

## PENERAPAN METODE *HYBRID* FIS TSUKAMOTO DAN ALGORITMA GENETIKA UNTUK PREDIKSI CURAH HUJAN DI DAERAH BATU

Ida Wahyuni<sup>1</sup>, Fadhli Almu'iini Ahda<sup>2</sup>, Philip Faster Eka Adipraja<sup>3</sup>

<sup>1,2,3</sup>Program Studi Informatika, STMIK Asia Malang, Jalan Soekarno Hatta-Rembuksari No.1A, Malang, Indonesia, (0341) 478877

Email: <sup>1</sup>idawahyuni@asia.ac.id, <sup>2</sup>fadhli@asia.ac.id, <sup>3</sup>philipfaster@gmail.com

(Naskah masuk: 31 Mei 2018, diterima untuk diterbitkan: 28 Agustus 2018)

### Abstrak

Curah hujan yang semakin tidak menentu memberikan efek yang cukup signifikan pada bidang pertanian dan perkebunan. Salah satu bidang perkebunan yang memanfaatkan pola curah hujan adalah perkebunan apel. Petani apel membutuhkan perhitungan curah hujan untuk menentukan kapan proses pembungaan yang tepat agar hasil panen yang dihasilkan dapat maksimal. Namun, karena tidak menentunya pola curah hujan, petani menjadi kesulitan dalam menentukan waktu pembungaan dan panen apel menjadi tidak maksimal. Pada penelitian ini dibuat sebuah pemodelan yang paling optimal dalam memprediksi curah hujan di daerah Batu, Jawa Timur menggunakan metode *hybrid* FIS Tsukamoto dan algoritma genetika. Metode *hybrid* yang dilakukan adalah mengoptimasi batasan fungsi keanggotaan FIS Tsukamoto menggunakan algoritma genetika. Setelah proses pengujian, penerapan metode Metode *hybrid* FIS Tsukamoto dan algoritma genetika dapat digunakan untuk memprediksi curah hujan dengan *error* RMSE lebih kecil jika dibandingkan dengan FIS Tsukamoto tanpa optimasi. Nilai *error* RMSE pada daerah Junggo sebesar 6.485, pada daerah Pujon sebesar 6.932, pada daerah Tinjomulyo sebesar 5.969, pada daerah Ngujung sebesar 5.498.

**Kata kunci:** Algoritma Genetika, Curah Hujan, FIS Tsukamoto, Hybrid, Kota Batu, Prediksi

## APPLICATION OF HYBRID FIS TSUKAMOTO AND GENETIC ALGORITHM FOR RAINFALL PREDICTION IN BATU REGION

### Abstract

*The erratic rainfall has a significant effect on agriculture and plantations. One area of plantations that utilizes rainfall patterns is apple plantations. Apple farmers need rainfall calculations to determine when the flowering process is right so that the yield can be maximized. However, due to the uncertainty of rainfall patterns, farmers have difficulty in determining the time of flowering and harvesting apples to be not optimal. In this study, the most optimal modeling was used to predict rainfall in the Batu area, East Java using the hybrid FIS Tsukamoto method and genetic algorithm. The hybrid method used is to optimize the boundary function of Tsukamoto's FIS membership using a genetic algorithm. After the testing process, the application of the hybrid method of the Tsukamoto FIS method and the genetic algorithm can be used to predict rainfall with a smaller RMSE error compared to the FIS Tsukamoto without optimization. RMSE error value in Junggo area is 6,485, in Pujon area is 6,932, in Tinjomulyo area is 5,969, in Ngujung area is 5,498.*

**Keywords:** Genetic Algorithm, Rainfall, FIS Tsukamoto, Hybrid, Batu City, Prediction

### 1. PENDAHULUAN

Curah hujan yang tidak menentu kini sudah menjadi permasalahan yang cukup krusial di bidang pertanian dan perkebunan (Wahyuni, Mahmudy, & Iryani, 2016). Bidang tersebut mendapatkan dampak yang cukup signifikan terhadap perubahan pola curah hujan. Salah satu bidang perkebunan yang mendapat dampak buruk dari tidak menentunya curah hujan adalah perkebunan apel. Curah hujan yang tidak menentu membuat petani apel mengalami

kesulitan dalam menentukan waktu pembungaan apel. Pembungaan pohon apel yang seharusnya setiap musim kemarau (biasanya dimulai pada awal Bulan Juli) menjadi tidak maksimal (Borchert, 1983). Hal tersebut disebabkan karena pola curah hujan yang tidak menentu bahkan dapat terjadi hujan sepanjang tahun atau musim kering yang lebih lama. Karena tidak menentunya curah hujan yang terjadi, hasil pembungaan apel menjadi kurang maksimal dan baik tidak nya pembuaan pada tanaman apel

akan berpengaruh pada hasil panen (Tutin & Fernandez, 1993).

Daerah Batu, Jawa Timur merupakan salah satu daerah dataran tinggi di Jawa Timur dengan luas wilayah mencapai 0,42% dari total luas Provinsi Jawa Timur atau sekitar 19.908,72 ha (BPS, 2015). Karena lokasinya yang berupa perbukitan dan pegunungan yang dingin, daerah Batu mempunyai potensi yang bagus sebagai pusat budidaya apel di Indonesia (Indahwati, Herdrarto, & Izzati, 2013). Menurut data BPS Kota Batu, luas perkebunan apel di Daerah Batu mencapai 2.993,89 Ha yang terpusat di Kecamatan Bumiaji yang tersebar di beberapa desa antara lain Desa Sumbergondo, Desa Tulungrejo, Desa Punten, Desa Sumberbrantas, Desa Gunungsari, Desa Bumiaji, Desa Giripurno, dan Desa Bulukerto.

Curah hujan pada Daerah Batu, Jawa Timur juga menjadi tidak menentu setelah terjadi perubahan iklim (BPS, 2015). Karena tidak menentunya curah hujan yang terjadi belakangan ini, produksi apel pada tahun 2014 menurun sebanyak 15% menjadi 708,438. Hasil tersebut jauh lebih sedikit jika dibandingkan dengan hasil panen apel pada tahun 2013 yaitu sebesar 838,915 ton (BPS, 2015). Penurunan panen apel tersebut disebabkan karena pada tahun 2014 di Bulan September sampai Oktober menjadi bulan kering karena tidak terjadi hujan. Jumlah hari hujan paling sedikit dialami pada bulan Agustus 2014 dan jumlah hari hujan paling banyak dialami pada bulan Desember 2014 dan Januari 2015. Curah hujan tertinggi mencapai 412 mm terjadi pada bulan Desember 2014. Fenomena tersebut menyebabkan kondisi cuaca tahun 2014 tidak menentu dan sulit diprediksi (BPS, 2015).

Ada banyak metode yang dapat digunakan untuk prediksi, salah satunya adalah metode *fuzzy inference system* (FIS) Tsukamoto. FIS Tsukamoto pernah digunakan oleh Wahyuni, Mahmudy, & Iryani (2016) untuk prediksi curah hujan di daerah Tengger, Jawa Timur pada empat kecamatan. Hasil *Error RMSE* terkecil berada di Kecamatan Tutar yaitu 8.64. Hasil *error* tersebut masih lebih besar jika dibandingkan dengan metode FIS Tsukamoto yang sudah optimasi dengan algoritma genetika (Wahyuni & Mahmudy, 2017). Proses optimasi yang dilakukan adalah optimasi pada batasan fungsi keanggotaan FIS Tsukamoto, sehingga dapat ditemukan batasan fungsi keanggotaan yang paling maksimum dari pemodelan FIS Tsukamoto untuk peramalan curah hujan di daerah Tengger. Optimasi memberikan nilai *error* yang lebih kecil yaitu nilai RMSE di daerah Tutar menjadi 6.63.

Pada penelitian ini, akan digunakan metode hybrid FIS Tsukamoto dan algoritma genetika (Hybrid FIS-GA) untuk memprediksi curah hujan di daerah Batu. Data yang digunakan untuk memprediksi curah hujan adalah data historis curah hujan selama 10 tahun kebelakang mulai tahun 2005 sampai tahun 2014. Variabel yang akan dijadikan

parameter input mengacu pada pemodelan yang digunakan oleh Wahyuni & Mahmudy (2017) yang telah berhasil digunakan untuk memprediksi curah hujan pada daerah Tengger. Algoritma genetika akan digunakan sebagai metode yang akan mengoptimasi batasan fungsi keanggotaan pada FIS Tsukamoto untuk mendapatkan *error RMSE* terkecil.

## 2. PREDIKSI CURAH HUJAN DENGAN FIS TSUKAMOTO DI DAERAH BATU

FIS Tsukamoto pernah digunakan untuk memprediksi curah hujan di Daerah Batu Jawa Timur oleh Wahyuni & Ahda (2018). Pada penelitian tersebut digunakan empat kriteria input yaitu Zt-1 (curah hujan rata-rata selama 10 hari kebelakang), Zt-2 (curah hujan rata-rata selama 20 hari kebelakang), Zt-17 (curah hujan rata-rata selama 170 hari kebelakang), Zt-34 (curah hujan rata-rata selama 340 hari kebelakang). Model untuk jumlah output ada satu output yaitu Zt atau curah hujan rata-rata selama 10 hari kedepan. Data yang digunakan adalah data historis curah hujan pada Daerah Batu selama 10 tahun dimulai dari tahun 2005 sampai 2014. Lokasi pengambilan data dilakukan pada empat pos hujan di Daerah Batu yaitu Pos Hujan Junggo, Pujon, Tinjomulyo, dan Ngujung. Pemodelan FIS Tsukamoto pada penelitian tersebut memberikan hasil prediksi curah hujan dengan nilai *Root Mean Square Error* (RMSE) paling besar pada daerah Pos Hujan Pujon yaitu 9.407. Hasil RMSE pada keempat lokasi pos hujan di Daerah Batu ditunjukkan pada Tabel 1.

Tabel 1. Nilai RMSE pada Empat Lokasi Pos Hujan di Daerah Batu

No.	Lokasi Pos Hujan	RMSE FIS Tsukamoto
1	Junggo	9.196
2	Pujon	9.407
3	Tinjomulyo	8.798
4	Ngujung	8.825

Nilai RMSE yang dihasilkan oleh FIS Tsukamoto masih dapat diperkecil lagi dengan beberapa optimasi. Salah satu optimasi yang dapat digunakan adalah optimasi derajat keanggotaan (Kurnianingtyas, Mahmudy, & Widodo, 2017) atau optimasi batasan fungsi keanggotaan pada FIS Tsukamoto dengan algoritma genetika (Wahyuni & Mahmudy, 2017). Algoritma genetika dapat digunakan untuk mengoptimasi batasan-batasan keanggotaan himpunan *fuzzy* agar nilai RMSE yang dihasilkan semakin kecil.

## 3. HIBRID FIS TSUKAMOTO DAN ALGORITMA GENETIKA

Pada penggunaan FIS Tsukamoto untuk proses prediksi dibutuhkan penentuan batasan-batasan fungsi keanggotaan himpunan *fuzzy* yang sesuai agar didapatkan hasil prediksi yang akurat. Batas-batas tersebut bisa ditentukan secara otomatis dengan

menggunakan algoritma genetika. Algoritma genetika dalam penerapannya memiliki beberapa tahap untuk menyelesaikan masalah, yaitu representasi kromosom, inisialisasi populasi, menghitung nilai *fitness*, proses reproduksi yaitu pindah silang dan mutasi, serta proses seleksi (Hannawati, Thiang, & Eleazar, 2002).

### 3.1 Representasi Kromosom

Representasi kromosom dirancang untuk menemukan optimasi solusi dari permasalahan yang ada. Pada penelitian ini, kromosom dibentuk dengan *Real Coded Genetic Algorithms* (RCGA). RCGA menggunakan sebuah *array* yang berisikan bilangan *real* sebagai representasi kromosom untuk batasan fungsi keanggotaan (Armanda & Mahmudy, 2016).

Dalam satu kromosom ada delapan gen. Setiap gen yang ada pada satu kromosom mewakili batasan fungsi keanggotaan setiap kriteria input pada pemodelan dengan FIS Tsukamoto. Gen pertama dan kedua digunakan untuk mewakili solusi batasan fungsi keanggotaan kriteria pertama, gen ketiga dan keempat digunakan untuk mewakili solusi batasan fungsi keanggotaan kriteria kedua, gen kelima dan keenam digunakan untuk mewakili solusi batasan fungsi keanggotaan kriteria ketiga, serta gen ketujuh dan kedelapan digunakan untuk mewakili solusi batasan fungsi keanggotaan kriteria keempat. Nilai dari masing-masing gen akan dibangkitkan secara acak dari range  $[0,38]$ . Nilai range tersebut diambil dari nilai batasan batasan fungsi keanggotaan *fuzzy* pada penelitian sebelumnya (Wahyuni & Ahda, 2018). Ilustrasi representasi kromosom ditunjukkan pada Gambar 1 berikut ini.

K1

a1	a2	a3	a4	a5	a6	a7	a8	a9	a10	a11
Zt-1	Zt-2	Zt-17	Zt-34	Zt						

Gambar 1. Ilustrasi Representasi Kromosom

Keterangan:

$K_i$  = Kromosom ke- $i$

$a1, a2$  = Segmen batasan fungsi keanggotaan  $Z_{t-1}$

$a3, a4$  = Segmen batasan fungsi keanggotaan  $Z_{t-2}$

$a5, a6$  = Segmen batasan fungsi keanggotaan  $Z_{t-17}$

$a7, a8$  = Segmen batasan fungsi keanggotaan  $Z_{t-34}$

$a9, a10, a11$  = Segmen batasan fungsi keanggotaan  $Z_t$

Contoh representasi kromosom dengan menggunakan pengkodean *real* ditunjukkan pada Gambar 2.

K1

33.1	12.5	1.8	7.8	35.1	25.2	9.4	14.3	1.3	7.4	14.3
------	------	-----	-----	------	------	-----	------	-----	-----	------

Gambar 2. Contoh Representasi Kromosom

Pada saat proses representasi kromosom, perlu dilakukan pengurutan nilai gen pada kromosom secara *ascending*. Nilai gen diurutkan sesuai dengan segmen yang dimodelkan pada representasi kromosom. Hasil pengurutan kromosom dapat dilihat pada Gambar 3.

K1

12.5	33.1	1.8	7.8	25.2	35.1	9.4	14.3	1.3	7.4	14.3
------	------	-----	-----	------	------	-----	------	-----	-----	------

Gambar 3. Contoh Representasi Kromosom Setelah Diurutkan

### 3.2 Inisialisasi Populasi

Pada tahapan inisialisasi populasi ditentukan jumlah populasi dalam algoritma genetika (*popSize*). Sebagai contoh, *popSize* dibuat 3 kromosom atau bisa dikatakan jumlah populasi adalah 3 mulai dari  $K_1 \dots K_n$ , dimana  $n = 3$ . Contoh inisialisasi populasi ditunjukkan pada Tabel 2.

Tabel 2. Ilustrasi Inisialisasi Populasi

K	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10	G11
K1	12.5	33.1	1.8	7.8	25.2	35.1	9.4	14.3	1.3	7.4	14.3
K2	16.2	31.2	3.2	9.2	16.5	23.1	3.4	18.6	9.7	27.1	34.4
K3	5.2	21.9	11.1	36.7	10.0	17.1	6.2	27.4	6.8	16.0	18.2

### 3.3 Perhitungan Nilai Kebugaran (*Fitness*)

Fungsi kebugaran digunakan untuk mengukur nilai kebaikan dari solusi yang didapatkan dari perhitungan algoritma genetika (Mahmudy, Marian, & Luong, 2013). Proses penghitungan nilai kebugaran pada penelitian ini dilakukan dengan menerapkan menerapkan FIS Tsukamoto untuk mengetahui kromosom yang menghasilkan *error* RMSE paling kecil. Solusi yang dicari dalam penelitian ini adalah optimasi batasan fungsi keanggotaan FIS Tsukamoto adalah *error* RMSE dari hasil prediksi curah hujan yang paling kecil. Apabila semakin kecil nilai *error* RMSE yang dimiliki oleh kromosom, maka semakin baik kromosom tersebut, sehingga perhitungan nilai kebugaran ( $f$ ) dinyatakan dalam Persamaan 1.

$$f = \frac{1}{e} \quad (1)$$

Keterangan:

$f$  = nilai kebugaran (*fitness*)

$e$  = *error* RMSE

Nilai *error* RMSE dihitung dengan mencari nilai galat yaitu selisih antara data aktual dengan data hasil prediksi. Untuk mengetahui nilai galat dan nilai *error* digunakan rumus galat dan rumus RMSE yang dinyatakan dalam Persamaan 2 dan Persamaan 3.

$$Galat = y - y' \quad (2)$$

Keterangan:

$y$  = data aktual

$y'$  = data hasil prediksi

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (3)$$

Keterangan:

$RMSE$  = *Root Mean Squared Error*

$n$  = jumlah data

$y$  = data aktual

$y'$  = data hasil prediksi

Proses penghitungan FIS Tsukamoto untuk prediksi curah hujan di Daerah Batu dijelaskan pada penelitian sebelumnya (Wahyuni & Ahda, 2018), sedangkan ilustrasi penghitungan nilai kebugaran pada kromosom K1 sampai K3 ditunjukkan pada Tabel 3.

Tabel 3. Ilustrasi Penghitungan Nilai Kebugaran pada Kromosom

K	Daerah	RMSE	$\bar{x}$ RMSE	f
K1	Junggo	7.85	7.128	0.14029
	Pujon	6.07		
	Tinjomulyo	7.91		
	Tutur	6.68		
K2	Junggo	9.871	9.471	0.10559
	Pujon	7.875		
	Tinjomulyo	8.420		
	Tutur	9.471		
K3	Junggo	8.361	7.006	0.14273
	Pujon	7.453		
	Tinjomulyo	7.033		
	Tutur	7.006		

### 3.4 Seleksi

Proses yang paling penting dalam algoritma genetika adalah proses reproduksi, sehingga untuk memilih *parent* yang akan dioptimasi butuh metode khusus. Oleh karena itu dibutuhkan proses seleksi untuk memilih *parent* yang akan direproduksi. Metode seleksi yang akan digunakan adalah seleksi Roulette wheel, dimana metode seleksi ini akan memilih *parent* untuk lolos ke proses reproduksi dengan memperhitungkan nilai probabilitas dari setiap *parent* (Herrera, Lozano, & Verdegay, 1998). Langkah awal untuk memulai seleksi Roulette wheel adalah menghitung nilai probabilitas dan kumulatif probabilitas dari masing-masing kromosom. Contoh perhitungan nilai probabilitas dan kumulatif probabilitas pada kromosom K1 sampai K3 ditunjukkan pada Tabel 4.

Tabel 4. Hasil Penghitungan Probabilitas Setiap Individu

Kromosom	Nilai Kebugaran (f)	Probabilitas	Kumulatif
K1	0.14029	0.351648352	0.351648352
K2	0.10559	0.263736264	0.615384615
K3	0.14273	0.384615385	1

Setelah nilai probabilitas dan kumulatif probabilitas diketahui, akan dilakukan pengacakan nilai random (R) antara [0, 1] sebanyak dua kali untuk menentukan kromosom yang akan dijadikan *parent* dengan ketentuan  $K[n-1] < R < K[n]$ . Hasil seleksi Roulette wheel lebih detail ditunjukkan pada Tabel 5.

Tabel 5. Kromosom Terpilih dari Seleksi Roulette Whell

Nilai Random (R)	Kromosom Terpilih
0.07720	K1
0.25347	K2

### 3.5 Pindah Silang

Dalam penelitian ini metode pindah silang yang digunakan adalah *extended intermediate crossover* (Muhlenbein & Schlierkamp-Voosen, 1993). Sebelum melakukan pindah silang, ditentukan terlebih dahulu variabel *crossover rate* (*cr*) yaitu salah satu parameter dalam algoritma genetika untuk menentukan jumlah *offspring* hasil pindah silang (Herman, Yusuf, & Mariyam, 2009). Jumlah *offspring* didapat dari rumus  $offspring = cr \times popSize$ . Nilai *crossover rate* ditentukan dengan rentang nilai [0, 1]. Sebagai contoh nilai *cr* yang akan digunakan adalah 0.5, sehingga jumlah  $offspring = 0.5 \times 3 = 1,5 = 2$ .

Proses pindah silang dengan *extended intermediate crossover* dimulai dengan memilih *parent* (*p*). *Parent* yang akan digunakan dalam proses pindah silang ini adalah dua buah kromosom yang sudah dipilih dengan metode seleksi Roulette wheel pada tahap sebelumnya. *Offspring* (*O*) diproduksi dengan sebuah rumus yang dituliskan pada Persamaan 3. Untuk melihat lebih detail langkah-langkah proses *extended intermediate crossover* dapat dilihat pada Gambar 4.

$$O_i = p_i^2 + \alpha_1(p_i^2 - p_i^1) \quad (3)$$

Keterangan:

$\alpha$  = nilai random antara interval [-0.25, 1.25]

*O* = *offspring*

*p* = *parent*

C1	12.5	33.1	1.8	7.8	25.2	35.1	9.4	14.3	1.3	7.4	14.3
C2	16.2	31.2	3.2	9.2	16.5	23.1	3.4	18.6	9.7	27.1	34.4
$\alpha$	0.1	0.48	-0.6	0.8	0.57	0.4	0.2	-0.1	0.9	0.2	-0.2
O1	16.5	30.2	2.3	10.3	11.5	18.3	2.2	18.1	17.2	31.0	30.3

Gambar 4. Contoh Proses Extended Intermediate Crossover

### 3.6 Mutasi

Metode mutasi yang digunakan pada penelitian ini adalah *simple random mutation*. Sebelum melakukan pindah silang, ditentukan terlebih dahulu variabel *mutation rate* (*mr*) yaitu salah satu parameter dalam algoritma genetika untuk menentukan jumlah *offspring* hasil mutasi (Herman et al., 2009). Misalkan variabel *mr* yang akan digunakan adalah 0.1, dimana nilai *mr* ini telah ditentukan sebelumnya dari rentang nilai [0, 1]. Proses mutasi akan menghasilkan *offspring* dengan rumus  $offspring = mr \times popSize = 0.1 \times 3 = 0.3 = 1$ .

Proses mutasi ini dimulai dengan menentukan *offspring* (*O*) dari *parent* (*p*) dengan menggunakan rumus dari Persamaan 4 (Michalewicz, 1992). Untuk melihat lebih detail proses *simple random mutation* dapat dilihat pada Gambar 5.

$$O_i = p_i(1 + \alpha) \quad (4)$$

Keterangan:

$\alpha$  = nilai random antara interval [-0.1, 0.1]

$O$  = offspring  
 $p$  = parent

C1	12.5	33.1	1.8	7.8	25.2	35.1	9.4	14.3	1.3	7.4	14.3
$\alpha$	-0.03	0.02	0.03	0.04	0.05	0.04	-0.10	0.01	0.04	0.09	0.10
O2	12.1	33.7	1.8	8.1	26.4	36.5	8.4	14.4	1.3	8.0	15.7

Gambar 5. Contoh Proses *Simple Random Mutation*

### 3.7 Elitisme (*Elitism*)

Setelah proses pindah silang dan mutasi selesai, kromosom *parent* dan *offspring* hasil pindah silang dan mutasi akan dihitung nilai kebugarannya sesuai dengan Persamaan 1. Hasil perhitungan nilai kebugaran setelah proses pindah silang dan mutasi ditunjukkan pada Tabel 6.

Tabel 6. Hasil Penghitungan Nilai Kebugaran Setelah Proses Reproduksi

Kromosom	Nilai Kebugaran
K1	0.14029
K2	0.10559
K3	0.14273
O1	0.1599
O2	0.1398

Langkah selanjutnya akan dipilih tiga kromosom (sesuai dengan jumlah *popSize*) dengan nilai kebugaran terbaik untuk lolos ke generasi selanjutnya. Metode seleksi yang akan digunakan adalah elitisme (*elitism*) yaitu pemilihan kromosom dengan memilih nilai kebugaran (*fitness*) yang paling besar sesuai dengan jumlah *popSize* (Wu, Long, & Liu, 2015). Contoh hasil seleksi dengan elitisme dapat dilihat pada Tabel 7.

Tabel 7. Hasil Seleksi *Elitism*

Kromosom	Nilai Kebugaran
K2	0.10559
O2	0.1398
K1	0.14029

### 3.8 Kondisi Berhenti

Pada penelitian ini, proses algoritma genetika akan berhenti jika jumlah generasi maksimal (Jafarian, 2010). Jumlah generasi akan ditentukan pada tahap pengujian algoritma genetika untuk mencari jumlah generasi yang paling optimal. Jumlah generasi tersebut akan di uji pada rentang 100 sampai 500 generasi.

## 4. HASIL DAN PEMBAHASAN

Pada penelitian ini akan dilakukan prediksi curah hujan pada Daerah Batu dengan data historis yang didapat dari empat lokasi pos hujan, yaitu Pos Hujan yaitu Pos Hujan Junggo, Pujon, Tinjomulyo, dan Ngujung. Ada 360 data curah hujan yang didapatkan dari tahun 2005-2014 dan akan menjadi acuan prediksi. Setiap data mewakili rata-rata curah hujan selama sepuluh hari, sehingga hasil prediksi juga akan menghasilkan data curah hujan pada

sepuluh hari kedepan atau dalam bentuk dasarian. Kriteria input FIS Tsukamoto yang digunakan pada penelitian ini sama dengan yang digunakan pada penelitian sebelumnya (Wahyuni & Ahda, 2018).

Sebelum memperoleh parameter algoritma genetika yang paling optimal untuk optimasi FIS Tsukamoto, dilakukan proses pengujian pada parameter-parameter algoritma genetika. Pengujian tersebut meliputi pengujian jumlah populasi (*popSize*), kombinasi nilai *cr* dan *mr*, dan jumlah generasi.


### 4.1 Pengujian Jumlah Populasi

Proses pengujian jumlah populasi dilakukan sebanyak lima kali terhadap jumlah populasi 50 sampai 250 dengan kenaikan jumlah populasi sebanyak 50. Nilai *cr* dan *mr* awal yang akan dipakai yaitu 0.9 dan 0.1 sedangkan jumlah generasi awal yang dipakai adalah 100. Nilai *fitness* yang dihasilkan dari lima kali pengujian akan dihitung rata-ratanya. Dari hasil rata-rata tersebut akan diketahui jumlah populasi yang paling optimum. Hasil pengujian jumlah populasi dapat dilihat lebih jelas pada Tabel 8.

Tabel 8. Hasil Pengujian Jumlah Populasi

Jumlah Populasi	Nilai Kebugaran					$\bar{x}$ Nilai Kebugaran
	1	2	3	4	5	
50	0.104	0.138	0.080	0.079	0.154	0.111
100	0.120	0.091	0.096	0.148	0.131	0.117
150	0.139	0.139	0.138	0.149	0.087	0.131
200	0.112	0.111	0.099	0.124	0.150	0.119
250	0.146	0.148	0.132	0.160	0.100	0.137

Berdasarkan Tabel 8 ditunjukkan bahwa rata-rata nilai kebugaran terbaik didapatkan pada jumlah populasi 250. Pada jumlah populasi tersebut didapatkan nilai kebugaran tertinggi yaitu 0.137. Jumlah populasi tersebut juga masih dalam batas yang normal dan tidak membutuhkan waktu komputasi yang lama (Mahmudy, Marian, & Luong, 2012). Grafik perubahan nilai nilai kebugaran sesuai dengan jumlah populasi dapat dilihat lebih jelas pada Gambar 6.



Gambar 6. Grafik Hasil Pengujian Populasi

### 4.2 Pengujian Kombinasi Nilai *cr* dan *mr*


Proses pengujian kombinasi nilai *cr* dan *mr* didasarkan pada teori Grefenstette (Grefenstette,

1986) untuk menentukan nilai  $cr$  nya. Jumlah populasi dan jumlah generasi terbaik akan digunakan dalam pengujian  $cr$  dan  $mr$ . Pengujian akan dilakukan sebanyak lima kali dan nilai kebugaran yang dihasilkan dari lima kali pengujian akan dihitung rata-ratanya. Dari hasil rata-rata tersebut akan diketahui jumlah  $cr$  dan  $mr$  yang paling optimum. Hasil pengujian pada jumlah populasi ditunjukkan pada Tabel 9.

Tabel 9. Hasil Pengujian Kombinasi  $cr$  dan  $mr$ 

Nilai Kebugaran						
Jumlah <i>cr</i>	Percobaan Ke-					$\bar{x}$ Nilai Kebugaran
	1	2	3	4	5	
0.45	0.156	0.070	0.115	0.068	0.131	0.108
0.6	0.137	0.094	0.113	0.101	0.072	0.103
0.95	0.117	0.094	0.157	0.103	0.137	0.122

Berdasarkan Tabel 9 ditunjukkan bahwa rata-rata nilai kebugaran yang paling baik didapatkan pada kombinasi nilai  $cr$  0.95 dan nilai  $mr$  0.05. Pada kombinasi nilai  $cr$  dan  $mr$  tersebut didapatkan nilai kebugaran tertinggi yaitu 0.122. Ketika nilai  $cr$  semakin kecil maka hasil nilai kebugaran ( $fitness$ ) tidak akan optimal karena algoritma genetika menggunakan metode *random search* yang tidak akan mampu mengeksplorasi pencarian solusi secara efektif saat nilai  $cr$  kecil (Wahyuni & Mahmudy, 2017). Grafik perubahan nilai kebugaran sesuai dengan nilai  $cr$  dan  $mr$  dapat dilihat pada Gambar 7.

Gambar 7. Grafik Hasil Pengujian Kombinasi  $cr$  dan  $mr$ 


#### 4.3 Pengujian Jumlah Generasi

Pengujian jumlah generasi dilakukan sebanyak lima kali terhadap jumlah generasi 100 sampai 500 dengan kenaikan jumlah generasi sebanyak 100. Nilai  $cr$  dan  $mr$  yang akan digunakan yaitu 0.95 dan 0.05, sedangkan jumlah populasi yang digunakan adalah 250 sesuai dengan hasil pengujian sebelumnya. Nilai kebugaran yang dihasilkan dari lima kali pengujian akan dihitung rata-ratanya. Dari hasil rata-rata tersebut akan diketahui jumlah generasi yang paling optimum. Hasil pengujian pada jumlah generasi dapat dilihat lebih jelas pada Tabel 10.

Tabel 10. Hasil Pengujian Jumlah Generasi

Jumlah Generasi	Nilai Kebugaran Percobaan Generasi Ke-					$\bar{x}$ Nilai Kebugaran
	1	2	3	4	5	
100	0.117	0.094	0.157	0.103	0.137	0.122
200	0.123	0.132	0.085	0.095	0.087	0.105
300	0.105	0.098	0.116	0.134	0.151	0.121
400	0.088	0.136	0.132	0.146	0.104	0.121
500	0.130	0.127	0.151	0.105	0.105	0.123

Berdasarkan Tabel 10 dapat dilihat bahwa rata-rata nilai kebugaran terbaik didapatkan pada jumlah generasi 100. Pada jumlah generasi tersebut didapatkan nilai  $fitness$  0.123 dan tidak mengalami peningkatan yang signifikan bahkan mengalami penurunan nilai kebugaran pada jumlah generasi yang lebih besar. Hal tersebut juga pernah dialami pada penelitian sebelumnya yang menyatakan bahwa kenaikan nilai kebugaran yang diperoleh tidak terlalu signifikan pada jumlah generasi yang lebih besar dari 100 (Mahmudy et al., 2012). Grafik perubahan nilai kebugaran sesuai dengan jumlah generasi dapat dilihat pada Gambar 8.




Gambar 8. Grafik Hasil Pengujian Jumlah Generasi


#### 4.4 Hasil Optimasi Batasan Fungsi Keanggotaan

Solusi yang dihasilkan dari perhitungan algoritma genetika adalah sebuah kromosom yang memiliki nilai  $fitness$  terbaik yang akan dijadikan batasan fungsi keanggotaan pada Tsukamoto FIS. Hasil dari proses pengujian parameter algoritma genetika yang sudah dilakukan mendapatkan nilai parameter yang paling optimal untuk prediksi curah hujan. Parameter tersebut antara lain jumlah populasi 250, kombinasi nilai  $cr$  dan  $mr$  terbaik yaitu 0.95 dan 0.05, dan jumlah generasi 100. Batasan fungsi keanggotaan yang sudah dioptimasi ditunjukkan pada Gambar 9 sampai Gambar 13.







Gambar 9. Hasil Optimasi Batasan Fungsi Keanggotaan Zt-1




Gambar 10. Hasil Optimasi Batasan Fungsi Keanggotaan Zt-2



Gambar 11. Hasil Optimasi Batasan Fungsi Keanggotaan Zt-17



Gambar 12. Hasil Optimasi Batasan Fungsi Keanggotaan Zt-34



Gambar 13. Hasil Optimasi Batasan Fungsi Keanggotaan Zt

#### 4.5 Penghitungan Akurasi Hasil Prediksi

Prediksi curah hujan di Daerah Batu dilakukan di empat lokasi yaitu Junggo, Pujon, Tinjomulyo, dan Ngujung. Hasil dari prediksi curah hujan yang ditunjukkan pada Tabel 11 adalah hasil pada Daerah Junggo. Pada Tabel 11 ditampilkan juga hasil penghitungan galat menggunakan Persamaan 2. Nilai galat yang dihasilkan akan digunakan untuk menghitung nilai RMSE menggunakan Persamaan 3.

Tabel 11. Hasil Prediksi Curah Hujan pada Daerah Junggo

No.	Data Aktual (y)	Hasil Prediksi (y')	Galat
1	2.400	0	2.4
2	5.300	0	5.3
3	5.364	0	5.3636363
4	0.000	3.185	-3.185
5	18.400	3.036264	15.363736
6	13.000	10.7911275	2.2088724
7	13.000	12.65690859	0.3430914
8	6.200	12.65690859	-6.456908
9	6.909	15.06377898	-8.154688
10	7.400	14.80984101	-7.409841
...	...	...	...
350	0.000	0	0
351	0.000	0	0
352	0.000	0	0
353	0.000	0	0
354	0.182	0	0.1818181
355	0.000	0	0
356	7.600	3.203801653	4.3961983
357	16.200	14.56301897	1.6369810
358	21.200	11.54639226	9.6536077
359	11.800	9.839562698	1.9604373

Pada tabel 11 ditunjukkan bahwa *hybrid* Tsukamoto FIS dan algoritma genetika dapat memprediksi curah hujan di Daerah Junggo, Batu dengan cukup baik. Dapat dilihat bahwa pemodelan metode tersebut dapat memprediksi curah hujan = 0 dengan tepat di beberapa data. Metode sebelumnya yang menggunakan FIS Tsukamoto tidak dapat melakukan hal tersebut (Wahyuni & Ahda, 2018).

#### 4.6 Perbandingan RMSE Hasil Prediksi

Nilai *error* RMSE hasil prediksi curah hujan menggunakan *hybrid* Tsukamoto FIS dan algoritma genetika akan dibandingkan dengan nilai *error* RMSE hasil prediksi pada penelitian sebelumnya yang dilakukan oleh Wahyuni & Ahda (2018). Perbandingan dilakukan pada empat lokasi yang sama. Hasil *error* RMSE dari Tsukamoto FIS dan *hybrid* *hybrid* Tsukamoto FIS dan algoritma genetika lebih jelas ditunjukkan pada Table 12.

Tabel 12. Perbandingan Hasil Prediksi antara Metode FIS Tsukamoto dan *Hybrid* FIS Tsukamoto dan GA

No.	Lokasi	RMSE FIS Tsukamoto	RMSE Hybrid FIS Tsukamoto GA	Kenaikan Akurasi
1	Junggo	9.196	6.485	29.5%
2	Pujon	9.407	6.932	26.3%
3	Tinjomulyo	8.798	5.969	32.2%
4	Ngujung	8.825	5.498	37.7%
Rata-Rata		9.06	6.22	31.4%

## 5. KESIMPULAN

Hybrid Tsukamoto FIS dan algoritma genetika dapat digunakan untuk melakukan optimasi batasan fungsi keanggotaan yang paling optimal untuk prediksi curah hujan di Daerah Batu, Jawa Timur. Setelah dilakukan pemodelan dan pengujian, didapatkan batasan fungsi keanggotaan yang optimal untuk memprediksi curah hujan menggunakan data historis dari empat lokasi pos hujan yaitu Junggo, Pujon, Tinjomulyo, dan Ngujung. Nilai *error* RMSE pada daerah Junggo sebesar 6.485, pada daerah Pujon sebesar 6.932, pada daerah Tinjomulyo sebesar 5.969, pada daerah Ngujung sebesar 5.498. Nilai RMSE tersebut 31.4 % lebih bagus jika dibandingkan dengan penelitian sebelumnya yang menggunakan Tsukamoto FIS (Wahyuni & Ahda, 2018).

## UCAPAN TERIMA KASIH

Penelitian ini secara finansial didanai oleh Kementerian Riset, Teknologi, dan Pendidikan Tinggi (Kemenristekdikti) melalui program hibah Penelitian Dosen Pemula (PDP) dan Badan Meteorologi, Klimatologi, dan Geofisika Karangploso, Malang.

## 6. DAFTAR PUSTAKA

- ARMANDA, R. S., & MAHMUDY, W. F. (2016). Penerapan Algoritma Genetika Untuk Penentuan Batasan Fungsi Kenggotaan Fuzzy Tsukamoto Pada Kasus Peramalan Permintaan Barang. *Teknologi Informasi Dan Ilmu Komputer(JTIIK)*, 3(3), 169–173.
- BORCHERT, R. (1983). Phenology and control of flowering in tropical trees. *Biotropica*, 15(2), 81–89. <https://doi.org/10.2307/2387949>
- BPS. (2015). *Statistik Daerah Kota Batu 2015*. Batu: BADAN PUSAT STATISTIK KOTA BATU.
- GREFENSTETTE, J. (1986). Optimization of Control Parameters for Genetic Algorithms. *IEEE Transactions on Systems, Man, and Cybernetics*, 16(1), 122–128. <https://doi.org/10.1109/TSMC.1986.289288>
- HANNAWATI, A., THIANG, & ELEAZAR. (2002). Pencarian Rute Optimum Menggunakan Algoritma Genetika. *Jurnal Teknik Elektro*, 2(2), 78–83. Retrieved from <http://puslit2.petra.ac.id/ejournal/index.php/elk/article/view/15857>
- HERMAN, N. S., YUSUF, I., & MARIYAM, S. (2009). Genetic Algorithms and Designing Membership Function In Fuzzy Logic Controllers. *World Congress on Nature & Biologically Inspired Computing (NaBIC 2009)*, 1753–1758.
- HERRERA, F., LOZANO, M., & VERDEGAY, J. L. (1998). Tackling Real-Coded Genetic Algorithms: Operators and Tools for Behavioural Analysis. *Artificial Intelligence Review*, 12, 265–319.
- INDAHWATI, R., HERDRARTO, B., & IZZATI, M. (2013). Perbedaan Kualitas Lahan Apel Sistem Pertanian Intensif dengan Sistem Pertanian Ramah Lingkungan ( Studi Kasus Di Kelompok Tani Makmur Abadi Desa Tulungrejo Kecamatan Bumiaji Kota Batu ) Abstrak. *BIOMA*, 15(2), 90–97.
- JAFARIAN, J. (2010). An Experiment to Study Wandering Salesman Applicability on Solving the Travelling Salesman Problem based on Genetic Algorithm. *International Conference on Educational and Information Technology (ICEIT 2010) An*, (Iceit), 1–7.
- KURNIANINGTYAS, D., MAHMUDY, W. F., & WIDODO, A. W. (2017). Optimasi Derajat Keanggotaan Fuzzy Tsukamoto Menggunakan Algoritma Genetika Untuk Diagnosis Penyakit Sapi Potong. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 4(1), 8. <https://doi.org/10.25126/jtiik.201741294>
- MAHMUDY, W. F., MARIAN, R. M., & LUONG, L. H. S. (2012). Flexible Manufacturing System Using Real Coded Genetic Algorithms – Part I: Modeling. *World Academy of Science, Engineering and Technology*, 69, 773–779.
- MAHMUDY, W. F., MARIAN, R. M., & LUONG, L. H. S. (2013). Modeling and Optimization of Part Type Selection and Loading Problem in Flexible Manufacturing System Using Real Coded Genetic Algorithms. *International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering*, 7(4), 251–260.
- MICHALEWICZ, Z. (1992). *Algorithms + Data Structures = Evolution Programs*. New York: Springer-Verlag.
- MUHLENBEIN, H., & SCHLIERKAMP-VOOSEN, D. (1993). Predictive Models for the Breeder Genetic Algorithm. *Evolutionary Computation*, 1(1), 25–49.
- TUTIN, C. E. G., & FERNANDEZ, M. (1993). Relationships between minimum temperature and fruit production in some tropical forest trees in Gabon. *Journal of Tropical Ecology*, 9(2), 241–248. <https://doi.org/10.1017/S0266467400007239>
- WAHYUNI, I., & AHDA, F. A. (2018). Pemodelan Fuzzy Inference System Tsukamoto Untuk Prediksi Curah Hujan Studi Kasus Kota Batu. *Jurnal Ilmiah Teknologi Dan Informasi ASIA (JITIKA)*, 12(2), 1–12.
- WAHYUNI, I., & MAHMUDY, W. F. (2017). Rainfall Prediction in Tengger-Indonesia Using Hybrid Tsukamoto FIS and Genetic Algorithm. *Journal of ICT Research and*



*Applications*, 11(1), 38–54.  
<https://doi.org/10.5614/itbj.ict.res.appl.2017.11.1.3>

- WAHYUNI, I., MAHMUDY, W. F., & IRYANI, A. (2016). Rainfall Prediction in Tengger Region Indonesia Using Tsukamoto Fuzzy Inference System. *1st International Conference on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2016*, 16, 130–135.  
<https://doi.org/10.1109/ICITISEE.2016.7803061>
- WU, J., LONG, J., & LIU, M. (2015). Evolving RBF neural networks for rainfall prediction using hybrid particle swarm optimization and genetic algorithm. *Neurocomputing*, 148, 136–142.  
<https://doi.org/10.1016/j.neucom.2012.10.043>

*Halaman ini sengaja dikosongkan*