

## Kombinasi SOM-RBF untuk prediksi drought code berdasarkan data curah hujan dan suhu udara

### *Combination of SOM-RBF for drought code prediction using rainfall and air temperature data*

Dwi Marisa Midyanti\*)

\*) Program Studi Rekayasa Sistem Komputer, FMIPA, Universitas Tanjungpura  
Jl. Prof. Dr. H. Hadari Nawawi, Pontianak, Indonesia 78124

---

**Cara sitasi:** D. M. Midyanti, "Kombinasi SOM-RBF untuk prediksi drought code berdasarkan data curah hujan dan suhu udara," *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 1, pp. 64-68, 2020. doi: [10.14710/jtsiskom.8.1.2020.64-68](https://doi.org/10.14710/jtsiskom.8.1.2020.64-68), [Online].

---

**Abstract** - This study aims to predict Drought Code (DC) in Kabupaten Kubu Raya using a combination of SOM-RBF. The final weight value of SOM was used as a center on the RBF network. The input data variables are rainfall data and air temperature data for three days with three binary outputs to predict DC values. This study also observed the effect of the number of neurons, learning rates, and the number of iterations on the results of the SOM-RBF network training. The smallest MSE of training result from the SOM-RBF network was 0.159933 using 65 neurons in the hidden layer, learning rate 0.007, and epoch 45000. The detection accuracy of SOM-RBF was 91.34 % from 245 test data.

**Keywords** – drought code prediction; self organizing map; radial basis function

**Abstrak** – Penelitian ini bertujuan untuk memprediksi Drought Code (DC) di Kabupaten Kubu Raya dengan menggunakan Kombinasi SOM-RBF. Nilai bobot akhir dari SOM digunakan sebagai center pada jaringan RBF. Penelitian ini menggunakan enam variabel data masukan, yaitu data curah hujan dan data suhu udara selama tiga hari dengan tiga keluaran biner untuk memprediksi nilai DC. Penelitian ini juga menganalisis pengaruh jumlah neuron, parameter laju pembelajaran, dan jumlah iterasi terhadap hasil pelatihan jaringan SOM-RBF. Hasil penelitian menunjukkan bahwa MSE pelatihan terkecil 0,159933 dari jaringan SOM-RBF didapat dengan menggunakan 65 neuron di lapisan tersembunyi, laju pembelajaran 0,007, dan 45000 iterasi. Dari 254 data uji, diperoleh akurasi SOM-RBF sebesar 91,34 %.

**Kata kunci** – prediksi drought code; self organizing map; radial basis function

## I. PENDAHULUAN

Drought code (DC) adalah salah satu parameter peringkat bahaya kebakaran. DC merupakan peringkat numerik dari kandungan kadar air di lapisan organik yang berada di bawah permukaan tanah. DC digunakan sebagai indikator kekeringan dan potensi terjadinya kabut asap. Peringkat DC yang tinggi biasanya terjadi pada kebakaran lahan gambut [1]. DC mewakili kadar air dari tanah organik padat pada kedalaman sedang (~18 cm) [2]. DC memiliki empat kategori kelas yang nilainya dapat diperoleh dari data curah hujan dan suhu udara, yaitu kelas rendah, sedang, tinggi, dan ekstrem. Kategori kelas DC tersebut digunakan untuk menentukan ada tidaknya pelarangan terhadap pembakaran hutan atau lahan gambut.

Algoritme penyelesaian masalah dalam *artificial neural network* (ANN) dapat digunakan untuk melakukan prediksi DC, salah satunya adalah *radial basis function* (RBF) [3]-[5]. RBF diaplikasikan untuk klasifikasi bibit tanaman lahan gambut berdasarkan bentuk daun dalam [4]. Algoritme RBF telah diimplementasikan di FPGA dalam [5] menggunakan bilangan *fixed point*. Permasalahan pada metode dengan titik pusat, seperti RBF, adalah membutuhkan set pelatihan yang besar untuk menghasilkan tingkat kinerja yang baik [3].

Modifikasi dan kombinasi RBF dengan metode lainnya dapat dilakukan untuk menyelesaikan masalah titik pusat tersebut, misalnya menggunakan data terdiskresi [6], *support vector machine* (SVM) [7], dan *self organizing map* (SOM) [8]-[13]. Modifikasi RBF dapat dilakukan dengan menggunakan keluaran dari SOM. SOM mampu memberikan solusi karena dapat memperkirakan lokasi yang tepat untuk pusat RBF di lapisan tersembunyi sehingga dapat menghasilkan kluster yang lebih baik [8], [9].

Metode SOM-RBF ini menghasilkan metode yang efisien untuk meningkatkan masa pakai node dalam [10] dalam pengelompokan dan penentuan jalur optimal pada jaringan *wireless*. SOM-RBF juga digunakan dalam memprediksi kecepatan angin [11], sistem deteksi

---

\*) Penulis korespondensi (Dwi Marisa Midyanti)  
Email: [dwi.marisa@siskom.untan.ac.id](mailto:dwi.marisa@siskom.untan.ac.id)

pembobolan jaringan [12], dan diagnosis penyakit epilepsi terotomatisasi [13]. Peningkatan akurasi metode diperoleh dari kombinasi SOM-RBF tersebut.

Penerapan algoritme SOM-RBF dilakukan untuk aplikasi prediksi, klasifikasi, dan diagnosis dalam berbagai bidang. Aplikasi klasifikasi DC berdasarkan kelas *fire weather index* (FWI) telah dilakukan dalam [14], namun klasifikasi tersebut menggunakan KNN. Secara khusus, penelitian ini bertujuan untuk mengkaji penerapan algoritme SOM-RBF untuk prediksi DC berdasarkan data curah hujan dan suhu udara di wilayah Kabupaten Kubu Raya, Kalimantan Barat. Model jaringan terbaik dianalisis berdasarkan pengaruh jumlah neuron sejumlah 5-100 neuron (kelipatan 5), parameter laju pembelajaran dari 0,001-0,01, dan pengaruh jumlah iterasi terhadap hasil pelatihan dari kombinasi SOM-RBF. Akurasi metode SOM-RBF dihitung berdasarkan data latih dan data uji yang digunakan.

## II. METODE PENELITIAN

Penelitian ini menggunakan SOM-RBF untuk memprediksi DC sebagai ukuran tingkat kekeringan. Untuk menentukan kelas DC dibutuhkan dua data, yaitu data curah hujan dan data suhu udara. DC mempunyai empat kategori kelas yaitu rendah, sedang, tinggi, dan ekstrim dengan klasifikasi seperti ditunjukkan Tabel 1. Kategori kelas DC tersebut digunakan untuk menentukan ada tidaknya pelarangan terhadap pembakaran hutan atau lahan gambut.

Data yang digunakan dalam penelitian ini adalah data curah hujan dan data suhu udara dari tanggal 2 Januari 2015 sampai 27 April 2017. Data yang digunakan sebanyak 848 data. Data yang diperoleh dibagi menjadi 2 bagian yaitu 594 data latih dan 254 data uji. Untuk memprediksi DC di hari ke empat, digunakan data curah hujan dan data suhu udara di hari pertama sampai hari ke tiga. Enam variabel data tersebut digunakan sebagai data masukan jaringan SOM-RBF.

Kombinasi SOM-RBF dimulai dengan menggunakan algoritme SOM untuk menghasilkan bobot akhir dari jaringan SOM. Tahapan metode SOM dinyatakan dalam Algoritme 1. Persamaan 1 digunakan untuk menghitung  $D(j)$ , yaitu jarak antara dua titik dengan  $w_{ij}$  merupakan bobot jaringan (Persamaan 2).

$$D(j) = \sum_i (w_{ij} - X_i)^2 \quad (1)$$

$$w_{ij}(i+1) = w_{ij}(i) + \alpha [x_i - w_{ij}(i)] \quad (2)$$


Setelah bobot akhir diperoleh, bobot tersebut menggantikan nilai *center* pada jaringan RBF. Penelitian ini menggunakan arsitektur dan persamaan RBF dalam [3]. Arsitektur RBF ditunjukkan pada Gambar 1. Persamaan 3 digunakan untuk menghitung nilai  $S_h(k)$  dimana  $\beta = \frac{1}{2\sigma^2}$  dan nilai  $v_h$  (jarak masukan) diperoleh dari Persamaan 4.

Tabel 1. Klasifikasi DC [15]

Tingkat	DC	Interpretasi
Rendah	<200	Kondisi basah, kabut asap tidak terjadi
Sedang	200 - 300	Kondisi normal, pembakaran harus dipantau
Tinggi	300 - 400	Kondisi puncak musim kering, pembakaran harus dipantau
Ekstrim	>400	Kondisi bahaya kekeringan, pembakaran sepenuhnya dilarang, berpotensi mengakibatkan kabut asap

Algoritme 1. Metode SOM [16]

- 0 : Tentukan nilai weight awal secara random, jumlah *topological neighboring parameters*. Tentukan kecepatan pembelajaran (antara 0 dan 1).
- 1 : Selama syarat menghentikan proses belajar belum terpenuhi, ulangi langkah 2 sampai 8.
- 2 : Untuk setiap masukan  $x$ , lakukan langkah 3 - 5
- 3 : Untuk setiap  $j$ , hitung  $D(j)$  (Persamaan 1)
- 4 : Temukan indeks  $j$  sehingga  $D(j)$  minimum
- 5 : Update nilai bobot pada unit  $j$  (Persamaan 2)
- 6 : Update kecepatan pembelajaran
- 7 : Kurangi radius lingkungan topologi pada waktu tertentu
- 8 : Biasanya kriteria berhenti adalah jumlah iterasi atau radius menjadi 0 atau matriks bobot berkurang menjadi nilai yang sangat diabaikan



Gambar 1. Arsitektur RBF [3]

$$S_h(k) = \varphi_h(X(k)) = e^{(-\beta v_h(k))} \quad (3)$$

$$v_h(k) = \sum_{i=1}^p (x_i(k) - c_{h,i})^2 \quad (4)$$

Untuk kombinasi SOM-RBF (Gambar 2), nilai  $c_h$  diperoleh dari nilai bobot akhir dari metode SOM. Nilai  $y_m(k)$  atau nilai keluaran pada jaringan diperoleh dari Persamaan 5. Nilai  $w_{mh}(k)$  atau bobot jaringan dapat diperoleh dengan menggunakan *Least Mean Square* (LMS) yang dihitung dengan menggunakan Persamaan

6. Error jaringan dihitung dengan *Mean Square Error* (MSE) seperti dinyatakan dalam Persamaan 7.

$$y_m(k) = \sum_{h=0}^H w_{mh}(k) e^{\left(\frac{-1}{2\sigma_h^2} |x(k) - c_h|^2\right)} \quad (5)$$

$$w_{mh}(k) = w_{mh}(k-1) + \mu e_m(k) + s_h(k) \quad (6)$$

$$MSE = \frac{1}{n} \sum_{i=1}^N (Desired - Actual)^2 \quad (7)$$

Pada penelitian ini, keluaran dari jaringan berupa bilangan biner dengan skema (Y1, Y2, Y3), yaitu sebagai berikut:

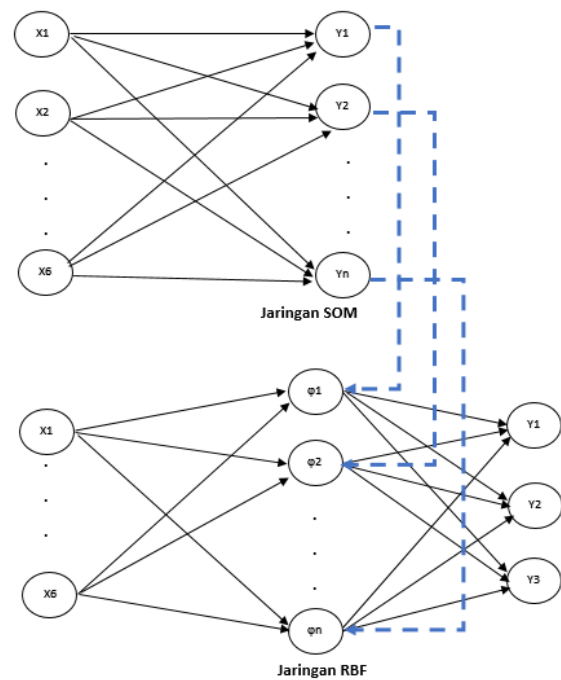
- 0 0 1: Rendah (kelas 1)
- 0 1 0: Sedang (kelas 2)
- 0 1 1: Tinggi (kelas 3)
- 1 0 0: Ekstrem (kelas 4)

### III. HASIL DAN PEMBAHASAN

Proses prediksi DC dimulai dengan memasukkan enam variabel data ke dalam jaringan SOM. Data tersebut adalah data curah hujan H-3 (x1), data suhu udara H-3 (x2), data curah hujan H-2 (x3), data suhu udara H-2 (x4), data curah hujan H-1 (x5), dan data suhu udara H-1 (x6). Penelitian ini menggunakan 100 kali iterasi pada jaringan SOM. Bobot akhir dari 100 kali iterasi tersebut digunakan sebagai *center* pada jaringan RBF.

Perubahan jumlah neuron di lapisan tersembunyi RBF diamati untuk memilih MSE terkecil dari 594 data latih. Dari 594 data latih, terdapat 497 data kelas 1, 75 data kelas 2, 15 data kelas 3 dan 7 data kelas 4. Penelitian ini membatasi jumlah neuron yang diamati, yaitu kelipatan 5 dengan maksimum neuron sebanyak 100. Laju pembelajaran yang digunakan sebesar 0,001 dengan jumlah iterasi sebesar 10000. **Tabel 2** menunjukkan hasil pelatihan SOM-RBF dengan perubahan jumlah neuron pada lapisan tersembunyi. MSE terkecil terjadi pada jumlah neuron 45 dan 65 di lapisan tersembunyi. Jumlah neuron yang dihasilkan ini selanjutnya digunakan dalam pengujian pengaruh laju pembelajaran terhadap MSE.

Pengujian pengaruh perubahan laju pembelajaran dilakukan pada neuron dengan lapisan tersembunyi 45 dan 60. Laju pembelajaran yang diamati adalah antara 0,001-0,01 dengan interval 0,001. **Tabel 3** menunjukkan hasil pelatihan SOM-RBF terhadap perubahan laju pembelajaran dengan menggunakan 45 neuron dan 65 neuron pada lapisan tersembunyi. MSE yang dihasilkan cenderung bertambah seiring naiknya laju pembelajaran dari 0,001-0,005, namun tidak mempunyai kecenderungan seperti halnya dalam [8]. Pengujian ini menghasilkan nilai MSE terkecil 0,1633 pada pelatihan dengan menggunakan 45 neuron di lapisan tersembunyi, dan diperoleh dengan menggunakan laju pembelajaran 0,001 dan 0,006. MSE terkecil diperoleh pada pelatihan dengan menggunakan



**Gambar 2.** Arsitektur jaringan SOM-RBF

**Tabel 2.** Hasil pelatihan SOM-RBF pada perubahan jumlah neuron.

Jumlah Neuron	Desired	Actual	MSE
5	594	493	0.170034
10	594	493	0.170034
15	594	483	0.186869
20	594	484	0.185185
25	594	482	0.188552
30	594	485	0.183502
35	594	478	0.195286
40	594	471	0.207071
<b>45</b>	<b>594</b>	<b>497</b>	<b>0.163300</b>
50	594	494	0.168350
55	594	482	0.188552
60	594	485	0.183502
<b>65</b>	<b>594</b>	<b>497</b>	<b>0.163300</b>
70	594	495	0.166667
75	594	494	0.168350
80	594	489	0.176768
85	594	494	0.168350
90	594	477	0.196970
95	594	451	0.240741
100	594	487	0.180135

65 neuron di lapisan tersembunyi dan laju pembelajaran sebesar 0,007, yaitu 0,161616.

Pengamatan selanjutnya adalah terhadap perubahan jumlah iterasi di jaringan RBF terhadap MSE. Laju pembelajaran yang digunakan adalah 0,007 dengan jumlah neuron pada lapisan tersembunyi sebanyak 65. Iterasi yang diamati adalah dari 10000 sampai 50000 dengan *interval* 5000. **Tabel 4** menunjukkan hasil pelatihan SOM-RBF terhadap perubahan iterasi. MSE terkecil sebesar 0,159933 diperoleh dengan laju pembelajaran 0,007 dan iterasi 45000 kali. Model

jaringan terbaik yang diperoleh adalah 6 masukan, 65 neuron di lapisan tersembunyi, dan 3 keluaran (6-65-3) dengan menggunakan laju pembelajaran sebesar 0,007 dan iterasi pada data latih sebesar 45000.

Matriks konfusi pengujian algoritme SOM-RBF menggunakan data latih ditunjukkan pada Tabel 5. Bobot akhir dari penggunaan 65 neuron pada lapisan tersembunyi dan laju pembelajaran 0,007 digunakan untuk mengetahui nilai akurasi 254 data uji. Dari 254 data uji, 239 data merupakan tingkat DC rendah dan 15 data dengan tingkat DC sedang.

Tabel 6 menunjukkan matriks konfusi pengujian algoritme SOM-RBF menggunakan data uji. Penerapan algoritme SOM-RBF menghasilkan nilai *recall* kelas 1 sebesar 97,07 % dan *recall* kelas 2 sebesar 0 %. Nilai presisi kelas 1 sebesar 93,93 % dan presisi kelas 2 sebesar 0 %. Akurasi yang dihasilkan adalah sebesar 91,34 %. Hasil tersebut menunjukkan bahwa algoritme SOM-RBF dapat mengenali kelas 1 dengan baik, namun tidak dapat mengenali kelas 2. Akurasi yang diperoleh ini lebih tinggi daripada metode RBF dalam [4] dan KNN dalam [14] dengan akurasi masing-masing 80 % dan 80,16 %.

Algoritme SOM-RBF yang digunakan menghasilkan akurasi yang tinggi dalam prediksi DC, selaras dengan hasil aplikasi SOM-RBF lain dalam [10]-[13]. Bahkan, akurasi yang diperoleh sebesar 91,34 % dalam kajian ini lebih tinggi daripada [11] yang menggunakan data uji sebanyak 418 data dengan akurasi 71,02 %. Namun, adanya kelas yang tidak dikenali menunjukkan metode tidak terlatih dengan baik untuk 594 data latih, dengan jumlah data 497 data kelas 1, 75 data kelas 2, 15 data kelas 3 dan 7 data kelas 4. Optimasi kinerja *runtime* saat pelatihan masih perlu dilakukan seperti dalam [9] sehingga dihasilkan sistem deteksi dengan akurasi dan waktu *runtime* yang optimal.

#### IV. KESIMPULAN

Metode SOM-RBF dapat diterapkan untuk memprediksi DC di Kabupaten Kubu Raya dengan menggunakan 100 iterasi pada SOM. Model jaringan terbaik yang diperoleh adalah 6 masukan, 65 neuron di lapisan tersembunyi, dan 3 keluaran dengan menggunakan laju pembelajaran sebesar 0,007, dan iterasi sebanyak 45000 pada data latih jaringan RBF dengan nilai akurasi sebesar 91,34 % dari 254 data uji.

#### DAFTAR PUSTAKA

- [1] -, "Laporan hasil pemantauan sumberdaya alam dan lingkungan serta mitigasi bencana alam berdasarkan data satelit penginderaan jauh," Lembaga Penerbangan dan Antariksa Nasional Indonesia, 2017. [Online]. Available: <http://pusfatja.lapan.go.id/index.php/publikasi>
- [2] Y. Yang, M. Uddstrom, G. Pearce, and M. Revell, "Reformulation of the drought code in the canadian fire weather index system implemented in New Zealand," *Journal of Applied Meteorology*

**Tabel 3.** Hasil pelatihan menggunakan 45 dan 65 neuron di lapisan tersembunyi

Laju Pembelajaran	MSE	
	45 Neuron	65 Neuron
<b>0,001</b>	<b>0,163300</b>	0,163300
0,002	0,164983	0,171717
0,003	0,168350	0,163300
0,004	0,171717	0,166667
0,005	0,191919	0,180135
<b>0,006</b>	<b>0,163300</b>	0,208754
0,007	0,180135	<b>0,161616</b>
0,008	0,180135	0,188552
0,009	0,170034	0,173401
0,010	0,163300	0,161616

**Tabel 4.** Hasil pelatihan SOM-RBF pada perubahan jumlah iterasi

Laju Pembelajaran	Iterasi	MSE
0.007	10000	0.161616
0.007	15000	0.164983
0.007	20000	0.161616
0.007	25000	0.163300
0.007	30000	0.170034
0.007	35000	0.244108
0.007	40000	0.161616
<b>0.007</b>	<b>45000</b>	<b>0.159933</b>
0.007	50000	0.168350

**Tabel 5.** Matriks konfusi data latih menggunakan SOM-RBF

Aktual	Pilihan				Recall (%)
	1	2	3	4	
1	497	0	0	0	100
2	71	2	0	2	2,67
3	15	0	0	0	0
4	7	0	0	0	0
<b>Precision (%)</b>	84,24	100	0	0	84,01

**Tabel 6.** Matriks konfusi data uji menggunakan SOM-RBF

Aktual	Prediksi				Recall (%)
	1	2	3	4	
1	232	0	2	5	97,07
2	15	0	0	0	0
<b>Precision (%)</b>	93,93	0	0	0	91,34

and *Climatology*, vol. 54, pp. 1523-1537, 2015. doi: [10.1175/JAMC-D-14-0090.1](https://doi.org/10.1175/JAMC-D-14-0090.1)

- [3] S. Haykin, *Neural Networks and Learning Machines, 3rd Edition*. New Jersey: Pearson Education, 2009.
- [4] R. Hidayati, D. M. Midyanti, and S. Bahri, "Klasifikasi bibit tanaman lahan gambut berdasarkan bentuk daun menggunakan metode

- radial basis function (RBF),” *Semnasteknomedia Online*, vol. 6, no. 1, pp. 12-18, 2018.
- [5] A. C. D. de Souza and M. A. C. Fernandes, “Parallel fixed point implementation of a radial basis function network in an FPGA,” *Sensors (Basel)*, vol. 14, no. 10, pp. 18223–18243, 2014. doi: [10.3390/s141018223](https://doi.org/10.3390/s141018223)
- [6] U. M. Tukur and S. M. Shamsuddin, “Radial basis function network learning with modified backpropagation algorithm,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 13, no. 2, pp. 369-378, 2015.
- [7] D. M. Alemayehu, A. D. Mengistu, and S. G. Mengistu, “Computer vision for ethiopian agricultural crop pest identification,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 3, no. 1, pp. 209-214, 2016.
- [8] A.D. Cahyani, B. K. Khotimah, and R. T. Rizkillah, “Perbandingan metode SOM (self organizing map) dengan pembobotan berbasis RBF (radial basis function),” *Jurnal Teknologi Technoscientia*, vol.7, no.1, pp. 85-92, 2014.
- [9] F. J. M. Lopez, J. A. T. Arriaza, S. M. Puertas, and M. M. P. Lopez, “Multilevel neuronal architecture to resolve classification problems with large training sets: Parallelization of the training process,” *Journal of Computational Science*, vol. 16, pp. 59-64, 2016. doi: [10.1016/j.jocs.2016.04.002](https://doi.org/10.1016/j.jocs.2016.04.002)
- [10] H. K. Hommod and T. K. Jebur, “Applying self-organizing map and modified radial based neural network for clustering and routing optimal path in wireless network,” *Journal of Physics: Conference Series*, vol. 1003, pp. 1-11, 2018. doi: [10.1088/1742-6596/1003/1/012040](https://doi.org/10.1088/1742-6596/1003/1/012040)
- [11] R. H. Julia, N. Nikentari, and N. Hayaty, “Penerapan self organizing maps (SOM) dan radial basis function (RBF) untuk memprediksi kecepatan angin di perairan kota Tanjungpinang,” *Jurnal Sustainable: Jurnal Hasil Penelitian dan Industri Terapan*, vol. 7, no. 2, pp. 102-107, 2018. doi: [10.31629/sustainable.v7i2.627](https://doi.org/10.31629/sustainable.v7i2.627)
- [12] S. Mohammadi and F. Amiri, “An efficient hybrid self-learning intrusion detection system based on neural networks,” *International Journal of Computational Intelligence and Applications*, vol. 18, no. 1, pp. 1950001, 2019. doi: [10.1142/S1469026819500019](https://doi.org/10.1142/S1469026819500019)
- [13] A. H. Osman and A. A. Alzahrani, “New approach for automated epileptic disease diagnosis using an integrated self-organization map and radial basis function neural network algorithm,” *IEEE Access*, vol. 7, pp. 4741-4747, 2018. doi: [10.1109/ACCESS.2018.2886608](https://doi.org/10.1109/ACCESS.2018.2886608)
- [14] M. R. Noviansyah, T. Rismawan, and D. M. Midyanti, “Penerapan data mining menggunakan metode k-nearest neighbor untuk klasifikasi indeks cuaca kebakaran berdasarkan data AWS (automatic weather station) (studi kasus : kabupaten Kubu Raya),” *Jurnal Coding, Sistem Komputer Untan*, vol. 6, no. 2, pp. 48-56, 2018.
- [15] E. Supartini et al., *Membangun Kesadaran, Kewaspadaan dan Kesiapsiagaan Dalam Menghadapi Bencana*. Jakarta: Badan Nasional Penanggulangan Bencana, 2017.
- [16] T. Kohonen, “Self-organized formation of topologically correct feature maps,” *Biological Cybernetics*, vol. 43, no. 1, pp. 59-69, 1982. doi: [10.1007/bf00337288](https://doi.org/10.1007/bf00337288)