

PERBANDINGAN SUARA PARU NORMAL DAN ABNORMAL MENGGUNAKAN PROBABILISTIC NEURAL NETWORK DAN SUPPORT VECTOR MACHINE CLASSIFICATION COMPARISON OF NORMAL AND ABNORMAL LUNG SOUNDS USING PROBABILISTIC NEURAL NETWORK AND SUPPORT VECTOR MACHINE

Chandraditya Aridela¹, Achmad Rizal, ST., MT.², Yuli Sun Hariyani, ST.MT.³
^{1,2,3}Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom
¹aridela12@gmail.com, ²arl@ittelkom.ac.id, ³yoeli.sun@gmail.com

ABSTRAK

Paru-paru adalah organ sistem pernapasan yang berfungsi untuk menukar oksigen dari udara dengan karbondioksida dari darah dengan bantuan hemoglobin. Sebagai organ yang penting perannya untuk tubuh tentu harus dijaga kesehatannya dari penyakit. Salah satu cara dokter mendiagnosa penyakit pada paru-paru adalah dengan mendengarkan suara pernapasan pada paru-paru dengan stetoskop. Suara paru-paru yang dihasilkan pada beberapa kasus penyakit berbeda-beda sehingga terdapat pola tertentu yang bisa dikenali. Pola suara ini dapat digunakan untuk mengklasifikasikan jenis-jenis penyakit pada paru-paru. Masalah yang timbul adalah suara paru-paru menempati frekuensi yang cukup rendah sekitar 20-2000 Hz, amplitudo yang rendah, masalah kebisingan lingkungan, kepekaan telinga dan pola suara yang mirip antara jenis suara paru-paru yang satu dengan yang lain. Karena faktor-faktor tersebut diatas, kesalahan diagnosis biasa terjadi apabila prosedur auskultasi tidak dilakukan dengan benar.

Pada penelitian ini dilakukan perbandingan klasifikasi suara paru-paru normal dan suara paru-paru abnormal untuk menentukan metode terbaik diantara dua metode yang akan digunakan. Suara paru-paru akan didekomposisi dengan menggunakan metode wavelet Daubechies2 level 5. Pada proses klasifikasi akan menggunakan metode klasifikasi Support Vector Machine One Against All, Support Vector Machine One Against One, dan klasifikasi jaringan syaraf tiruan PNN (*Probabilistic Neural Network*).

Hasil penelitian ini adalah: akurasi rata-rata *Support Vector Machine One against all* sebesar 47,55%, maksimum akurasi sebesar 70%, dan rata-rata waktu komputasi selama 0.006 detik. Akurasi rata-rata *Support Vector Machine One Against One* sebesar 50,92%, maksimum akurasi sebesar 75%, dan rata-rata waktu komputasi selama 0.012 detik. Akurasi rata-rata *Probabilistic Neural Network* 70%, maksimum akurasi sebesar 70%, dan rata-rata waktu komputasi selama 0.313 detik.

Kata Kunci : suara paru-paru, dekomposisi wavelet Daubechies2, *Support Vector Machine*, *probabilistic neural network*.

ABSTRACT

Lung is one of respiratory organ which function is to exchange oxygen and carbondioxide from blood with hemoglobin helps. As an important organ to body, its health must be taken care properly from any disease. One of doctors way to diagnose lung disease is hearing breathing sound in lung using stetoscope. Some lung disease produce unique lung sounds, which is refers to special recognized pattern. This pattern could be use to classify which kind of disease it is. The problem is the frequency of lung sounds are low (20 - 2000 Hz), low amplitude, interference from other sounds, ear sensitiveness, and low variety of the pattern of lung sounds that are almost similar. These factors remain to the false diagnosing of lungs disease if the auscultation procedures aren't conducted correctly.

In these research will be comparing classification of normal and abnormal lung sound to determine which metode is better. Lung sound will be decompose using 5 level wavelet daubechies2 transformation. In classification process will using Support Vector Machine One Against all, Support Vector Machine One Against One, and PNN (*Probabilistic Neural Network*).

The result of this research are: average accuration for Support Vector Machine One Against All is 47,55%, Maximum accuration is 70%, and average computation time is 0,006 second. Average accuration for Support Vector Machine One Against One is 50,92%, Maximum accuration is 75%, and average computation time is 0.012 second. Average accuration for Probabilistic Neural Network is 70%, maximum accuration is 70%, and average computation time is 0.313 second.

Keywords : Lung sound, wavelet Daubechies2 decomposition, *Support Vector Machine*, *probabilistic neural network*

1. Pendahuluan

Dalam menentukan penyakit paru-paru biasanya dokter menggunakan stetoskop untuk mendengarkan suara pernafasan pada paru-paru. Penyakit paru-paru atau saluran pernafasan dapat dideteksi dengan mendengarkan pola suara tambahan yang terjadi selama proses pernafasan. Pola suara tambahan ini terjadi karena adanya hambatan pada saluran pernafasan, adanya cairan di paru-paru, atau adanya pengerasan jaringan di paru akibat suatu penyakit tertentu. Dengan menentukan jenis suara tambahan yang muncul, dokter akan mempunyai gambaran yang lebih jelas akan kondisi paru-paru pasien. Dengan demikian proses penegakan diagnosis akan lebih mudah.

Masalah yang muncul dari proses penentuan jenis suara tambahan pada suara paru-paru yaitu suara paru menempati frekuensi yang cukup rendah sekitar 20-2000 Hz, amplitudo yang rendah, masalah kebisingan lingkungan, kepekaan telinga dan pola suara yang relatif sama antara jenis suara yang satu dengan yang lain. Untuk menentukan tiap jenis suara tambahan ini memerlukan keahlian lebih dari seorang dokter. Maka dari itu pada penelitian ini akan dirancang alat bantu untuk mengenali jenis-jenis suara tambahan pada paru-paru. Pada tugas akhir ini akan dilakukan perbandingan performansi antrara metode klasifikasi PNN dan SVM. Adapun teknik ekstraksi ciri yang digunakan untuk memproses sinyal adalah teknik dekomposisi paket wavelet.

Penelitian sebelumnya telah dilakukan oleh Achmad Rizal dkk^[8] yaitu mengekstraksi ciri suara paru menggunakan Wavelet Packet Decomposition 5-level dan menghasilkan akurasi sampai 84.62% dan penelitian lainnya yang telah dilakukan oleh Samira Abbasi dkk^[1] yaitu membandingkan performansi klasifikasi Support Vector Machine dengan Probabilistic Neural Network.

Dasar Teori

2.1 Suara pernafasan normal^[8]

Secara tradisional, suara ini dikategorikan berdasarkan intensitas, pitch, lokasi, dan rasio inspirasi dan ekspirasi. Suara pernafasan terbentuk dari turbulen aliran udara. Pada inspirasi, udara bergerak ke saluran udara yang lebih sempit dengan alveoli sebagai akhirnya. Saat udara menabrak dinding saluran pernafasan, terbentuk turbulen dan menghasilkan suara. Pada saat ekspirasi, udara mengalir ke arah yang berlawanan menuju saluran pernafasan yang lebih lebar. Turbulen yang terjadi lebih sedikit, sehingga pada ekspirasi normal terbentuk suara yang lebih kecil dibanding ekspirasi. Suara Pernafasan normal dibagi menjadi 4 jenis yaitu: Tracheal, Vesicular, Bronchial, Bronchovesicular.

2.2 Suara Pernafasan Abnormal^[8]


Suara pernafasan abnormal dapat dibagi 2 yaitu hilangnya suara pernafasan atau menurun: *ARDS, Asthma, atelectasis, emphysema, pleural effusion, pneumothorax*.

Dan suara pernafasan bronchial pada daerah *over consolidated*.

Ada pula suara nafas tambahan seperti: *Crackle, wheeze, ronchi, stridor, pleural (friction) rub, mediastinal crunch (hamman's sign)*

2.3 Transformasi Wavelet^[2]


Untuk melakukan transformasi wavelet diperlukan dua buah filter, yaitu *high pass filter* dan *low pass filter*. Satu sistem tersebut dinamakan *filter bank structure*. Filter digital yang digunakan adalah jenis FIR filter.



Gambar 2.1 Proses Dekomposisi Wavelet^[2]

Low pass filter menghasilkan bentuk gelombang yang disebut dengan aproksimasi dan *high pass filter* menghasilkan gelombang acak yang disebut detail. Dalam analisa paket wavelet yang lengkap (*full decomposition*), selain aproksimasi yang didekomposisi, bagian detail juga ikut didekomposisi lebih lanjut. Setelah didekomposisi sesuai dengan tingkat yang diinginkan, sinyal tersebut akan terbagi sebanyak 2^m sub


band. Masing-masing sub band tersebut akan dihitung periodogramnya sehingga menghasilkan energi sinyal yang akan menjadi ciri dari data latih maupun data uji.



Gambar 2.2 Dekomposisi Paket Wavelet^[2]

2.4 Support Vector Machine^{[5] [9]}

Support vector machine adalah suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi. Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah class pada input space. Berikut adalah ilustrasi dari pemilihan *hyperplane* terbaik untuk memisahkan dua kelas data



Gambar 2.3 (a)Hyperplane Kurang baik (b)Hyperplane Terbaik^[6]

Pada gambar diatas, SVM akan berusaha menemukan *hyperplane* terbaik untuk memisahkan kedua kelas tersebut. *Hyperplane* terbaik dapat ditemukan dengan cara mengukur margin *hyperplane* tersebut. Margin adalah jarak antara *hyperplane* tersebut dengan titik terdekat dari masing-masing class. Titik terdekat yang dilingkari dalam gambar ini disebut sebagai *support vector*. Proses mencari *support vector* untuk memperoleh *hyperplane* yang terbaik merupakan proses learning dalam SVM, sehingga hanya *support vector* saja yang berpengaruh sedang data yang lain tidak mempengaruhi *hyperplane*.

2.5 Probabilistic Neural Network^[12]

Jaringan syaraf tiruan probabilistik tergolong dalam pembelajaran terawasi (*supervised learning*) karena keluaran yang diharapkan telah diketahui sebelumnya dan merupakan model yang dibentuk berdasarkan penaksir fungsi peluang. Model ini memberikan unjuk kerja pengklasifikasian yang sangat baik dan cepat dalam pelatihan karena dilakukan hanya dalam satu tahap pelatihan. Metode Bayes untuk mengklasifikasikan pola menggunakan suatu aturan pengambilan keputusan yang meminimalkan risiko yang dihadapi. Misalkan terdapat n kelas, $C_0, C_1, C_2, \dots, C_{n-1}$; diasumsikan pola yang diamati adalah variabel acak x dengan m -dimensi dan fungsi padat peluang bersyarat x , bila diketahui bahwa pola tersebut berasal dari kelas C_k , dinotasikan dengan $p(x|C_k)$. Dengan menerapkan aturan pertama dari Bayes, dapat ditulis peluang berikutnya dari variabel x pada kelas C_k sebagai :

$$\Pr(C_k|x) = \frac{p(x|C_k)\Pr(C_k)}{p(x)} \quad (17)^{[12]}$$

Keputusan dari masalah tersebut dapat diformulasikan dengan cara yang lebih umum untuk meminimalkan resiko yaitu dengan meminimalkan peluang.

Aturan keputusan Bayes dalam kasus ini cukup sederhana untuk menentukan kelas C_k , yaitu dengan memilih $\Pr(C_k|x)$ yang paling besar, hal ini berarti :

$$d(x) = C_k \quad \text{jika} \quad p(x|C_k)\Pr(C_k) > p(x|C_j)\Pr(C_j) \quad (18)^{[12]}$$

Model jaringan syaraf tiruan probabilistic yang dibuat oleh Cain memperbolehkan setiap kelas memiliki parameter penghalus, σ_k , yang berbeda satu dengan yang lain dan menerapkan algoritma belajar yang baru untuk memperoleh σ_k secara otomatis. Apabila tiap kelas memiliki parameter yang memiliki fungsi peluang dapat ditulis sebagai :

$$p(x|C_k) = \frac{1}{(2\pi)^{\frac{m}{2}} \sigma_k^m |C_k|} \sum_{\rho_i \in C_k} \exp[-\|x - w_i\|^2 / (2\sigma_k^2)] \quad (19)^{[12]}$$


dimana :

m : jumlah pola latih pada kelas C_k ;
 $|C_k|$ merupakan dimensi vektor pola masukan;
 w_i : adalah vektor bobot pada pola latih ke- i .

Algoritma pelatihan yang mengatur sendiri nilai σ_k menyebabkan jaringan secara otomatis membentuk parameter tersebut untuk tiap kelas pada proses pelatihan tahap ke dua

Arsitektur jaringan syaraf tiruan probabilistik diperlihatkan pada Gambar. Jaringan tersebut memiliki empat lapisan yang terdiri atas:

1. Lapisan dengan m unit masukan yang menerima probabilitas masukan x .
2. Lapisan unit-unit pola yang terhubung penuh dengan pola masukan.
3. Lapisan unit-unit hasil penjumlahan yang terhubung penuh dengan tiap kelas.
4. Lapisan keputusan untuk memilih nilai yang terbesar.




Gambar 2.5 Arsitektur jaringan syaraf tiruan probabilistik^[12]

2. Perancangan Sistem

3.1 Model Sistem

Diagram blok sistem yang dirancang dapat dilihat pada gambar 3. Masukan dari sistem adalah suara paru-paru. Suara paru-paru yang digunakan diperoleh dari pembimbing berupa file suara *.wav dengan frekuensi sampling 8000 Hz dan resolusi 8 bit.



Gambar 3.1 Diagram blok sistem

Setelah data masukan telah dipilih dilakukan normalisasi pada sinyal masukan untuk menyamakan amplitudo dan menghilangkan komponen DC dari sinyal. Selanjutnya dilakukan dekomposisi paket wavelet untuk membagi sinyal menjadi subband-subband yang diharapkan. Tiap subband ini kemudian dihitung energinya untuk menjadi masukan bagi metode klasifikasi yang akan digunakan yakni PNN atau SVM.

3.2 Dekomposisi Paket Wavelet^[7]

Pada penelitian ini akan digunakan dekomposisi paket wavelet pada sinyal hingga maksimum sampai level 5. Skenario dekomposisi ini dirancang sebagai berikut: pita frekuensi suara dipecah menjadi masing-masing 125 Hz untuk wilayah di bawah 1000 Hz, 250 Hz untuk wilayah 1000-2000 Hz, 500 Hz untuk wilayah 2000-3000 Hz. Sedangkan untuk daerah 3000-4000 Hz tidak dibagi karena biasanya suara paru tidak menempati frekuensi sampai setinggi ini. Dengan skenario dekomposisi ini akan didapat 15 subband sinyal yang akan menjadi bahan untuk menentukan fitur tiap jenis suara paru-paru.

Energi setiap subband menjadi parameter yang akan digunakan pada proses klasifikasi. Parameter yang akan digunakan ada 4 yaitu: nilai rata-rata pada koefisien tiap subband, Nilai rata-rata koefisien energi tiap subband, Standar deviasi dari koefisien tiap subband, Rasio dari nilai rata-rata koefisien tiap subband.^[5]

3.3 Klasifikasi

Dalam metode klasifikasi *Support vector machine* ada dua jenis yang akan digunakan yaitu jenis *one against one* (OAO) dan *one against all* (OAA).

Parameter yang akan digunakan sebagai masukan untuk metode OAO dan OAA adalah:

1. C (cost parameter) = 1000
2. Lambda = sebagai parameter kondisi untuk metode quadratic programming dalam tugas akhir nilai $\lambda = 1e-7$
3. Kernel option = (1-10)
4. Kernel = nama kernel yang akan digunakan yaitu rbf atau gaussian

Probabilistic Neural Network (PNN) adalah metode klasifikasi kedua yang akan digunakan. Di PNN akan menggunakan toolbox yang sudah tersedia dari matlab dan parameter yang akan digunakan adalah parameter "spread".

Spread disini adalah parameter penghalus (σ) memiliki fungsi yang sama seperti parameter Kernel option.

Jika spread mendekati 0 maka jaringan akan memilih vektor terdekat, sedangkan semakin besar nilai spread maka jaringan akan mempertimbangkan vektor-vektor lain yang berada di sekitarnya.^[8]

3.5 Confusion Matrix^[11]

Confusion Matrix merupakan suatu alat pengukuran akurasi klasifikasi yang biasanya merupakan pembelajaran terawasi. *Confusion Matrix* digunakan untuk mempermudah perbandingan akurasi antar klasifikasi.

Pengukuran yang akan digunakan dalam tugas akhir ini adalah pengukuran multi-kelas klasifikasi. Kualitas dari keseluruhan klasifikasi biasanya diukur dengan 2 cara yaitu *macro-averaging* dan *micro-averaging*. *Macro-averaging* mengukur dengan memperhatikan pada tiap kelas, sedangkan *micro-averaging* mengukur dengan memperhatikan pada 1 percobaan keseluruhan.

Aspek yang diukur pada multikelas klasifikasi adalah: Average Accuracy, Error rate, Precision _{μ} , Recall _{μ} , Fscore _{μ} , Precision_M, Recall_M, dan Fscore_M.

3. PENGUJIAN PENGUJIAN SISTEM DAN ANALISIS.

4.1 Lingkup Pengujian

File suara yang akan digunakan dikelompokkan menjadi 5 kelas yaitu:

Asthma, Bronchial, Crackle, Friction, dan Stridor.

Setiap kelas berisikan 12 file suara paru yang kemudian akan dibagi menjadi 3 bagian berisikan masing-masing 4 file suara paru. Setelah itu di ambil masing-masing 1 folder dari tiap kelas untuk dijadikan data latih, disini akan dibuat 10 folder data latih. Selanjutnya dibuat folder untuk data uji yang berisikan file suara yang tidak digunakan di folder data latih, dibuat menjadi 10 file folder yang berbeda.

4.2 Skenario Pengujian

Seperti sudah dijelaskan pada BAB 3 akan dilakukan 10 kali percobaan pada metode SVM dan PNN berdasarkan parameter kernel option dan spread dengan data latih dan uji yang sudah disiapkan sebelumnya.

Setelah dilakukan pengujian 5 kelas didapatkan hasil yang kurang memuaskan di kelas kelima yaitu stridor, sehingga dilakukan pengujian kedua yang hanya berisikan 4 kelas saja yaitu: asthma, bronchial, crackle, dan friction.

4.3 Pengujian 5 kelas

Tabel 4.1 Rata-rata pengujian suara paru dengan 5 kelas

Parameter	OAA	OA	PNN
P1 (%)	23.95617	28.51632	54.52612
P2 (%)	82.6	81.31667	60.7756
P3 (%)	59.06549	63.44189	54.08548
P4 (%)	31.89623	35.54123	29.525
P5 (%)	51.32996	53.57106	68.16738
R1 (%)	54.775	49.675	75.85
R2 (%)	54.4	54.275	67.075
R3 (%)	60.79167	66.925	77.425
R4 (%)	18.975	23.175	29.175
R5 (%)	50.2	61.975	31.4
Pm (%)	49.76957	52.47743	53.41591
Rm (%)	47.82833	51.205	56.185
Pμ (%)	47.71263	51.08842	55.96816
Rμ (%)	47.71263	51.08842	55.96816
Fscorem (%)	48.13804	51.26733	54.5172
Fscoreμ (%)	47.71263	51.08842	55.96816
AA (%)	6.384424	6.97912	7.866886
ER (%)	46.57107	44.27258	41.13458
A (%)	47.555	50.92	55.7
MIN (%)	25	20	30
MAX (%)	70	75	70
Waktu (detik)	0.006591	0.012861	0.313489

Data diatas merupakan keseluruhan pengujian yang sudah dirata-rata. Presisi kelas ini dipengaruhi karena sistem belum bisa mengidentifikasi kelas stridor dengan baik. Data stridor cukup unik karena memiliki 4 kasus berbeda yang keunikan frekuensi suaranya berada pada subband yang sama dengan keunikan 4 kelas lainnya. Tapi disini kelas *stridor* paling mirip dengan kelas *asthma* dapat dilihat dari presisi kelas *asthma* (P1) dan kelas *Stridor* (P5) yang rendah di tiap klasifikasi.

Dilihat dari hasil recall diatas sistem dirasa masih jauh dari efektif untuk memisahkan tiap-tiap kelas, terutama pada kelas *friction*(R4) dan *stridor*(R5).

Nilai error rate pada tiap percobaan masih dibawah 50% , rata-rata akurasi sekitar 50% dan serta Fscore berada di sekitar 50% dapat dikatakan hasil klasifikasi dari sistem ini lumayan memuaskan, karena dalam beberapa percobaan ada yang menghasilkan akurasi lumayan tinggi yaitu OAA(70%), OAO(75%), PNN(70%) pada saat $\sigma = 4$ dan 8. Walaupun SVM OAO memiliki akurasi maksimal sebesar 75% , klasifikasi PNN memiliki akurasi maksimal sebesar 70% di setiap σ .

Dari segi waktu komputasi ketiga percobaan tersebut relatif cepat karena tiap pengujian dapat diselesaikan dengan waktu dibawah 1 detik.

4.4 Pengujian 4 kelas

Tabel 4.2 Rata-rata pengujian suara paru dengan 4 kelas

Parameter	OAA	OA0	PNN
P1 (%)	42.6373	44.935	84.0198
P2 (%)	100	98.5	91.7183
P3 (%)	83.5004	86.6207	76.4455
P4 (%)	33.8494	37.5794	38.3
R1 (%)	87.7841	93.3133	87.0268
R2 (%)	64.2852	64.309	82.6548
R3 (%)	76.375	83.55	99.975
R4 (%)	22	26.485	37.525
Pm (%)	64.9968	66.9088	72.6209
Rm (%)	62.6111	66.9143	76.7954
P μ (%)	64.9037	67.8447	79.3118
R μ (%)	63.0989	65.9941	77.6927
Fscorem (%)	63.3616	66.0212	74.2929
Fscore μ (%)	63.9081	66.8222	78.4104
AA (%)	12.3363	13.0915	16.6469
ER (%)	12.6637	11.9085	8.35308
A (%)	64.9313	67.8688	79.6313
MIN (%)	18.75	18.75	56.25
MAX (%)	100	100	100
Waktu (detik)	0.00473	0.00829	0.25843

Data diatas merupakan keseluruhan pengujian yang sudah dirata-rata. Dilihat dari presentase presisi tiap kelas sistem dinilai sukses mengenali data tiap kelas. Nilai Presisi pada klasifikasi PNN naik dengan cukup signifikan. Nilai Presisi pada klasifikasi PNN naik dengan cukup signifikan.

Hasil *Recall* pada pengujian 4 kelas ini juga naik cukup besar kecuali di kelas *friction*. Sistem dapat dinilai efektif untuk membedakan 4 kelas data suara paru.

Nilai error rate pada tiap percobaan berada dibawah 15% , rata-rata akurasi sekitar 65-80% dan serta Fscore berada di sekitar 60-75% dapat dikatakan hasil klasifikasi dari sistem ini memuaskan, karena dalam beberapa percobaan ada yang menghasilkan akurasi maksimal yaitu OAA(100%), OA0(100%), PNN(100%) pada saat $\sigma = 9$ dan 10. Klasifikasi PNN memiliki akurasi maksimal sebesar 100% di setiap σ .

Dari segi waktu komputasi ketiga percobaan tersebut relatif cepat karena tiap pengujian dapat diselesaikan dengan waktu dibawah 1 detik.

5.1. Kesimpulan

Beberapa kesimpulan hasil analisis percobaan pada tugas akhir ini adalah sebagai berikut:

1. Dekomposisi paket wavelet 5 tingkat belum cukup untuk mengekstraksi ciri kelas Stridor karena sering terbaca di kelas asthma sehingga menyebabkan presentase P1 pada pengujian 5 kelas baik untuk SVM OAA, SVM OAO dan PNN lebih kecil dibandingkan Presentase P1 pada pengujian 4 kelas.
2. Penggunaan parameter σ berpengaruh pada hasil akurasi pada performansi tiap metode klasifikasi. Dapat dilihat dari hasil percobaan bahwa untuk pengujian 5 kelas $\sigma = 8$ memiliki hasil terbaik diantara yang lain OAA = 70% ; OAO = 75%; PNN = 70%. Untuk pengujian 4 kelas $\sigma = 9$ dan 10 memiliki hasil terbaik dimana hasil akurasinya OAA = 100% ; OAO = 100%; PNN = 100%
3. SVM OAA memiliki waktu komputasi tercepat 0,006 detik untuk pengujian 5 kelas dan 0,004 detik untuk pengujian 4 kelas dibandingkan dengan SVM OAO 0.012 detik untuk pengujian 5 kelas dan 0.008 detik untuk pengujian 4 kelas dan PNN 0,313 detik untuk pengujian 5 kelas dan 0,258 detik untuk pengujian 4 kelas.
4. Probabilistic Neural Network memiliki performansi lebih baik, Probabilistic Neural Network memiliki hasil yang konsisten baik di pengujian 5 kelas dengan akurasi 70% maupun pengujian 4 kelas dengan akurasi 100%.

Berdasarkan hasil yang didapat dari penelitian tugas akhir ini, beberapa saran yang diajukan untuk memperbaiki kekurangan yang ada:

1. Tambahkan parameter ekstraksi ciri yang belum digunakan yaitu *skewness* di tiap subband dan *kurtosis* di tiap subband.
2. Gunakan metode kernel lain yang belum digunakan seperti *linear*, *polynomial*, *sigmoid*.

Daftar Pustaka:

- [1] Abbasi, S., Derakhshanfar, R., & Abbasi, A. (2013). "Classification Of Normal and Abnormal Lung Sounds Using Neural Network and Support Vector Machines". *2013 21st Iranian Conference on Electrical Engineering (ICEE)*, 188-192.
- [2] Agfianto, E. P. (2006). "Transformasi Paket Wavelet, Dekomposisi Wavelet dan Korelasi pada Data Seismik Gunung Merapi, Jawa - Indonesia". *Seminar Nasional Teknologi Informasi 2006*.
- [3] DW, M. (2015, Mei 19). *LinkedIn*. Diambil kembali dari [www.slideshare.net](http://www.slideshare.net/Kampus-Sakinah/pemeriksaan-fisik-28268584): <http://www.slideshare.net/Kampus-Sakinah/pemeriksaan-fisik-28268584>
- [4] Hashemi, A., Arabalibiek, H., & Agin, K. (2011). "Classification of Wheeze Sounds Using Wavelets and Neural Network". *International Conference on Biomedical Engineering and Technology IPCBEE vol.11*.
- [5] Kerami, D., & Murfi, H. (2004). "KAJIAN KEMAMPUAN GENERALISASI SUPPORT VECTOR MACHINE DALAM PENGENALAN JENIS SPLICE SITES PADA BARISAN DNA". *MAKARA, SAINS, VOL. 8, NO. 3*, 89-95.
- [6] Nugroho, A. S., Witarto, A. B., & Handoko, D. (2003). "Support Vector Machine -Teori dan Aplikasinya dalam Bioinformatika-". *Kuliah umum ilmukomputer.com*.
- [7] Putra, T. W. (2013). *"Pengenal Wajah dengan Matriks Kookurensi Aras Keabuan dan Jaringan Syaraf Probabilistik. Semarang"*. Semarang.
- [8] Rizal, A., Mengko, T. L., & Suksmono, A. B. (2006). "Lung Sound Recognition Using Wavelet Packet Decomposition and ART2 (Adaptive Resonance Theory 2) Neural Network". *Proceeding Biomedical Engineering Day, 2006, 2006. vol 2, pp, 2-6*.
- [9] Santosa, B. (2007, May 18). *"Data mining Teknik Pemanfaatan Data untuk Keperluan Bisnis"*. Yogyakarta: Graha Ilmu. Diambil kembali dari [bsantosa.files.wordpress.com](https://bsantosa.files.wordpress.com/2015/03/tutorial-svm-2015.pdf): <https://bsantosa.files.wordpress.com/2015/03/tutorial-svm-2015.pdf>
- [10] Saritha, M., Joseph, K. P., & Mathew, A. T. (2013). "Classification of MRI Brain Images Using Combined Wavelet Entropy Bases Spider Web Plots and Probabilistic Neural Network". *Pattern Recognition Letters* 34, 2151-2156.
- [11] Sokolova, M., & Lapalme, G. (2009). "A Systematic Analysis of Performance Measures for Classification Tasks". *Information Processing and Management* 45, 427-437.
- [12] Suyanto. (2014). *"Artificial Intelligence Searching - Learning - Planning - Learning Revisi Kedua"*. Bandung: Informatika Bandung.

