

Klasifikasi Penyakit Pernapasan berdasarkan Suara Paru-Paru menggunakan *Probabilistic Neural Network*

Shiennyta Florensia Adiriyanto^{a1}, I Gede Arta Wibawa^{a2}, Made Agung Raharja^{a3}, Gst. Ayu Vida Mastrika Giri^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana

Badung, Bali, Indonesia

¹shiennyflorensia@gmail.com

²gede.arta@unud.ac.id

³made.agung@unud.ac.id

⁴vida@unud.ac.id

Abstract

This research study aims to classify respiratory diseases using lung sound data analyzed with Probabilistic Neural Network (PNN) model. The research utilized secondary data from the "Respiratory Sound Database", which is the same dataset used in International Conference on Biomedical and Health Informatics (ICBHI) 2017 Challenge. This dataset includes 920 samples of lung sounds from 126 patients, categorized into various respiratory diseases such as asthma, bronchiectasis, bronchiolitis, COPD, healthy, LRTI, pneumonia and URTI. Lung sound recordings were processed through pre-processing, feature extraction using Mel-Frequency Cepstral Coefficients (MFCC), data resampling, and classification using PNN. K-stratified cross validation and confusion matrix were done for evaluating the model. The PNN model achieved a highest accuracy of 98.88%, with an average accuracy of 98.51%, an average precision of 98.54%, and an average recall of 98.51%. These results demonstrate that the PNN method is quite effective in identifying respiratory diseases, offering a potential diagnostic aid in healthcare.

Keywords: Classification, Respiratory Disease, Lung Sounds, MFCC, Probabilistic Neural Network

1. Pendahuluan

Paru-paru merupakan organ penting dalam sistem pernapasan manusia, dan tidak sedikit orang memiliki gangguan pada organ tersebut. Berdasarkan *the Global Burden of Diseases, Injuries, and Risk Factors Study*, ditemukan penyakit infeksi pernapasan menjadi peringkat kedua pada penyakit yang diderita oleh anak-anak di bawah umur 10 tahun secara global pada tahun 2019 [1]. Selain itu, tingkat polusi udara yang buruk di Indonesia juga menjadi penyebab meningkatnya pengidap gangguan pernapasan [2]. Melihat dari kurangnya dokter spesialis paru di Indonesia, dibutuhkan bantuan pengklasifikasi penyakit untuk mendapatkan penanganan yang cepat dan tepat.

Berdasarkan permasalahan tersebut, salah satu solusi untuk mendeteksi gangguan pada paru-paru dapat dilakukan dengan melakukan pemrosesan sinyal digital suara pernapasan menggunakan *Mel-Frequency Cepstral Coefficients* (MFCC) dan *Probabilistic Neural Network* (PNN). MFCC merupakan sebuah metode untuk ekstraksi fitur yang memiliki kelebihan dalam mendapatkan dan menghasilkan data dengan jumlah minimal dari informasi yang terdapat pada data suara [3][4]. MFCC juga terdiri dari beberapa tahapan seperti *pre-emphasis*, *frame blocking*, *windowing*, *Fast Fourier Transform* (FFT), *Mel-Frequency Warping*, dan *Discrete Cosine Transform* (DCT) atau bisa juga disebut tahap *cepstrum* [5]. PNN atau jaringan syaraf tiruan probabilistik ini merupakan salah satu metode klasifikasi yang didasari oleh pengklasifikasi Parzen dan Bayes [6]. PNN ini merupakan *feed forward neural network* yang berarti hubungan antar *node*-nya tidak membentuk siklus [7]. PNN juga termasuk dalam *supervised learning* dikarenakan keluaran yang diharapkan sudah diketahui terlebih dahulu. Selain itu, PNN dikatakan memiliki hasil pengklasifikasian yang sangat cepat dan baik karena hanya dilakukan dalam satu tahap pelatihan [8][9].

PNN melakukan pengklasifikasian dengan menggunakan pendekatan berbasis memori statistika. Berdasarkan penelitian yang dilakukan oleh Dongwoo Lee, beberapa kelebihan dari PNN di antara lainnya adalah memiliki arsitektur yang sederhana dengan maksud tidak ada *backpropagation*, memiliki banyak cara dalam mengelola suatu algoritma dengan menentukan bentuk rupa kurva lonceng (*bell curve*), memiliki tingkat akurasi lebih baik pada masalah pengklasifikasian, dan tidak sensitif pada titik *noise* [10]. Berdasarkan Satapathy et al., dikatakan juga bahwa PNN memiliki beberapa kelebihan seperti memiliki proses pelatihan lebih cepat dibandingkan dengan *backpropagation*, tidak memiliki isu pada *local minima*, dan menjamin cakupan ke pengklasifikasi optimal seiring dengan meningkatnya ukuran set pelatihan. Penggunaan PNN ini sangat efektif jika digunakan bersama dengan metode dalam ekstraksi fitur dan reduksi fitur [11].

Salah satu penelitian yang mengangkat mengenai klasifikasi penyakit paru-paru dilakukan oleh Sukma et al., dengan menggunakan MFCC dan SVM. Pada penelitian yang dilakukan, didapatkan tingkat akurasi sebesar 80% [12]. Penelitian lainnya juga dilakukan oleh Rafiqo et al., yang menggunakan MFCC dan CNN pada penelitiannya, dengan hasil akurasi rata-rata sebesar 71,85% [13]. Terdapat juga penelitian oleh Aridela et al., yang membandingkan penggunaan dari SVM dan PNN dengan hasil akhir PNN memiliki nilai performansi yang lebih baik dalam hal presisi dan akurasi, sedangkan SVM memiliki waktu komputasi yang lebih cepat dibandingkan PNN walaupun kedua pengujian dari metode tersebut dapat diselesaikan dalam waktu kurang dari 1 detik [14].

Berdasarkan penelitian-penelitian yang sudah dilakukan sebelumnya, pada penelitian ini akan dilakukan klasifikasi penyakit pernapasan berdasarkan suara paru-paru dengan menggunakan metode MFCC dan PNN. Penelitian ini akan melakukan akuisisi data suara paru-paru dari dataset yang sudah disiapkan. Data yang sudah diakuisisi tersebut akan dilakukan *pre-processing* terlebih dahulu, dilanjutkan dengan MFCC, *resampling* data, kemudian dilaksanakan klasifikasi penyakit pernapasan dengan metode PNN. Harapannya setelah dilakukan penelitian ini, dapat diketahui akurasi, presisi, dan *recall* dari penggunaan metode tersebut dalam menentukan penyakit.

2. Metode Penelitian

Metode penelitian memiliki peran yang sangat penting dalam menentukan hasil dari suatu penelitian. Hal ini disebabkan oleh pentingnya pendekatan yang tepat dalam melaksanakan penelitian tersebut. Berikut merupakan urutan dari metode penelitian yang akan dilaksanakan.

2.1. Pengumpulan Data

Dalam pengumpulan data ini, akan digunakan 920 data suara paru-paru dalam rupa WAV dari 126 pasien yang dimana terdapat 14 pasien URTI, 2 pasien LRTI, 1 pasien asma, 64 pasien COPD, 7 pasien bronkiektasis, 6 pasien bronkiolitis, 6 pasien pneumonia, serta 26 orang sehat. Selain *file* WAV tersebut, diberikan juga anotasi dalam rupa TXT untuk setiap rekaman suara, TXT berisikan perbedaan nama *file*, TXT berisikan format nama *file*, dan diagnosis pasien dalam bentuk CSV.

Durasi masing-masing rekaman suara paru-paru tersebut berkisar dari 10-90 detik. Total lama waktu data tersebut sepanjang 5,5 jam yang berisikan sebanyak 6898 siklus pernapasan, dengan 1864 siklus dengan suara *crackle*, 886 siklus dengan suara *wheeze*, dan 506 siklus dengan suara *crackle* dan *wheeze*. Data suara ini juga mencakup rekaman pernapasan yang bersih serta rekaman bising yang mensimulasikan kondisi kehidupan nyata. Setiap file audio diberikan info nomor pasien, indeks rekaman, lokasi dada, mode akuisisi, dan alat rekam yang digunakan. Anotasi teks yang diberikan juga memiliki 4 kolom, yaitu awal siklus pernapasan, akhir siklus pernapasan, ada/tidak adanya *crackles*, dan ada/tidak adanya *wheezes*. *Crackle* atau bunyi kresak merupakan salah satu suara non-musikal yang dapat dibagi menjadi dua, yaitu kresak halus dan kresak kasar, sedangkan *wheeze* atau mengi termasuk dalam suara musical, yaitu suara yang bersifat kontinu, dan memiliki frekuensi dominan tinggi dan dapat bersifat monofonik maupun polifonik [15].

2.2. Pre-processing Data

Dalam tahap *pre-processing* ini akan dilakukan untuk mempersiapkan data sebelum masuk ke dalam tahap ekstraksi ciri. Beberapa hal yang akan dilakukan dalam tahapan ini adalah pembuatan csv kumpulan data, pemisahan siklus data suara paru-paru, penyesuaian nama pada csv dengan data suara, dan normalisasi data suara.

Pada pembuatan csv kumpulan data, akan digabungkan 'patient_diagnosis.csv' dengan anotasi dari setiap data suara, sehingga didapatkan waktu mulai dan selesai setiap siklus pernapasan, disertai dengan kelas penyakitnya. Berdasarkan data yang sudah didapatkan, semua data suara akan dipisahkan per siklusnya dan disimpan dalam *folder* baru. Nama dari data suara juga akan ditambahkan angka di akhir supaya setiap data memiliki nama berbeda. Dengan begitu, nama pada csv akan disamakan dengan nama data yang sudah diperbarui.

Selanjutnya adalah normalisasi, yang digunakan untuk menyeragamkan jangkauan data menjadi -1 hingga 1. Untuk mendapatkan hasil normalisasi, data sinyal suara akan dibagi dengan nilai maksimum dari data tersebut. Rumus dari normalisasi dapat dilihat pada Persamaan (1).

$$\|x(n)\| = \frac{x(n)}{\max |x(n)|} \quad (1)$$

Dengan $\|x(n)\|$ adalah hasil normalisasi data, $x(n)$ adalah data sinyal suara, dan $\max |x(n)|$ merupakan nilai maksimum data. Pada langkah ini, data suara dengan format WAV diubah amplitudonya menjadi maksimal 1 dan minimal -1.

2.3. Ekstraksi Ciri

Data yang sudah dilakukan *pre-processing* tersebut akan dilakukan ekstraksi ciri dengan menggunakan MFCC. Tahapan dari MFCC adalah *pre-emphasis*, *frame blocking*, *windowing*, *Fast Fourier Transform* (FFT), *Mel-Frequency Warping*, dan *cepstrum*. Pada tahapan pertama, akan dilakukan *pre-emphasize* pada data suara. Tahapan ini dilakukan untuk mengurangi *noise* pada suara, sehingga hasil yang didapatkan menjadi lebih akurat [16][17]. Adapun persamaan dari tahapan *pre-emphasize* dapat dilihat pada Persamaan (2).

$$y(n) = s(n) - \alpha s(n - 1) \quad (2)$$

Dengan $y(n)$ merupakan data sinyal hasil *pre-emphasize*, $s(n)$ adalah data sinyal sebelum *pre-emphasize*, dan α yaitu Nilai *alpha*. Pada persamaan tersebut, nilai *alpha* yang umumnya digunakan sebesar 0,97.

Setelah dilakukan *pre-emphasize*, akan dilakukan *frame blocking* yaitu membagi sinyal suara ke dalam *frame-frame* kecil. Proses ini akan menggunakan *Short-Time Fourier Transform* (STFT), dengan ukuran *frame* sebesar 2048 sampel dan perpindahan antar *frame* sebesar 512 sampel, yaitu $\frac{1}{4}$ dari ukuran *frame*. Dikarenakan semua data memiliki *sample rate* 22.050, didapatkan ukuran *frame*, perpindahan *frame* dan overlap secara berturut adalah 93 ms, 23 ms dan 70 ms. *Overlapping* ini dilakukan untuk menghindari hilangnya ciri data suara pada perbatasan perpotongan setiap *frame* [18]. Melalui tahap ini, akan didapatkan sebanyak 43 *frame* per detiknya dan 259 *frame* untuk 6 detik.

Setelah melakukan *frame blocking*, pada setiap *frame* tersebut akan dilakukan *windowing* menggunakan *Hanning window* untuk meminimalisasi sinyal tak kontinyu pada bagian awal dan akhir *frame*. Rumus dari *Hanning window* dapat dilihat pada Persamaan (3)

$$w(n) = 0.5 - 0.5 \cos \left[\frac{2\pi n}{N-1} \right] \quad (3)$$

Dengan $w(n)$ adalah hasil *Hanning window* dan N adalah jumlah sampel pada *frame*. Selanjutnya akan dilakukan tahap *Fast Fourier Transform* (FFT) yang mengubah *frame-frame* tersebut dari domain waktu menjadi domain frekuensi dengan cara yang dapat dilihat pada Persamaan (4).

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j2\pi kn/N} \quad (6)$$

Dengan $X[k]$ merupakan hasil *fast fourier transform* dari sinyal waktu $x[n]$, N merupakan jumlah *sample* pada *frame*, k adalah indeks frekuensi, dan j adalah bilangan imajiner $\sqrt{-1}$. Tahap selanjutnya adalah *Mel-Frequency Warping* yang dilakukan dengan menggunakan *filterbank* yang diterapkan di domain frekuensi untuk mengubahnya menjadi *mel scale* [19]. Dalam tahap ini, digunakan sebanyak 40 filter mel dan frekuensi maksimum sebesar setengah dari *sample rate*, yaitu 11.025. Dengan demikian akan didapatkan ukuran *mel spectrogram* 40×43 per detik dan 40×259 untuk 6 detik. Rumus dari *mel scale* sendiri dapat dilihat pada Persamaan (7).

$$mel(f) = 2595 \times \log_{10}\left(1 + \frac{f}{700}\right) \quad (7)$$

Dengan $mel(f)$ adalah fungsi *mel scale* dan f adalah frekuensi. Tahapan terakhir pada ekstraksi ciri dengan MFCC ini adalah *Discrete Cosine Transform* (DCT) [20]. Akan dilakukan konversi untuk mengubah *mel spectrogram* atau spektrum log mel kembali menjadi domain waktu menggunakan terlebih dahulu menggunakan Persamaan (8).

$$S_{dB} = 10 \log_{10}(S) \quad (8)$$

Dengan S_{dB} adalah hasil dalam skala desibel dan S adalah *Mel spectrogram*. Dari hasil konversi tersebut akan dilakukan DCT untuk mendapatkan nilai MFCC dengan menggunakan Persamaan (9).

$$c_n = \sum_{m=1}^M S_{dB}(m) \cos\left[\frac{\pi n}{M}(m + 0.5)\right] \quad (9)$$

Dengan c_n adalah *Mel-Frequency Cepstral Coefficients*, $S_{dB}(m)$ adalah *Mel spectrogram* dalam dB dan M merupakan jumlah koefisien. Koefisien MFCC yang digunakan adalah 20, sehingga akan menghasilkan MFCC dengan ukuran 20×43 per detik dan 20×259 untuk 6 detik.

2.4. Resampling Data

Setelah mendapatkan ciri, data dari setiap kelas akan disamakan banyaknya menjadi 1.500, sehingga data semua kelas menjadi seimbang. Untuk data lebih dari 1.500, akan dilakukan *downsampling* menggunakan algoritma *K-Means*, sedangkan pada data kurang dari 1500 akan dilakukan *oversampling* menggunakan *resample*. Algoritma *K-Means* dapat menghasilkan representasi data yang rata-rata dalam ruang fitur karena pusat kluster mewakili distribusi data. Dalam *resample*, data minoritas akan diduplikasi secara *random* untuk memperbanyak data. Dengan begitu, akan didapatkan total sebanyak 12.000 data untuk dilakukan klasifikasi pada PNN.

2.5. Klasifikasi

Klasifikasi data akan dilakukan dengan menggunakan *Probabilistic Neural Network* (PNN). Terdapat empat lapisan layer pada PNN, yaitu *input layer*, *pattern layer*, *summation layer*, dan *output layer*. *Input layer* terdiri dari *neuron* yang merupakan fitur data, sehingga banyak *neuron* pada *layer* ini adalah 5180, mengikuti banyak ciri MFCC. Pada *pattern layer*, dilaksanakan perhitungan kedekatan jarak antara data latih dan data uji menggunakan *Gaussian kernel* seperti pada Persamaan (10).

$$K(x, y) = e^{-\frac{\|x-y\|^2}{2\sigma^2}} \quad (10)$$

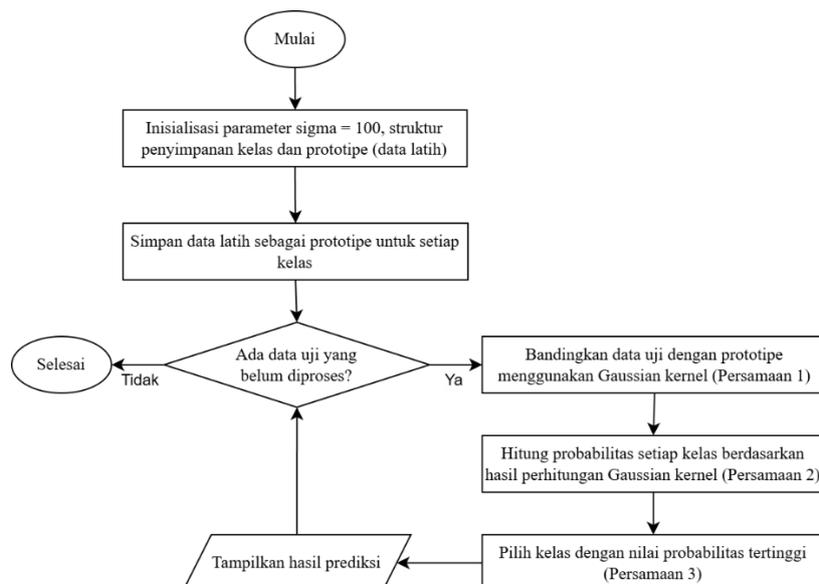
Parameter σ pada Gaussian kernel yang digunakan juga adalah sebesar 100, yang cocok untuk data input dalam penelitian ini. *Neuron* pada *layer* ini sama dengan jumlah data latih, yaitu 9.600. Pada *summation layer*, akan dikelompokkan hasil luaran *pattern layer* berdasarkan kelas dan kemudian dijumlahkan nilai probabilitasnya menggunakan Persamaan (11).

$$S_c = \sum_{i \in C} K(x, x_i) \quad (11)$$

Banyak *neuron* dari *summation layer* adalah sesuai dengan banyak kelas yaitu 8. Pada *output layer*, hanya ada 1 *neuron* yang merupakan hasil klasifikasi berdasarkan kelas dengan probabilitas tertinggi yang dihitung pada *summation layer*, sesuai dengan Persamaan (12).

$$\text{Output} (z) = \max P(X|C_j) \quad (12)$$

Melalui langkah ini, hasil akhir yang didapatkan berupa kelas yang mendapatkan probabilitas tertinggi berdasarkan input vektor ciri suara yang diberikan. Pada Gambar 2, ditampilkan flowchart dari alur pelaksanaan PNN yang akan dilakukan.



Gambar 2. Flowchart PNN

2.6. Pengujian dan Evaluasi

Pelaksanaan evaluasi hasil klasifikasi akan dilakukan dengan dua tahapan yaitu *K-Fold Cross Validation* yang kemudian dilanjutkan dengan *confusion matrix*. *K-Fold cross validation* merupakan sebuah metode yang dapat digunakan dalam mengevaluasi model yang dibuat dengan cara membagi data yang ada menjadi data latih dan data uji. Jenis *K-Fold* yang digunakan adalah *stratified K-Fold*, sehingga distribusi kelas pada setiap *fold* tetap seimbang. Mengikuti jumlah pembagian umum data latih dan data uji secara berturut-turut sebesar 80% dan 20%, k yang akan digunakan adalah 5. Dengan begitu, data yang tersedia akan dibagi menjadi 5 dengan 4 bagian sebagai data latih dan 1 bagian sebagai data uji, yang dimana setiap *fold*-nya akan digunakan sebanyak 9.600 data sebagai data latih dan 2.400 data sebagai data uji. Dilakukan sebanyak 5 iterasi dengan menukar data latih menjadi data uji seperti pada Tabel 1.

Tabel 1. 5-Fold Cross Validation

| Fold | Bagian | | | | |
|------|--------|---|---|---|---|
| | 1 | 2 | 3 | 4 | 5 |
| 1 | | | | | |
| 2 | | | | | |
| 3 | | | | | |
| 4 | | | | | |
| 5 | | | | | |

Keterangan:

| | |
|--|------------|
| | Data latih |
| | Data uji |

Confusion matrix adalah sebuah matriks dari hasil representasi yang membandingkan prediksi dari sistem dengan kelas asli dari data masukan. Hasil nilai evaluasi yang didapatkan dari pengujian *5-fold cross validation* akan dicatat di sini. Dengan begitu, akan didapatkan nilai *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN) sehingga dapat ditentukan akurasi, presisi, serta *recall* dari hasil penelitian yang dilaksanakan. Pada Tabel 2, dapat dilihat tabel dari *confusion matrix*.

Tabel 2. Confusion Matrix

| Confusion Matrix | | Kelas Prediksi | |
|-------------------------|---------|-----------------------|---------|
| | | Positif | Negatif |
| Kelas Asli | Positif | TP | FN |
| | Negatif | FP | TN |

Rumus untuk menghitung akurasi, presisi, serta *recall* dapat dilihat pada Persamaan (13), (14), dan (15).

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (13)$$

$$presisi = \frac{TP}{TP+FP} \times 100\% \quad (14)$$

$$recall = \frac{TP}{TP+FN} \times 100\% \quad (15)$$

3. Hasil dan Diskusi

Berdasarkan metode penelitian yang sudah dilakukan, didapatkan hasil evaluasi klasifikasi PNN dengan *K-Fold* dan *Confusion Matrix* dari setiap *fold*-nya sebagai berikut.

| | | precision | recall | f1-score | support | | | | | | | |
|-------------------|-----|-----------|--------|--------------|---------|------|-------|----------------|------|------|------|-----|
| Fold 1 | | | | | | | | | | | | |
| Confusion Matrix: | | | | | | | | | | | | |
| [[300 | 0 | 0 | 0 | 0 | 0 | 0 | 0] | Asthma | 1.00 | 1.00 | 1.00 | 300 |
| [0 | 300 | 0 | 0 | 0 | 0 | 0 | 0] | Bronchiectasis | 0.98 | 1.00 | 0.99 | 300 |
| [0 | 0 | 300 | 0 | 0 | 0 | 0 | 0] | Bronchiolitis | 0.99 | 1.00 | 0.99 | 300 |
| [0 | 6 | 3 | 271 | 5 | 0 | 13 | 2] | COPD | 0.99 | 0.90 | 0.95 | 300 |
| [0 | 0 | 1 | 2 | 294 | 0 | 1 | 2] | Healthy | 0.98 | 0.98 | 0.98 | 300 |
| [0 | 0 | 0 | 0 | 0 | 300 | 0 | 0] | LRTI | 0.99 | 1.00 | 1.00 | 300 |
| [0 | 0 | 0 | 0 | 0 | 2 | 298 | 0] | Pneumonia | 0.96 | 0.99 | 0.97 | 300 |
| [0 | 1 | 0 | 0 | 0 | 1 | 0 | 298]] | URTI | 0.99 | 0.99 | 0.99 | 300 |
| | | | | accuracy | | | 0.98 | 2400 | | | | |
| | | | | macro avg | 0.98 | 0.98 | 0.98 | 2400 | | | | |
| | | | | weighted avg | 0.98 | 0.98 | 0.98 | 2400 | | | | |

Gambar 3. Fold 1 PNN

Pada Gambar 3 ditampilkan hasil dari *fold 1*, yang dimana terdapat 39 data yang salah diklasifikasikan. Data uji untuk kelas asma, bronkiektasis, bronkiolitis, dan LRTI berhasil diklasifikasikan dengan benar. Presisi terendah ditemukan pada kelas pneumonia sebesar 96%, sedangkan *recall* terendah terdapat pada kelas COPD sebesar 90%, menghasilkan akurasi 98,38%, dengan rata-rata presisi 98,4% dan rata-rata *recall* 98,38%.

| | | precision | recall | f1-score | support | | | | | | | |
|-------------------|-----|-----------|--------|--------------|---------|------|-------|----------------|------|------|------|-----|
| Fold 2 | | | | | | | | | | | | |
| Confusion Matrix: | | | | | | | | | | | | |
| [[300 | 0 | 0 | 0 | 0 | 0 | 0 | 0] | Asthma | 1.00 | 1.00 | 1.00 | 300 |
| [0 | 300 | 0 | 0 | 0 | 0 | 0 | 0] | Bronchiectasis | 0.98 | 1.00 | 0.99 | 300 |
| [0 | 0 | 300 | 0 | 0 | 0 | 0 | 0] | Bronchiolitis | 0.99 | 1.00 | 1.00 | 300 |
| [0 | 6 | 1 | 272 | 5 | 1 | 10 | 5] | COPD | 1.00 | 0.91 | 0.95 | 300 |
| [0 | 0 | 0 | 0 | 299 | 0 | 1 | 0] | Healthy | 0.97 | 1.00 | 0.98 | 300 |
| [0 | 0 | 0 | 0 | 0 | 300 | 0 | 0] | LRTI | 0.99 | 1.00 | 1.00 | 300 |
| [0 | 0 | 0 | 0 | 4 | 0 | 296 | 0] | Pneumonia | 0.96 | 0.99 | 0.98 | 300 |
| [0 | 0 | 2 | 0 | 0 | 1 | 0 | 297]] | URTI | 0.98 | 0.99 | 0.99 | 300 |
| | | | | accuracy | | | 0.98 | 2400 | | | | |
| | | | | macro avg | 0.99 | 0.98 | 0.98 | 2400 | | | | |
| | | | | weighted avg | 0.99 | 0.98 | 0.98 | 2400 | | | | |

Gambar 4. Fold 2 PNN

Pada Gambar 4 ditampilkan hasil dari *fold 2*, yang mendapatkan sebanyak sebanyak 36 data yang salah diklasifikasikan. Data uji untuk kelas asma, bronkiektasis, bronkiolitis, dan LRTI berhasil diklasifikasikan dengan benar. Presisi terendah kembali terjadi pada kelas pneumonia sebesar 96%, sementara *recall* terendah terdapat pada kelas COPD sebesar 91%. *Fold* ini menunjukkan kinerja yang sedikit lebih tinggi dibandingkan *Fold 1*, dengan akurasi 98,5%, rata-rata presisi 98,53%, dan rata-rata *recall* 98,5%.

| | | precision | recall | f1-score | support | | | | | | | |
|-------------------|-----|-----------|--------|--------------|---------|------|-------|----------------|------|------|------|-----|
| Fold 3 | | | | | | | | | | | | |
| Confusion Matrix: | | | | | | | | | | | | |
| [[300 | 0 | 0 | 0 | 0 | 0 | 0 | 0] | Asthma | 1.00 | 1.00 | 1.00 | 300 |
| [0 | 300 | 0 | 0 | 0 | 0 | 0 | 0] | Bronchiectasis | 0.97 | 1.00 | 0.99 | 300 |
| [0 | 0 | 300 | 0 | 0 | 0 | 0 | 0] | Bronchiolitis | 0.98 | 1.00 | 0.99 | 300 |
| [1 | 9 | 4 | 262 | 8 | 0 | 13 | 3] | COPD | 0.99 | 0.87 | 0.93 | 300 |
| [0 | 0 | 2 | 3 | 295 | 0 | 0 | 0] | Healthy | 0.97 | 0.98 | 0.98 | 300 |
| [0 | 0 | 0 | 0 | 0 | 300 | 0 | 0] | LRTI | 1.00 | 1.00 | 1.00 | 300 |
| [0 | 0 | 0 | 0 | 0 | 0 | 299 | 1] | Pneumonia | 0.96 | 1.00 | 0.98 | 300 |
| [0 | 0 | 0 | 0 | 2 | 0 | 0 | 298]] | URTI | 0.99 | 0.99 | 0.99 | 300 |
| | | | | accuracy | | | 0.98 | 2400 | | | | |
| | | | | macro avg | 0.98 | 0.98 | 0.98 | 2400 | | | | |
| | | | | weighted avg | 0.98 | 0.98 | 0.98 | 2400 | | | | |

Gambar 5. Fold 3 PNN

Pada Gambar 5 ditampilkan hasil dari *fold 3*, yang dimana terdapat sebanyak 46 data salah diklasifikasikan. Kelas asma, bronkiektasis, bronkiolitis, dan LRTI seluruhnya berhasil diklasifikasikan dengan benar. Presisi terendah ditemukan pada kelas pneumonia sebesar 96%, dan *recall* terendah

terjadi pada kelas COPD sebesar 87%. *Fold* ini menghasilkan kinerja terendah dibandingkan *fold* lainnya, dengan akurasi 98,08%, rata-rata presisi 98,11%, dan rata-rata *recall* 98,08%.

| | | precision | recall | f1-score | support |
|-------------------|----------------|-----------|--------|----------|---------|
| Fold 4 | | | | | |
| Confusion Matrix: | | | | | |
| [[300 | 0 | 0 | 0 | 0 | 0 |
| [0 | 300 | 0 | 0 | 0 | 0 |
| [0 | 0 | 300 | 0 | 0 | 0 |
| [1 | 5 | 1 | 281 | 2 | 0 |
| [0 | 0 | 0 | 0 | 298 | 0 |
| [0 | 0 | 0 | 0 | 0 | 300 |
| [0 | 0 | 0 | 1 | 0 | 0 |
| [0 | 0 | 0 | 0 | 2 | 1 |
| [0 | 0 | 0 | 0 | 2 | 295]]] |
| | Asthma | 1.00 | 1.00 | 1.00 | 300 |
| | Bronchiectasis | 0.98 | 1.00 | 0.99 | 300 |
| | Bronchiolitis | 1.00 | 1.00 | 1.00 | 300 |
| | COPD | 1.00 | 0.94 | 0.97 | 300 |
| | Healthy | 0.99 | 0.99 | 0.99 | 300 |
| | LRTI | 1.00 | 1.00 | 1.00 | 300 |
| | Pneumonia | 0.96 | 1.00 | 0.98 | 300 |
| | URTI | 0.99 | 0.98 | 0.99 | 300 |
| | accuracy | | | 0.99 | 2400 |
| | macro avg | 0.99 | 0.99 | 0.99 | 2400 |
| | weighted avg | 0.99 | 0.99 | 0.99 | 2400 |

Gambar 6. Fold 4 PNN

Pada Gambar 6 ditampilkan hasil dari *fold* 4, yang dimana terdapat sebanyak 27 data salah diklasifikasikan. Kelas asma, bronkiektasis, bronkiolitis, dan LRTI berhasil diklasifikasikan dengan benar. Presisi terendah kembali terjadi pada kelas pneumonia sebesar 96%, sementara *recall* terendah terdapat pada kelas COPD sebesar 94%. *Fold* ini memberikan hasil kinerja tertinggi di antara seluruh *fold*, dengan akurasi 98,88%, rata-rata presisi 98,89%, dan rata-rata *recall* 98,88%.

| | | precision | recall | f1-score | support |
|-------------------|----------------|-----------|--------|----------|---------|
| Fold 5 | | | | | |
| Confusion Matrix: | | | | | |
| [[300 | 0 | 0 | 0 | 0 | 0 |
| [0 | 300 | 0 | 0 | 0 | 0 |
| [0 | 0 | 300 | 0 | 0 | 0 |
| [2 | 10 | 0 | 271 | 4 | 0 |
| [0 | 0 | 0 | 0 | 299 | 0 |
| [0 | 0 | 0 | 0 | 0 | 300 |
| [0 | 0 | 0 | 0 | 0 | 300 |
| [0 | 0 | 0 | 0 | 0 | 1 |
| [0 | 0 | 0 | 0 | 0 | 299]]] |
| | Asthma | 0.99 | 1.00 | 1.00 | 300 |
| | Bronchiectasis | 0.97 | 1.00 | 0.98 | 300 |
| | Bronchiolitis | 1.00 | 1.00 | 1.00 | 300 |
| | COPD | 1.00 | 0.90 | 0.95 | 300 |
| | Healthy | 0.99 | 1.00 | 0.99 | 300 |
| | LRTI | 1.00 | 1.00 | 1.00 | 300 |
| | Pneumonia | 0.96 | 1.00 | 0.98 | 300 |
| | URTI | 1.00 | 1.00 | 1.00 | 300 |
| | accuracy | | | 0.99 | 2400 |
| | macro avg | 0.99 | 0.99 | 0.99 | 2400 |
| | weighted avg | 0.99 | 0.99 | 0.99 | 2400 |

Gambar 7. Fold 5 PNN

Pada Gambar 7 ditampilkan hasil dari *fold* 5, yang dimana sebanyak 31 data salah diklasifikasikan. Kelas asma, bronkiektasis, bronkiolitis, LRTI, dan pneumonia berhasil diklasifikasikan dengan benar. Presisi terendah kembali terjadi pada kelas pneumonia sebesar 96%, sementara *recall* terendah terdapat pada kelas COPD sebesar 90%. *Fold* ini mencapai kinerja tertinggi kedua dengan akurasi 98,71%, rata-rata presisi 98,75%, dan rata-rata *recall* 98,71%.

Berdasarkan 5 *fold* yang sudah dilakukan, *fold* 4 mencapai akurasi tertinggi sebesar 98,88%, sedangkan *fold* 3 memiliki akurasi terendah sebesar 98,08%. Rata-rata keseluruhan untuk akurasi, presisi, dan *recall* dari seluruh *fold* juga sebesar 98,51%, 98,54%, dan 98,51% secara berturut.

4. Kesimpulan

Dalam klasifikasi penyakit pernapasan dengan ekstraksi ciri menggunakan *Mel-Frequency Cepstral Coefficients* (MFCC), *Probabilistic Neural Network* (PNN) sebagai model pengklasifikasi menunjukkan tingkat performa yang baik. Model ini mencapai akurasi tertinggi sebesar 98,88%, dengan rata-rata akurasi sebesar 98,51%, rata-rata presisi sebesar 98,54%, dan rata-rata *recall* sebesar 98,51%. Hasil ini menunjukkan bahwa metode PNN efektif dalam mengidentifikasi penyakit pernapasan, memberikan potensi sebagai alat bantu diagnosis dalam bidang kesehatan.

Daftar Pustaka

- [1] T. Vos *et al.*, "Global burden of 369 diseases and injuries in 204 countries and territories, 1990–2019: A systematic analysis for the global burden of disease study 2019," *The Lancet*, vol. 396, no. 10258, p. 1204, 2020. doi: 10.1016/s0140-6736(20)30925-9.
- [2] Perhimpunan Dokter Paru Indonesia, *Panduan Umum Praktis Klinis Penyakit Paru dan Pernapasan*, Jakarta: Perhimpunan Dokter Paru Indonesia, 2021. [Online]. Available: <https://bukupdpi.klikpdpi.com/buku-pupk-pdpi-2021-2/>. [Accessed: Jan. 21, 2025].
- [3] I. P. B. C. Buana, I. G. A. Wibawa, A. Muliantara, M. A. Raharja, I. P. G. H. Suputra, and L. G. Astuti, "Deteksi Suara Paru-Paru Menggunakan MFCC (Mel Frequency Cepstral Coefficient) dan M-KNN (Modified K-Nearest Neighbor)," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 4, pp. 845–853, 2022. doi: <https://doi.org/10.24843/jlk.2023.v11.i04.p25>.
- [4] A. Buono, "Representasi nilai hos dan model MFCC sebagai ekstraksi ciri pada sistem indentifikasi pembicara di lingkungan ber-noise menggunakan HMM," M.S. thesis, Program Studi Ilmu Komputer, Universitas Indonesia, Depok, Indonesia, 2009.
- [5] N. M. A. Suandewi, I. G. A. Wibawa, I. G. N. A. Cahyadi, I. K. A. Mogi, N. A. S. ER, and C. R. A. Pramatha, "Penerapan Metode MFCC dan Naive Bayes untuk Deteksi Suara Paru-Paru," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 1, pp. 75–82, 2022. doi: <https://doi.org/10.24843/jlk.2022.v11.i01.p08>.
- [6] B. Mohebbi *et al.*, "Probabilistic neural networks: a brief overview of theory, implementation, and application," in *Handbook of Probabilistic Models*, Kidlington, Oxford, United Kingdom: Butterworth-Heinemann, an imprint of Elsevier, 2020, pp. 347–367.
- [7] R. Novita *et al.*, "The implementation of probabilistic neural network algorithm for classification of Family Hope Program in Pekanbaru City," *Journal of Physics: Conference Series*, vol. 1783, no. 1, pp. 1–6, 2021. doi: 10.1088/1742-6596/1783/1/012018.
- [8] C. Shilaja and T. Arunprasath, "Retraction Note: Energy demand classification by probabilistic neural network for medical diagnosis applications," *Neural Computing and Applications*, vol. 36, no. 24, pp. 15199–15199, 2024. doi: <https://doi.org/10.1007/s00521-024-10091-8>.
- [9] S. J. Siregar, A. I. Lubis, and E. F. Ginting, "Penerapan neural network Dalam Klasifikasi citra Permainan Batu kertas Gunting Dengan probabilistic neural network," *Building of Informatics, Technology and Science (BITS)*, vol. 3, no. 3, pp. 420–425, 2021. doi: 10.47065/bits.v3i3.1143.
- [10] D. Lee, S. Derrible, and F. C. Pereira, "Comparison of four types of Artificial Neural Network and a multinomial logit model for travel mode choice modeling," *Transportation Research Record: Journal of the Transportation Research Board*, vol. 2672, no. 49, pp. 101–112, 2018. doi: 10.1177/0361198118796971.
- [11] S. K. Satapathy *et al.*, "EEG Brain Signal Classification for Epileptic Seizure Disorder Detection," Academic Press, 2019, pp. 1–25. doi: <https://doi.org/10.1016/B978-0-12-817426-5.00001-6>.
- [12] N. P. D. Sukma *et al.*, "Klasifikasi Penyakit Paru-Paru berdasarkan Suara Paru-Paru menggunakan metode MFCC Dan SVM," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 11, no. 3, pp. 553–560, 2023. doi: 10.24843/jlk.2023.v11.i03.p11.
- [13] D. Rafiqo, Y. Suyanto, and C. Atmaji, "Klasifikasi Suara Paru-Paru berdasarkan Ciri MFCC," *Jurnal ELEMENTER (Elektro dan Mesin Terapan)*, vol. 7, no. 1, pp. 20–34, 2022.
- [14] C. Aridela, A. Rizal, and Y. S. Hariyani, "Perbandingan Suara Paru Normal dan Abnormal menggunakan Probabilistic Neural Network dan Support Vector Machine," *e-Proceeding of Engineering*, vol. 4, no. 1, pp. 165–172, 2017.

- [15] K. N. Priftis, L. J. Hadjileontiadis, and M. L. Everard, *Breath Sounds from Basic Science to Clinical Practice*, Cham, Zug: Springer International Publishing, 2018.
- [16] K. Mridha, S. Sarkar, and D. Kumar, "Respiratory Disease Classification by CNN using MFCC," in *2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA)*, 2021. doi: <https://doi.org/10.1109/iccca52192.2021.9666346>.
- [17] F. Syafria, A. Buono, and B. P. Silalahi, "Pengenalan Suara Paru-paru dengan mfcc Sebagai Ekstraksi Ciri Dan Backpropagation Sebagai classifier," *Jurnal Ilmu Komputer dan Agri-Informatika*, vol. 3, no. 1, pp. 27–37, 2014. doi: 10.29244/jika.3.1.27-36.
- [18] Y. Yan, S. O. Simons, L. van Bommel, L. G. Reinders, F. M. E. Franssen, and V. Urovi, "Optimizing MFCC parameters for the automatic detection of respiratory diseases," *Applied Acoustics*, vol. 228, pp. 110299–110299, 2024. doi: <https://doi.org/10.1016/j.apacoust.2024.110299>.
- [19] A. Mustofa, "Sistem Pengenalan penutur dengan metode Mel-frequency wrapping," *Jurnal Teknik Elektro*, vol. 7, no. 2, pp. 88–96, 2007. doi: 10.9744/jte.7.2.88-96.
- [20] I. S. Permana, Y. I. Nurhasanah, and A. Zulkarnain, "Implementasi metode MFCC Dan DTW untuk Pengenalan Jenis suara pria dan wanita," *MIND Journal*, vol. 3, no. 1, pp. 49–63, 2018. doi: 10.26760/mindjournal.v3i1.61-76.