



---

*Research Articles*

## **Klasifikasi Multiclass Pada Sound Healing menggunakan Algoritma Pseudo Nearest Neighbor**

### *Multiclass Classification of Sound Healing Using Pseudo-Nearest Neighbor*

**Cipta Ramadhani\*, I Made Budi Sukmadana, Made Sutha Yadnya**

Jurusan Teknik Elektro Universitas Mataram, Universitas Mataram

\*corresponding author, email: [cipta.ramadhani@unram.ac.id](mailto:cipta.ramadhani@unram.ac.id)

Manuscript received: 26-11-2024. Accepted: 15-12-2024

#### **ABSTRAK**

Sound healing atau yang biasa disebut dengan terapi musik dengan menggunakan peralatan *Acoustic Sound for Wellbeing* (ASW) seperti Drums, Gong lonceng dan jenis lainnya yang dapat mengeluarkan getaran frekuensi tertentu yang digunakan dalam dunia medis untuk membantu pasien yang sedang mengalami gangguan kecemasan atau depresi. saat ini penelitian tentang sound healing difokuskan pada metode untuk mengenali frekuensi yang sesuai yang mempengaruhi stress dan kecemasan yang timbul pada seorang pasien. Penelitian ini memaparkan implementasi algoritma Pseudo-Nearest Neighbor (P-NN) untuk mengklasifikasikan multiclass ASW. Secara umum, algoritma PNN memberikan performa yang lebih baik untuk multiclass dalam skenario yang dibuat terutama dalam mengenali data pencilan pada tiap kelas. Dengan menggunakan 2 kelas (Gong dan Singing Bowl), nilai akurasi untuk algoritma P-NN diatas 92%. peningkatan nilai akurasi juga dapat dilihat untuk jumlah kelas yang lebih besar. Hal ini membuktikan bahwa algoritma P-NN dapat memberikan performa yang lebih baik untuk mengatasi data pencilan atau outlier yang dimiliki oleh dataset ASW.

**Kata kunci:** Sound Healing; klasifikasi; Pseudo-Nearest Neighbour

#### **ABSTRACT**

Sound healing, or commonly referred to as music therapy using *Acoustic Sound for Wellbeing* (ASW) equipment such as drums, gongs, bells, and other types that produce specific frequency vibrations, is used in the medical field to help patients experiencing anxiety or depression. Currently, research on sound healing focuses on methods to identify appropriate frequencies that influence stress and anxiety experienced by patients. This study presents the implementation of the Pseudo-Nearest Neighbour (P-NN) algorithm for classifying multiclass ASW. In general, the P-NN algorithm performs better for multiclass scenarios, particularly in identifying outlier data in each class. Furthermore, P-NN provides better performance for all confusion matrix parameters. Using two classes (Gong and Singing Bowl), the accuracy of the P-NN algorithm exceeds 92%. This demonstrates that the P-NN algorithm can provide better performance in handling outliers within the ASW dataset.

**Key words:** Sound Healing; classification; Pseudo-Nearest Neighbor

## PENDAHULUAN

Sound healing atau yang biasa disebut dengan terapi musik adalah salah satu teknik digunakan dalam dunia medis untuk membantu pasien yang sedang mengalami gangguan kecemasan atau depresi yang sering muncul terutama didaerah perkotaan(Pheasant, 2016). Padatnya kendaraan, suara pekerjaan konstruksi serta intents pembicaraan diruang terbuka menyebabkan kondisi seperti insomnia, stres kronis dan gangguan pendengaran(Brown et al., 2015). Penggunaan sound healing menjadi sangat populer saat ini baik dikalangan therapis maupun dari para peneliti. Peralatan yang biasa digunakan antara lain adalah Drums, Gong lonceng dan jenis lainnya yang dapat mengeluarkan getaran frekuensi tertentu yang dapat membantu memberikan tenang menghilangkan perasaan panik dan stress(Bradt et al., 2011). Penelitian pada sound healing saat ini difokuskan pada bagaimana cara untuk mengenali pola frekuensi yang sesuai dan dapat mempengaruhi stress dan kecemasan yang timbul pada seorang pasien. Oleh karena itu, kebutuhan dalam pengklasifikasian jenis suara yang ditimbulkan oleh peralatan sangat dibutuhkan untuk memberikan informasi jenis-jenis sound healing yang dibutuhkan.

Machine learning sebagai salah satu cabang dari Artificial Intelligence saat ini sudah banyak digunakan dalam mengklasifikasi jenis-jenis dari sound healing(Quinn et al., 2022)(Ramadhani, 2021). Variabel seperti frekuensi, amplitudo dan waveform dapat digunakan menjadi paramater yang penting untuk mengklasifikasikan jenis dari sound healing. Akan tetapi tingkat akurasi, presisi serta kompleksnya data menjadi masalah yang perlu diperhatikan dalam prosesnya. Sebagai contoh adalah algoritma *K-Nearest Neighbor* (K-NN). Algoritma K-NN cenderung memberikan performa yang kurang baik terutama dalam pencarian dan pemilihan tetangga terdekat(Gou et al., 2019). Masalah ini tentunya akan berimbas pada kemampuan K-NN dalam mengklasifikasikan sejumlah data yang memiliki *outlier* (pencilan) yang cukup banyak.

Untuk mengatasi masalah pencilan pada data ASW tersebut, pada penelitian ini akan digunakan algoritma P-NN. Algoritma P-NN sangat efektif untuk mengatasi jenis data yang memiliki nilai pencilan dan dimensi data yang cukup besar(Zeng et al., 2009). P-NN merupakan algoritma yang menggunakan konsep tetangga terdekat semu yang menghitung jarak total antara data yang diuji dengan k sampel yang terdekatnya. Berbeda halnya dengan algoritma K-NN yang hanya melihat dari jumlah k tetangga terdekatnya saja. Algoritma P-NN akan mengkalkulasi jarak total keseluruhan tetangga terdekat sebagai penentu proses klasifikasi. Pada paper ini akan meneliti keunggulan dari algoritma P-NN dalam mengklasifikasikan jenis-jenis sound healing berdasarkan sejumlah variabel yang dimiliki.

Beberapa penelitian yang telah dilakukan menunjukkan bahwa algoritma P-NN memberikan performa yang cukup baik dan banyak diterapkan dalam berbagai bidang termasuk pengenalan pola. Sebagai contoh, P-NN digunakan sebagai algoritma untuk melacak dan mengkoordinasikan lokasi sejumlah radar dalam *Asynchronous Track-to-Track associated* (TTTA) (Chen et al., 2023). Algoritma P-NN dalam TTTA digunakan untuk mengkalkulasi jarak terdekat antara titik lokasi dengan titik pada dataset yang dimiliki. Dari hasil penelitian tersebut didapatkan bahwa algoritma P-NN dapat mengurangi error pada waktu dalam proses estimasi propagasi. Selain itu, dengan menggunakan algoritma P-NN didapatkan nilai rata-rata association rate yang cukup tinggi untuk tiap pelacakan lokasi radar dengan tingkat akurasi diatas 99%. Peneliti lainnya (Hendrawan et al., 2022) menggunakan algoritma P-NN untuk


mengklasifikasikan penyakit *Typus* dan *Dengue Fever*. Penelitian tersebut menggunakan *5-fold cross validation* sebagai bagian dari evaluasi algoritma. Dari hasil penelitian tersebut didapatkan bahwa nilai  $k$  yang terbaik yang digunakan adalah  $k=6$ .

Peneliti lainnya melakukan kajian tentang sentimen analysis pada media sosial Twitter dengan menggunakan algoritma P-NN (Pratama et al., 2023). Dalam penelitian tersebut mereka menggunakan *Term Frequency-Inverse Document Frequency* (TF-IDF) sebagai teknik untuk memproses teks yang biasa digunakan dalam *Natural Language Processing* (NLP). Dari hasil penelitian tersebut didapatkan bahwa nilai  $k$  yang terbaik untuk klasifikasi didapatkan dalam proses training adalah  $k=3$  dengan nilai 89%.

Pada penelitian lainnya, algoritma P-NN dikombinasikan dengan *Minkowski Distance-weighted* untuk mengukur jarak antar objek (Jiarui et al., 2024). Ide dasarnya adalah dengan memberikan nilai bobot untuk tetangga berdasarkan jarak dari titik query. Object tetangga yang lebih dekat akan menerima nilai bobot yang lebih besar. Dari hasil penelitian ini didapatkan bahwa P-NN dengan menggunakan *Minkowski Distance-weighted* memberikan performa yang cukup baik terutama untuk mengatasi masalah imbalance dataset yang dimiliki. Konsep ini akan memberikan nilai performa yang lebih baik. Penelitian berikutnya dilakukan oleh (Pambudi et al., 2019). Ia menggunakan algoritma P-NN untuk mengklasifikasikan jenis berita yang sedang viral di Indonesia. Dari penelitian tersebut didapatkan nilai *cross validation error* sebesar 0,1495 dengan menggunakan metode *Cosine Proximity*.

P-NN secara harfiah dapat juga disebut sebagai tetangga terdekat semu. Ia adalah algoritma yang digunakan untuk mengatasi kelemahan yang timbul dari K-NN dengan cara mengurangi proses pencarian dengan memilih jumlah data ketetanggaaan yang lebih kecil. Secara umum, algoritma P-NN bekerja dengan cara menghitung nilai dari jarak total data uji dengan sejumlah  $k$  sampel tetangga terdekatnya pada setiap kelas. Kemudian, dengan melakukan pembobotan secara proporsional P-NN akan memutuskan kelas dengan nilai jarak terpendek dalam perhitungannya untuk menjadi bagian dari kelas data uji yang digunakan.

Cara Kerja algoritma PNN dapat diilustrasikan seperti pada gambar 1. Dimisalkan terdapat dua kelas yaitu kelas lingkaran dan kelas kotak, dimana kedua kelas tersebut memiliki jumlah populasi data yang hampir sama. Apabila kita akan menambahkan sebuah data uji yaitu data dengan label belah ketupat maka data uji tersebut akan diukur jaraknya dengan kedua populasi kelas tadi. Apabila menggunakan  $k=3$ , maka tiga object yang terdekat dari masing-masing kelas akan diukur jaraknya terhadap objek dengan label lingkaran. Total jarak yang terkecil dari objek akan mengklasifikasikan data baru (objek lingkaran) sebagai bagian dari kelas tersebut (Zeng et al., 2009). Teknik yang digunakan pada algoritma P-NN ini akan mengatasi kelemahan yang dimiliki oleh algoritma K-NN yang disebabkan oleh banyaknya jumlah data pencilan yang mungkin ada.



Gambar 1. Perbedaan algoritma PNN dan KNN. (a) dengan nilai  $k=3$ , algoritma KNN salah mengklasifikasikan objek dengan simbol bintang. (b) sedangkan algoritma PNN berhasil mengklasifikasikan objek dengan simbol bintang dengan kelas sebenarnya

Dari gambar diatas dapat kita lihat bahwa, dengan menggunakan algoritma K-NN data uji yang baru gagal diklasifikasikan sebagai kelas lingkaran karena hanya melihat data berdasarkan jumlah objek terdekat saja. Sedangkan, apabila menggunakan algoritma P-NN, data uji (belah ketupat) berhasil diklasifikasikan sebagai bagian dari kelas lingkaran karena proses klasifikasinya bukan berdasarkan jumlah objek dengan jarak lokasi terdekat, akan tetapi dengan melihat jarak total dari objek terdekat dari data uji.

## BAHAN DAN METODE

Pada penelitian ini, data yang digunakan diambil dari dataset (Baird, Alice; Schuller, n.d.) yang berisi data *Acoustic Sound for Wellbeing* (ASW). Dimana data tersebut akan dibagi menjadi dua bagian yaitu 80% untuk data latih dan 20% digunakan sebagai data uji. Untuk proses training, digunakan metode *10-fold cross validation* sebagai langkah validasi terhadap proses klasifikasi.

### Praprocessing Data

Data ASW didapatkan dari *The Accoustic Sounds for Wellbeing* Dataset. Pada penelitian ini digunakan 2.200 file (wav) sound healing dengan 4 kelas yang berbeda. Durasi dari masing-masing suara diambil selama 4 menit yang dianggap sebagai suara dari sound healing. Format awal dari data ASW adalah format WAV. Oleh karena itu dilakukan serangkaian perubahan dimana variabel diambil dalam Domain waktu dan diubah dengan menggunakan *Fast Fourier Transform* untuk mendapatkan data dalam domain frekuensi agar data dapat diolah lebih lanjut. Selanjutnya untuk memahami karaktersitik dari data ASW akan digunakan variabel statistik seperti mean, median, standar deviasi dan beberapa Atribut lainnya yang dapat dilihat pada Tabel 1.

**Tabel 1. Dataset Variabel**

Data dalam Domain Frekuensi	Variabel
	Rata-rata
	Nilai Tengah
	Standard Deviasi
	Nilai Terkecil
	Nilai Terbesar
	Quartile 1
	Quartile 3
	Interquartile Range

Variabel dalam tabel 1 digunakan pada data *time series* dan FFT sehingga untuk klasifikasi menggunakan algoritma P-NN kita memiliki 16 variabel data. Semua program dibuat dengan bahasa pemrograman python tanpa menggunakan library khusus untuk klasifikasi

**Tabel 2. Dataset**

Jenis Sound Healing	Jumlah of Dataset			
	Train	Validate	Test	$\Sigma$
Singing Bowl	396	44	110	550
Gong	396	44	110	550
Drum	396	44	110	550
Lonceng	396	44	110	550
$\Sigma$	1.584	176	440	<b>2.200</b>

Untuk penelitian ini, digunakan 4 jenis data ASW yaitu Drum, Singing Bowl, Gong dan Wind-Chimes. Tabel 2 menunjukkan sejumlah langkah yang dilakukan dalam proses klasifikasi yaitu pelatihan (*training*), validasi (*validation*) dan bagian Test (*testing*) dengan menggunakan data ASW. Seperti yang telah disampaikan sebelumnya bahwa data ASW terdiri dari 2200 data sound healing yang akan dibagi dalam 550 data untuk tiap kelasnya. Untuk mendapatkan hasil yang maksimal, dilakukan *K-fold cross validation* untuk proses pelatihan dan validasi. Sementara itu, sisa data 20% digunakan untuk proses testing.

Dalam penelitian ini, tiga skenario eksperimen dilakukan pada data ASW untuk melihat kemampuan algoritma P-NN dalam mengklasifikasikan empat kelas (multi class) jenis sound healing yang ada. Tiga skenario tersebut antara lain :

### **Gong (gon) dan Singing Bowl (sb)**

Alasan menggunakan kedua kelas tersebut adalah karena kedua instrumen tersebut memiliki kesamaan seperti jenis bahan yang digunakan. Percobaan ini untuk melihat sejauh mana algoritma P-NN dalam mengenali dan membedakan kedua instrumen tersebut.

### **Tiga kelas yaitu Lonceng (chi), Drum (dru) dan Gong**

Untuk 3 jenis kelas diatas, Tujuan percobaannya adalah untuk melihat perbedaan karakteristik jenis akustiknya.

### **Empat kelas yaitu Lonceng (chi), Drum (dru), Singing Bowl dan Gong**

Untuk jenis yang terakhir yaitu menggunakan 4 kelas, Tujuan percobaannya adalah untuk melihat kemampuan algoritma P-NN dalam mengklasifikasikan dataset ASW secara keseluruhan.

### **Evaluasi Model klasifikasi**

Untuk evaluasi model klasifikasi algoritma P-NN, penelitian ini menggunakan confusion matrix model dengan sejumlah parameter yaitu akurasi, presisi dan recall dengan rumus sebagai berikut :

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad \dots (1)$$

$$Recall = \frac{TP}{TP+FN} \quad \dots (2)$$

$$Precision = \frac{TP}{TP+FP} \quad \dots (3)$$

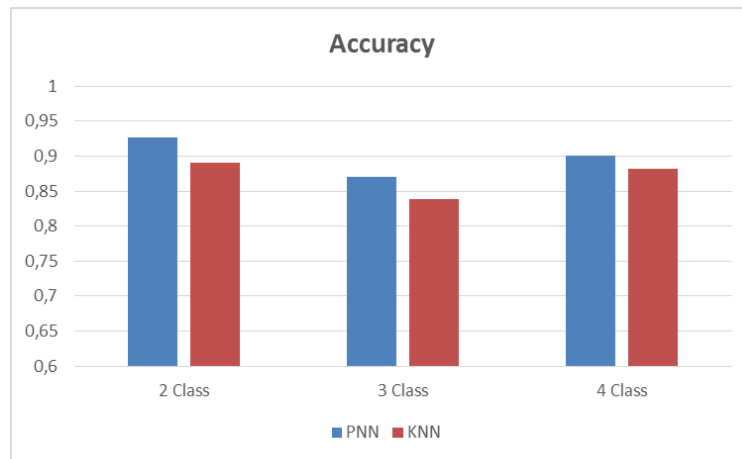
(TP= True Positive, TN= True Negative, FP= False Positive and FN= False Negative).

Selain itu, proses training algoritma P-NN pada penelitian ini menggunakan parameter K ganjil dengan nilai ( k=3 sampai dengan k=21) untuk mendapatkan nilai k yang cocok sebagai nilai parameter ketetangaan.

## **HASIL DAN PEMBAHASAN**

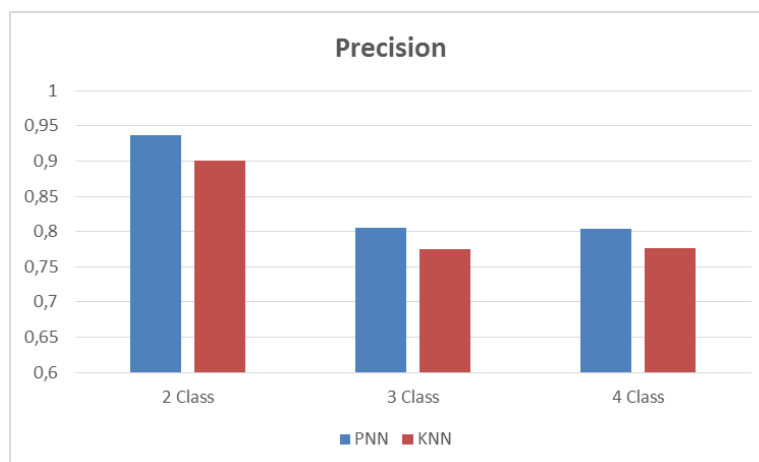
Pada penelitian ini, digunakan parameter akurasi, presisi dan recall untuk melihat kemampuan algoritma P-NN dalam mengklasifikasikan data sound healing. Nilai k diambil dari k=3 sampai dengan k=21 untuk nilai k ganjil. Sebagai pembanding, algoritma K-NN akan digunakan dalam penelitian ini.

Dari gambar 2 dapat dilihat bahwa algoritma P-NN memberikan nilai akurasi yang cukup baik dengan tingkat akurasi diatas 0,92 untuk 2 kelas. Sedangkan untuk 3 dan 4 kelas secara berturut-turut memberikan nilai sekitar 0,85 dan 0,9. Dari gambar ini juga dapat dilihat bahwa seiring dengan bertambahnya kelas maka nilai akurasi juga ikut menurun meskipun terdapat fluktuasi



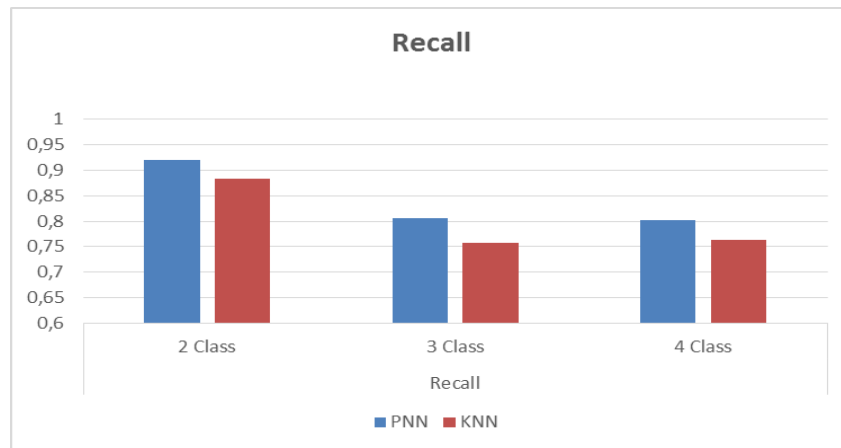
Gambar 2. Nilai Akurasi algoritma P-NN dan K-NN

Parameter berikutnya yang akan di ukur adalah presisi. Pada gambar 3 dapat dilihat bahwa algoritma P-NN memberikan nilai presisi yang cukup tinggi untuk 2 kelas yaitu sekitar 0,93. Nilai ini lebih tinggi 0,05 jika dibandingkan dengan algoritma K-NN dengan nilai sekitar 0,87. Nilai presisi untuk 3 dan 4 kelas juga memberikan nilai yang cukup tinggi untuk algoritma P-NN yaitu 0,805 dan 0,806 secara berturut-turut. Kedua nilai tersebut melebihi nilai presisi untuk algoritma K-NN dengan jumlah kelas yang sama.



Gambar 3 nilai presisi untuk algoritma P-NN dan K-NN

Dari gambar 3 juga dapat dilihat bahwa secara umum nilai presisi akan menurun seiring dengan meningkatnya jumlah kelas, baik itu algoritma P-NN maupun algoritma K-NN. Parameter terakhir yang diukur pada penelitian ini adalah recall. Seperti yang terlihat pada gambar 4. pola grafik memiliki kesamaan dengan dua gambar sebelumnya dimana, untuk algoritma P-NN memberikan nilai performa yang lebih baik jika dibandingkan dengan algoritma K-NN. Dengan menggunakan 2 kelas, nilai recall untuk P-NN sekitar 0,91 sedangkan untuk algoritma K-NN mendapatkan nilai 0,88. Begitu juga untuk 3 dan 4 kelas berturut-turut mendapatkan nilai 0,806 dan 0,802 untuk algoritma P-NN.



Gambar 4 nilai recall untuk algoritma P-NN dan K-NN

### KESIMPULAN

Penelitian ini memaparkan implementasi algoritma P-NN untuk mengatasi data penciran pada multiclass ASW. Pada tahap evaluasi, teknik 10-Fold cross validation digunakan untuk mendapatkan nilai K yang optimal. Selain itu confusion matrix digunakan untuk memvisualisasi nilai presisi, recall dan akurasi.

Secara umum, algoritma P-NN memberikan performa yang lebih baik untuk multiclass dalam skenario yang dibuat. Selain itu, Jika dibandingkan dengan algoritma K-NN, P-NN memberikan performa yang lebih baik untuk semua parameter confusion matrix. Dengan menggunakan 2 kelas (Gong dan Singing Bowl), nilai akurasi untuk algoritma P-NN diatas 0,92. Begitupun jika menggunakan parameter yang lain seperti presisi dan recall, nilai performa yang dimiliki oleh algoritma P-NN berada diatas algoritma K-NN. Hal ini membuktikan bahwa algoritma P-NN dapat memberikan performa yang lebih baik untuk mengatasi data penciran atau outlier yang dimiliki oleh dataset ASW.

### DAFTAR PUSTAKA

- Baird, Alice;Schuller, B. (n.d.). PRESENTING THE ACOUSTIC SOUNDS FOR WELLBEING DATASET AND BASELINE CLASSIFICATION RESULTS. 2019. <https://doi.org/https://doi.org/10.5281/zenodo.3360675>
- Bradt, J., Dileo, C., Grocke, D., & Magill, L. (2011). Music interventions for improving psychological and physical outcomes in cancer patients. In J. Bradt (Ed.), *Cochrane Database of Systematic Reviews*. John Wiley & Sons, Ltd. <https://doi.org/10.1002/14651858.CD006911.pub2>
- Brown, B., Rutherford, P., & Crawford, P. (2015). The role of noise in clinical environments with particular reference to mental health care: A narrative review. *International Journal of Nursing Studies*, 52(9), 1514–1524. <https://doi.org/10.1016/j.ijnurstu.2015.04.020>
- Chen, S., Zhang, H., Ma, J., & Xie, H. (2023). Asynchronous Track-to-Track Association Based on Pseudo Nearest Neighbor Distance for Distributed Networked Radar System. *Electronics*, 12(8), 1794. <https://doi.org/10.3390/electronics12081794>
- Gou, J., Qiu, W., Yi, Z., Shen, X., Zhan, Y., & Ou, W. (2019). Locality constrained representation-based K-nearest neighbor classification. *Knowledge-Based Systems*, 167, 38–52. <https://doi.org/10.1016/j.knosys.2019.01.016>
- Hendrawan, I. D. N. T., Dwidasmara, I. B. G., Kadyanan, I. G. A. G. A., Suputra, I. P. G. H., Karyawati, A. A. I. N. E., & Mahendra, I. B. M. (2022). Classification of Typhus and Dengue Fever Using the Pseudo Nearest Neighbor Algorithm. *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*,



- 11(1), 147. <https://doi.org/10.24843/JLK.2022.v11.i01.p16>
- Jiarui, H., Dinghan, K., & Yimeng, M. (2024). An Improved Pseudo Nearest Neighbor: Minkowski Distance-weighted Classification Algorithm. *2024 IEEE 4th International Conference on Electronic Technology, Communication and Information (ICETCI)*, 669–674. <https://doi.org/10.1109/ICETCI61221.2024.10594686>
- Pambudi, R. A., Adiwijaya, & Mubarok, M. S. (2019). Multi-label classification of Indonesian news topics using Pseudo Nearest Neighbor Rule. *Journal of Physics: Conference Series*, 1192, 012031. <https://doi.org/10.1088/1742-6596/1192/1/012031>
- Pheasant, R. J. (2016). Book review. *Applied Acoustics*, 114, 18. <https://doi.org/10.1016/j.apacoust.2016.06.005>
- Pratama, Y., Abdiansyah, A., & Miraswan, K. J. (2023). Sentiment Analysis Using PSEUDO Nearest Neighbor and TF-IDF TEXT Vectorizer. *Sriwijaya Journal of Informatics and Applications*, 4(2). <https://doi.org/10.36706/sjia.v4i2.68>
- Quinn, C. A., Burns, P., Gill, G., Baligar, S., Snyder, R. L., Salas, L., Goetz, S. J., & Clark, M. L. (2022). Soundscape classification with convolutional neural networks reveals temporal and geographic patterns in ecoacoustic data. *Ecological Indicators*, 138, 108831. <https://doi.org/10.1016/j.ecolind.2022.108831>
- Ramadhani, cipta et al. (2021). MULTICLASS CLASSIFICATION OF SOUND HEALING WITH K-NEAREST NEIGHBOR ALGORITHM. *DIELEKTRIKA*, 8(2), 156–163.
- Zeng, Y., Yang, Y., & Zhao, L. (2009). Pseudo nearest neighbor rule for pattern classification. *Expert Systems with Applications*, 36(2), 3587–3595. <https://doi.org/10.1016/j.eswa.2008.02.003>