaitu RCPSP dengan solusi valid yang dibuat memiliki nilai *maskepan* yang masih jauh dari nilai *maskepan* terkecil yang bisa diperoleh dan RCPSP dengan solusi valid yang dibuat telah mendekati *maskepan* terkecil yang bisa diperoleh. Pada kasus RCPSP dengan solusi valid yang memiliki nilai *maskepan* yang masih jauh dari nilai *maskepan* terkecil yang bisa diperoleh menghasilkan solusi yang berbeda-beda setiap kali program dijalankan sehingga diperlukan beberapa kali simulasi untuk memastikan solusi yang didapatkan benar-benar memiliki *maskepan* terkecil. Bila solusi valid yang dibuat memiliki *maskepan* yang telah mendekati *maskepan* terkecil yang bisa diperoleh program akan menghasilkan solusi yang sama setiap program dijalankan. Perlu menerapkan Algoritma Cat Swarm Optimization pada permasalahan lain yang akan diselesaikan adalah *Multi-Mode Resource Constrained Project Scheduling Problem* (MMRCPSP) karena permasalahan MMRCPSP lebih mendekati kondisi dunia nyata dari pada *Single-Mode Resource Constrained Project Scheduling Problem* (SMRCPSP). Dalam penelitian ini simulasi program dengan data masih dilakukan secara manual dimana data dimasukkan dalam *coding*. Penelitian selanjutnya perlu ada pengembangan program yang lebih praktis dalam penginputan data secara langsung melalui *Excel*, *notepad*, dll. Dalam menyelesaikan kasus *Resource Constrained Project Scheduling Problem* (RCPSP) dapat menerapkan algoritma CSO yang lain, misalnya *Binary Cat Swarm Optimization*, *Average-Inertia Weighted Cat Swarm Optimization*, dan lainnya.

## DAFTAR PUSTAKA

- Arifudin, R. (2012). Optimasi penjadwalan proyek dengan penyeimbangan biaya menggunakan kombinasi CPM dan algoritma genetika. *Jurnal Masyarakat Informatika*, 2(4), 1-14.
- Apriana, I.W.R., Tastrawati, N. K. T., & Sari, K. (2016). Implementasi algoritma cat swarm optimization dalam menyelesaikan job shop scheduling problem (JJSP). *E-jurnal Matematika*, 5(3), 90-97.
- Chan, W. T., Chua, D. K., & Kannan, G. (1996). Construction resource scheduling with genetic algorithms. *Journal Construction Engineering and Management*, 122(2), 125-132.
- Chu, S.C. & Tsai, P.W. (2006). Cat swarm optimization. *Proceedings of the 9th Pasific Rim International Conference on Artificial Intelligence LNAI 4099*, 854-858.
- Dhanasaputra, N., Santosa, B., & Industri, J. T. (2010). Pengembangan algoritma cat swarm optimization (CSO) untuk klasifikasi. *Jurnal ITS*. 3.
- Dhanasaputra, N. & Santosa B. (2010). Pengembangan algoritma cat swarm optimization (CSO) untuk klasifikasinya. *Jurnal ITS*. 3.
- Putra, R.I., & Putranto. (2013). Penerapan algoritma harmony search pada resource-constrained project scheduling problem (RCPSP). *Jurnal Online Universitas Negeri Malang*. Diakses tanggal 20 Mei 2017.
- Krisnawati, M. (2014). Penyelesaian permasalahan penjadwalan aktivitas proyek dengan batasan sumber daya menggunakan metode cross entropy. *Dinamika Rekayasa*, 10(1), 1-5.
- Merkel, D., Minddendorf, M., & Schmeck, H. (2002). Ant colony optimization for resource-constrained project scheduling. *IEEE Transactions on Evolutionary Computation*, 6(4), 333-346.
- Soeharto, I. (1999). *Manajemen Proyek (dari Konseptual sampai Operasional)*, Jilid I, Edisi 2. Jakarta: Erlangga.
- Widyawati, K., Mashuri, & Arifudin, R. (2014). Analisis algoritma branchand bound untuk menyelesaikan masalah penjadwalan proyek pembangunan mega tower. *UNNES Journal of Mathematics*, 3(1), 2460-5859.
- Zhang, H., Li, H., & Tam, C.M. (2006). Particle swarm optimization for resource-constrained project scheduling. *International Journal of Project Management*, 24(1), 83- 92.

## **Peningkatan Ketepatan Klasifikasi Model Regresi Logistik Biner dengan Metode Bagging (Bootstrap Aggregating)**

**Dwi Liana Wella Putri\*, Scolastika Mariani, Sunarmi**

Jurusan Matematika, FMIPA, Universitas Negeri Semarang, Indonesia  
Gedung D7 Lt.1, Kampus Sekaran Gunungpati, Semarang 50229  
\*E-mail: [dwilianawella@gmail.com](mailto:dwilianawella@gmail.com)

Diterima 5 Januari 2021

Disetujui 12 September 2021

Dipublikasikan 31 Oktober 2021

### **Abstrak**

Tujuan penelitian ini adalah mengetahui ketepatan klasifikasi regresi logistik dan bagging (*bootstrap aggregating*) regresi logistik biner pada status peserta KB Kota Tegal tahun 2016 serta mengetahui model terbaik regresi logistik biner. Penelitian ini melakukan estimasi status peserta KB Kota Tegal dengan metode maximum likelihood estimation disertai dengan algoritma newton raphson, dilanjutkan dengan pengujian signifikansi parameter baik secara simultan dengan Uji likelihood ratio dan parsial dengan uji wald. Selanjutnya uji kesesuaian model menggunakan Hosmer dan Lemeshow, uji ketepatan klasifikasi regresi logistik biner dan bootstrap aggregating, dan pemilihan model terbaik dengan melihat nilai ketepatan klasifikasi tertinggi dengan tingkat kesalahan terkecil. Software yang digunakan adalah program R 3.4.1. Disimpulkan, ketepatan klasifikasi metode bagging (*bootstrap aggregating*) sebesar 75,641% dengan kesalahan klasifikasi 24,359%. Metode bagging (*bootstrap aggregating*) meningkatkan ketepatan klasifikasi pada model regresi logistik biner dengan nilai ketepatan klasifikasi pada model regresi logistik biner 69,74% meningkat menjadi 75,641%. Model yang terbaik adalah model regresi logistik biner dengan menggunakan bagging (*bootstrap aggregating*).

Kata kunci: *KB, Kota Tegal, Metode Bagging, Regresi Logistik*

### **Abstract**

*The purpose of this research is to know the accuracy of classification of logistic regression and bagging (bootstrap aggregating) logistic regression with binary data of KB participant in Tegal City year 2016 as well as logistic regression model find out binary. This research do estimation KB participant in Tegal City by the method of maximum likelihood estimation algorithm with newton raphson accompanied, followed by testing the significance of parameters simultaneously with partial likelihood ratio test and the test with wald. The next test of suitability of the model by using the hosmer and lemeshow test and the accuracy of the classification of binary logistic regression and bootstrapping aggregating and conducted the selection of the best model by looking at the value of the highest level of classification accuracy the smallest mistake. The software used in the program R.3.4.1. the conclusion obtained from this research method of bagging (bootstrap aggregating) is 75,651% with 24,359% classification error. The method of bagging (bootstrap aggregating) improves the accuracy of classification of binary logistic regression models with the highest precision of the logistic regression model is a classification of binary 69,74% increase to 75,64%. The best model is a binary logistic regression model using bagging (bootstrap aggregating).*

Key words: Bagging method, KB, Kota Tegal, Logistic regression

### **How to cite:**

Putri, D.L.W., Mariani, S., & Sunarmi. (2021). Peningkatan Ketepatan Klasifikasi Model Regresi Logistik Biner dengan Metode Bagging (Bootstrap Aggregating). *Indonesian Journal of Mathematics and natural Sciences*, 44(2), 61-72

### **PENDAHULUAN**

Salah satu metode analisis statistik yang digunakan untuk mencari hubungan antar variabel respon dengan variabel prediktor adalah regresi logistik biner. Pada regresi logistik biner, variabel

respon bersifat biner dan variabel prediktor bersifat polikotomus atau kontinu. Pada regresi logistik biner, nilai variabel respon bersifat dikotomi yaitu variabel yang hanya mempunyai dua kemungkinan, misalnya “sukses” atau “gagal”. Dalam memudahkan penerapan regresi logistik, diperlukan adanya notasi pada tiap variabel yaitu variabel Y sebagai variabel respon dan X sebagai variabel prediktor (Hosmer & Lemeshow, 2000).

Pada masalah klasifikasi data, terdapat banyak klasifikasi seperti *Decision Tree*, *Artificial Neural Network*, *Logistic Regression*, dan *Naive Bayes*. Naive Bayes bekerja sangat baik ketika distribusi suatu variabel respon pada sekumpulan data set yang seimbang (Nai-arun & Moungrmai, 2015). Akan tetapi, pada kenyataannya masalah ketidakseimbangan dapat terjadi seperti pada klasifikasi dokumen (Laza et al., 2011), dan prediksi kegagalan *credit-scoring* (Brown & Mues, 2012). Salah satu klasifikasi data yang masuk dalam kategori ini adalah data dengan variabel respon biner. Sekumpulan data yang seimbang sangat penting untuk membuat model prediksi yang baik. Untuk memprediksi suatu model regresi logistik biner, dibutuhkan nilai akurasi yang stabil. Namun, terkadang pendugaan parameter pada regresi logistik biner mengalami ketidakseimbangan klasifikasi (*missclassification*). Hal ini disebabkan data memiliki nilai varians yang tinggi (*noise*) sehingga menyebabkan kurangnya akurasi pada klasifikasi meskipun nilai akurasi keseluruhan tinggi (Prasetio & Pratiwi, 2015; Kim & Kang, 2012). Untuk mengatasi ketidakseimbangan model pada regresi logistik biner, dapat digunakan salah satu metode klasifikasi yaitu metode *bagging* (*bootstrap aggregating*).

Metode *bagging* merupakan salah satu metode yang mengkombinasikan *bootstrapping* dan *aggregating* (Alfaro et al., 2013). Metode ini digunakan untuk meningkatkan ketepatan klasifikasi pada sekumpulan data dengan cara mengurangi varians dengan tetap menjaga atau hanya sedikit meningkatkan bias. Metode *bagging* adalah metode *ensemble* yang sederhana namun efektif dan telah diterapkan untuk banyak aplikasi di dunia nyata (Liang & Zhang, 2011). Ide dasar dari *bagging* adalah menggunakan *bootstrap* dimana ketika dikombinasikan seharusnya hasilnya lebih baik dibandingkan dengan prediktor tunggal yang dibangun untuk menyelesaikan masalah yang sama. Menurut Hosmer dan Lemeshow (2000), pada regresi logistik biner, keluaran dari variabel respon terdiri dari dua kategori, misalnya sukses atau gagal yang dinotasikan dengan  $y = 1$  berarti sukses atau  $y = 0$  berarti gagal. Dengan demikian, variabel respon mengikuti distribusi Bernoulli. Fungsi probabilitas untuk setiap observasi dapat dituliskan sebagai berikut :

$$f(y) = \pi^y(1 - \pi)^{1-y}; y = 0,1$$

Pada regresi linear variabel respon diasumsikan berdistribusi normal, namun pada regresi logistik biner variabel bersifat kategorikal. Bentuk fungsi regresi logistiknya adalah sebagai berikut:

$$f(x) = \frac{1}{1 + e^{-x}}, -\infty < x < \infty$$

bentuk regresi logistiknya:

$$\pi(x) = \frac{e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_i x_i)}}{1 + e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_i x_i)}}$$

Persamaan diatas mempunyai bentuk yang tidak linier. Untuk membuat persamaan tersebut menjadi persamaan yang linier, maka persamaan diatas perlu ditransformasikan dengan menggunakan transformasi logit. Bentuk transformasinya adalah:

$$g(x) = \ln\left(\frac{\pi(x)}{1 - \pi(x)}\right) = \beta_0 + \beta_1 x_1 + \dots + \beta_i x_i$$

Menurut Bakari (2016), ada beberapa metode yang baik dalam mengestimasi parameter, yaitu metode momen, maximum likelihood estimation, dan metode bayes. Namun, dari beberapa metode tersebut, metode *maximum likelihood estimation* merupakan metode yang kemungkinan menghasilkan penaksir yang baik. Dalam menentukan penaksir *maximum likelihood*, diperlukan adanya fungsi yang disebut fungsi *likelihood*. Fungsi ini menyatakan kemungkinan dari data yang diamati sebagai fungsi dari parameter yang tidak diketahui. Untuk menaksir parameter  $\beta$ , fungsi *likelihood* dimaksimumkan dengan syarat bahwa data tersebut mengikuti suatu distribusi tertentu. Pada regresi logistik biner, setiap pengamatan mengikuti distribusi Bernoulli sehingga didapat fungsi *likelihood*-nya. Untuk mendapatkan hasil yang konvergen, fungsi *likelihood* dimaksimumkan dengan algoritma newton raphson (Hosmer & Lemeshow, 2000).

Pada regresi logistik biner, uji signifikansi parameter dalam model dapat dilakukan dengan uji rasio *likelihood* dan uji wald. uji wald pada regresi logistik biner dapat dituliskan sebagai berikut:  
Hipotesis:

$H_0 : \beta_j = 0$  (parameter  $\beta$  tidak berpengaruh secara signifikan terhadap variabel respon secara individu)

$H_1 : \beta_j \neq 0 ; j = 1, 2, \dots, p$  (parameter  $\beta$  berpengaruh secara signifikan terhadap variabel respon secara individu)

dengan bentuk statistik uji wald:

$$W_j = \frac{(\hat{\beta}_j)}{[SE(\hat{\beta}_j)]}$$

di mana

$\beta_j$  : nilai koefisien regresi logistik untuk variabel ke- j

$\hat{\beta}_j$  : penduga dari parameter  $\beta$

$SE(\hat{\beta}_j)$  : nilai standar error untuk variabel ke -i

Tolak  $H_0$ , jika  $|W_j| > Z_{(\alpha; db)}$  atau  $W_j^2 > \chi^2_{(db, \alpha)}$  yang berarti parameter  $\beta$  berpengaruh secara signifikan terhadap variabel respon secara individu.

Uji simultan atau serentak merupakan pengujian yang dilakukan untuk memeriksa signifikansi parameter  $\beta$  terhadap variabel prediktor secara keseluruhan. Pada uji ini, statistik yang digunakan adalah statistik uji  $G$  atau *Likelihood Ratio Test* (Hosmer & Lemeshow, 2000).

Hipotesis :

$H_0 : \beta_1 = \beta_2 = \dots = \beta_j = 0$  (variabel prediktor tidak berpengaruh secara signifikan terhadap variabel respon)

$H_1$  : paling sedikit ada satu  $\beta_j \neq 0$  ( $i = 1, 2, \dots, j$ ) (variabel prediktor berpengaruh secara signifikan terhadap variabel respon)

Bentuk statistik uji *Likelihood Ratio Test*:

$$G = -2 \ln \left( \frac{L_0}{L_1} \right)$$

$L_0$  : likelihood tanpa variabel bebas

$L_1$  : likelihood dengan variabel bebas

Pada hipotesis  $H_0$ , bahwa  $\beta_1$  sama dengan nol, statistik uji  $G$  mengikuti distribusi *Chi-Square*. Hasil uji statistik diatas bahwa  $H_0$  ditolak jika  $G > \chi^2_{(db, \alpha)}$  atau  $p\text{-value} < \alpha$ .

Uji kesesuaian model merupakan uji yang digunakan untuk mengetahui apakah terdapat perbedaan antara hasil observasi dengan kemungkinan hasil prediksi. Proses pengujian yang digunakan pada uji ini adalah uji Hosmer dan Lemeshow. Hipotesis yang digunakan adalah sebagai berikut:

Hipotesis :

$H_0$  : model sesuai (tidak ada perbedaan antara hasil observasi dengan hasil prediksi)

$H_1$  : Model tidak sesuai (ada perbedaan antara hasil observasi dengan hasil prediksi)

Bentuk statistik uji :

$$\hat{C} = \sum_{f=1}^g \left[ \frac{(O_f - n\bar{\pi}_f)^2}{(n_f \pi_f (1 - \pi_f))} \right]$$

Di mana :

$g$  : jumlah grup

$O_f$  : jumlah nilai variabel respon pada grup ke -f

$\bar{\pi}_f$  : rata-rata taksiran peluang

$n_f$  : banyak observasi pada grup ke -f

Kriteria uji :  $H_0$  ditolak jika  $\hat{C} > \chi^2_{(g-2, \alpha)}$

Menurut Arleina dan Otok (2014), Press'Q adalah ukuran yang digunakan untuk mengetahui kestabilan dalam pengklasifikasian atau sejauh mana kelompok-kelompok tersebut dapat dipisahkan. Bentuk uji statistik dari press'Q dapat dituliskan sebagai berikut:

$$\frac{[N - (nK)]^2}{N(K - 1)} \sim \chi^2_{(1)}$$

dimana

$N$  : banyaknya pengamatan  
 $n$ : banyaknya individu yang tepat diklasifikasikan  
 $K$  : banyaknya kelompok

$APER$  (*Apparent Error Rate*) merupakan suatu nilai yang digunakan untuk melihat kesalahan dalam mengklasifikasi suatu objek. Nilai  $APER$  didapatkan dengan perhitungan diberikan pada Tabel 1.

Tabel 1 Tabel Klasifikasi Regresi Logistik

Hasil Observasi	Taksiran	
	$y_1$	$y_2$
$y_1$	$n_{11}$	$n_{12}$
$y_2$	$n_{21}$	$n_{22}$

Keterangan:

$n_{11}$  : jumlah subjek dari  $y_1$  tepat diklasifikasikan sebagai  $y_1$   
 $n_{12}$  : jumlah subjek dari  $y_1$  salah diklasifikasikan sebagai  $y_2$   
 $n_{21}$  : jumlah subjek dari  $y_2$  salah diklasifikasikan sebagai  $y_1$   
 $n_{22}$  : jumlah subjek dari  $y_2$  tepat diklasifikasikan sebagai  $y_2$

$$\begin{aligned}
 APER(\%) &= \frac{\text{jumlah prediksi salah}}{\text{jumlah total prediksi}} \\
 &= \frac{n_{12} + n_{21}}{n_{11} + n_{12} + n_{21} + n_{22}} \times 100\%
 \end{aligned}$$

dengan nilai akurasi:

$$\begin{aligned}
 AKURASI &= 1 - APER \\
 &= 1 - \frac{\text{jumlah prediksi salah}}{\text{jumlah total prediksi}}
 \end{aligned}$$

Untuk memperoleh parameter yang stabil pada regresi logistik biner, dapat digunakan suatu pendekatan bootstrap yaitu metode *bagging* (*bootstrap aggregating*). *Bagging* merupakan metode untuk menghasilkan beberapa versi prediktor dan menggunakannya untuk mendapatkan prediktor agregat. Rata-rata agregat dari beberapa prediktor digunakan untuk memprediksi keluaran numerik. Prediktor-prediktor terbentuk dengan replikasi bootstrap pada data dan menggunakannya sebagai data baru.

Himpunan data (data set)  $\mathcal{E}$  terdiri dari  $\{(y_n, x_n), n = 1, \dots, N\}$  dengan  $y$  dapat berupa kelas label atau numerik respon. Jika input adalah  $x$ , maka  $y$  diprediksi dengan  $\varphi(x, \mathcal{E})$  dimana  $\varphi(x, \mathcal{E})$  adalah parameter. Untuk mendapatkan prediktor yang lebih baik maka dilakukan replikasi bootstrap  $\{\mathcal{E}_k\}$  yang kemudian disebut  $\{\varphi(x, \mathcal{E}_k)\}$ . Replikasi bootstrap dilakukan sebanyak  $B$  kali sehingga  $\{\mathcal{E}^{(B)}\}$  dari  $\mathcal{E}$  dan dibentuk prediktor  $\{\varphi(x, \mathcal{E}^{(B)})\}$  dimana  $\{\mathcal{E}^{(B)}\}$  adalah *resampling* dengan pengembalian. Jika  $y$  data numerik, maka prosedur nyata untuk menggantikan  $\varphi(x, \mathcal{E})$  dengan mengambil rata-rata dari  $\{\varphi(x, \mathcal{E}_k)\}$  untuk memprediksi kelas. Ambil bootstrap sampel dengan pengulangan  $\{\mathcal{E}^{(B)}\}$  dari  $\mathcal{E}$  dan membentuk  $\{\varphi(x, \mathcal{E}^{(B)})\}$  (Breiman, 1994).

Metode *aggregate classifier*  $\mu_A$  secara umum dapat dituliskan sebagai berikut:

$$\mu_A(y) = E_F[\hat{\mu}(y, \mathcal{E}_k)]$$

Langkah-langkah algoritma *bagging* dapat dituliskan sebagai berikut :

1. Mengambil sampel bootstrap sebanyak  $n$  dari data set  $\mathcal{E}$  dengan pengulangan sebanyak  $n$ . Pengambilan sampel sedemikian hingga setiap variabel aggregate dalam setiap observasi.
2. Memodelkan regresi logistik hasil sampel bootstrap  $\mathcal{E}^{(B)}$ .
3. Menghitung peluang kumulatif, peluang masing-masing kategori respon untuk setiap observasi dan menghitung ketepatan klasifikasi. Kesalahan klasifikasi pada langkah ini disebut  $e_B$ .
4. Mengulang langkah 1-3 sebanyak  $B$  kali (Replikasi bootstrap)
5. Memperoleh ketepatan klasifikasi *bagging* yaitu rata-rata ketepatan klasifikasi setiap pengulangan sampai  $B$  sehingga kesalahan *bagging* untuk replikasi  $B$  kali adalah  $\bar{e}_B$ .

6. Membentuk model bagging regresi logistik dari rata-rata setiap parameter pada pengulangan sampai B.

Hasil sensus penduduk yang dilakukan oleh Badan Pusat Statistik (BPS) tahun 2010 menyebutkan bahwa jumlah penduduk di Indonesia adalah 238,52 juta jiwa dan bertambah menjadi sekitar 255,46 juta jiwa pada tahun 2015. Jumlah penduduk Kota Tegal tahun 2015 berdasarkan hasil SUSENAS sendiri mencapai 276.734 jiwa. Kepadatan penduduk di Kota Tegal tercatat sebesar 6.203 jiwa setiap kilometer persegi. Untuk mengendalikan jumlah penduduk yang terus meningkat, Badan Kependudukan dan Keluarga Berencana Nasional (BKKBN) melakukan program Keluarga Berencana (KB) bagi pasangan usia subur. Penelitian ini menerapkan metode bootstrap aggregating untuk meningkatkan ketepatan klasifikasi pada model regresi logistik biner dalam kasus status peserta KB Kota Tegal pada tahun 2016. Pada penelitian ini akan dibandingkan nilai ketepatan klasifikasi antara regresi logistik biner dan bootstrap aggregating dan akan didapat model terbaik antara regresi logistik biner dengan *bagging* (*bootstrap aggregating*).

## METODE

Penelitian ini berfokus pada (1) Penelitian menggunakan model regresi logistik biner dan *bagging* (*bootstrap aggregating*), (2) Estimasi parameter yang digunakan dalam penelitian ini menggunakan metode *maximum likelihood estimation* dan algoritma newton raphson, (3) peningkatan ketepatan klasifikasi pada model regresi logistik biner menggunakan *bagging* (*bootstrap aggregating*) untuk meningkatkan akurasi, (4) Penelitian didukung dengan bantuan program R.3.4.1 dan SPSS v.23.

Data yang diperoleh dari BKKBN Provinsi Jawa Tengah tahun 2016 yaitu data status peserta KB ( $Y$ ) dengan kategori: bukan peserta KB (0) dan peserta KB (1). Variabel usia istri ( $X_1$ ) dengan kategori:  $\leq 50$  tahun,  $> 50$  tahun. Usia suami ( $X_2$ ) dengan kategori:  $\leq 50$  tahun,  $> 50$  tahun. Pendidikan terakhir istri ( $X_3$ ) dengan kategori: Tidak/belum sekolah, Tidak tamat SD/MI, Tamat SD/MI, Tidak tamat SLTP/MTSN, Tamat SLTP/MTSN, Tidak tamat SLTA/MA, Tamat SLTA/MA, Tidak tamat PT/akademi, Tamat PT/akademi. Pendidikan terakhir suami ( $X_4$ ) dengan kategori: Tidak/belum sekolah, Tidak tamat SD/MI, Tamat SD/MI, Tidak tamat SLTP/MTSN, Tamat SLTP/MTSN, Tidak tamat SLTA/MA, Tamat SLTA/MA, Tidak tamat PT/akademi, Tamat PT/akademi. Pekerjaan istri ( $X_5$ ) dengan kategori: Petani, Nelayan, Pedagang, PNS/TNI/POLRI, Pegawai swasta, Wiraswasta, Pensiunan, Pekerja lepas, Lainnya, Tidak bekerja. Pekerjaan suami ( $X_6$ ) dengan kategori: Petani, Nelayan, Pedagang, PNS/TNI/POLRI, Pegawai swasta, Wiraswasta, Pensiunan, Pekerja lepas, Lainnya, Tidak bekerja. Variabel terakhir yaitu jumlah anak hidup ( $X_7$ ).

Langkah-langkah yang digunakan dalam metode penelitian ini adalah :

- (1) Menguji OLS (*Ordinary Least Square*).
- (2) Pembentukan model regresi logistik biner dengan mengestimasi parameter menggunakan MLE.
- (3) menentukan model regresi dengan pengujian secara simultan terhadap seluruh variabel prediktor dengan cara memasukkan seluruh variabel prediktor yang signifikan berpengaruh pada pengujian secara individu.
- (4) Melakukan analisis regresi logistik biner dengan pengujian secara individu terhadap masing-masing variabel prediktor.
- (5) Melakukan uji kesesuaian model dengan menggunakan uji Hosmer dan lemeshow lalu diperoleh variabel prediktor yang signifikan berpengaruh terhadap model regresi logistik biner.
- (6) Menentukan kesalahan klasifikasi regresi logistik biner.
- (7) Melakukan *bootstrap aggregating* untuk prediktor dari model regresi logistik biner sebanyak B 50 replikasi bootstrap.
- (8) Menentukan ketepatan klasifikasi pada setiap pengambilan sampel B replikasi bootstrap, sehingga diperoleh kesalahan klasifikasi  $e_B$ .
- (9) Menentukan kesalahan klasifikasi *bagging*  $\bar{e}_B$ .
- (10) Membandingkan ketepatan klasifikasi model regresi logistik biner dan *bagging* regresi logistik biner.

## HASIL DAN PEMBAHASAN

Berdasarkan uji OLS (*Ordinary Least Square*) kriteria yang tidak memenuhi adalah kriteria normalitas, dan heterokedastisitas sehingga data ini didekati dengan pendekatan regresi logistik biner. Uji heteroskedastisitas tidak bias memenuhi karena pada data ini berbentuk kategorik sehingga

tidak bias dilakukan penyembuhan. Selanjutnya dilakukan pembentukan model awal regresi logistik biner dengan menggunakan estimasi *maximum likelihood estimation* dan algoritma *newton raphson* seperti terlihat pada Tabel 2.

Tabel 2 Estimasi Parameter untuk Model Awal Regresi Logistik Biner

No	$(X_i)$	$\beta_j$
1	$(X_{1,2})$	0,76527
2	$(X_{2,2})$	1,10945
3	$(X_{3,2})$	-1,08088
4	$(X_{3,4})$	-0,80080
5	$(X_{3,5})$	-0,57856
6	$(X_{3,6})$	-2,00045
7	$(X_{3,7})$	-14,71783
8	$(X_{3,8})$	-2,05412
9	$(X_{3,9})$	15,17975
10	$(X_{4,2})$	-0,71855
11	$(X_{4,3})$	17,22801
12	$(X_{4,4})$	-0,51464
13	$(X_{4,5})$	17,84836
14	$(X_{4,6})$	0,11024
15	$(X_{4,7})$	0,56627
16	$(X_{4,8})$	0,91570
17	$(X_{4,9})$	-0,06683
18	$(X_{5,2})$	-0,43856
19	$(X_{5,3})$	0,05113
20	$(X_{5,4})$	-1,19291
21	$(X_{5,5})$	0,39449
22	$(X_{5,6})$	0,24773
23	$(X_{5,7})$	17,98805
24	$(X_{5,8})$	-0,16053
25	$(X_{5,9})$	1,44986
26	$(X_{5,10})$	1,27527
27	$(X_{6,2})$	-33,45318
28	$(X_{6,3})$	-18,28683
29	$(X_{6,4})$	-17,24723
30	$(X_{6,5})$	-19,40141
31	$(X_{6,6})$	-18,73082
32	$(X_{6,8})$	-17,11914
33	$(X_{6,9})$	-17,79022
34	$(X_{6,10})$	-18,52069
35	$(X_7)$	0,34417

dengan

- $(X_{1,2})$  : usia istri diatas 50 tahun
- $(X_{2,2})$  : usia suami diatas 50 tahun
- $(X_{3,2})$  : pendidikan terakhir istri tidak tamat SD
- $(X_{3,4})$  : pendidikan terakhir istri tidak tamat SLTP
- $(X_{3,5})$  : pendidikan terakhir istri tamat SLTP
- $(X_{3,6})$  : pendidikan terakhir istri tidak tamat SLTA
- $(X_{3,7})$  : pendidikan terakhir istri tamat SLTA
- $(X_{3,8})$  : pendidikan terakhir istri tidak tamat PT/akademi
- $(X_{3,9})$  : pendidikan terakhir istri tamat PT/akademi
- $(X_{4,2})$  : pendidikan terakhir suami tidak tamat SD
- $(X_{4,3})$  : pendidikan terakhir suami tamat SD
- $(X_{4,4})$  : pendidikan terakhir suami tidak tamat SLTP

- $(X_{4,5})$  : pendidikan terakhir suami tamat SLTP
- $(X_{4,6})$  : pendidikan terakhir suami tidak tamat SLTA
- $(X_{4,7})$  : pendidikan terakhir suami tamat SLTA
- $(X_{4,8})$  : pendidikan terakhir suami tidak tamat PT/akademi
- $(X_{4,9})$  : pendidikan terakhir suami tamat PT/akademi
- $(X_{5,2})$  : pekerjaan istri (nelayan)
- $(X_{5,3})$  : pekerjaan istri (pedagang)
- $(X_{5,4})$  : pekerjaan istri (PNS)
- $(X_{5,5})$  : pekerjaan istri (pegawai swasta)
- $(X_{5,6})$  : pekerjaan istri (wiraswasta)
- $(X_{5,7})$  : pekerjaan istri (pensiunan)
- $(X_{5,8})$  : pekerjaan istri (pekerja lepas)
- $(X_{5,9})$  : pekerjaan istri (lainnya)
- $(X_{5,10})$  : pekerjaan istri (tidak bekerja)
- $(X_{6,2})$  : pekerjaan suami (nelayan)
- $(X_{6,3})$  : pekerjaan suami (pedagang)
- $(X_{6,4})$  : pekerjaan suami (PNS)
- $(X_{6,5})$  : pekerjaan suami (pegawai swasta)
- $(X_{6,6})$  : pekerjaan suami (wiraswasta)
- $(X_{6,8})$  : pekerjaan suami (pekerja lepas)
- $(X_{6,9})$  : pekerjaan suami (lainnya)
- $(X_{6,10})$  : pekerjaan suami (tidak bekerja)
- $(X_7)$  : jumlah anak hidup

dengan bentuk regresi logistik biner:

$$g(x) = 17,14729 + 0,76527 X_{1,2} + 1,10945 X_{2,2} - 1,08088 X_{3,3} - 0,80080 X_{3,4} - 0,57856 X_{3,5} - 2,00045 X_{3,6} - 14,71783 X_{3,7} - 2,05412 X_{3,8} + 15,17975 X_{3,9} - 0,71855 X_{4,2} + 17,22801 X_{4,3} - 0,51464 X_{4,4} + 17,84836 X_{4,5} + 0,11024 X_{4,6} + 0,56627 X_{4,7} + 0,9157 X_{4,8} - 0,06683 X_{4,9} - 0,43856 X_{5,2} + 0,05113 X_{5,3} - 1,19291 X_{5,4} + 0,39449 X_{5,5} + 0,24773 X_{5,6} + 17,98805 X_{5,7} - 0,16053 X_{5,8} + 1,44986 X_{5,9} + 1,27527 X_{5,10} - 33,45318 X_{6,2} - 18,28683 X_{6,3} - 17,24723 X_{6,4} - 19,40141 X_{6,5} - 18,73082 X_{6,6} - 17,11914 X_{6,8} - 17,79022 X_{6,9} - 18,52069 X_{6,10} + 0,34417 X_7$$

di mana

$$\pi(x) = \frac{e^{g(x)}}{1 + e^{g(x)}}$$

Langkah selanjutnya dilakukan uji signifikansi parameter baik simultan dan uji parsial. Langkah pengujian simultan menggunakan uji  $G$  atau uji likelihood ratio test dengan prosedur pengujian sebagai berikut:

hipotesis:

$H_0$  :  $\beta_1 = \beta_2 = \dots = \beta_j = 0$  (variabel prediktor tidak berpengaruh secara signifikan terhadap variabel respon)

$H_1$  : paling sedikit ada satu  $\beta_j \neq 0$  ( $i = 1, 2, \dots, j$ ) (variabel prediktor berpengaruh secara signifikan terhadap variabel respon)

dengan taraf signifikansi 5% diperoleh statistik uji  $G$  seperti pada Tabel 3.

Tabel 3. Likelihood Ratio Test		
	LogLik	Pr(>Chisq)
$L_0$	-198,25	
$L_1$	-245,38	2,453-07***

Karena nilai  $(G = 94,26) > (\chi^2_{(0,05,35)} = 49,802)$ , atau dapat dilihat nilai dari  $p\text{-value} = 2,453e - 07 < \alpha = 0,05$ , dengan demikian  $H_0$  ditolak. Artinya usia istri ( $X_1$ ), usia suami ( $X_2$ ), pendidikan terakhir istri ( $X_3$ ), pendidikan terakhir suami ( $X_4$ ), pekerjaan istri ( $X_5$ ), pekerjaan suami ( $X_6$ ) serta



jumlah anak hidup ( $X_7$ ) secara bersama-sama berpengaruh secara signifikan terhadap status peserta KB. Selanjutnya dilakukan uji wald pada model regresi logistik biner dengan prosedur pengujian sebagai berikut:

Hipotesis:

$H_0 : \beta_j = 0$  (parameter  $\beta$  tidak berpengaruh secara signifikan terhadap variabel respon secara individu)

$H_1 : \beta_j \neq 0 ; j = 1, 2, \dots, p$  (parameter  $\beta$  berpengaruh secara signifikan terhadap variabel respon secara individu)

Taraf signifikansi 5%. Hasil uji wald diberikan pada Tabel 4.

Tabel 4. Nilai Uji Wald untuk Setiap Parameter pada Model Awal

No	( $X_i$ )	<i>p-value</i>	Keputusan
1	( $X_{1,2}$ )	0,004	$H_0$ ditolak
2	( $X_{2,2}$ )	0,024	$H_0$ ditolak
3	( $X_{3,2}$ )	0,058	$H_0$ diterima
4	( $X_{3,4}$ )	0,224	$H_0$ diterima
5	( $X_{3,5}$ )	0,690	$H_0$ diterima
6	( $X_{3,6}$ )	0,006	$H_0$ ditolak
7	( $X_{3,7}$ )	0,995	$H_0$ diterima
8	( $X_{3,8}$ )	0,018	$H_0$ ditolak
9	( $X_{3,9}$ )	0,995	$H_0$ diterima
10	( $X_{4,2}$ )	0,277	$H_0$ diterima
11	( $X_{4,3}$ )	0,994	$H_0$ diterima
12	( $X_{4,4}$ )	0,473	$H_0$ diterima
13	( $X_{4,5}$ )	0,994	$H_0$ diterima
14	( $X_{4,6}$ )	0,880	$H_0$ diterima
15	( $X_{4,7}$ )	0,805	$H_0$ diterima
16	( $X_{4,8}$ )	0,320	$H_0$ diterima
17	( $X_{4,9}$ )	0,968	$H_0$ diterima
18	( $X_{5,2}$ )	0,638	$H_0$ diterima
19	( $X_{5,3}$ )	0,960	$H_0$ diterima
20	( $X_{5,4}$ )	0,339	$H_0$ diterima
21	( $X_{5,5}$ )	0,694	$H_0$ diterima
22	( $X_{5,6}$ )	0,802	$H_0$ diterima
23	( $X_{5,7}$ )	0,991	$H_0$ diterima
24	( $X_{5,8}$ )	0,865	$H_0$ diterima
25	( $X_{5,9}$ )	0,203	$H_0$ diterima
26	( $X_{5,10}$ )	0,398	$H_0$ diterima
27	( $X_{6,2}$ )	0,990	$H_0$ diterima
28	( $X_{6,3}$ )	0,994	$H_0$ diterima
29	( $X_{6,4}$ )	0,994	$H_0$ diterima
30	( $X_{6,5}$ )	0,994	$H_0$ diterima
31	( $X_{6,6}$ )	0,994	$H_0$ diterima
32	( $X_{6,8}$ )	0,994	$H_0$ diterima
33	( $X_{6,9}$ )	0,994	$H_0$ diterima
34	( $X_{6,10}$ )	0,994	$H_0$ diterima
35	( $X_7$ )	0,000	$H_0$ ditolak

$H_0$  ditolak jika  $W_j^2 > \chi^2_{(0,05,1)}$  atau *p-value* <  $\alpha$

Jadi, pada taraf signifikansi 5% terlihat bahwa variabel prediktor yang mempengaruhi variabel dependen adalah  $X_1, X_2, X_3$  dan  $X_7$ , sedangkan variabel lain tidak mempengaruhi. Pada variabel pendidikan terakhir istri ( $X_3$ ) dengan kategori tidak tamat SD/MI, tidak tamat SLTP/MTSN, tamat SLTP/MTSN, tamat SLTA/MA, dan tamat PT/Akademi dianggap signifikan karena masih satu variabel dengan pendidikan terakhir istri. Sedangkan variabel pendidikan terakhir suami ( $X_4$ ),

pekerjaan istri ( $X_5$ ), pekerjaan suami ( $X_6$ ) dihilangkan karena tidak memberikan pengaruh yang signifikan terhadap variabel dependen. Langkah selanjutnya dibentuk model baru dengan menggunakan variabel  $X_1, X_2, X_3$ , dan  $X_7$  dan diuji rasio likelihood serta uji wald kedua. Diperoleh bentuk model regresi logistik kedua seperti pada Tabel 5.

Tabel 5. Estimasi Parameter pada Model Regresi Logistik Kedua

No	( $X_i$ )	$\beta_j$
1	( $X_{1,2}$ )	0,734
2	( $X_{2,2}$ )	0,886
3	( $X_{3,2}$ )	-1,266
4	( $X_{3,4}$ )	-0,536
5	( $X_{3,5}$ )	0,082
6	( $X_{3,6}$ )	-1,311
7	( $X_{3,7}$ )	-14,117
8	( $X_{3,8}$ )	-1,182
9	( $X_{3,9}$ )	14,742
10	( $X_7$ )	0,273

Diperoleh nilai

$$g(x) = -1,268 + 0,734X_{1,2} + 0,886X_{2,2} - 1,266X_{3,2} - 0,536X_{3,4} + 0,082X_{3,5} - 1,311X_{3,6} - 14,117X_{3,7} - 1,182X_{3,8} + 14,742X_{3,9} + 0,273X_7$$

Setelah dibentuk model kedua dengan variabel yang signifikan yaitu  $X_1, X_2, X_3$ , dan  $X_7$ . Langkah selanjutnya yaitu uji likelihood ratio test sebagai berikut:

Hipotesis:

$H_0 : \beta_1 = \beta_2 = \dots = \beta_j = 0$  (variabel prediktor tidak berpengaruh secara signifikan terhadap variabel respon)

$H_1 : \text{paling sedikit ada satu } \beta_j \neq 0 (i = 1, 2, \dots, j)$  (variabel prediktor berpengaruh secara signifikan terhadap variabel respon)

Dengan taraf signifikansi 5% diperoleh bentuk uji *likelihood ratio test* seperti pada Tabel 6.

Tabel 6 Likelihood Ratio Test	
	Pr(>Chisq)
$L_0$	-224,26
$L_1$	6,844e-06***

Karena nilai ( $G = 42,24$ ) > ( $\chi^2_{(0,05,10)} = 18,307$ ), atau dapat dilihat nilai dari  $p\text{-value} = 6,844e - 06 < \alpha = 0,05$ , dengan demikian  $H_0$  ditolak. Artinya usia istri ( $X_1$ ), usia suami ( $X_2$ ), pendidikan terakhir istri ( $X_3$ ), serta jumlah anak hidup ( $X_7$ ) secara bersama-sama berpengaruh secara signifikan terhadap status peserta KB.

Uji wald kedua digunakan untuk melihat pengaruh masing-masing variabel prediktor terhadap variabel respon dengan menggunakan variabel prediktor  $X_1, X_2, X_3$ , dan  $X_7$  diperoleh hipotesis sebagai berikut:

$H_0 : \beta_j = 0$  (parameter  $\beta$  tidak berpengaruh secara signifikan terhadap variabel respon secara individu)

$H_1 : \beta_j \neq 0 ; j = 1, 2, \dots, p$  (parameter  $\beta$  berpengaruh secara signifikan terhadap variabel respon secara individu)

Dengan taraf signifikansi 5% diperoleh nilai uji wald seperti Tabel 7.

Jadi, pada taraf signifikansi 5% terlihat bahwa variabel prediktor yang mempengaruhi variabel dependen adalah  $X_1, X_2, X_3$ , dan  $X_7$ . Pada variabel pendidikan terakhir istri ( $X_3$ ) dengan kategori tidak tamat SLTP/MTSN, tamat SLTP/MTSN, tamat SLTA/MA, dan tamat PT/Akademi dianggap signifikan karena nilai tidak signifikan bukan berarti tidak mempengaruhi, akan tetapi variabel pendidikan terakhir istri dengan kategori tidak tamat SLTP/MTSN, tamat SLTP/MTSN, tamat SLTA/MA, dan tamat PT/Akademi memiliki pengaruh yang sangat sedikit sekali sehingga tidak signifikan.

Tabel 7. Nilai Uji Wald untuk Setiap Parameter pada Model Kedua

No	( $X_i$ )	p-value	Keputusan
1	( $X_{1,2}$ )	0,001	$H_0$ ditolak
2	( $X_{2,2}$ )	0,05	$H_0$ ditolak
3	( $X_{3,2}$ )	0,004	$H_0$ ditolak
4	( $X_{3,4}$ )	0,279	$H_0$ diterima
5	( $X_{3,5}$ )	0,940	$H_0$ diterima
6	( $X_{3,6}$ )	0,007	$H_0$ ditolak
7	( $X_{3,7}$ )	0,987	$H_0$ diterima
8	( $X_{3,8}$ )	0,030	$H_0$ ditolak
9	( $X_{3,9}$ )	0,987	$H_0$ diterima
10	( $X_7$ )	0,001	$H_0$ ditolak

Untuk melihat apakah data hasil observasi sesuai dengan hasil prediksi perlu dilakukan uji hosmer dan lemeshow dengan prosedur pengujian sebagai berikut:

Hipotesis:

$H_0$  : model sesuai (tidak ada perbedaan antara hasil observasi dengan hasil prediksi)

$H_1$  : Model tidak sesuai (ada perbedaan antara hasil observasi dengan hasil prediksi)

Dengan taraf signifikansi 5% dengan kriteria  $H_0$  ditolak jika  $\hat{C} > \chi^2_{(0,05,8)}$  atau  $p\text{-value} < \alpha$  diperoleh hasil pengujian seperti pada Tabel 8.

Tabel 8. Uji Hosmer dan Lemeshow

<i>Hosmer and Lemeshow goodness of fit (GOF) test</i>		
<i>X-squared</i>	<i>df</i>	<i>p-value</i>
8,048	8	0,4288

Diperoleh nilai ( $\hat{C} = 8,048$ )  $< (\chi^2_{(0,05,8)} = 15,507)$  atau ( $p\text{-value} = 0,4288$ )  $> (\alpha = 005)$ . Dengan demikian,  $H_0$  diterima, artinya model sesuai atau tidak ada perbedaan antara hasil observasi dengan hasil prediksi.

Berdasarkan hasil uji diatas diperoleh model akhir regresi logistik biner sebagai berikut:

$$g(x) = -1,268 + 0,734X_{1,2} + 0,886X_{2,2} - 1,266X_{3,2} - 0,536X_{3,4} + 0,082X_{3,5} - 1,311X_{3,6} - 14,117 X_{3,7} - 1,182X_{3,8} + 14,742X_{3,9} + 0,273 X_7$$

Untuk menghitung ketepatan klasifikasi, maka perlu dihitung probabilitas peserta KB dari data yang diolah. Diperoleh nilai ketepatan klasifikasi seperti pada Tabel 9.

Tabel 9. Ketepatan Klasifikasi

Observasi	Prediksi	
	Bukan peserta KB	Peserta KB
Bukan peserta KB	237	27
Peserta KB	91	35

$$\begin{aligned} APER(\%) &= \frac{\text{jumlah prediksi salah}}{\text{jumlah total prediksi}} \\ &= \frac{n_{12} + n_{21}}{n_{11} + n_{12} + n_{21} + n_{22}} \times 100\% \\ &= 30,2564\% \end{aligned}$$

Persentase tingkat kesalahan klasifikasi (akurasi) pada model regresi logistik biner adalah 30,2564% , sehingga diperoleh nilai persentase ketepatan klasifikasi adalah  $1 - APER = 1 - 0,302564 = 0,697436 = 69,7436\%$

Hasil dari model regresi logistik biner menyimpulkan bahwa variabel prediktor yang berpengaruh secara signifikan terhadap status peserta KB adalah usia istri ( $X_1$ ), usia suami ( $X_2$ ),

pendidikan istri ( $X_3$ ), dan jumlah anak hidup ( $X_7$ ). Langkah selanjutnya yaitu melakukan *resampling bootstrap* diperoleh hasil pengujian seperti pada Tabel 10.

Tabel 10 Ketepatan Klasifikasi dengan Bagging

Predicted Class	Observed Class	
	0	1
0	295	95
1	0	0

$$APER = 0,243590 = 24,359\%$$

Persentase tingkat kesalahan klasifikasi (akurasi) pada model regresi logistik biner adalah 24,359%, sehingga diperoleh nilai persentase ketepatan klasifikasi adalah  $1 - APER = 1 - 0,24359 = 0,75641 = 75,641\%$ .

Langkah selanjutnya membandingkan hasil ketepatan klasifikasi antara regresi logistik biner dan bagging (*bootstrap aggregating*) regresi logistik biner seperti pada Tabel 11.

Tabel 11. Perbandingan Ketepatan Klasifikasi

Ketepatan Klasifikasi dengan Bagging	Ketepatan Klasifikasi regresi logistik biner	Peningkatan klasifikasi
69,7436%.	75,641%.	5,9064%

Berdasarkan Tabel 11 terlihat bahwa metode bagging (*bootstrap aggregating*) meningkatkan ketepatan klasifikasi dari model data set tunggal sebesar 69,7436% menjadi 75,641% sehingga peningkatan ketepatan klasifikasi sebesar 5,9064%. Dengan demikian ketepatan klasifikasi terbaik menggunakan bagging (*bootstrap aggregating*) logistik biner dengan model regresi logistik biner sebagai berikut:

$$g(x) = -1,8843 + 0,9594X_{1_2} + 1,1098X_{2_2} - 0,9515X_{3_2} - 1,0364X_{3_4} + 0,354X_{3_5} - 1,5016X_{3_6} - 1,0836X_{3_8} - 0,5354X_{3_9} + 0,3501X_7$$

### SIMPULAN

Berdasarkan analisis yang telah dilakukan dapat disimpulkan bahwa Hasil metode bagging (*bootstrap aggregating*) untuk meningkatkan ketepatan klasifikasi model regresi logistik biner pada status peserta KB Kota Tegal yaitu dengan menggunakan uji APER diperoleh kesalahan klasifikasi pada model bagging (*bootstrap aggregating*) regresi logistik biner sebesar 24,359% dengan ketepatan klasifikasi sebesar 75,641%. Ketepatan klasifikasi Ketepatan klasifikasi pada model regresi logistik biner sebesar 69,231%, dengan menggunakan metode bagging (*bootstrap aggregating*) ketepatan klasifikasi menjadi 75,641%. Dengan demikian, metode bagging meningkatkan ketepatan klasifikasi pada model regresi logistik biner sebesar 6,41%. Model terbaik regresi logistik biner menggunakan model bagging (*bootstrap aggregating*) regresi logistik biner adalah sebagai berikut:

$$g(x) = -1,8843 + 0,9594X_{1_2} + 1,1098X_{2_2} - 0,9515X_{3_2} - 1,0364 X_{3_4} + 0,3545 X_{3_5} - 1,5016 X_{3_6} - 1,0836 X_{3_8} - 0,5354X_{3_9} + 0,3501X_7$$

Metode *bagging* (*bootstrap aggregating*) dapat diterapkan pada metode lain, misalnya CHAID karena hasil peningkatan ketepatan klasifikasi bekerja sangat baik pada model prediksi. Metode bagging memiliki ketepatan klasifikasi yang baik sehingga instansi dapat menggunakan metode tersebut untuk mengambil kebijakan. Variabel yang paling berpengaruh, berdasarkan hasil penelitian ini berturut-turut adalah usia suami, usia istri, pendidikan terakhir istri dan jumlah anak hidup. BKKBN dapat melakukan sosialisasi kepada masyarakat tentang pentingnya menggunakan KB dengan memperhatikan usia suami pada status peserta KB.

### DAFTAR PUSTAKA

- Alfaro, E., Gámez, M., & Garcia, N. (2013). adabag: An R package for classification with boosting and bagging. *Journal of Statistical Software*, 54(2), 1-35.
- Arleina, O. D., & Otok, B. W. (2014). Bootstrap aggregating multivariate adaptive regression splines (Bagging MARS) untuk mengklasifikasikan rumah tangga miskin di kabupaten jombang. *Jurnal Sains dan Seni ITS*, 3(2), D91-D96.

- Breiman, L. (1994). *Bagging Predictors. Technical report No 421*. Departement of statistics University of California.
- Brown, I., & Mues, C. (2012). An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert Systems with Applications*, 39(3), 3446-3453.
- Hosmer, D.W. & Lemeshow, S. (2000). *Applied Logistic Regression*. USA: John Willey and Sons.
- Kim, M. J., & Kang, D. K. (2012). Classifiers selection in ensembles using genetic algorithms for bankruptcy prediction. *Expert Systems with applications*, 39(10), 9308-9314.
- Laza, R., Pavón, R., Reboiro-Jato, M., & Fdez-Riverola, F. (2011). Evaluating the effect of unbalanced data in biomedical document classification. *Journal of integrative bioinformatics*, 8(3), 105-117.
- Liang, G. & Zhang, C. (2011). Empirical study of bagging predictors on medical data. *Journal of the centre for quantum computation & intelligent system*, 121.
- Nai-arun, N. & Moungrmai, R. (2015). Comparison of Classifiers for the Risk of Diabetes Prediction. *Procedia Computer Sains*, 69, 132-142.
- Prasetio, R.T. & Pratiwi. (2015). Penerapan teknik bagging pada algoritma klasifikasi untuk mengatasi ketidakseimbangan kelas dataset medis. *Jurnal Informatika* 2(2).

**Analisis Perbandingan Akurasi Metode Fuzzy Tsukamoto dan Fuzzy Sugeno  
Dalam Prediksi Penentuan Harga Mobil Bekas**

**Reynaldi\*, Wahyu Syafrizal, M. Faris Al Hakim**

Jurusan Ilmu Komputer, FMIPA, Universitas Negeri Semarang, Indonesia  
Gedung D5 Lt. 2, Kampus Sekaran, Gunungpati, Semarang 50229  
E-mail: reynaldi8080@students.unnes.ac.id

Diterima 2 Juli 2021

Disetujui 15 September 2021

Dipublikasikan 31 Oktober 2021

**Abstrak**

Mobil merupakan transportasi darat yang sangat membantu aktivitas manusia dalam melakukan kegiatan sehari-hari. Toyota Avanza 47% mendominasi pasar mobil bekas dibanding merek lainnya. Dalam transaksi jual beli mobil bekas, selisih harga yang berbeda sering memiliki nilai yang jauh berbeda. Logika fuzzy dapat digunakan untuk memprediksi harga mobil bekas dengan memperhatikan beberapa aspek. Penelitian ini bertujuan untuk membandingkan tingkat akurasi prediksi antara metode *Fuzzy Tsukamoto* dengan *Fuzzy Sugeno*. *Fuzzy Tsukamoto* bersifat intuitif dan dapat memberikan tanggapan berdasarkan informasi yang bersifat kualitatif, tidak akurat, dan ambigu. Sedangkan *Fuzzy Sugeno* yang terdiri atas basis aturan dengan beberapa aturan penarikan kesimpulan fuzzy. Gagasan ini ditulis dengan analisis melalui studi literatur buku, jurnal dan pengumpulan data berupa dataset maupun landasan teori yang terkait. Berdasarkan analisis data sampel penjualan mobil bekas dan perbandingan 2 metode dengan variabel yang sama. Hasil dari penelitian yang telah dihitung, diperoleh bahwa metode *Fuzzy Tsukamoto* memiliki tingkat *error* sebesar 8% dan *Fuzzy Sugeno* sebesar 38% pada prediksi harga mobil Toyota Avanza bekas.

Kata kunci: Tsukamoto, Sugeno, mobil bekas, logika fuzzy

**Abstract**

*The car is a land transportation that is very helpful for human activities in carrying out daily activities. Toyota Avanza dominates the used car market by 47 percent compared to other brands. In buying and selling used cars, different price differences often have far different values. Fuzzy logic can be used to predict the price of a used car by considering several aspects. This paper aims to compare the level of prediction accuracy between the Fuzzy Tsukamoto method and the Fuzzy Sugeno method. Fuzzy Tsukamoto is intuitive and can provide responses based on information that is qualitative, inaccurate, and ambiguous. Meanwhile, Fuzzy Sugeno which consists of a rule base with several rules for drawing fuzzy conclusions. This idea was written by analyzing through literature studies of books, journals and data collection in the form of datasets and related theoretical foundations. Based on data analysis of used car sales samples and comparison of 2 methods with the same variables. The results of the research that have been calculated, it is found that the Fuzzy Tsukamoto method has an error rate of 8% and Fuzzy Sugeno is 38% in the prediction of the price of a used Toyota Avanza.*

Keywords: Tsukamoto, Sugeno, used car, fuzzy logic

**How to cite:**

Reynaldi, Syafrizal, W., & Hakim, M. F. A. H. (2021). Analisis Perbandingan akurasi metode fuzzy tsukamoto dan Fuzzy Sugeno dalam prediksi penentuan harga mobil bekas. *Indonesian Journal of Mathematics and Natural Science*, 44(2), 73-80


## PENDAHULUAN

Mobil merupakan kendaraan yang sering digunakan banyak orang. Keberadaan mobil sangatlah membantu aktivitas manusia melakukan kegiatan sehari-hari. Dibandingkan dengan motor, mobil lebih nyaman digunakan kegiatan sehari-hari karena mobil memiliki pelindung dari sinar matahari dan hujan. Transaksi jual beli mobil sudah menjadi hal umum, tak terkecuali transaksi mobil bekas. Mobil bekas memiliki harga yang bervariasi sesuai kualitas yang ada. Dalam jual beli mobil bekas, pembeli sering mengalami kerugian karena kurang memperhatikan faktor-faktor yang mempengaruhi harga mobil bekas tersebut. Toyota merupakan sebuah tipe brand mobil yang diluncurkan di Indonesia oleh pabrikan Daihatsu, dan dipasarkan dalam dua merek dan nama yaitu Toyota Avanza dan Daihatsu Xenia. Generasi pertama mobil ini diluncurkan saat berlangsungnya kegiatan Gaikindo Auto Expo 2003 dan terjual sebesar 100.000-unit pada tahun tersebut, dan masih merupakan mobil yang sering dijual di pasar mobil bekas. Merek mobil bekas terlaris masih dikuasai Toyota sebesar 47%, Daihatsu 16%, Honda 15%, Suzuki 8% dan merek lainnya sebesar 6% (Mobil88). Spesifikasi yang mempengaruhi harga mobil Toyota Avanza bekas adalah sisi eksterior, sisi interior, dan performa mesin. Kerugian pembeli terjadi karena penjual kurang memperhatikan faktor-faktor di atas dan memasang harga sesukanya. Untuk mengatasi permasalahan tersebut digunakan penerapan logika fuzzy, karena dalam logika fuzzy terdapat data yang bisa diperhitungan untuk memperkirakan harga mobil bekas. Dengan menggunakan *fuzzy logic*, prediksi yang dihasilkan bukanlah prediksi asal yang tidak berdasar. Hasil inferensi dari *fuzzy logic* berupa angka taksiran berdasarkan perhitungan matematis sehingga tingkat keakuratannya bisa diukur (Winarto & Sutojo, 2012).

Logika fuzzy (logika samar) adalah suatu cara yang tepat untuk memetakan suatu ruang input ke dalam suatu ruang output. Di dalam logika fuzzy, juga terdapat fungsi keanggotaan yang merupakan nilai suatu kurva yang menunjukkan pemetaan titik-titik input ke dalam nilai keanggotaannya yang memiliki interval antara 0 sampai 1 (Ayuningtias *et al.*, 2017). Logika fuzzy memungkinkan penggunaan nilai-nilai linguistik dari variabel dan hubungan tidak tepat untuk perilaku sistem modeling. Himpunan fuzzy tidak memiliki batas yang tegas. Namun, metode ini secara matematis tepat dan mewakili pengetahuan yang tersedia dengan akurasi yang cukup baik (Lukács, 2020; Sutara & Kuswanto, 2019). Logika Fuzzy sering digunakan pada sistem cerdas dalam memilah proses untuk mendeteksi cacat dalam penerapannya (Saputra, 2019).

Metode Tsukamoto merupakan perluasan dari penalaran monoton. Pada metode Tsukamoto, setiap konsekuen pada aturan yang berbentuk IF-THEN harus dipresentasikan dengan suatu himpunan fuzzy dengan fungsi keanggotaan yang monoton. Sebagai hasilnya, output hasil inferensi dari tiap-tiap aturan diberikan secara tegas (*crisp*) berdasarkan  $\alpha$ -predikat (*fire strength*) (Sulistiani & Shandi, 2016). Kelebihan dari metode Tsukamoto adalah bersifat intuitif dan dapat memberikan tanggapan berdasarkan informasi yang bersifat kualitatif, tidak akurat, dan ambigu (Ferdiansyah & Hidayat, 2018).


### 1) Linear Naik



Gambar 1. Grafik Fuzzy Linear Naik

$$\mu(x) = \begin{cases} 0; & x \leq a \\ \frac{(x - a)}{(b - a)} & a \leq x \leq b \\ 1; & x \geq b \end{cases}$$

## 2) Linear Turun



Gambar 2. Grafik Fuzzy Linear Turun

$$\mu(x) = \begin{cases} 1; & x \leq a \\ \frac{(b-x)}{(b-a)} & a \leq x \leq b \\ 0; & x \geq b \end{cases}$$

Sistem fuzzy Sugeno memiliki kelemahan terutama pada bagian THEN, yaitu dengan adanya perhitungan matematika sehingga tidak dapat menyediakan kerangka alami untuk representasikan pengetahuan manusia dengan sebenarnya. Secara umum bentuk model inferensi fuzzy Sugeno Orde-Satu adalah:

$$\text{IF } (x_1 \text{ is } A_1) \text{ o } (x_2 \text{ is } A_2) \text{ o } \dots \text{ o } (X_N \text{ is } A_N) \\ \text{THEN } z = p_1 * x_1 + \dots + p_N * x_N + q$$

Dengan  $A$  adalah himpunan fuzzy ke- $i$  sebagai anteseden, dan  $P_i$  Adalah suatu konstanta (tegas) ke-I dan  $q$  juga merupakan konstanta dalam konsekuen. Dalam penelitiannya, Ayuningtias *et al.* (2017) menyatakan bahwa metode Mamdani mempunyai tingkat *error* yang lebih kecil (sebesar 19,76%) dibandingkan dengan metode Tsukamoto (39,03%) dan Sugeno sebesar 86,41% pada prediksi jumlah pendaftar mahasiswa baru.

Penelitian untuk penentuan harga jual sepeda motor juga menunjukkan bahwa metode Sugeno juga lebih unggul dibandingkan metode Tsukamoto (Astuti & Mashuri, 2020). Berdasarkan latar belakang yang telah dideskripsikan, maka penelitian ini bertujuan untuk menganalisis perbandingan tingkat akurasi penentuan harga jual mobil bekas dari kedua metode.

### METODE

Penelitian ini merupakan penelitian komparatif, sejenis penelitian deskriptif yang ingin mencari jawaban secara mendasar tentang sebab akibat, dengan menganalisis faktor-faktor penyebab terjadinya ataupun munculnya suatu fenomena tertentu (Saputra, 2016). Pada penelitian ini dilakukan analisis perbandingan harga mobil bekas Toyota Avanza berdasarkan metode Tsukamoto, dan Sugeno dengan menggunakan variabel yang sama. Sampel data yang digunakan adalah data penjualan mobil bekas pada UD. Dito Motor, Banyumanik, Semarang (Tabel 1).

Data penjualan mobil bekas untuk produk Toyota Avanza 1.3 G M/T dan 1.3 G A/T pada bulan Desember 2011 (Winarto & Sutojo, 2012). Fungsi aturan dalam penelitian ini menggunakan metode MIN. Aturan (*rule*) dapat dilihat pada Tabel 2. Analisis perbedaan tingkat *error* masing-masing metode dievaluasi dengan menggunakan perhitungan AFER (*Average Forecasting Error Rate*). Secara keseluruhan, tahapan penelitian ditampilkan pada Gambar 3.




Tabel 1. Sampel Data Penjualan Mobil Bekas

N O	Tipe Mobil	Warna ( $X_1$ )	Transmisi ( $X_2$ )	Kondisi (%) ( $X_3$ )	Harga Baru(Jt) ( $X_4$ )	Tahun ( $X_5$ )	Harga Bekas(Jt)
1.	Avanza 1.3 G	Silver	Automatic	75	150	2004	114
2.	Avanza 1.3 G	Silver	Manual	80	145	2004	115
3.	Avanza 1.3 G	Hitam	Manual	80	148	2005	113
4.	Avanza 1.3 G	Hitam	Automatic	80	155	2005	117
5.	Avanza 1.3 G	Silver	Automatic	80	155	2006	116
6.	Avanza 1.3 G	Silver	Manual	85	149	2006	120
7.	Avanza 1.3 G	Silver	Automatic	82	155	2007	124
8.	Avanza 1.3 G	Hitam	Automatic	85	155	2007	129,5
9.	Avanza 1.3 G	Hitam	Manual	90	155	2007	133
10.	Avanza 1.3 G	Hitam	Manual	92	155	2008	135
11.	Avanza 1.3 G	Silver	Automatic	85	165	2009	132
12.	Avanza 1.3 G	Hitam	Manual	90	155	2009	134
13.	Avanza 1.3 G	Hitam	Manual	90	158	2009	136,5
14.	Avanza 1.3 G	Hitam	Manual	90	158	2009	137,5
15.	Avanza 1.3 G	Hitam	Manual	95	160	2010	138

Tabel 2. Basis Aturan

Kode	Aturan ( <i>rules</i> )
R1	IF HargaBaru <b>mahal</b> AND Kondisi <b>bagus</b> Then HargaBekas <b>mahal</b>
R2	IF HargaBaru <b>mahal</b> AND Kondisi <b>sedang</b> Then HargaBekas <b>mahal</b>
R3	IF HargaBaru <b>murah</b> AND Kondisi <b>bagus</b> Then HargaBekas <b>murah</b>
R4	IF HargaBaru <b>murah</b> AND Kondisi <b>sedang</b> Then HargaBekas <b>murah</b>



Gambar 3. Tahapan Penelitian

## HASIL DAN PEMBAHASAN

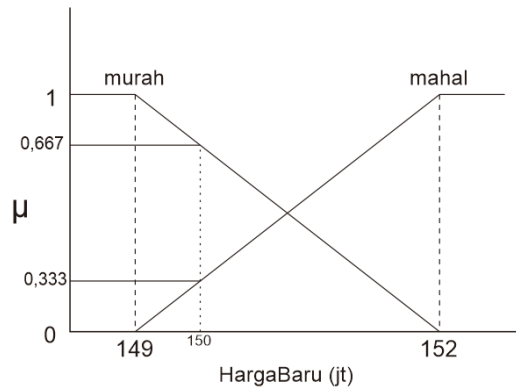
### Mesin inferensi metode *Fuzzy Tsukamoto*

Fungsi inferensi *fuzzy* Tsukamoto menggunakan MIN, yaitu dengan mengambil nilai minimum dari variabel input sebagai output. Menghitung nilai keanggotaan himpunan masing-masing variabel

Harga mobil Toyota Avanza baru

$$\mu_{\text{mahal}}(150), (150-149)/3 = 0,333$$

$$\mu_{\text{murah}}(150), (152-150)/3 = 0,667$$




Gambar 4. Grafik variabel harga baru

Kondisi mobil Toyota Avanza

$$\mu_{\text{bagus}}(75), (75-80)/15 = 0$$

$$\mu_{\text{sedang}}(75), (95-75)/15 = 1$$



Gambar 5. Grafik variabel kondisi

Menghitung nilai keanggotaan (inferensi) anteseden ( $\alpha$ -predikat) dan nilai  $z$  untuk tiap rule *fuzzy*.

$$R1 = \min(0.333, 0)$$

$$0 = \frac{z-130}{10}$$

$$z = 130 + 0 = 130$$

$$R2 = \min(0.333, 1)$$

$$0,333 = \frac{z-130}{10}$$

$$z = 130 + 3,33 = 133,33$$

$$R3 = \min(0.667, 0)$$

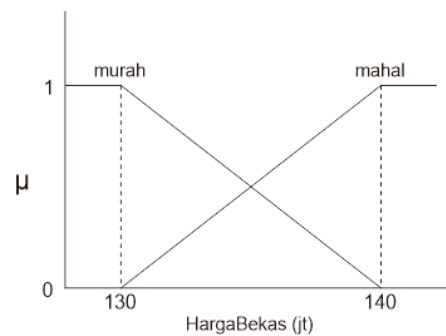
$$0 = \frac{140-z}{10}$$

$$z = 140 - 0 = 140$$

$$R4 = \min(0.667, 1)$$

$$0,667 = \frac{140-z}{10}$$

$$z = 140 - 6,67 = 133,33$$



Gambar 6. Grafik variabel harga bekas

Menentukan *Output Crisp* (Defuzzifikasi)

$$\begin{aligned}
 &= \frac{(\alpha_{pred1} * z_1) + (\alpha_{pred2} * z_2) + (\alpha_{pred3} * z_3) + (\alpha_{pred4} * z_4)}{\alpha_{pred1} + \alpha_{pred2} + \alpha_{pred3} + \alpha_{pred4}} \\
 &= \frac{(0 * 140) + (0,333 * 133,33) + (0 * 130) + (0,667 * 133,33)}{0 + 0,333 + 0 + 0,667} \\
 &= 133,33
 \end{aligned}$$

**Mesin inferensi metode Fuzzy Sugeno**

Konsekuensi Rule 1

$$Z_1 = \text{HargaBaru} - \text{HargaBekas} = 150 - 114 = 36$$

Konsekuensi Rule 2

$$Z_2 = \text{HargaBaru} = 150$$

Konsekuensi Rule 3

$$Z_3 = \text{HargaBaru} = 150$$

Konsekuensi Rule 4

$$Z_4 = 1,25 * \text{HargaBaru} - \text{HargaBekas} = 1,25 * 150 - 114 = 73,5$$

Menentukan *Output Crisp* (Defuzzifikasi)

$$\begin{aligned}
 &= \frac{(\alpha_{pred1} * z_1) + (\alpha_{pred2} * z_2) + (\alpha_{pred3} * z_3) + (\alpha_{pred4} * z_4)}{\alpha_{pred1} + \alpha_{pred2} + \alpha_{pred3} + \alpha_{pred4}} \\
 &= \frac{(0 * 36) + (0,091 * 150) + (0 * 150) + (0,909 * 73,5)}{0 + 0,091 + 0 + 0,909} \\
 &= 99
 \end{aligned}$$

**Perbandingan prediksi metode Tsukamoto dan Sugeno**

Untuk menghitung akurasi prediksi, penulis menggunakan perhitungan AFER (*Average Forecasting Error Rate*) untuk menentukan nilai error dari prediksi tersebut. Berikut rumus perhitungan AFER :

$$AFER = \frac{\sum \left( \frac{A_i - F_i}{A_i} \right)}{n} \times 100\%$$

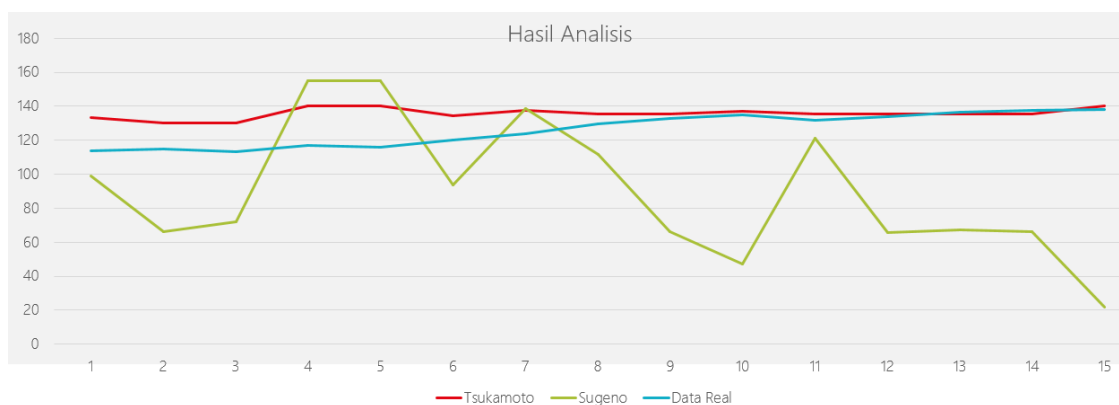
Dimana  $A_i$  merupakan nilai aktual pada data, dan  $F_i$  adalah nilai hasil prediksi untuk data ke-i. Adapun n adalah banyaknya data (Fauzan *et al.*, 2019).

Tabel 3. Hasil Uji Prediksi Menggunakan Metode Tsukamoto

No.	Harga Mobil Bekas (A)	Hasil Prediksi (F) Tsukamoto	(A-F)	(A-F)/A
1	114,0	133,333	19,333	0,170
2	115,0	130,000	15,000	0,130
3	113,0	130,000	17,000	0,150
4	117,0	140,000	23,000	0,197
5	116,0	140,000	24,000	0,207
6	120,0	134,444	14,444	0,120
7	124,0	137,689	13,689	0,110
8	129,5	135,556	6,056	0,047
9	133,0	135,556	2,556	0,019
10	135,0	136,800	1,800	0,013
11	132,0	135,556	3,556	0,027
12	134,0	135,556	1,556	0,012
13	136,5	135,556	0,944	0,007
14	137,5	135,556	1,944	0,014
15	138,0	140,000	2,000	0,014
		Rata-rata		<b>0,083</b>
		Dalam persen		<b>8%</b>

Tabel 4. Hasil Uji Prediksi Menggunakan Metode Sugeno

No.	Harga Mobil Baru (A)	Hasil Prediksi (F) Sugeno	(A-F)	(A-F)/A
1	114,0	99,000	15,000	0,132
2	115,0	66,250	48,750	0,424
3	113,0	72,000	41,000	0,363
4	117,0	155,000	38,000	0,325
5	116,0	155,000	39,000	0,336
6	120,0	93,833	26,167	0,218
7	124,0	138,467	14,467	0,117
8	129,5	111,833	17,667	0,136
9	133,0	66,333	66,667	0,501
10	135,0	47,000	88,000	0,652
11	132,0	121,000	11,000	0,083
12	134,0	65,667	68,333	0,510
13	136,5	67,000	69,500	0,509
14	137,5	66,333	71,167	0,518
15	138,0	22,000	116,000	0,841
Rata-rata Dalam persen				<b>0,378</b> <b>38%</b>



Gambar 7. Grafik Perbandingan Metode Tsukamoto Dan Sugeno Dengan Data *Real*

Dari perhitungan tersebut didapatkan nilai AFER dengan metode Tsukamoto sebesar 8%, sementara metode Sugeno sebesar 38%, yang berarti bahwa metode Tsukamoto mempunyai nilai *error* yang lebih kecil dan mempunyai tingkat akurasi yang lebih tinggi dibandingkan dengan metode Sugeno.

## SIMPULAN

Metode fuzzy Tsukamoto mempunyai tingkat *error* yang lebih kecil (sebesar 8%) dibandingkan metode Sugeno (sebesar 38%) pada prediksi harga mobil bekas Toyota Avanza. Metode Tsukamoto yang lebih tepat dan akurat untuk memprediksi harga mobil bekas Toyota Avanza 2004-2010. Faktor penentu dari sistem prediksi harga mobil bekas ini adalah batasan nilai pada fungsi keanggotaan masing-masing variabel. Untuk meningkatkan akurasi prediksi, diperlukan batasan yang lebih optimal, agar menghasilkan nilai *error* yang lebih kecil pada sistem prediksi ini. Selain itu nilai dari variabel “kondisi” tidaklah memiliki satuan yang jelas, sehingga sistem prediksi memerlukan kemampuan khusus manusia untuk menilai kondisi mobil/sistem yang dapat menilai kondisi mobil, karena perbedaan nilai pada variabel tersebut dapat mengakibatkan hasil yang cukup berbeda. Perlu kajian lebih mendalam tentang metode algoritma yang digunakan, serta penentuan batas fungsi keanggotaan derajat fuzzy untuk menghasilkan akurasi yang lebih optimal.

## DAFTAR PUSTAKA

- Astuti, D. P. P. & Mashuri. (2020). Penerapan metode fuzzy Tsukamoto dan Fuzzy Sugeno dalam penentuan harga jual sepeda motor. *Unnes Journal of Mathematics*, 9(2), 125-130.
- Ayuningtias, L. P., Irfan, M., & Jumadi. (2017). Analisa perbandingan logic fuzzy metode Tsukamoto, Sugeno, dan Mamdani (studi kasus : prediksi jumlah pendaftar mahasiswa baru Fakultas Sains dan Teknologi Universitas Islam Negeri Sunan Gunung Djati Bandung). *Jurnal Teknik Informatika*, 10(1), 9-16.
- Fauzan, M. A., Setiawan, B. D., & Indriati. (2019). Algoritma genetika untuk optimasi fuzzy time series dalam memprediksi debit air (studi kasus: PDAM Indramayu). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(1), 831-835.
- Ferdiansyah, Y. & Hidayat, N. (2018). Implementasi metode fuzzy Tsukamoto untuk diagnosis penyakit pada kelamin laki laki. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(12), 7516-7520.
- Lukács, J. (2020). A fuzzy approach for in-car sound quality prediction. *Acta Polytechnica Hungarica*, 17(6),75-94.
- Saputra, E. W. (2019). Optimasi fungsi keanggotaan fuzzy Mamdani menggunakan algoritma genetika untuk penentuan penerima beasiswa. *Jurnal Sistem Informasi dan Manajemen Basis Data (SIMADA)*, 2(2), 161-165.
- Saputra, K. E. A. (2016). Studi komparatif prestasi belajar mahasiswa jurusan pendidikan ekonomi ditinjau dari jalur penerimaan mahasiswa baru tahun 2011. *Jurnal Jurusan Pendidikan Ekonomi*, 6(1),
- Suliastiani, E. & Shandi, N. (2016). Penerapan FIS metode Tsukamoto untuk menentukan kelayakan pemberian kredit. *Jurnal Informatika Universitas Pamulang*, 1(1), 22-27.
- Sutara, B. & Kuswanto, H. (2019). Analisa perbandingan fuzzy logic metode Tsukamoto, Sugeno, Mamdani dalam penentuan keluarga miskin. *Infotekmesin*, 10(2), 38-49.
- Winarto, S. S. & Sutojo, T. (2012). Menentukan harga mobil bekas dengan menggunakan metode fuzzy Mamdani dan metode jaringan syaraf tiruan. *Techno.com*, 11(3), 134-141.

## **Analisis Citra Hasil Scanning Electron Microscopy Energy Dispersive X-Ray (SEM EDX) Komposit Resin Timbal dengan Metode Contrast to Noise Ratio (CNR)**

**Alvin Fachrully Septiano\*, Susilo, Natalia Erna Setyaningsih**

Jurusan Fisika, FMIPA, Universitas Negeri Semarang, Indonesia  
Gedung D7 Lt.2, Kampus Sekaran Gunungpati, Semarang 50229  
\*E-mail: [alvinfachrully@mail.unnes.ac.id](mailto:alvinfachrully@mail.unnes.ac.id)

Diterima 21 Mei 2021

Disetujui 6 September 2021

Dipublikasikan 31 Oktober 2021

### **Abstrak**

Bahan resin timbal menjadi bahan alternatif dari bahan proteksi radiasi. Scanning Electron Microscopy Electron Dispersive X-ray (SEM EDX) banyak digunakan sebagai karakterisasi suatu material karena mampu mendapatkan hasil topologi dan nilai konsentrasi atomik dari suatu bahan. Dalam penelitian dilakukan uji SEM EDX dengan sampel resin timbal berbentuk serbuk dengan variasi komposisi resin dan timbal asetat sebesar 0;100, 90;10, 70;30, dan 50;50. Hasil scan EDX menunjukkan komposisi 50;50 memiliki kandungan timbal lebih besar sehingga mampu menjadi bahan proteksi yang baik. Sedangkan uji SEM menghasilkan data berupa citra yang dilakukan perbesaran sebesar 3000, 5000 dan 10.000x. Hasil analisis citra SEM menggunakan metode Contrast to Noise Ratio (CNR) menghasilkan rata-rata nilai CNR pada perbesaran 3000, 5000 dan 10.000 kali adalah 8.085, 11.0425, dan 18.495. Dari hasil rata-rata nilai CNR dapat disimpulkan bahwa nilai CNR paling besar pada citra dengan perbesaran 10.000 kali dan dari hasil pengamatan visual citra dengan perbesaran 10.000 kali memiliki detail yang lebih baik dibandingkan perbesaran lainnya sehingga peneliti lebih mudah menentukan objek dan background.

Kata kunci: *Timbal, Scanning Electron Microscopy Electron Dispersive X-ray (SEM EDX), Topologi, Contrast to Noise Ratio (CNR)*

### **Abstract**

*Lead resin is an alternative material for radiation protection. Scanning Electron Microscopy Dispersive Electron X-ray (SEM EDX) is widely used as a material characterization because it can obtain topological results and atomic concentration values of a material. In this study, SEM EDX test was conducted with resin samples in powder form with variations in resin and lead acetate compositions of 0; 100, 90; 10, 70; 30, and 50; 50. The results of the EDX scan show that the composition of 50;50 has a higher lead content so that it can be a good radiation protection material. While the SEM test produces data in the form of images that are magnified at 3000, 5000 and 10,000x. The results of SEM image analysis using the Contrast to Noise Ratio (CNR) method produce the average CNR values at magnifications of 3000, 5000 and 10,000 times, namely 8085, 11.0425, and 18.495. From the results of the average CNR value, it can be ascertained that the largest CNR value with a magnification of 10,000 times and from visual researchers with a magnification of 10,000 times has better detail than other magnifications so that it is easier to determine objects and backgrounds.*

Key words: Resin, Lead, Scanning Electron Microscopy Electron Dispersive X-ray (SEM EDX), Topology, Contrast to Noise Ratio (CNR)

### **How to cite:**

Septiano, A.F., Susilo, & Setyaningsih, N.E. (2021). Analisis citra hasil scanning electron microscopy energy dispersive X-Ray (SEM EDX) komposit resin timbal dengan metode contrast to noise ratio (CNR). *Indonesian Journal of Mathematics and Natural Sciences*, 44(2), 81-85

### **PENDAHULUAN**

Penggunaan bahan campuran resin dan timbal asetat telah disarankan sebagai bahan alternatif penyusun dari kaca timbal (Septiano *et al.*, 2020). Dalam bidang radiologi kaca timbal digunakan sebagai peralatan proteksi radiasi. Sinar-X adalah gelombang elektromagnetik yang memiliki panjang gelombang antara  $10^{-9}$  sampai  $10^{-8}$  m yang jauh lebih pendek dari cahaya tampak, sehingga energinya lebih besar. Interaksi radiasi pada manusia dapat menyebabkan perubahan struktur sel, hal ini dapat menimbulkan kerugian bagi pekerja atau pasien dari yang paling ringan sampai yang paling fatal. Oleh karena itu

membutuhkan sistem pelindung radiasi untuk menghindari bahaya yang tidak diinginkan dan memanfaatkan radiasi. Berbagai bahan pelindung digunakan untuk melemahkan atau benar-benar menyerap radiasi, salah satu bahan alternatif yang di sarankan salah satunya resin timbal (Septiano *et al.*, 2021).

Scanning Electron Microscopy (SEM) merupakan salah satu jenis mikroskop elektron yang mampu menghasilkan resolusi tinggi dari gambaran permukaan suatu sampel. Prinsip kerja alat SEM adalah dengan memanfaatkan hamburan balik elektron (electron beam) pada permukaan objek dan mengambil gambar dengan mendeteksi elektron yang muncul pada permukaan objek (Setyaningsih & Septiano, 2019). Kemajuan dalam penggunaan *Scanning Electron Microscopy* (SEM) memungkinkan pemindaian area yang luas dan mengumpulkan sejumlah besar data untuk mendapatkan karakteristik sampel, diantaranya adalah menghitung objek dan mengumpulkan statistik objek tersebut, salah satunya mendapatkan citra morfologi ukuran untuk menentukan distribusi ukuran (Kharin, 2020). Pengujian Scanning Electrom Microscopy (SEM) memungkinkan mendapatkan hasil citra morfologi dan konsentrasi dari campuran bahan (Septiano *et al.*, 2021).

*Contrast to Noise Ratio* (CNR) dapat didefinisikan sebagai kemampuan sistem pencitraan untuk memvisualisasikan struktur tertentu relatif terhadap sekitarnya dan *noise* sinyalnya (Harun *et al.*, 2019). Contrast to Noise Ratio (CNR) menggambarkan rasio perbedaan kontras terhadap tingkat noise pada gambar dan digunakan sebagai ukuran kualitas gambar yang bergantung pada kontras dari background dan objek (Kocasarac *et al.*, 2020). Dalam penelitian ini digunakan hasil citra SEM dengan variasi perbesaran dan diuji dengan metode CNR dengan aplikasi matlab 2015b.

## METODE

Metode yang digunakan dalam penelitian ini adalah metode eksperimen. Alat yang digunakan dalam penelitian ini adalah suite SEM EDX Merk Phenom Pro X dan software Matlab 2015a. Bahan yang digunakan timbal asetat dan resin yukalac 108. Alur penelitian ini diawali dengan pencarian komposisi campuran terbaik dengan membuat sampel awal dengan perbandingan timbal asetat dan resin 0:100, 10:90, 30:70, dan 50:50.

Objek dicetak pada media plastik berbentuk tabung. Dalam proses pencampuran bahan sampel diperlukan pemanasan menggunakan bunsen agar campuran memiliki suhu 60°C untuk menghilangkan gelembung pada saat proses pencetakan dan proses pengeringan menggunakan suhu ruangan agar proses pengeringan dapat diamati. Kemudian sampel dihaluskan untuk mendapatkan presisi yang optimal, yang mana dari proses abrasif tersebut menghasilkan serbuk yang digunakan sebagai sampel uji SEM EDX. Citra morfologi hasil scan SEM EDX dilakukan analisis menggunakan gui Matlab 2015a.

Perhitungan CNR dapat dijelaskan dengan mendapatkan ukuran yang digunakan untuk menentukan kualitas gambar. CNR mirip dengan rasio signal-to-noise (SNR) matrix, tetapi mengurangi substrat sebelum mengambil rasio. Persamaan CNR adalah sebagai berikut (Prieto *et al.*, 2020).

$$CNR = \frac{\text{Mean Pick Value (object)} - \text{Mean Pick Value (background)}}{\sqrt{\frac{\text{Standard Deviasi (object)}^2 + \text{Standard Deviasi (background)}^2}{2}}}$$

## HASIL DAN PEMBAHASAN

### Uji *Scanning Electron Microscopy* dan *Energy Dispersive X-ray Spectroscopy* (SEM EDX)

Pengujian dilakukan dengan variasi komposisi 0:100, 10:90, 30:70, dan 50:50 dengan preparasi sampel bubuk dan pelapisan dengan gas argon dan menghasilkan data seperti dalam Tabel 1. Dari data pada Tabel 1 uji EDX dapat menunjukkan hasil campuran dengan komposisi 90:10 Kandungan Karbon (C) diperoleh konsentrasi 87,09%, kandungan Timbal (Pb) dapat konsentrasi 2,39%, sedangkan kandungan Oksigen (O) sebesar 10,59%. Untuk campuran dengan komposisi 70:30, kandungan karbon konsentrasi 57,39%, kandungan timbal 20,51%, sedangkan kandungan oksigen 22,11%. Dan hasil campuran dengan komposisi 50:50, kandungan karbon diperoleh konsentrasi 40,62%, kandungan Timbal (Pb) diperoleh konsentrasi 31,61%, sedangkan kandungan oksigen 27,77%. Pada komposisi 100:0 hanya memiliki kandungan karbon 85,26% dan kandungan oksigen 14,47%.


Dari data terlihat bahwa hasil pencampuran perbandingan resin dan timbal asetat menghasilkan 3 elemen utama yakni Karbon (C), Oksigen (O) dan Timbal (Pb). Dengan adanya unsur timbal dalam campuran maka sampel mampu menjadi bahan proteksi radiasi. Unsur timbal sangat cocok untuk mengurangi efek sinar gamma dan sinar-X karena memiliki nomor atom yang tinggi (Tishkevich, 2018).

Tabel 1. Hasil Pengujian EDX

Komposisi Resin:Timbal Asetat	Konsentrasi Atomik (%)	Elemen
90:10	87,09	C
	10,52	O
	2,39	Pb
70:30	57,39	C
	22,11	O
	20,51	Pb
50:50	40,62	C
	27,77	O
	31,61	Pb
100:0	85,26	C
	14,47	O
	0,00	Pb

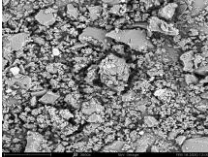
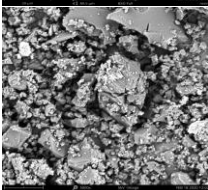
**Analisis citra scanning electron microscopy dan energy dispersive X-ray spectroscopy (SEM EDX)**

Dalam penelitian ini digunakan citra *Scanning Electron Microscopy* (SEM) dengan perbesaran 3000, 5000, 10.000 kali dan menggunakan analisis *Contrast to Noise Ratio* (CNR) pada aplikasi Matlab 2015a. Gui analisis CNR dikembangkan dengan aplikasi matlab (Gambar 1) sehingga memudahkan peneliti untuk melakukan analisis CNR sebuah citra. Peneliti hanya menentukan sisi background dan objek sebuah citra.

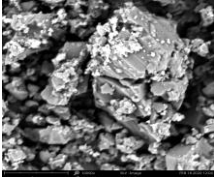
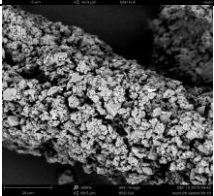

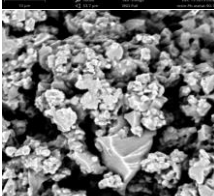

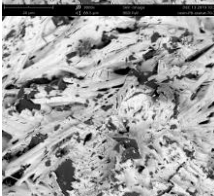

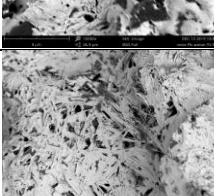



Gambar 1. Desain gui Matlab 2015


Tabel 2. Hasil Analisis Citra Morfologi SEM EDX

Komposisi Resin:Timbal Asetat	Perbesaran	Citra	CNR	Standar Deviasi
100:0	3000		8,90	17,56
	5000		9,46	14,65



		10000		12,64	14,41
90:10		3000		13,61	13,37
		5000		18,67	9,63
		10000		25,94	7,12
70:30		3000		4,56	36,90
		5000		8,63	18,39
		10000		15,58	9,14
50:50		3000		5,27	26,47
		5000		7,41	21,23

10000



19,82

7,02

Dari Tabel 2 menunjukkan bahwa nilai CNR pada perbesaran 1000x memiliki nilai yang paling besar di bandingkan perbesaran 3000 dan 5000. Pada komposisi 100:0 didapatkan nilai CNR dengan perbesaran 3000, 5000 dan 10.000 adalah 8,90; 9,46 dan 12,64. Pada komposisi 90:10 didapatkan nilai CNR dengan perbesaran 3000, 5000 dan 10.000 adalah 13,61; 18,67, dan 25,94. Pada komposisi 70:30 didapatkan nilai CNR dengan perbesaran 3000, 5000 dan 10.000 adalah 4,56; 8,63 dan 15,58. Sementara komposisi 50:50 didapatkan nilai CNR dengan perbesaran 3000, 5000 dan 10.000 adalah 5,27; 7,41 dan 19,82. Hasil rata-rata nilai CNR pada perbesaran 3000, 5000 dan 10.000 kali adalah 8,085; 11,0425 dan 18,495. Dari hasil rata-rata nilai CNR dapat disimpulkan bahwa nilai CNR paling besar pada citra dengan perbesaran 10.000 kali dan dari hasil pengamatan visual citra dengan perbesaran 10.000 kali memiliki detail yang lebih baik dibandingkan perbesaran lainnya sehingga lebih mudah menentukan objek dan background.

## SIMPULAN

*Scanning Electron Microscopy dan Energy Dispersive X-ray (SEM EDX)* dapat digunakan sebagai karakterisasi suatu bahan dan perbesaran citra hasil SEM mempengaruhi nilai analisis CNR. Semakin besar nilai CNR semakin besar dan kualitas citra yang semakin baik.

## DAFTAR PUSTAKA

- Harun, A.Z., Rashud, R.A., Razak, K.A., Geso, M., Rahman, W.N.W.A. (2019). Evaluation of contrast-noise ratio (CNR) in contrast enhanced CT images using different sizes of gold nanoparticles. *Materials Today: Proceedings*, 16, 1757-1765.
- Kharin, A.Y. (2020). Deep learning for scanning electron microscopy: synthetic data for the nanoparticle's detection. *Ultramicroscopy*, 113125.
- Kocasarac, H.D.,Kursun-Cakmak, E.S., Ustaoglu, G., & Noujeim, M. (2020). Assessment of signal-to-noise ratio and contrast-to-noise ratio in 3 T magnetic resonance imaging in the presence of zirconium, titanium, and titanium-zirconium alloy implants. *Oral and Maxillofacial Radiology*, 129 (1),
- Prieto, D., Chiva, M., Orozco, F., Martinez, A.M., Camara, M., Capuz, A.B., Andres, J.C.D., Bejar, M.J., Garcia, J.D., Colmenares, R., Sevillano, D., Moris, R., & Garcia, F. (2020). Dosimetric and contrast noise ratio comparison of three different digital imaging technologies in mammography. *Journal of Medical Imaging and Radiation Sciences*, 51, 88-94.
- Septiano, A.F., Sutanto, H., & Susilo. (2020). Fabrication and analysis of radiation dose for elastic lead polyester composites as a glass coating. *Journal Of Physics: Conf Series*, 1567.
- Septiano, A.F., Sutanto, H., & Susilo. (2021). Synthesis and characterization of resin lead acetatecomposites and ability test of X-ray protection. *Journal Of Physics: Conf Series*, 1918.
- Setyaningsih, N.E. & Septiano, A.F. (2019). Optimasi kualitas citra scanning electron microscopy (sem) dengan metode contrast to noise ratio (CNR). *Prosiding Seminar Nasional IV Hasil Penelitian Pranata Laboratorium Pendidikan Indonesia, IV - ISSN: 2548-1924*.
- Tishkevich, D.I., Grabchikov, S.S., & Lastovskii, S.B. (2018). Function composites materials for shielding applications: correlation between phase separation and attenuation properties. *Journal of Alloys and Compounds*, 771, 238-245.

**Uji Toksisitas Ekstrak Daun Cassava Terhadap Larva *Artemia salina* Leach dengan Metode *Brine Shrimp Lethality Test***

**Rizki Budiyo Putri, WH Nugrahaningsih\*, Nur Kusuma Dewi**

Jurusan Biologi FMIPA Universitas Negeri Semarang  
Jl. Raya Sekaran-Gunungpati, Semarang, Jawa Tengah, Indonesia 50229  
Email: nugrahaningsihwh@mail.unnes.ac.id

Diterima 7 Juni 2021

Disetujui 29 September 2021

ipublikasikan 31 Oktober 2021

**Abstrak**

Daun cassava (singkong; *Manihot esculenta*) merupakan salah satu bahan tanaman yang memiliki potensi untuk dikembangkan sebagai obat herbal. Penelitian ini bertujuan mengetahui nilai LC<sub>50</sub> ekstrak aquades daun singkong yang diuji toksisitas terhadap *Artemia salina* Leach dengan metode brine shrimp lethality test (BSLT). Jenis penelitian experimental dengan Post Test-Only Grup Design. Populasi hewan uji pada penelitian ini adalah larva *Artemia salina* Leach. Sampel diambil dengan kriteria inklusi larva berusia 48 jam dan tidak tampak cacat secara anatomi, dan secara eksklusi menunjukkan aktivitas pergerakan sebelum perlakuan. Variabel bebas penelitian yaitu ekstrak daun singkong dengan konsentrasi 0 µg/ml, 1 µg/ml, 2 µg/ml, 5 µg/ml dan 10 µg/ml. Serta tingkat kematian larva *Artemia salina* Leach sebagai variabel tergantung. Data pada penelitian ini didapatkan dari jumlah larva udang yang mati 24 jam setelah perlakuan. Hasil yang diperoleh pada penelitian ini, ditemukan 2 kematian pada kelompok perlakuan dosis 1 µg/ml, 1 kematian pada kelompok perlakuan dosis 2 µg/ml, 12 kematian pada kelompok perlakuan dosis 5 µg/ml, dan 3 kematian pada kelompok perlakuan dosis 10 µg/ml. Selanjutnya dari data kematian yang diperoleh dianalisis dengan analisis probit pada SPSS 21.0 for windows untuk dihitung nilai LC<sub>50</sub> nya. Setelah dianalisis pada SPSS diperoleh nilai LC<sub>50</sub> untuk ekstrak aquades daun singkong adalah sebesar 493,86 µg/ml.

**Kata kunci:** *Artemia salina* Leach, BSLT, Cassava, *Manihot esculenta*, toksisitas.

**Abstract**

*Cassava (Manihot esculenta) leaf is one of plants potentially develop to medicinal herb. This research aimed to determine the LC<sub>50</sub> value of aquades extract of cassava leaf that was tested its toxicity toward Artemia salina Leach with Brine Shrimp lethality Test method. The type of this research was experimental research with Post Test-Only Design Group. The population of animal test in this research was larva Artemia salina Leach. The samples were taken with inclusion criteria of larva 48 hours old without anatomically defective and with exclusion criteria showed movement activity prior to the treatment. The independent variable of this research t was cassava leaf extract with concentration considered 1 µg/ml, 2 µg/ml, 5 µg/ml, and 10 µg/ml. While the death rate of Artemia salina Leach larvae was as dependent variable. The data in this research was obtained from the number of shrimp larvae that died in 24 hours after treatment. From the results, it was found 2 deaths in experimental grup with dose 1 µg/ml, 1 death in experimental grup with dose 2 µg/ml, 12 deaths in experimental grup with dose 5 µg/ml, and 3 deaths in experimental grup with dose 10 µg/ml. Furthermore, the death's data obtained was calculated by probit analysis on SPSS for windows 21.0 to find its LC<sub>50</sub> value. After analyzed on SPSS, it was obtained LC<sub>50</sub> value for aquades extract of cassava leaf of 493.86 µg/ml.*

**Key words:** *Artemia salina* Leach, BSLT, Cassava, *Manihot esculenta*, toxicity.

**How to cite:**

Putri, R.B., Nugrahaningsih, W.H., & Dewi, N.K. (2021). Uji toksisitas ekstrak daun cassava terhadap larva artemia salina leach dengan metode *brine shrimp lethality test*. *Indonesian Journal of Mathematics and natural Sciences*, 44(2), 86-91

## PENDAHULUAN

Masyarakat Indonesia telah mengenal pemanfaatan tanaman sebagai obat-obatan. Banyak macam tanaman obat telah diteliti kandungan kimia dan khasiatnya. Salah satu tanaman yang dikenal dan dimanfaatkan oleh masyarakat adalah tanaman cassava/singkong (*Manihot esculenta*). Daun Cassava dapat memiliki potensi sebagai antikanker (Sutiningsih *et al.*, 2020; Yusuf *et al.*, 2006), mempercepat penyembuhan luka (Angraini *et al.*, 2017; Megawati *et al.*, 2020; Sukmawati *et al.*, 2021), analgetik (Miladiyah *et al.*, 2011; Bokanisereme *et al.*, 2013), dan antibakteri (Mustarichie *et al.*, 2020).

Tanaman cassava (singkong) banyak tumbuh subur di berbagai wilayah Indonesia. Banyak varietas ditemukan di berbagai wilayah yang berbeda dari seluruh Indonesia. Bagian yang banyak dimanfaatkan pada cassava selain umbinya adalah daunnya. Daun cassava (*Manihot esculenta*) memiliki kandungan protein, vitamin C, flavonoid, saponin, tannin dan triterpenoid (Nisa *et al.*, 2013). Kandungan vitamin C nya lebih tinggi daripada sayuran lainnya, yaitu 275 mg per 100-gram daun singkong. Kadar proteinnya juga cukup tinggi. Daun singkong juga sebagai sumber vitamin A, setiap 100-gram mencapai 3.300 RE sehingga baik untuk kesehatan mata. Kandungan serat daun singkong juga tinggi sehingga dapat memperlancar buang air besar dan mencegah kanker usus serta penyakit jantung. Flavonoid pada daun cassava dapat berperan sebagai antimikroba. Triterpenoid berperan sebagai antifagus dan insektisida serta mempengaruhi sistem saraf manusia. Senyawa triterpenoid, saponin dan flavonoid diduga bersifat toksik pada kadar tertentu. Selain mengandung banyak metabolit yang berguna, daun cassava juga mengandung sianida dengan kadar rendah (Triana & Kamila, 2018). Asam sianida jika dikonsumsi dalam jumlah banyak dapat menyebabkan keracunan.

Sebelum menjadi suatu sediaan fitofarmaka atau obat herbal terstandar, setiap bahan alam harus melewati beberapa tahapan meliputi uji farmakologi eksperimental, uji toksisitas, uji praklinis, uji kualitas dan pengujian lain sesuai persyaratan yang berlaku demi menjamin keamanan masyarakat yang mengkonsumsinya. Uji toksisitas merupakan tahap awal penggunaan daun singkong sebagai obat atau suplemen untuk manusia. *Brine shrimp lethality test* (BSLT) adalah suatu metode pengujian dengan menggunakan hewan uji *Artemia salina* Leach. *Artemia salina* Leach digunakan sebagai hewan uji karena hewan ini merupakan *bioassay* pertama di alam yang mampu mendeteksi ketoksitasan suatu bahan alam. *Artemia salina* Leach merupakan hewan uji standart yang digunakan pada uji toksisitas metode BSLT. Penelitian ini bertujuan untuk mengetahui keamanan penggunaan ekstrak daun singkong sebagai obat untuk manusia dengan menghitung LC<sub>50</sub> menggunakan metode BSLT.

## METODE

### Ekstrak daun cassava

Tanaman singkong yang digunakan pada penelitian ini adalah singkong dari spesies *esculenta* varietas marsinah. Daun cassava dibuat ekstrak dengan pelarut akuades. Proses ekstraksi dilakukan dengan metode maserasi dilakukan di Laboratorium Biokimia Jurusan Biologi UNNES. Ekstrak daun cassava selanjutnya disiapkan dengan konsentrasi 1 µg/ml, 2 µg/ml, 5 µg/ml, dan 10 µg/ml yang dilarutkan pada air laut. Air laut diperoleh dari Balai Besar Perikanan dan Budidaya Air Payau (BBPBAP) Jepara.

### Metode *Brine Shrimp Lethality Test*

Uji BSLT dilakukan di Laboratorium Fisiologi Hewan Jurusan Biologi UNNES. Populasi hewan uji pada penelitian ini adalah larva *Artemia salina* Leach. Telur *Artemia salina* Leach diperoleh dari BBPBAP Jepara. Penetasan dan pemilihan telur *Artemia salina* Leach dilakukan dengan merendam telur artemia pada air laut dengan salinitas 30 ‰ di petri dish. Telur yang baik akan tenggelam dan yang kurang baik akan mengapung. Setelah 24 jam telur yang telah menetas dipindah pada petri yang berbeda agar tidak terjadi kerancuan umur larva. Larva diambil secara acak sebanyak 50 larva, kemudian dibagi menjadi 5 kelompok, masing-masing 10 larva dan ditempatkan pada flakon berisi 5ml air laut. Dengan cara yang sama, dibuat 5 kelompok pengulangan. Kelompok kontrol (K) tanpa diberi ekstrak, kelompok perlakuan 1 (Kp1) diberi 1 µg/ml ekstrak, Kp2 diberi 2 µg/ml ekstrak, Kp3 diberi 5 µg/ml ekstrak, dan Kp4 diberi 10 µg/ml ekstrak. Flakon ditempatkan pada suhu kamar dan tidak terkena sinar matahari langsung selama 24 jam. Setelah 24 jam dihitung larva yang mati pada setiap flakon dan dicatat pada tabel. Nilai LC<sub>50</sub> diperoleh dengan analisis probit menggunakan SPSS 21.0 for windows.

## HASIL DAN PEMBAHASAN

Penelitian uji toksisitas ekstrak akuades daun singkong terhadap larva *Artemia salina* Leach dengan metode BSLT dilakukan dengan mengamati dan mencatat jumlah kematian larva setelah 24 jam pemberian ekstrak. Jumlah larva *Artemia salina* Leach yang mati pada tiap flakon digunakan untuk menghitung LC<sub>50</sub>. Kematian larva *Artemia salina* merupakan respon alami sebagai bioassay yang pertama untuk penelitian keamanan penggunaan bahan alam. Jumlah larva *Artemia salina* Leach yang mati pada tiap flakon disajikan dalam Tabel 1.

Tabel 1. Jumlah Kematian *Artemia salina* Leach pada uji toksisitas ekstrak akuades daun singkong

Ulangan ke-	Mortalitas <i>Artemia salina</i> Leach (ekor)				
	Kontrol	Kp1 (1 µg/ml)	Kp2 (2 µg/ml)	Kp3 (5 µg/ml)	Kp4 (10 µg/ml)
1	0	0	0	3	0
2	0	1	0	3	2
3	0	0	1	2	0
4	0	1	0	3	0
5	0	0	0	1	1
Total	0	2	1	12	3
Rerata	0	0,4	0,2	2,4	0,6
Persentase	0%	4%	2%	24%	6%

Data pada Tabel 1 menunjukkan adanya kematian di semua kelompok perlakuan. Kematian terbanyak ditemukan pada kelompok perlakuan Kp3 yang diberi 5 µg/ml ekstrak akuades yaitu ada 12 kematian larva dari total 50 larva sampel yang diujikan atau tingkat kematiannya 24%. Untuk kelompok perlakuan ketiga yaitu dosis tertinggi 10 µg/ml ditemui 3 kematian dari 50 total larva yang diujikan atau tingkat kematiannya 6%. Hasil analisis probit menunjukkan nilai LC<sub>50</sub> dari ekstrak akuades daun singkong adalah sebesar 493,86 µg/ml.

Untuk memanfaatkan suatu hasil alam sebagai obat atau suplemen harus dilalui beberapa tahapan prosedural. Salah satunya uji toksisitas dengan metode *brine shrimp lethality test*. Daun singkong dipilih sebagai obyek penelitian karena daun singkong mudah ditemui di sekitar kita, harganya pun relatif murah daripada tanaman lain. Pengembangbiakan tanaman singkong juga relatif mudah dan perawatannya murah. Karena tanaman singkong lebih banyak dimanfaatkan umbinya, daun singkong menjadi bahan samping yang pemanfaatannya tidak lebih banyak daripada umbi singkong itu sendiri.

Uji toksisitas dengan BSLT merupakan cara yang paling mudah dan sederhana untuk meneliti toksisitas akut suatu senyawa, dengan cara menentukan nilai LC<sub>50</sub> dari komponen aktif suatu simplisia maupun bentuk sediaan ekstrak suatu tanaman. Apabila suatu ekstrak tanaman bersifat toksik menurut harga LC<sub>50</sub> dengan metode BST, maka tanaman tersebut dapat dikembangkan sebagai obat. Namun, bila tidak bersifat toksik maka tanaman tersebut dapat diteliti kembali untuk mengetahui khasiat lainnya dengan menggunakan hewan coba lain yang lebih besar dari larva *Artemia salina* Leach seperti mencit dan tikus secara *in vivo*.

Suatu senyawa dinyatakan mempunyai potensi toksisitas akut jika mempunyai harga LC<sub>50</sub> kurang dari 1000 µg/ml. LC<sub>50</sub> (*Lethal Concentration 50*) merupakan konsentrasi zat yang menyebabkan terjadinya kematian pada 50% hewan percobaan. Hasil analisis probit dengan SPSS 21.0 menunjukkan nilai LC<sub>50</sub> ekstrak akuades daun singkong sebesar 493,86 µg/ml, sehingga dapat dikatakan ekstrak daun singkong memiliki potensi toksisitas akut menurut metode BST pada perlakuan hewan coba larva *Artemia salina* Leach. Nilai LC<sub>50</sub> yang diperoleh dari uji toksisitas metode BST ekstrak akuades daun singkong dapat dikatakan aman dan dapat digunakan sebagai obat atau suplemen di masa yang akan datang.

Jika dibandingkan dengan beberapa tanaman lain, nilai LC<sub>50</sub> ekstrak akuades daun singkong lebih tinggi daripada nilai LC<sub>50</sub> ekstrak tanaman patah tulang, namun lebih rendah dibandingkan anggur. Nilai LC<sub>50</sub> ekstrak daun singkong (493,86 µg/ml) memiliki tingkat keamanan yang lebih baik jika digunakan untuk obat dari pada kafein yang memiliki nilai LC<sub>50</sub> 306 (Meyer *et al.*, 1982). Ekstrak daun singkong lebih tinggi nilai LC<sub>50</sub> nya daripada kafein. Hal ini mungkin berhubungan dengan beberapa kandungan pada daun singkong, diantaranya kandungan beberapa metabolik sekunder serta sianida pada daun singkong. Nilai LC<sub>50</sub> ini berhubungan dengan kandungan dari daun singkong itu sendiri. Kandungan senyawa dalam daun singkong antara lain adalah flavonoid, triterpenoid,

saponin, tannin dan vitamin C (Nurdiana, 2013). Belum diketahui kandungan sianida dan kandungan lainnya masih utuh atau tidak setelah melalui proses ekstraksi.

Pada kadar tertentu kandungan pada ekstrak akuades daun singkong memiliki potensi toksisitas akut serta dapat menyebabkan kematian larva *Artemia salina* Leach. Mekanisme kematian larva berhubungan dengan fungsi senyawa metabolik sekunder seperti triterpenoid, saponin dan flavonoid dalam daun singkong yang dapat menghambat daya makan larva (*antifedant*). Cara kerja senyawa-senyawa tersebut adalah dengan bertindak sebagai *stomach poisoning* (racun perut) (Rita *et al.*, 2008). Mekanisme kerja dalam menghambat pertumbuhan larva diduga dengan cara menghambat transduksi sinyal ke inti melalui inhibisi protein kinase sehingga menghambat proliferasi dan pertumbuhan sel. Reseptor tirosin kinase berperan dalam meningkatkan pertumbuhan sel. Kandungan saponin bekerja dengan menginduksi *cell cycle arrest* dan apoptosis sel (Supriningrum *et al.*, 2016). Bila senyawa-senyawa ini masuk ke dalam tubuh larva, alat pencernaannya akan terganggu. Selain itu, senyawa ini menghambat reseptor perasa pada daerah mulut larva, mengakibatkan larva gagal mendapatkan stimulus rasa sehingga tidak mampu mengenali makanannya dan larva mati kelaparan (Rita *et al.*, 2008).

Terkait dengan kandungan sianida pada daun singkong, mungkin tidak lebih banyak daripada umbi singkong. Juga belum diketahui apakah sianida masih atau hilang pada proses ekstraksi. Belum ada penelitian mengenai hal ini. Jika pada proses ekstraksi daun singkong ini hilang, maka toksisitas pada daun singkong berkaitan dengan kandungan lain pada daun singkong. Apabila suatu ekstrak tanaman bersifat toksik, maka tanaman tersebut aman dan dapat dikembangkan sebagai obat. Sesuai penelitian sebelumnya yang menyatakan bahwa apabila suatu ekstrak tanaman memiliki nilai LC<sub>50</sub> >1000 dengan metode BST, maka tanaman tersebut aman dan dapat dikembangkan sebagai obat, maka daun singkong dapat dilanjutkan penelitiannya sebagai obat di masa yang akan datang (Mayer *et al.*, 1982).

Singkong memiliki lebih dari 100 varietas, dan yang digunakan pada penelitian ini adalah singkong dari spesies *esculenta* dan varietas *marsinah*. Varietas singkong ini paling banyak dimanfaatkan daunnya oleh masyarakat Indonesia, dan banyak ditemui tumbuh dengan baik di wilayah Jawa Tengah. Salah satu tanaman singkong spesies *Manihot rubricaulis* I.M. JOHNSTON dengan pelarut etanol yang memiliki nilai LC<sub>50</sub> lebih dari 1000. Hal ini menunjukkan bahwa setiap spesies singkong memiliki kandungan yang berbeda baik secara kualitas maupun kuantitasnya, serta tergantung juga pada pelarut yang digunakan dalam proses ekstraksi.

Berikut (Tabel 2) adalah beberapa nilai LC<sub>50</sub> tanaman yang banyak ditemui dan berpotensi untuk dijadikan obat, yang telah dipublikasikan sebelumnya. Dari nilai LC<sub>50</sub> beberapa tanaman tersebut (Tabel 2), nilai LC<sub>50</sub> ekstrak daun singkong berada lebih tinggi dari ekstrak daun patah tulang, namun lebih rendah dibanding ekstrak anggur dan buah pare. Nilai tersebut menunjukkan bahwa ekstrak akuades daun singkong dapat digunakan sebagai obat layaknya ekstrak patah tulang. Nilai keamanannya juga tidak jauh berbeda dari nilai LC<sub>50</sub> ekstrak anggur dengan pelarut etanol. Kemampuan ekstrak akuades daun singkong untuk membunuh larva *Artemia salina* termasuk dalam kategori *practically non-toxic*, karena konsentrasinya >100 µg/ml (Moshi *et al.*, 2010). Kategori *practically non-toxic* membuat ekstrak daun singkong tidak memiliki efek buruk pada penggunaannya karena tidak berada di kategori sangat toksik. Hal ini menunjukkan bahwa keamanan ekstrak daun singkong apabila digunakan sebagai obat atau suplemen.

Tabel 2. Nilai LC<sub>50</sub> Beberapa Tanaman

Tanaman	Pelarut	Nilai LC <sub>50</sub>	Peneliti
Buah Pandan	Etanol	0,25	Rizki Nifsi Ramdhini
Daun Soyogik	Metanol	35,4	Arter D. Muaja
Daun Sambiloto	Metanol	64,5	Lihardo Sinaga
Daun Pletekan	Etanol	142,16	Nurhawa Vitalia
Ranting Patah Tulang	Metanol	332,2489	Sandriani A. Aratmangun
Buah Anggur	Etanol	648,004	Dita Mutia
Buah Lakum	Alkohol 75%	172,38	Retno Prasetya
Akar KB	Etanol	299,23	Risa Supriningrum
Buah Mahkota Dewa	Metanol	0,16	Vivi Lisdawati
Buah Pare	Etanol	519,226	Robby Cahyadi

Uji toksisitas dapat digunakan untuk melakukan skrining jenis tanaman yang berpotensi sebagai antikanker. Pemanfaatan bahan alam untuk dijadikan antikanker dibutuhkan nilai LC<sub>50</sub> yang rendah, karena semakin toksik maka semakin baik untuk mengobati kanker. Nilai LC<sub>50</sub> ekstrak daun singkong tidak menunjukkan potensinya sebagai antikanker. Namun ada beberapa penelitian yang menyatakan bahwa ekstrak daun singkong dapat menurunkan viabilitas sel Raji (Sutiningsih *et al.*, 2020).

Pelarut yang digunakan pada penelitian ini adalah akuades, karena dari penelitian ini diharapkan ekstrak daun singkong dapat dijadikan obat atau suplemen bagi manusia. Jika menggunakan pelarut yang lain dikhawatirkan akan terganjal untuk mendapatkan sertifikat halal. Penggunaan pelarut tergantung pada tujuan penelitian. Jika untuk menarik suatu zat tertentu, maka digunakan pelarut yang dapat melarutkan bahan lain dan menyimpan utuh bahan yang digunakan. Jenis pelarut juga berpengaruh pada nilai LC<sub>50</sub> nya. Ekstrak akuades sebenarnya tidak spesifik menarik suatu zat tertentu, namun keamanannya sebagai obat semakin tinggi.

Penelitian ini terbatas hanya meneliti nilai LC<sub>50</sub> ekstrak akuades daun singkong. Selanjutnya nilai LC<sub>50</sub> dapat dijadikan indikasi kemungkinan toksisitas ekstrak daun singkong. Mekanisme yang menyebabkan kematian pada larva *Artemia salina* Leach diperoleh dari literatur mengenai penelitian serupa. Informasi lain mengenai ekstrak daun singkong, dipelukan penelitian lebih lanjut.

## SIMPULAN

Nilai LC<sub>50</sub> ekstrak akuades daun singkong yang diuji toksisitas terhadap *Artemia salina* Leach dengan metode *Brine Shrimp lethality Test* adalah 493,86 µg/ml. Nilai tersebut memiliki tingkatan yang rendah sehingga tidak toksik.

## UCAPAN TERIMA KASIH

Terima kasih kepada yang terhormat Prof. Dr. Priyantini Widiyaningrum, MS yang telah memberikan banyak masukan selama penelitian dan selama penyusunan artikel ini.

## DAFTAR PUSTAKA

- Anggraini, D., Suhada, A., & Rahmawati, S. (2017). Efektivitas ekstrak etanol daun singkong (manihot esculenta) dalam mengobati luka bakar kulit punggung tikus (*Rattus novergicus*) jantan. *Jurnal Farmasetis*, 6(2), 39-46
- Bokanisereme, Yusuf, U.F., & Okechukwu, P.N. (2013). Anti-inflammatory, analgesic, and anti-pyretic activity of cassava leaves extract. *Asian Journal of Pharmaceutical and Clinical Research*, 6(4), 89-92
- Miladiyah, I., Dayi, F., & Desrini, S. (2011). Analgesic activity of ethanolic extract of Manihot esculenta Crantz leaves in mice. *Universa Medicina*, 30(1), 3-10
- Megawati, S., Nur'aini, & Kurniasih, D. (2020). Uji efektivitas gel ekstrak etanol 96% daun singkong (Manihot esculenta Crantz.) pada penyembuhan luka sayat kelinci jantan galur New Zealand White. *Jurnal Farmagazine*, 7(1), 1-12.
- Moshi, M.J., Innocent, E., Magadula, J.J., Otieno, D.F., & Weisheit, A. (2010). Brine shrimp toxicity of some plants used as traditional medicines in Kagera Region, Northwestern Tanzania. *Tanzania Journal of Health Research*, 12(1), 63-67.
- Mustarichie, R., Sulistiyaningsih, S., & Runadi, D. (2020). Antibacterial activity test of extracts and fractions of cassava leaves (Manihot esculenta Crantz) against clinical isolates of *Staphylococcus epidermidis* and *Propionibacterium acnes* causing acne. *International Journal of Microbiology*. ID.1975904
- Nisa, V.M., Zahara, M., & Puji, A. (2013). Efek pemberian ekstrak daun singkong (manihot esculenta) terhadap proses penyembuhan luka gingiva tikus. *Artikel Ilmiah Hasil Penelitian Mahasiswa*. Universitas Jember.
- Nurdiana, A. R. (2013). Uji ekstrak daun singkong (Manihot esculenta) terhadap jumlah neutrofil pada proses penyembuhan luka tikus (*Rattus norvegicus*). *Skripsi*. Universitas Jember.
- Rita, W.S., Suirta, I.W., & Sabikin, A. (2008). Isolasi dan identifikasi senyawa yang berpotensi sebagai antitumor pada daging buah pare (*Momordica charantia* L.). *Jurnal Kimia (Journal of Chemistry)*, 2(1).
- Sukmawati, S.S., Hastuti, S., & Rejeki, S. (2021). Activity test of the ethanol extract of cassava leaves (Manihot esculenta Crantz) against the healing of crosses in rabbit. *Indonesian Journal on Medical Science*, 8(2), 160-165.

- Supriningrum, R., Sapri, & Pranamala, V.A. (2016). Uji toksisitas akut ekstrak etanol akar kb (*Coptosapelta tomentosa* Valetton ex K.Heyne) dengan metode brine shrimp lethality test (BST). *Jurnal Ilmiah Manuntung*, 2(2), 161-165.
- Sutiningsih, D., Wuryanto, M.A., Susanto, H.S., Hariyadi, S., & Mustofa. (2020). anticancer activity of linamarin from cassava leaves (*Manihot esculenta* Cranz) on raji cells. *International Journal of Cancer Research*, 16(1), 18-27,
- Triana, L., & Kamila, L. (2018). Analisis kadar asam sianida pada ubi kayu yang direndam dalam larutan nahco3 20% dengan variasi waktu. *Jurnal Laboratorium Khatulistiwa*, 1(2), 130-136
- Yusuf, U.F., Fakhru'l-Razi, A., Rosli, R., Iyuke, S.E., Billa, N., Abdullah, N., & Umar-Tsafe, N. (2006). An in vitro inhibition of human malignant cell growth of crude water extract of cassava (*Manihot esculenta* Crantz) and commercial linamarin. *Songklanakarinn Journal of Science and Technology*, 28(Suppl. 1), 145-155.