

DIAGNOSIS PENYAKIT PARKINSON MELALUI ANALISIS POLA BERJALAN BERDASARKAN VGRF MENGGUNAKAN WAVELET DAN SUPPORT VECTOR MACHINE

DIAGNOSIS OF PARKINSON'S DISEASE THROUGH GAIT ANALYSIS BASED ON VGRF USING WAVELET AND SUPPORT VECTOR MACHINE

Gusty Aditya Arrazaq¹, Rita Magdalena², Ratri Dwi Atmaja³

^{1,2,3}Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

¹gustvaditya@student.telkomuniversity.ac.id, ²ritamagdalenat@telkomuniversity.ac.id,

³ratriidwiatmaja@telkomuniversity.ac.id

Abstrak

Penyakit parkinson atau *Parkinson's Disease* (PD) tidak dapat didiagnosis disaat gejala muncul melalui citra medis yang didapatkan dari teknologi pindaian otak menggunakan *computed tomography* dan *magnetic resonance imaging* terhadap penderita PD karena tampak normal. Maka dari itu dibutuhkan metode lain yang dapat digunakan untuk mendiagnosis PD secara dini meskipun penderita PD masih tampak normal. Penderita PD bukan hanya memiliki gejala kegoyahan dan kekakuan saja melainkan juga memiliki kelainan bergerak dan kehilangan keseimbangan. Oleh karena itu, penelitian ini dilakukan dengan cara mengklasifikasi rekaman sinyal yang dihasilkan oleh sensor *vertical ground reaction force* (VGRF) bersumber dari *database* Physiobank. Sensor VGRF berjumlah 16 sensor dipasang pada kaki saat berjalan agar dapat mendiagnosis PD melalui analisis pola berjalan dengan menggabungkan koefisien *wavelet* dari hasil dekomposisi sinyal VGRF dan diklasifikasi menggunakan *support vector machine* (SVM). Penelitian ini menunjukkan bahwa koefisien *wavelet* adalah ciri yang baik untuk mewakili sinyal VGRF. SVM pada 140 vektor pelatihan dan 139 vektor pengujian mencapai akurasi klasifikasi sebesar 81,29% dengan waktu *central processing unit* (CPU) selama 80,87 detik sehingga metode ini dapat dipertimbangkan untuk digunakan pada analisis pola berjalan bagi penderita PD berdasarkan rekaman sinyal VGRF.

Kata kunci: *Parkinson's Disease*, *Vertical Grond Reaction Force*, *Wavelet*, *Support Vector Machine*, Analisis Pola Berjalan.

Abstract

Parkinson's Disease (PD) cannot be diagnosed by a medical image when the initial symptoms appear because brain scans technology using *computed tomography* and *magnetic resonance imaging* for PD symptoms looks normal. Therefore, it is needed an analytical method that can be used for early PD diagnostics even though people with PD still looks normal. Patients with PD not only have symptoms of shakiness and stiffness but also have movement disorder and loss of balance. Thus, this research is done by classifying the record of signals which generated by the *vertical ground reaction force* (VGRF) sensor from the Physiobank database. The VGRF sensor totals 16 sensors mounted on the feet during walking in order to diagnose PD through a gait analysis by combining the *wavelet* coefficients of the VGRF signal decomposition results and classified using the *support vector machine* (SVM). This study shows that the *wavelet* coefficient is a good feature for representing VGRF signals. The SVM on 140 training vectors and 139 testing vectors achieves classification accuracy of 81,29% with 80,87 seconds on *central processing unit* (CPU) time, then this method can be considered for the gait analysis based on VGRF signal recording.

Keywords: Parkinson's Disease, Vertical Grond Reaction Force, Wavelet, Support Vector Machine, Gait Analysis.

1. Pendahuluan

Telah banyak penelitian yang dilakukan sebagai upaya menyembuhkan penyakit parkinson dengan menggunakan teknologi canggih dalam bidang ilmu biomedis pada saat ini. Namun para penderita parkinson masih belum dapat disembuhkan dengan spesifik. Selama ini obat-obatan dan terapi digunakan untuk merawat gejala penyakit parkinson agar tidak berkembang dengan cepat dan mengganggu kegiatan sehari-hari para penderita [1,2]. Oleh karena itu, pencegahan dengan cara diagnosis gejala parkinson secara dini sangat direkomendasikan oleh para ahli saraf dimana kolaborasi dari berbagai bidang ilmu pengetahuan akan sangat dibutuhkan agar penelitian menjadi lebih efektif [2].

Pada penelitian ini, diagnosis penyakit parkinson dengan menganalisis pola bagaimana seseorang berjalan dilakukan karena dapat menunjukkan sumber masalah dari otot, saraf, atau tulang [3,4,5]. Diagnosis penyakit parkinson dianalisis melalui pola berjalan melalui rekaman VGRF yang diterima melalui 16 buah sensor yang dipasang pada kaki kanan dan kaki kiri objek penelitian dengan menghitung tekanan (dalam newton) pada tiap sensor [1].

Analisis dilakukan pada rekaman VGRF dalam bentuk sinyal dimana sumber data rekaman berasal dari *database* Physiobank. Rekaman VGRF ini mungkin mengandung petunjuk penting tentang sifat penyakit yang dialami penderita PD. Rekaman sinyal VGRF adalah sinyal nonstasioner, sehingga status kesehatan tampak secara tidak teratur dalam skala waktu. Jika analisis tidak dilakukan pada interval waktu yang tepat terdapat kemungkinan peneliti kehilangan informasi penting. Sehingga analisis komputasi dan klasifikasi penyakit dapat membantu dalam mendiagnosis.


Hasil ekstraksi ciri dari pengukuran rekaman data yang telah melalui proses *preprocessing* berupa *wavelet shrinkage denoising* disebut sebagai vektor ciri, yang dapat digunakan untuk menggambarkan morfologi dari rekaman sinyal yang diproses. Modul dari pemilihan ciri adalah tahap opsional, dimana vektor ciri mengurangi ukuran data dan dapat dipertimbangkan sebagai ciri yang dibutuhkan sebagai pemisah dari sudut pandang klasifikasi. Modul klasifikasi adalah tahap akhir dalam diagnosis otomatis. Modul ini menguji input vektor ciri dan berdasarkan ketentuan algoritmik menghasilkan hipotesis sugestif [6-8].

Transformasi *wavelet* atau *wavelet transformation* (WT) diterapkan untuk ekstraksi koefisien *wavelet* dari sinyal waktu diskrit. Skema yang diajukan adalah *subband coding* atau analisis sinyal multiresolusi [8,9]. Ciri multiresolusi dari WT memungkinkan dekomposisi sinyal kedalam sejumlah skala, tiap skala mewakili kekasaran tertentu dari sinyal yang dipelajari. WT menyajikan teknik umum yang dapat diterapkan pada banyak kasus dalam pemrosesan sinyal. Salah satu penerapan penting adalah kemampuan untuk komputasi dan memanipulasi data dalam parameter terkompresi yang disebut ciri [10-13]. Kemudian sinyal VGRF yang mengandung banyak titik data dapat dikompresi kedalam beberapa parameter. Parameter ini mengkarakterisasi kebiasaan dari sinyal VGRF. Ciri dari penggunaan sejumlah kecil parameter untuk mewakili sinyal VGRF adalah penting untuk tujuan pengenalan dan diagnostik [14-16].

Terdapat beberapa metode untuk menunjukkan pola sebagai pengelompokan ciri. Pemilihan metode yang tepat untuk memberikan tugas analisis pola jarang ditemukan. Pada tiap level (ekstraksi ciri, pemilihan ciri, klasifikasi) banyak metode yang dapat digunakan [6,7]. Dalam rangka membedakan sinyal VGRF normal dan parkinson yang diperoleh dari *database* Physiobank, SVM berdasarkan vektor ciri yang telah melalui tahap *preprocessing* yaitu *wavelet shrinkage denoising* dan tahap ekstraksi ciri yaitu *wavelet transform* diterapkan. Kontribusi yang signifikan dari penelitian ini digunakan untuk menguji pada klasifikasi sinyal VGRF. WT mampu mengekstraksi dan melokalisasi pola transien yang spesifik dari sinyal untuk membuat sinyal tersebut menjadi *input* yang tepat dalam klasifikasi SVM. Tiap bagian yang dipelajari dari sinyal yang diproses menggunakan dekomposisi *wavelet* kedalam multi-level *low-* dan *high-pass subband* akan dijadikan *input* kedalam SVM untuk tujuan pelatihan dan pengujian. Akurasi tinggi didapatkan dengan menggunakan LSSVM dengan kernel *polynomial* yang dilatih pada koefisien *wavelet*. Penelitian ini dilakukan untuk membuka peluang penyembuhan parkinson dengan akurasi sebesar 81,29% dengan waktu *central processing unit* (CPU) selama 80,87 detik sehingga metode ini dapat dipertimbangkan serta mencegah terjadinya perkembangan gejala penyakit ini secara dini.

2. Analisis spektral menggunakan *discrete wavelet transform*

Sinyal nonstasioner sering dianalisis menggunakan WT karena WT melokalisasi waktu dan frekuensi secara baik. Keuntungan utama dari WT adalah memiliki ukuran window yang beragam, tersebar di frekuensi rendah dan terbatas pada frekuensi tinggi, yang kemudian mengarah pada resolusi waktu-frekuensi yang optimal dalam semua ukuran frekuensi. Karena itu, analisis spektral dari sinyal VGRF dilakukan menggunakan DWT.

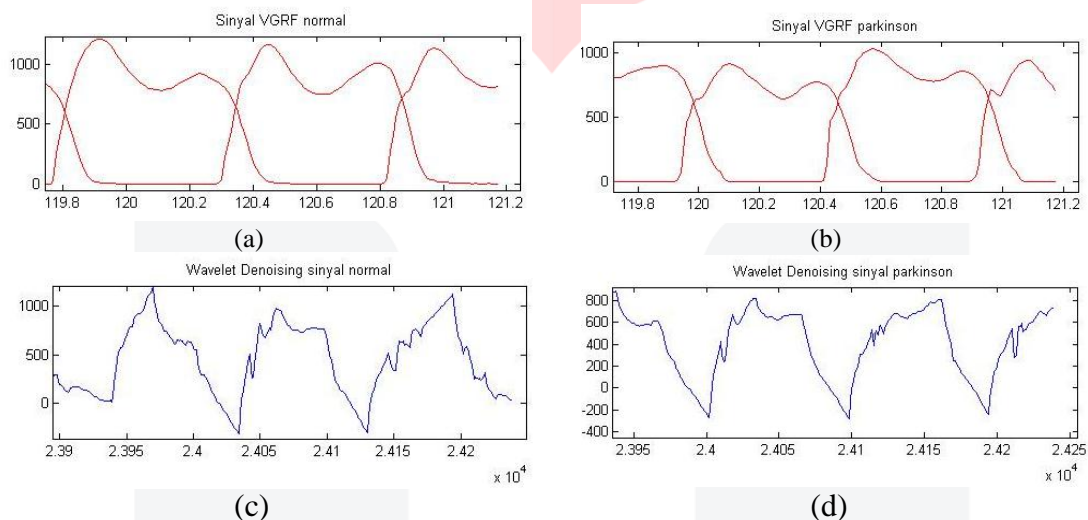


Gambar 2.1 Struktur umum skenario evaluasi [3]

Pemilihan *wavelet* yang tepat dan jumlah level dekomposisi sangat penting dalam analisis sinyal menggunakan WT. Level dipilih berdasarkan hasil simulasi yang memiliki performansi dan efisiensi terbaik sehingga bagian sinyal yang berkorelasi dengan frekuensi yang dibutuhkan untuk klasifikasi sinyal dipertahankan dalam koefisien *wavelet*. Pada penelitian ini, jumlah level dekomposisi yang dipilih adalah 4 sama seperti yang ditentukan dalam penelitian [8] dan [16]. Jadi, sinyal VGRF didekomposisi kedalam detail D1 - D4 dan aproksimasi A4. Percobaan dilakukan menggunakan berbagai tipe dari *wavelet* dan salah satu tipe *wavelet* yang memberikan efisiensi maksimum dipilih untuk diterapkan pada sinyal VGRF.

Mother wavelet pada proses *wavelet shrinkage denoising* yang lebih cocok digunakan pada sinyal VGRF adalah Daubechies orde 2 (db2). Sedangkan parameter denoising seperti TPTR (karakter vektor yang berisi aturan pemilihan *threshold*), SORH (*soft* atau *hard threshold* pada vektor input) dan SCAL (*rescaling threshold* multiplikatif) yang cocok untuk digunakan pada proses preprocessing adalah Stein's Unbiased Risk Estimation (SURE), *soft thresholding* dan 'mln' (*rescaling* menggunakan estimasi *level-dependent* dari tingkat derau). Berdasarkan parameter yang cocok digunakan dapat disimpulkan bahwa sinyal VGRF memiliki detail pada bagian sinyal yang berderau. Plot sinyal normal dan parkinson yang belum dan telah melalui *wavelet denoising* ditunjukkan pada Gambar 2.2.

Pada proses ekstraksi ciri, *mother wavelet* yang sesuai untuk digunakan pada sinyal VGRF adalah Daubechies orde 6 (db6). Sehingga, koefisien *wavelet* dihitung menggunakan *mother wavelet* tersebut dalam penelitian ini. Untuk meneliti efek dari *wavelet* lainnya dalam akurasi klasifikasi, pengujian dilakukan menggunakan *wavelet* lainnya juga.



Gambar 2.2 Plot sinyal VGRF: (a) sinyal normal, (b) sinyal parkinson, (c) sinyal normal yang telah melalui *wavelet denoising*, (d) sinyal parkinson yang telah melalui *wavelet denoising*

Tabel 2.1 Total akurasi klasifikasi SVM pada tiap *wavelet* sinyal VGRF

Tipe <i>mother wavelet</i>	Total akurasi klasifikasi (%)	Iterasi	Waktu CPU (detik)
Discrete Meyer (dmey)	79,13	9533	114,44
Symlet orde 2 (sym2)	79,85	10863	180,00
Symlet orde 10 (sym10)	79,13	11188	164,52
Coiflet orde 1 (coif1)	79,85	17435	240,42
Coiflet orde 4 (coif4)	77,69	12437	164,13
Daubechies orde1 (db1)	77,69	5983	79,24
Daubechies orde2 (db2)	79,85	10863	153,94
Daubechies orde6 (db6)	81,29	7020	80,87
Daubechies orde7 (db7)	76,25	9082	135,46
Daubechies orde8 (db8)	79,97	11938	198,25
Biorthogonal 1.1 (bior1.1)	77,69	5983	70,78
Reverse Biorthogonal 1.1 (rbio1.1)	77,69	5983	88,65

Selain *mother wavelet* yang sesuai tersebut, Symlet orde 2 (sym2), Symlet orde 10 (sym10), Coiflet orde 1 (coif1), Coiflet orde 4 (coif4), Daubechies orde 1 (db1), Daubechies orde 2 (db2), Daubechies orde 7 (db7), Daubechies orde 8 (db8), Biorthogonal 1.1 (bior1.1), Reverse Biorthogonal 1.1 (rbio1.1) dan Discrete Meyer (dmey) juga diteliti. Total akurasi klasifikasi yang diperoleh tiap *wavelet* saat sinyal VGRF diklasifikasikan menggunakan SVM ditunjukkan dalam Tabel 2.1 dimana dibuktikan bahwa *mother wavelet* Daubechies orde 6 (db6) lebih baik dan lebih efisien diterapkan pada sinyal VGRF dibandingkan dengan *mother wavelet* lainnya. Sedangkan ekstraksi ciri dari contoh rekaman pada tiap kelas sinyal VGRF berdasarkan koefisien *wavelet* diskrit yang telah dihitung pada tiap *subband* disajikan pada Tabel 2.2.

Pada percobaan pertama, koefisien *wavelet* yang dihitung dari sinyal VGRF digunakan sebagai vektor ciri yang mewakili sinyal. Contohnya pada *database* Normal1.txt terdapat vektor berjumlah 12119 yang harus melalui proses *preprocessing* dan *framing* dalam simulasi MATLAB untuk digunakan sebagai vektor ciri (input pada SVM). Setelah itu sinyal didekomposisi WT sehingga koefisien *wavelet* berjumlah 81 vektor untuk digunakan pada proses klasifikasi. Pada percobaan kedua, ciri statistik digunakan sebagai vektor ciri. Contohnya pada *database* Normal1.txt yang terdapat vektor berjumlah 12119 melalui proses *preprocessing* dan DWT level 4 sehingga vektor menjadi 24280, dimana detail koefisien *wavelet* (dk, k=1,2,3,4) di level pertama, kedua, ketiga dan keempat (12124+6067+3039+1525 koefisien) dan aproksimasi koefisien *wavelet* (a4) di level keempat (1525 koefisien) dihitung secara statistik. Ciri statistik dibawah ini digunakan untuk mewakili distribusi waktu-frekuensi dari sinyal VGRF: nilai maksimum dari koefisien *wavelet* tiap *subband*, rata-rata dari koefisien *wavelet* tiap *subband*, nilai minimum dari koefisien *wavelet* tiap *subband* dan standar deviasi dari koefisien *wavelet* tiap *subband*. Ciri-ciri statistik tersebut dapat diterapkan pada MATLAB dan dirumuskan sebagai berikut [17]:

$$\text{Rata-rata} : \bar{X} = \frac{1}{n} \sum_{i=1}^n Xi \quad (2.1)$$

$$\text{Standar deviasi} : s = \frac{1}{n-1} (\sum_{i=1}^n (Xi - \bar{X})^2)^{1/2} \quad (2.2)$$

$$\text{Nilai maksimum} : C = \max_x (Xi) \quad (2.3)$$

$$\text{Nilai minimum} : C = \min_x (Xi) \quad (2.4)$$

dimana \bar{X} = nilai rata-rata koefisien *wavelet*.

Xi = vektor koefisien *wavelet*.

n = jumlah elemen pada sampel.

Ciri-ciri ini memiliki keuntungan besar karena kebal terhadap variasi tanda titik acuan. Beberapa penulis menggunakan teknik ini untuk mengurangi ruang kosong dari ciri-ciri setelah menerapkan transformasi *wavelet* [8][18]. Sehingga digunakan sebanyak 20 vektor ciri pada percobaan kedua. Hasil dari kedua percobaan ini disajikan pada Tabel 3.3.

Tabel 2.2 Contoh ekstraksi ciri rekaman sinyal VGRF pada tiap kelas

Sinyal VGRF	Ekstraksi ciri	Koefisien <i>wavelet</i>				
		D1	D2	D3	D4	A4
Normal	Maksimum	90,30	156,93	416,25	1086,10	4835,10
	Rataan	-0,02	-0,02	0,97	0,01	2171,80
	Minimum	-110,54	-119,31	-503,55	-1250,40	-710,76
	Standar Deviasi	15,94	29,60	96,08	361,05	1720,7
Parkinson	Maksimum	37,19	55,46	135,12	396,52	3167,00
	Rataan	-0,04	0,07	0,79	-3,51	1424,60
	Minimum	-42,81	-57,47	-113,22	-435,91	-228,70
	Standar Deviasi	6,39	11,11	29,47	158,56	1123,10

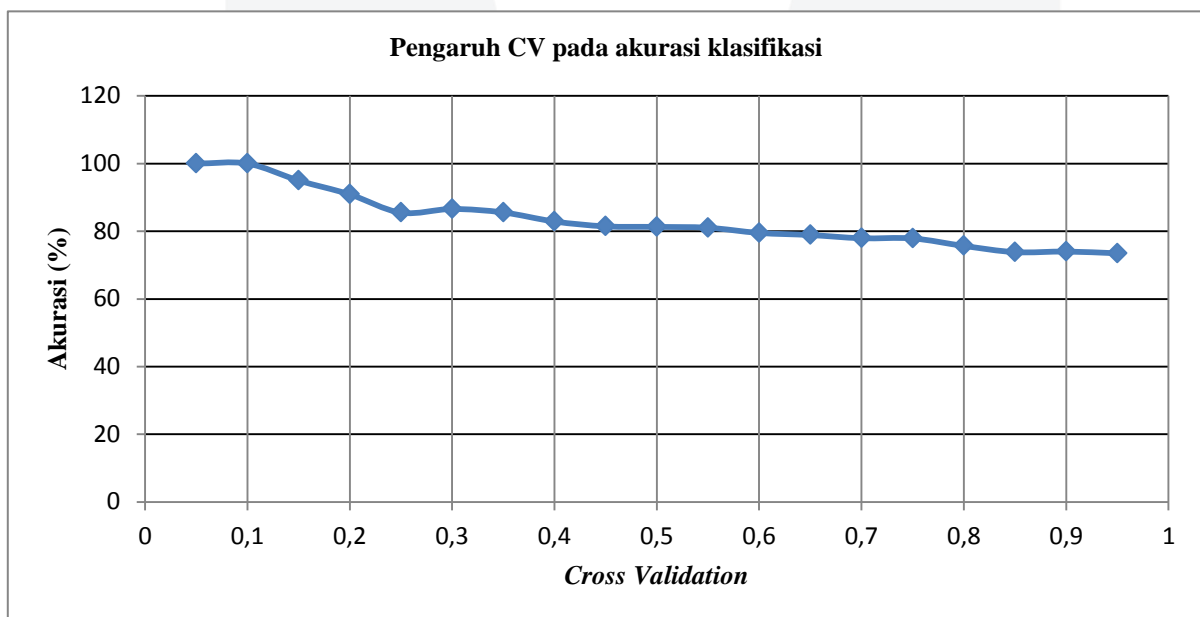
3. Implementasi SVM

Fungsi yang memadai dari jaringan saraf tiruan bergantung pada ukuran dari set pelatihan dan set pengujian. Berbagai percobaan dilakukan untuk menentukan ukuran set pelatihan dan set pengujian dari sinyal VGRF. Total akurasi klasifikasi diperoleh dari percobaan ini disajikan dalam Tabel 3.1. Set pelatihan dan pengujian disusun oleh 279 vektor (86 vektor milik 86 rekaman sinyal normal dan 193 vektor milik rekaman sinyal parkinson) dalam 20 dimensi (dimensi dari vektor ekstraksi ciri). Seluruh vektor dimensi tersebut digunakan untuk mendefinisikan ciri ekstraksi dari sinyal VGRF.

Tabel 3.1 Total akurasi klasifikasi diperoleh dari berbagai percobaan yang berhubungan dengan ukuran set pelatihan dan pengujian dari sinyal VGRF

CV	Jumlah vektor pelatihan	Jumlah vektor pengujian	Total akurasi klasifikasi (%)
0,10	252	27	100,00
0,20	224	55	90,90
0,30	196	83	86,58
0,40	168	111	82,88
0,50	140	139	81,29
0,60	112	167	79,51
0,70	84	195	77,94
0,80	56	223	75,67
0,90	28	251	74,00

Untuk menentukan performansi SVM yang digunakan untuk klasifikasi sinyal VGRF, spesifisitas, sensitivitas, total akurasi klasifikasi dan waktu *central processing unit* (CPU) disajikan dalam Tabel 3.2. Metode terbaik dalam pelatihan berdasarkan penelitian yang telah dilakukan adalah *least squares SVM* (LSSVM). Sedangkan diantara fungsi kernel *linear*, *radial basis function* (RBF), *quadratic*, *polynomial* dan *multilayer perceptron* (MLP), fungsi kernel yang cocok digunakan pada sinyal VGRF adalah kernel *Polynomial*.



Gambar 3.1 Grafik pengaruh *cross validation* pada akurasi klasifikasi

Total akurasi klasifikasi SVM yang diperoleh dalam percobaan pertama (81 koefisien *wavelet* digunakan sebagai input SVM) adalah 71,94% dengan waktu CPU selama 752,11 detik. Sementara percobaan kedua (ciri statistik digunakan sebagai input SVM) meningkatkan total akurasi klasifikasi dan mengurangi waktu CPU cukup signifikan. Berdasarkan penelitian ini dibuktikan bahwa dimensi yang tinggi dari vektor ciri meningkatkan kompleksitas perhitungan dan berdampak pada performansi dan efisiensi sistem. Percobaan ketiga dan keempat pada Tabel 3.3 dilakukan untuk membuktikan bahwa vektor ciri statistik yang digunakan sebagai input pada metode klasifikasi SVM memiliki performansi dan efisiensi yang lebih baik dibandingkan dengan metode KNN

Tabel 3.2 Nilai parameter statistik dan waktu CPU dari pelatihan klasifikasi SVM berdasarkan metode dan kernel berbeda

Metode	Kernel	Parameter statistik			Iterasi	Waktu CPU (detik)
		Sensitivitas (%)	Spesifisitas (%)	Total akurasi klasifikasi (%)		
SMO	Linear	60,46	76,04	71,22	51	24,55
	RBF	20,93	100,00	75,53	15363	903,29
	Quadratic	48,83	90,62	77,69	5630	2172,10
	Polynomial	67,44	79,16	75,53	22	2,41
	MLP	55,81	73,95	68,34	9589	436,15
LS	Linear	69,76	82,29	78,41	6022	95,94
	RBF	20,93	100,00	75,53	2884	40,93
	Quadratic	58,13	82,29	74,82	6790	98,19
	Polynomial	76,74	83,33	81,29	7020	80,87
	MLP	69,76	70,83	70,50	3973	68,59
QP	Linear	69,76	82,29	78,41	6022	715,05
	RBF	20,93	100,00	75,53	2884	119,27
	Quadratic	53,48	87,50	76,97	6490	4383,30
	Polynomial	72,09	86,45	82,01	7928	3933,90
	MLP	-	-	-	-	-

Setelah mendapatkan ciri maka dilakukan klasifikasi menggunakan SVM. Metode dan kernel dipilih berdasarkan analisis simulasi MATLAB. Performansi analisis sistem pola berjalan dari pengolahan sinyal VGRF akan diperoleh dengan melihat sensitivitas, spesifisitas, total akurasi klasifikasi dan waktu CPU. Sensitivitas, spesifisitas, dan total akurasi klasifikasi didefinisikan sebagai berikut [8]:

Sensitivitas: jumlah keputusan positif yang benar/jumlah kasus positif sebenarnya.

Spesifisitas: jumlah keputusan negatif yang benar/jumlah kasus negatif sebenarnya.

Total akurasi klasifikasi: jumlah keputusan yang benar/total jumlah kasus.

Tabel 3.3 Nilai parameter statistik dan waktu CPU pada metode klasifikasi dengan vektor ciri berbeda

Klasifikasi	Vektor ciri	Sensitivitas (%)	Spesifisitas (%)	Akurasi (%)	Iterasi	CPU (detik)
SVM	Koefisien wavelet	25,58	92,70	71,94	37605	752,11
	Statistik	76,74	83,33	81,29	7020	80,87
KNN	Koefisien wavelet	25,58	96,87	74,82	287	7,44
	Statistik	62,79	86,45	79,13	4382	101,43

4. Analisis Hasil

Berdasarkan hasil dari penelitian ini ditekankan bahwa metode *preprocessing* dan ekstraksi ciri adalah penting dalam mengembangkan sistem pendiagnosian karena pada tahap ini dapat mengubah akurasi klasifikasi. Penelitian ini sesuai dengan penelitian [8] dan [14-16] yang mendemonstrasikan analisis berdasarkan *wavelet* dan membuktikan bahwa analisis ini memberikan hasil yang baik. Penggunaan parameter 'rigsure' pada TPTR

berdasarkan hasil performansi terbaik dari *wavelet shrinkage denoising* membuktikan bahwa koefisien detail sinyal VGRF berada pada bagian sinyal yang memiliki derau.

Selama pelatihan SVM, banyak upaya perhitungan dipakai dalam menyelesaikan masalah SVM untuk menemukan *support vector*. SVM memetakan ciri ke ruang dimensi yang lebih tinggi dan kemudian menggunakan *hyperplane* optimal dalam ruang pemetaan. Ini menyiratkan bahwa meskipun ciri asli membawa informasi memadai untuk klasifikasi yang baik, pemetaan ruang ciri berdimensi lebih tinggi berpotensi memberikan petunjuk diskriminatif yang tidak disajikan dalam ruang ciri asli dan membutuhkan waktu CPU yang lebih lama. Akurasi klasifikasi berdasarkan vektor ciri statistik dari SVM memberikan wawasan tentang ciri yang digunakan untuk mendefinisikan sinyal VGRF. Kesimpulan atas penelitian ini membuktikan vektor ciri statistik koefisien *wavelet* adalah ciri yang baik untuk mewakili sinyal VGRF dan dengan penggunaan ciri ini sifat khusus yang baik antar kelas dapat diperoleh dan mengurangi waktu CPU cukup signifikan.

Pemilihan fungsi kernel yang tepat diperoleh melalui proses *trial-and-error*. Peneliti tidak dapat mengetahui fungsi kernel yang tepat dan performansi SVM sampai peneliti mencoba dan mengujinya dengan data yang dianalisis. Untuk pelatihan LSSVM terhadap rekaman sinyal VGRF dengan fungsi kernel *Polynomial* berdasarkan ciri statistik dekomposisi WT pada tiap *subband* yang sebelumnya dihilangkan deraunya melalui *wavelet shrinkage denoising* menghasilkan total akurasi klasifikasi terbaik dan memiliki waktu *central processing unit* (CPU) tercepat.

5. Kesimpulan

Berdasarkan penelitian ini yang telah dilakukan untuk menyelidiki performansi dan efisiensi dari SVM yang dilatih dalam koefisien *wavelet* dalam klasifikasi pola berjalan berdasarkan sinyal VGRF yang digunakan untuk mendiagnosis secara dini penyakit parkinson, maka dapat disimpulkan beberapa hal, yaitu *stein's unbiased risk estimation* (SURE) dengan *mother wavelet* Daubechies 2 merupakan teknik yang tepat untuk digunakan pada teknik *denoising*. Penggunaan SURE sebagai parameter TPTR terbaik membuktikan bahwa koefisien detail sinyal VGRF berada pada bagian sinyal yang memiliki derau. Berdasarkan percobaan yang telah dilakukan dari berbagai kasus ditetapkan bahwa *wavelet* dengan empat level dekomposisi dan *mother wavelet* Daubechies 6 untuk ekstraksi ciri tepat untuk digunakan. Vektor ciri statistik yang diambil yaitu nilai maksimum dari koefisien *wavelet* tiap *subband*, rataan dari koefisien *wavelet* tiap *subband*, nilai minimum dari koefisien *wavelet* tiap *subband* dan standar deviasi dari koefisien *wavelet* tiap *subband* dapat mewakili sinyal VGRF dengan baik. Untuk metode klasifikasi *least squares support vector machine* (LSSVM) memiliki total akurasi klasifikasi sebesar 81,29% dengan waktu CPU selama 80,87 detik sehingga metode ini dapat dipertimbangkan untuk digunakan sebagai algoritma klasifikasi pendiagnosis penyakit parkinson berdasarkan rekaman sinyal yang dihasilkan dari sensor VGRF. LSSVM dengan kernel *Polynomial* dapat digunakan untuk klasifikasi sinyal VGRF untuk diagnosis PD dengan mempertimbangkan waktu CPU. Klasifikasi dengan menggunakan kernel tersebut memiliki tingkat sensitivitas sebesar 76,74%, spesifisitas sebesar 83,33% dan total akurasi klasifikasi sebesar 81,29%.

Daftar Pustaka

- [1] "Hope Through Research: Parkinson's Disease," in *National Institute of Neurological Disorders and Stroke*, vol. December, 2014, p. 56.
- [2] N. Lahiri *et al.*, "Quantitative assessment of biological and clinical manifestations of Huntington's disease before and after diagnosis," *J. Neurol. Neurosurg. Psychiatry*, vol. 81, no. 11, pp. e59–e59, 2010.
- [3] A. Kandaswamy, C. S. Kumar, R. P. Ramanathan, S. Jayaraman, and N. Malmurugan, "Neural classification of lung sounds using wavelet coefficients," *Comput. Biol. Med.*, vol. 34, no. 6, pp. 523–537, 2004.
- [4] M. Yoneyama, Y. Kurihara, K. Watanabe, and H. Mitoma, "Accelerometry-based gait analysis and its application to Parkinson's disease assessment-Part 1: Detection of stride event," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 22, no. 3, pp. 613–622, 2014.
- [5] J. S. Brach, J. E. Berlin, J. M. VanSwearingen, A. B. Newman, and S. a Studenski, "Too much or too little step width variability is associated with a fall history in older persons who walk at or near normal gait speed.," *J. Neuroeng. Rehabil.*, vol. 2, p. 21, 2005.
- [6] N. Kwak and C. Choi, "Input Feature Selection for Classification Problems," vol. 13, no. 1, pp. 143–159, 2002.
- [7] E. D. Übeyli, "Feature extraction from Doppler ultrasound signals for automated diagnostic systems," vol. 35, pp. 735–764, 2005.
- [8] E. D. Übeyli, "ECG beats classification using multiclass support vector machines with error correcting output codes," *Digit. Signal Process. A Rev. J.*, vol. 17, no. 3, pp. 675–684, 2007.
- [9] S. Soltani, "On the use of the wavelet decomposition for time series prediction," vol. 48, pp. 267–277,

- 2002.
- [10] S. Osowski and D. D. Nghia, "Fourier and wavelet descriptors for shape recognition using neural networks — a comparative study," vol. 35, pp. 1949–1957, 2002.
 - [11] M. Unser and W. Aldroubi, "A review of wavelets in Biomedical Applications," vol. 84, no. 4, pp. 626–638, 1996.
 - [12] N. Hazarika, J. Zhu, C. Ah, C. Tsoi, and A. Sergejew, "Classification of EEG Signals Using the Wavelet Transform," pp. 89–92, 1997.
 - [13] E. D. Ubeyli, "Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients," pp. 113–121, 2005.
 - [14] P. Taylor, S. C. Saxena, V. Kumar, and S. T. Hamde, "Feature extraction from ECG signals using wavelet transforms for disease diagnostics," no. June 2013, pp. 37–41, 2010.
 - [15] K. Sternickel, "Automatic pattern recognition in ECG time series," vol. 68, pp. 109–115, 2002.
 - [16] C. Education and E. Engineering, "ECG beat classifier designed by combined neural network model," vol. 38, pp. 199–208, 2005.
 - [17] "MATLAB." The MathWorks, Inc., 2013.
 - [18] E. J. da S. Luz, W. R. Schwartz, G. Cámara-Chávez, and D. Menotti, "ECG-based heartbeat classification for arrhythmia detection: A survey," *Comput. Methods Programs Biomed.*, vol. 127, pp. 144–164, 2015.