

Identifikasi Gangguan di Saluran Transmisi Tenaga Listrik Berbasis Metode Hibrid

Syukri Darmawan¹⁾, Azriyenni Azhari Zakri²⁾

¹⁾Mahasiswa Program Studi Teknik Elektro ²⁾Dosen Program Studi Teknik Elektro
Program Studi Teknik Elektro S1, Fakultas Teknik Universitas Riau
Kampus Bina Widya, Jl. H. R. Soebrantas Km. 12,5 Simpang Baru, Panam
Pekanbaru 28293
Email: darmawan.syukri@gmail.com

ABSTRACT

This research discusses a Hybrid Method for identifying short circuit faults in transmission line. The identification fault is done in the classification and estimation of fault location in Riau system (three buses). Hybrid Method is used such as Discrete Wavelet Transform (DWT) and Support Vector Machine (SVM). DWT is used to extract information of transient signals from each phase current and zero sequence current for one cycle when the fault begins. SVM classification is used to detect any fault in each phase and ground in determining the type of short circuit fault. SVM regression is used to estimate fault location that occurs in transmission line. The training and testing data are generated by simulating each type of short circuit fault in Simulink Matlab R2018a with variation of fault location, fault resistance and fault inception angle. Short circuit faults is applied in transmission line on simulink model from Koto Panjang (KP) bus to Garuda Sakti (GS) bus in Riau Province with voltage 150 kV and length 64 km. The obtained results are classification with accuracy 100 % and estimated fault location with the highest mean error value is 0.021529 %.

Keywords: Discrete wavelet transform, Estimate, Fault, Short circuit, Support vector machine.

1. PENDAHULUAN

Saluran transmisi merupakan hal yang sangat penting pada sistem tenaga listrik karena berfungsi menyalurkan energi listrik dari pembangkit menuju jaringan distribusi yang tersambung ke beban. Proteksi terhadap saluran transmisi merupakan persoalan penting pada sistem tenaga listrik karena 85-87% gangguan sistem tenaga terjadi pada saluran transmisi (Manohar Singh, 2011). Terjadinya gangguan pada saluran transmisi dapat menimbulkan terputusnya suplai energi listrik menuju beban sehingga mengakibatkan kerugian bagi konsumen dengan terganggunya kegiatan produksi.

Gangguan yang sering terjadi pada saluran transmisi yaitu gangguan hubung singkat. Gangguan hubung singkat yang terjadi dapat berupa asimetris dan simetris. Gangguan asimetris terdiri dari gangguan satu fasa ke tanah, fasa ke fasa dan dua fasa ke tanah. Sedangkan gangguan simetris yakni gangguan 3 fasa. Setiap jenis gangguan hubung singkat yang terjadi memiliki karakteristik yang berbeda untuk arus dan tegangannya. Maka setiap gangguan hubung singkat yang terjadi di saluran transmisi harus diketahui jenisnya terlebih

dahulu dan kemudian baru dilakukan estimasi terhadap lokasi gangguan yang terjadi.

Penelitian ini menggunakan metode hibrid untuk melakukan klasifikasi jenis dan estimasi lokasi gangguan hubung singkat. Metode hibrid dalam penelitian ini adalah gabungan dari metode Transformasi Wavelet Diskrit (TWD) dan *Support Vector Machine* (SVM). Transformasi wavelet memiliki keunggulan dibandingkan dengan transformasi *fourier* yang mana informasinya terbatas hanya pada domain frekuensi. Sedangkan informasi yang didapat dari transformasi wavelet dapat berupa domain frekuensi dan waktu. TWD digunakan untuk mendapatkan informasi dari sinyal transien saat gangguan hubung singkat mulai terjadi.

Pengolahan hasil TWD akan digunakan sebagai masukan dalam menggunakan SVM untuk mengklasifikasi jenis dan estimasi lokasi gangguan hubung singkat. Dengan menggunakan SVM, klasifikasi jenis gangguan lebih mudah dilakukan dan memiliki tingkat keakuratan yang juga tinggi. Begitu juga dalam penggunaan SVM untuk estimasi lokasi gangguan hubung singkat.

Abdullah Asuhaimi Mohd Zin dkk., 2015 telah mengklasifikasikan jenis gangguan hubung singkat yang terjadi pada saluran transmisi paralel menggunakan TWD dengan mother wavelet tipe daubechies orde 4 dengan frekuensi sampling 200 kHz dan Back-Propagation Neural Network (BPNN). Hasil yang diperoleh pada nilai *mean square error* 0.03721 dan *mean absolute error* 0.11952 (Zin et al., 2015).

Lalu Ahmed Saber dkk., 2016 telah mengusulkan penerapan TWD dengan mother wavelet tipe daubechies orde 4 dengan frekuensi sampling 50 kHz dan SVM. Penjumlahan nilai absolut dari koefisien detail level 8 dan 9 digunakan sebagai masukan untuk SVM. Hasil yang didapatkan bahwa metode ini mampu mengklasifikasi gangguan pada saluran transmisi paralel dengan benar (Saber, Emam and Amer, 2016).

Selanjutnya Papia Ray dan Debani Prasad Mishra, 2016 telah melakukan pengolahan data yang dihasilkan dari TWD sebagai masukan pada SVM untuk klasifikasi gangguan. Teknik SVM dalam mengklasifikasi gangguan memiliki tingkat keakuratan yang lebih tinggi dibandingkan teknik lainnya seperti ANN, Probabilistic Neural Network (PNN) dan Adaptive Neural Fuzzy Interface System (ANFIS) (Ray and Mishra, 2016).

Berdasarkan penelitian yang terdahulu yang berkaitan tentang klasifikasi gangguan menggunakan konsep teknik cerdas. Maka penelitian ini pula akan mengusulkan penerapan metode hibrid yaitu TWD dan SVM untuk mengklasifikasi gangguan hubung singkat yang terjadi pada saluran transmisi dengan model sistem yang menjadi objek penelitian adalah sistem transmisi yang ada di Riau dengan studi kasus tiga bus.

Transformasi Wavelet Diskrit

Transformasi wavelet memiliki kemampuan untuk menganalisa berbagai jenis gangguan dengan informasi yang diperoleh daripada domain frekuensi dan domain waktu. Transformasi wavelet sangat berguna dalam mendeteksi dan mengolah berbagai data gangguan karena sensitif terhadap ketidakteraturan sinyal.

Transformasi wavelet dapat dibagi menjadi dua jenis, yaitu transformasi wavelet kontinu dan transformasi wavelet diskrit. wavelet kontinyu digunakan untuk menghitung transisi sinyal dari sinyal modular kapan saja ke skala yang diinginkan. Skala jendela memiliki mode yang dapat

dimodifikasi. Dengan memberikan gelombang $f(t)$, transformasi wavelet kontinu dapat dihitung sebagai berikut (Rucka and Wilde, 2006; Jamali and Ghaffarzadeh, 2011).


$$TWK(f, a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \varphi^* \frac{(t-b)}{a} dt \quad (1)$$

Dimana a dan b adalah konstanta skala dan konstanta transisi (pergeseran waktu), $TWK(f, a, b)$ adalah koefisien TWK, dan φ adalah wavelet buatan. Sinyal input $f(t)$ telah disusun ulang menggunakan parameter perpindahan dan ekspansi waktu untuk skala yang tepat.

Transformasi wavelet diskrit dianggap sebagai implementasi yang relatif mudah dibandingkan dengan transformasi wavelet kontinu. Prinsip TWD adalah bagaimana mendapatkan waktu dan skala representasi sinyal menggunakan teknik curing digital dan operasi sub-sampling. Koefisien gelombang TWD dapat diperoleh dengan menerapkan TWD sebagai persamaan berikut (Mosavi and Tabatabaei, 2014).

$$TWD(f.m.k) = \frac{1}{\sqrt{a_0^m}} \sum_k f(k) \varphi^* \left[\frac{n - ka_0^m}{a_0^m} \right] \quad (2)$$


Dimana parameter a dan b dalam persamaan (2) diganti sebagai a_0^m , ka_0^m , k dan m adalah bilangan bulat positif. Dari beberapa contoh koefisien transformasi wavelet yang diambil, dekomposisi TWD didasarkan pada Algoritma Mallat (Mallat, 1989; Chandra, Kishore and Sinha, 2003).



Gambar 1. Diagram skema pengolahan sinyal dengan TWD (Misiti et al., 2016)

Pada gambar 1 gelombang sinyal input dibagi menjadi dua bagian, sinyal frekuensi rendah dikenal sebagai aproksimasi dan bagian frekuensi tinggi sebagai detail. Pada transformasi wavelet digunakan *mother wavelet* dalam mengolah sinyal

asli. *Mother wavelet* terdiri dari berbagai jenis seperti Haar, Daubechies, Coiflets, Symlets, dll. *Mother wavelet* yang paling banyak digunakan adalah daubechies yang biasa ditulis *dbN*, di mana *N* adalah orde, dan *db* menunjukkan nama *mother wavelet* Daubechies (Borghetti et al., 2008).




Gambar 2. Proses dekomposisi pada TWD (Misiti et al., 2016)

Gambar 2 menampilkan proses dekomposisi pada TWD dengan keluaran berupa aproksimasi yang dijadikan kembali sebagai masukan TWD untuk level berikutnya. Sinyal pertama dikirim ke filter *high-pass* dan filter *low-pass* lalu bagian dari setiap keluaran diambil sebagai sampel.

Support Vector Machine


SVM adalah sistem pembelajaran yang menggunakan hipotesis fungsi linear dalam ruang berdimensi tinggi dan dilatih dengan algoritma berdasarkan teori optimasi *learning bias*. Tujuan utama dari algoritma ini adalah untuk membangun *optimal separating hyperplane*, yang berfungsi pemisahan optimum yang dapat digunakan sebagai klasifikasi.



Gambar 3. *Hyperplane* pada SVM (Nugroho, Witarto and Handoko, 2003)

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*. Gambar 3 memperlihatkan beberapa *pattern* yang merupakan anggota dari dua buah *class* : +1 dan -1. *Pattern* yang tergabung pada *class* -1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada *class* +1, disimbolkan dengan warna kuning (lingkaran). Masalah klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut.

Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada gambar 3. *Hyperplane* pemisah terbaik antara kedua *class* dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. Margin adalah jarak antara *hyperplane* tersebut dengan pola terdekat dari masing-masing *class*. Pola yang paling dekat ini disebut sebagai *support vector*.



Gambar 4. *Hyperplane* terbaik dengan margin besar (Nugroho, Witarto and Handoko, 2003)

Garis solid pada gambar 4 menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua *class*, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM.

Bidang pembatas pertama membatasi kelas pertama sedangkan bidang pembatas kedua membatasi kelas kedua, sehingga diperoleh (Murty and Raghava, 2016):

$$\begin{aligned} \mathbf{x}_i \mathbf{w} + b &\geq 1, y_i = 1 \\ \mathbf{x}_i \mathbf{w} + b &\geq -1, y_i = -1 \end{aligned} \quad (3)$$

$\mathbf{w}$ adalah bidang normal dan b adalah posisi bidang alternatif terhadap pusat koordinat. Nilai margin pada SVM yang merupakan rumus jarak antara bidang pembatas adalah sebagai berikut (Kowalczyk, 2017):

$$m = \frac{2}{\|\mathbf{w}\|} \quad (4)$$

Nilai margin ini akan dimaksimalkan dengan tetap memenuhi persamaan (3), dengan mengalikan b dan $\mathbf{w}$, maka akan menghasilkan nilai margin yang dikalikan dengan konstanta yang sama. *Constraint* pada persamaan (3) merupakan *scaling constraint* yang dapat dipenuhi dengan *rescaling* b dan $\mathbf{w}$. Oleh karena itu, untuk memaksimalkan $1/\|\mathbf{w}\|$ sama dengan meminimumkan $\|\mathbf{w}\|^2$. Kedua bidang pembatas pada persamaan (3) akan direpresentasikan dalam pertidaksamaan, sebagai berikut (Kowalczyk, 2017):

$$y_i(\mathbf{x}_i \mathbf{w} + b) \geq 1 \quad (5)$$

Pemisahan garis bidang yang terbaik adalah nilai margin terbesar dapat dirumuskan menjadi optimasi konstrain, sebagai berikut (Mahmud et al., 2016):

$$\min \frac{1}{2} \|\mathbf{w}\|^2 \quad (6)$$

Untuk mengklasifikasikan data secara linear menggunakan formula SVM, maka ditambahkan variabel ξ_i yang dinamakan *soft margin hyperplane*. Dengan demikian formula perhitungan bidang pemisah terbaik menjadi (Kowalczyk, 2017):

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (7)$$

dengan $y_i(\mathbf{x}_i \mathbf{w} + b) \geq 1 - \xi_i$, $\xi_i \geq 0$

Parameter C adalah untuk menentukan besar penalti akibat kesalahan dalam klasifikasi data dan nilainya ditentukan oleh pengguna. Sehingga peran parameter C untuk meminimalkan kesalahan pelatihan dan mengurangi kompleksitas model.

Paramater C pada SVM lazim juga dipanggil *box constraint* (Kowalczyk, 2017).

Kernel trick memberikan berbagai kemudahan, karena dalam proses pembelajaran SVM, untuk menentukan *support vector*, kita hanya cukup mengetahui fungsi kernel yang dipakai, dan tidak perlu mengetahui wujud dari fungsi non-linier Φ . Pada penelitian ini digunakan jenis kernel gaussian dengan persamaan sebagai berikut.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (8)$$

Parameter SVM yang diatur pada penelitian ini adalah *gamma* γ dan *box constraint* C . Ketika pengaturan *gamma* terlalu kecil, model SVM memiliki bentuk *hyperplane* seperti SVM linier. Ketika *gamma* terlalu besar, *hyperplane* model SVM akan terlalu banyak dipengaruhi oleh setiap *support vector*. Sedangkan dengan pengaturan parameter C kita dapat menetapkan bagaimana SVM menangani *error*. Sehingga dilakukan berbagai simulasi dengan parameter yang berbeda untuk mendapatkan hasil SVM yang baik.

Persentase Kesalahan (Error)

Persentase kesalahan dapat dihitung dengan menggunakan persamaan (9) (Ihsan and Sukma, 2017).

$$E(\%) = \frac{|y_i - y'_i|}{y_i} \times 100 \quad (9)$$

Dimana :

y_i = Nilai target aktual

y'_i = Nilai keluaran prediksi

Sedangkan untuk persentase kesalahan pada estimasi lokasi gangguan yang terjadi pada saluran transmisi dapat menggunakan persamaan (10) (Dash, Pradhan and Panda, 2000).

$$E_{lokasi}(\%) = \frac{|\text{jarak sebenarnya} - \text{jarak prediksi}|}{\text{panjang saluran}} \times 100 \quad (10)$$

Root Mean Square Error dan Mean Absolute Error

Baik *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) biasanya digunakan dalam studi evaluasi model. RMSE adalah aturan penskalaan kuadrat yang juga mengukur besar kesalahan rata-rata. Yaitu akar kuadrat dari rata-rata perbedaan kuadrat antara nilai aktual dan prediksi. Sedangkan MAE mengukur besarnya rata-rata kesalahan dalam satu set prediksi, tanpa

mempertimbangkan arahnya. Yaitu rata-rata pada sampel uji dari perbedaan mutlak antara nilai aktual dan prediksi dimana semua perbedaan tiap data memiliki bobot yang sama. Rumus persamaan RMSE dan MAE dari jumlah data sebanyak n dapat dilihat dibawah ini (Chai and Draxler, 2014).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (12)$$

Dimana :

y_i = Nilai target sebenarnya

y'_i = Nilai keluaran prediksi


n = Jumlah data

2. METODA PENELITIAN

Metode penelitian yang digunakan kali ini adalah menggunakan data sistem transmisi tenaga listrik yang didapatkan dari PT. PLN (Persero), kemudian melakukan pemodelan pada data sistem transmisi tenaga listrik pada Matlab/Simulink. Selanjutnya model tersebut dilakukan simulasi gangguan hubung singkat dengan variasi berupa jenis gangguan, lokasi gangguan, resistansi gangguan dan sudut mula gangguan (*Fault Inception Angle/ FIA*). Kemudian, data-data yang diperoleh dari simulasi gangguan hubung singkat diolah menggunakan TWD sebagai masukan pada SVM untuk klasifikasi dan estimasi lokasi gangguan. Berikutnya dilakukan analisis terhadap hasil klasifikasi dan estimasi gangguan menggunakan TWD dan SVM tersebut.

Adapun sistem transmisi tenaga listrik yang digunakan sebagai objek penelitian berupa sistem transmisi yang dimulai dari bus Koto Panjang, Bangkinang dan Garuda Sakti di Provinsi Riau, yaitu sistem transmisi dengan topologi jaringan loop. Sistem ini mempunyai tiga unit generator sinkron sebagai pembangkit pada bus Koto Panjang dan daya yang diterima dari bus Payakumbuh ke bus Koto Panjang serta juga beban pada setiap bus. Pada bus Garuda Sakti terdapat *capacitor bank* dengan kapasitas 50 MVar. Gangguan diletakkan pada saluran transmisi antara bus Koto Panjang dan Garuda Sakti yang memiliki panjang saluran sebesar 64 km. Pada gambar 5 menampilkan *single line diagram* pada sistem transmisi objek penelitian. Terdapat 3 bus dengan

KP sebagai bus Koto Panjang, BG sebagai bus Bangkinang dan GS sebagai bus Garuda Sakti.



Gambar 5. Sistem Transmisi Objek Penelitian


Kemudian data gelombang arus hasil simulasi gangguan dengan frekuensi *sampling* 50 kHz akan diolah dengan menggunakan TWD dan diambil data arus selama satu siklus setelah gangguan terjadi. Urutan dekomposisi pada data arus yang mempunyai frekuensi *sampling* 50 kHz dapat dilihat pada tabel 1.

Tabel 1. Urutan dekomposisi wavelet dengan frekuensi *sampling* 50 kHz

Level	Approximation	Detail
1	0 – 12.5 kHz	12.5 – 25 kHz
2	0 – 6.25 kHz	6.25 – 12.5 kHz
3	0 – 3.125 kHz	3.125 – 6.25 kHz
4	0 – 1.563 kHz	1.563 – 3.125 kHz
5	0 – 781 Hz	781 – 1.563 kHz
6	0 – 391 Hz	391 – 781 Hz
7	0 – 195 Hz	195 – 391 Hz
8	0 – 98 Hz	98 – 195 Hz
9	0 – 49 Hz	49 – 98 Hz

Penentuan *mother wavelet* yang digunakan dalam proses TWD terhadap sinyal arus adalah *daubechies* orde 4 karena menghasilkan akurasi klasifikasi yang lebih baik dan nilai *error* yang lebih kecil pada estimasi lokasi gangguan dibandingkan *mother wavelet* lainnya (Ray and Mishra, 2016) dan sangat efektif untuk menganalisa terhadap sinyal transien (Saber, Emam and Amer, 2016; Mahmud et al., 2016).

Data arus selama satu siklus setelah gangguan terjadi hasil keluaran TWD pada detail level 8 (D8) dan detail level 9 (D9) dihitung nilai RMS untuk digunakan sebagai masukan pada SVM. Pengolahan sinyal untuk masukan SVM dapat dilihat pada flowchart di gambar 6.



Gambar 6. Flowchart pengolahan sinyal arus dan tegangan

Kemudian dilakukan pemilihan model terhadap hasil SVM yang paling baik pada klasifikasi dan estimasi. Lalu, dilakukan pengujian kembali dengan masukan yang berbeda dari data pelatihan dan pengujian SVM seperti terlihat pada tabel 2.

Dihitung akurasi dan error yang didapat dari hasil pengujian menggunakan SVM klasifikasi dan estimasi lokasi gangguan yang telah dipilih.

Tabel 2. Parameter simulasi untuk pengujian SVM klasifikasi dan estimasi lokasi gangguan

Identifikasi	Gangguan	L (%)	R (Ω)	D ($^{\circ}$)
Klasifikasi dan Estimasi	FT	0.5, 0.15,	100	30
	FF	0.25, ...,		
	FFT	98.5,		
	FFF	99.5		

Perancangan Model SVM Klasifikasi Gangguan

SVM klasifikasi jenis gangguan dibuat dengan menggunakan SVM yang mengklasifikasi gangguan pada setiap fasa dan *tanah* yang bekerja secara paralel. Ketika ada gangguan pada suatu fasa, maka SVM tersebut akan memberikan informasi berupa adanya gangguan pada fasa tersebut. Begitu juga jika terjadi gangguan ke tanah, maka SVM akan membaca melalui sinyal arus urutan nol dan memberikan informasi adanya gangguan sesuai dengan nilai arus urutan nol yang dilatihkan pada SVM. Dengan menggabungkan seluruh informasi

yang didapat dari klasifikasi gangguan yang terjadi pada setiap fasa dan *tanah* menggunakan SVM maka kita dapat mengetahui gangguan hubung singkat yang terjadi pada saluran transmisi.

Pada penelitian ini SVM klasifikasi gangguan diberikan masukan berupa variasi nilai RMS sinyal arus koefisien D8 dan D9 dari setiap hasil simulasi. Dimana masukan tersebut divariasikan yaitu :

1. 2 RMS koefisien detail sinyal arus fasa A
2. 2 RMS koefisien detail sinyal arus fasa B
3. 2 RMS koefisien detail sinyal arus fasa C
4. 2 RMS koefisien detail sinyal arus urutan nol

Untuk masing – masing SVM yang mengklasifikasi gangguan pada fasa (A, B dan C) yang digunakan sebagai masukan adalah sampel arus masing – masing fasa tersebut, sedangkan untuk klasifikasi gangguan pada *tanah* yang akan digunakan sebagai masukan adalah sampel arus urutan nol.

Sedangkan untuk parameter pada SVM digunakan jenis kernel yakni Gaussian. Variasi terhadap nilai parameter γ dan $\text{box constraint } C$ dilakukan untuk mendapatkan dan memilih hasil akurasi yang baik serta lama waktu pelatihan fungsi SVM yang singkat. Parameter γ dengan nilai 10^{-2} , 10^{-1} sedangkan parameter C dengan nilai 10^0 , 10^1 , 10^2 , 10^3 sehingga dilakukan sebanyak 8 kali simulasi pelatihan SVM pada setiap fasa dan *tanah* (Ma and Guo, 2014).

Perancangan Model SVM Estimasi Lokasi Gangguan

Pada penelitian ini SVM estimasi lokasi gangguan diberikan 6 masukan, yang berupa nilai RMS koefisien D8 dan D9 dari sinyal arus setelah gangguan pada setiap fasa. Masukan dari SVM estimasi lokasi gangguan dapat dirumuskan sebagai berikut :

1. 2 RMS koefisien detail sinyal arus fasa A
2. 2 RMS koefisien detail sinyal arus fasa B
3. 2 RMS koefisien detail sinyal arus fasa C

SVM digunakan jenis kernel Gaussian. Masukan SVM untuk estimasi lokasi gangguan berupa ϵ , γ dan $\text{box constraint } C$. Nilai ϵ menunjukkan batas galat dengan masukan nilai tetap sebesar 10^{-3} . Sedangkan nilai parameter γ dan $\text{box constraint } C$ bervariasi agar mendapatkan hasil perhitungan RMSE yang kecil dan lama waktu pelatihan fungsi SVM yang singkat. Parameter γ dengan nilai 10^{-2} , 10^{-1} sedangkan parameter C dengan nilai 10^0 , 10^1 , 10^2 , 10^3 , 10^4

sehingga dilakukan sebanyak 10 kali simulasi pelatihan SVM pada setiap (Ma and Guo, 2014).

3. HASIL DAN PEMBAHASAN

Tabel 3 dan 4 adalah hasil pelatihan dan pengujian masing-masing model SVM klasifikasi dan estimasi lokasi gangguan.

Tabel 3. Rata-rata jumlah iterasi dan akurasi pada masing – masing model SVM klasifikasi gangguan

No	Model	Parameter SVM		Rata-Rata	
		γ	C	Jumlah Iterasi	Akurasi (%)
1	FC11	0.01	1	236	99.83
2	FC12		10	85	99.96
3	FC13		100	41	100.00
4	FC14		1000	36	100.00
5	FC21	0.1	1	90	99.98
6	FC22		10	55	100.00
7	FC23		100	55	100.00
8	FC24		1000	181	100.00


Tabel 4. Rata-rata RMSE dan MAE pada masing – masing model SVM estimasi lokasi gangguan

No	Model	Parameter SVM		Rata-Rata RMSE	Rata-Rata MAE
		γ	C		
1	FL11	0.01	1	11.4767	9.6839
2	FL12		10	1.2711	0.8940
3	FL13		100	0.1003	0.0624
4	FL14		1000	0.0255	0.0166
5	FL15		10000	0.0097	0.0060
6	FL21	0.1	1	8.1796	5.4478
7	FL22		10	0.7748	0.3567
8	FL23		100	0.0919	0.0531
9	FL24		1000	0.0241	0.0137
10	FL25		10000	0.0186	0.0095

Dari hasil perancangan SVM untuk klasifikasi gangguan dipilih hasil pelatihan dan pengujian model terbaik dengan parameter γ 0.01 dan C 1000. Sedangkan SVM estimasi lokasi


gangguan dipilih hasil pelatihan dan pengujian model terbaik dengan parameter γ 0.01 dan C 10000.

Hasil pengujian SVM klasifikasi dan estimasi lokasi gangguan menggunakan parameter SVM yang dipilih dapat dihitung nilai persentase *error* masing-masing model SVM klasifikasi dan estimasi lokasi gangguan. Pada SVM klasifikasi gangguan dapat menentukan adanya gangguan pada masing-masing fasa dan tanah secara benar sesuai dengan jenis gangguan yang terjadi, sehingga akurasi SVM klasifikasi gangguan adalah 100 % tanpa ada satupun *error*. Sedangkan untuk SVM estimasi lokasi gangguan dapat dihitung nilai *error* hasil SVM seperti terlihat pada gambar 7 dibawah ini.



Gambar 7. Persentase *error* SVM estimasi lokasi setiap gangguan

Gambar 7 merupakan hasil perhitungan *error* estimasi lokasi gangguan terhadap berbagai gangguan yang telah disimulasikan. Adapun gangguan yang terjadi berupa AG, BG, CG, AB, AC, BC, ABG, ACG, BCG dan ABC. Hasil pengujian dari SVM estimasi lokasi gangguan yang menghasilkan rata-rata *error* pengujian terkecil dihasilkan oleh model SVM estimasi lokasi gangguan jenis ABC yaitu sebesar 0.002281 %, sedangkan rata-rata *error* terbesar dihasilkan oleh model estimasi lokasi gangguan jenis BG yaitu sebesar 0.021529 %.



Gambar 8. Hasil perhitungan RMSE dan MAE pengujian SVM estimasi lokasi gangguan

Hasil perhitungan nilai RMSE dan MAE dari pengujian dapat dilihat pada gambar 8 dibawah ini. Garis merah menunjukkan hasil perhitungan RMSE sedangkan garis biru menunjukkan hasil perhitungan MAE. Dapat dilihat model SVM estimasi lokasi gangguan yang memiliki nilai RMSE dan MAE terkecil yaitu pada gangguan ABC sebesar 0.0023 dan 0.0015. Sedangkan yang memiliki nilai RMSE terbesar terletak pada gangguan BC sebesar 0.0202 dan nilai MAE terbesar terletak pada gangguan BG 0.0138.

4. KESIMPULAN

Berdasarkan hasil perancangan dan analisa TWD dan SVM sebagai klasifikasi gangguan dan estimasi lokasi gangguan di sistem transmisi tenaga listrik dari bus Koto Panjang, bus Bangkinang dan bus Garuda Sakti dapat diambil kesimpulan. Pertama, perancangan model SVM FC15 klasifikasi gangguan sebagai model SVM klasifikasi terpilih pada masing – masing fasa dan tanah dengan nilai γ 0.01 dan nilai C 1000 menghasilkan akurasi klasifikasi yaitu sebesar 100 %. Kedua, perancangan model SVM FL16 sebagai model SVM estimasi terpilih pada setiap jenis gangguan dengan nilai γ 0.01 dan nilai C 10000 menghasilkan rata-rata error pengujian yang terendah yaitu pada gangguan ABC sebesar 0.002281 % dengan RMSE 0.0023 dan MAE 0.0015, sedangkan rata-rata error yang terbesar yaitu pada gangguan BG sebesar 0.021529 % dengan RMSE 0.0197 dan MAE 0.0138.

DAFTAR PUSTAKA

Borghetti, A., Bosetti, M., Silvestro, M. Di, Nucci, C.A. and Paolone, M., 2008. Continuous-wavelet transform for fault location in

distribution power networks: definition of mother wavelet inferred from fault originated transients. *IEEE Transactions on Power Systems*, 23(2), pp.380–389.

Chai, T. and Draxler, R.R., 2014. Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), pp.1247–1250.

Chandra, D., Kishore, N.K. and Sinha, A., 2003. A wavelet multi resolution analysis for location of fault on transmission line. *Electrical Power and Energy System*, 25, pp.59–69.

Dash, P.K., Pradhan, A.K. and Panda, G., 2000. A novel fuzzy neural network based distance relaying scheme. *IEEE Transactions on Power Delivery*, 15(3), pp.902–907.

Ihsan, B. and Sukma, D.Y., 2017. Pengaruh masukan dan fungsi aktivasi terhadap kecepatan pelatihan jaringan syaraf tiruan (JST) modular sebagai klasifikasi dan estimasi lokasi gangguan pada saluran distribusi bawah tanah PT. Pertamina RU II Dumai. *JOM FTEKNIK*, 4(1), pp.1–8.

Jamali, S. and Ghaffarzadeh, N., 2011. A new method for arcing fault location using discrete wavelet transform and wavelet networks. *European Transactions on Electrical Power*, 22, pp.601–615.

Kowalczyk, A., 2017. *Support Vector Machine Succinctly*. Syncfusion, Inc.

Ma, Y. and Guo, G. eds., 2014. *Support Vector Machines Applications*. New York: Springer.

Mahmud, M.N., Ibrahim, M.N., Osman, M.K. and Hussain, Z., 2016. Fault classification in transmission line using support vector machine (SVM) and wavelet features. *Journal of Engineering and Applied Sciences*, 11(11), pp.2479–2484.

Mallat, S.G., 1989. Theory for multi resolution signal decomposition the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), pp.674–693.

Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J.-M., 2016. *Wavelet Toolbox™ Getting Started Guide*. Natick: The MathWorks, Inc.

Mosavi, M.R. and Tabatabaei, A., 2014. Wavelet and neural network-based fault location in power systems using statistical analysis of traveling wave. *Arab J Sci Eng*, 8, pp.1–8.

Murty, M.N. and Raghava, R., 2016. *Support Vector Machines and Perceptrons Learning*,

Optimization, Classification, and Application to Social Networks. Springer.

- Nugroho, A.S., Witarto, A.B. and Handoko, D., 2003. Application of support vector machine in bioinformatics. In: *Proceeding of Indonesian Scientific Meeting*. Gifu, Japan.
- Ray, P. and Mishra, D.P., 2016. Support vector machine based fault classification and location of a long transmission line. *Engineering Science and Technology, an International Journal*, [online] 19(3), pp.1368–1380. Available at: <<http://dx.doi.org/10.1016/j.jestch.2016.04.001>>.
- Rucka, M. and Wilde, K., 2006. Application of continuous wavelet transform in vibration based damage detection method for beams and plates. *Journal of Sound and Vibration*, 297, pp.536–550.
- Saber, A., Emam, A. and Amer, R., 2016. Discrete wavelet transform and support vector machine-based parallel transmission line faults classification. *IEEJ Transactions on Electrical and Electronic Engineering*, 11(1), pp.43–48.
- Zin, A.A.M., Saini, M., Mustafa, M.W., Sultan, A.R. and Rahimuddin, 2015. New algorithm for detection and fault classification on parallel transmission line using DWT and BPNN based on Clarke's transformation. *Neurocomputing*, 168(30), pp.983–993.