



Perbandingan *Classification Advanced Methods* Dalam Klasifikasi Indeks Kekeringan di Provinsi Nusa Tenggara Timur

Kayla Azka Dhiya Tsabithah¹, Grahani Switamy Br Manik², Muhammad ‘Anil ‘Aziz³,
Robert Kurniawan⁴

^{1, 2, 3} Program Studi D-IV Statistika, Politeknik Statistika STIS

⁴ Program Studi D-IV Komputasi Statistik, Politeknik Statistika STIS

¹ 212112130@stis.ac.id

² 212112080@stis.ac.id

³ 212112204@stis.ac.id

⁴ robertk@stis.ac.id

Corresponding author email: 212112130@stis.ac.id

Abstract: East Nusa Tenggara (NTT) Province is a dry area, with only four wet months and eight dry months. This research aims to determine the level of drought at the sub-district level using the Normalized Difference Drought Index (NDDI) indicator, as well as compare the three Advanced Classification Methods, namely K-Nearest Neighbor (KNN), Support Vector Machine (SVM), and Random Forest (RF), to determine the best classification method for identifying each level of drought using various satellite-based drought indicators. The results of this research show that NTT Province is dominated by areas with mild and moderate drought levels. Areas that show signs of drought generally have low average SBI, NDWI, NDVI, and rainfall values and high average ET and air temperature. Then, the SVM classification method has an accuracy value of 91.1 percent, which is greater than the other two methods. Therefore, the SVM method is the best method for classifying drought levels based on NDDI labels in East Nusa Tenggara Province in 2023.

Keywords: Satellite Based Drought Indicators, Classification Advanced Methods, KNN, SVM, RF

Abstrak: Provinsi Nusa Tenggara Timur (NTT) termasuk wilayah kering dengan hanya empat bulan basah dan delapan bulan kering. Penelitian ini bertujuan untuk mengetahui gambaran tingkat kekeringan pada level kecamatan melalui indikator Normalized Difference Drought Index (NDDI), serta membandingkan ketiga *Classification Advanced Methods*, yakni *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), dan *Random Forest* (RF), untuk menentukan metode klasifikasi terbaik dalam mengidentifikasi setiap tingkat kekeringan dengan menggunakan berbagai indikator kekeringan berbasis satelit. Hasil dari penelitian ini menunjukkan bahwa Provinsi NTT didominasi oleh wilayah dengan tingkat kekeringan ringan dan sedang. Wilayah yang menunjukkan tanda-tanda kekeringan umumnya memiliki nilai rata-rata SBI, NDWI, NDVI, dan curah hujan yang cenderung rendah serta rata-rata ET dan suhu udara yang tinggi. Kemudian, metode klasifikasi SVM memiliki nilai akurasi sebesar 91,1 persen, lebih besar dibandingkan kedua metode lainnya. Oleh karena itu, metode SVM merupakan metode terbaik untuk melakukan klasifikasi tingkat kekeringan berdasarkan label NDDI di Provinsi Nusa Tenggara Timur pada tahun 2023.

Kata kunci: Indikator Kekeringan Berbasis Satelit, Metode Klasifikasi Lanjutan, KNN, SVM, RF

I. PENDAHULUAN

Kekeringan menurut Konvensi PBB adalah kejadian yang berlangsung saat curah hujan berada jauh dibawah tingkat normal sehingga berdampak pada produksi sumber daya di daratan akibat keadaan hidrologi yang tidak seimbang (Mishra & Singh, 2010). Kekeringan berdampak pada sumber daya air di bumi yaitu menyebabkan berkurangnya pasokan air, penurunan kualitas air, dan kegagalan hasil panen, berkurangnya produktivitas, berkurangnya pembangkitan listrik, terganggunya habitat sungai, dan terhentinya kegiatan rekreasi, serta mempengaruhi sejumlah kegiatan ekonomi dan sosial (Riebsame dkk., 1990). Kekeringan menghasilkan dampak yang kompleks dan mencakup banyak hal pada sektor masyarakat, termasuk perekonomian karena sekitar separuh populasi terestrial di bumi permukaan rentan terhadapnya. Mendekati tahun 2025, diperkirakan 2,7 milyar orang akan dihadapi dengan masalah krisis air (Dinar, 1998). Selain itu, apabila tidak segera diatasi kemungkinan 2/3 penduduk bumi segera menghadapi masalah krisis air pada 2050 (Abu-zeid, 1998).



Kekeringan dapat memberikan dampak yang buruk terhadap berbagai negara, terutama negara agraris salah satunya di Indonesia. Kekeringan di Indonesia juga diperparah dengan adanya El Nino (pemanasan air laut). Catatan jangka panjang dari tahun 1830 hingga 1953 menunjukkan bahwa 93 % kekeringan di Indonesia yang terjadi selama bertahun-tahun bersamaan dengan El Niño (Quinn dkk., 1978, dikutip dalam Surmaini dkk., 2015). Selain itu, dilaporkan bahwa 17 dari 21 kejadian kekeringan di Indonesia terjadi bersamaan dengan El Niño (D’Arrigo dkk., 2008). Berbagai provinsi di Indonesia telah terkena dampak dari kekeringan. Wilayah yang menjadi prioritas utama yang paling rentan dalam terkena kekeringan adalah Provinsi Nusa Tenggara Timur (NTT) (Kuswanto & Naufal, 2019).

Menurut Pemerintah Kabupaten Sumba Barat, Provinsi NTT adalah wilayah yang tergolong kering. Hal ini dikarenakan di Nusa Tenggara Timur hanya 4 bulan yang cenderung basah (Desember sampai April), sementara 8 bulan yang lain cenderung kering. Pada tahun 2023, Pemerintah Provinsi NTT sejak akhir April 2023 menetapkan status siaga darurat kekeringan di level provinsi. Penetapan status darurat tersebut selama enam bulan sejak 27 April 2023 hingga 27 Oktober 2023. Wakil Gubernur NTT menandatangani SK Gubernur NTT Nomor 172/Kep/HK/2023 tentang penanganan kekeringan dan kebakaran di NTT yang berstatus menjadi siaga darurat. Dalam surat tersebut bencana kekeringan itu diperkirakan provinsi NTT mengalami musim kemarau yang lebih parah dibanding biasanya. Selain itu, BMKG menyebutkan beberapa wilayah NTT selama 60 hari tidak mengalami hujan sama sekali. Hal ini menyebabkan NTT mengalami kekeringan yang lebih parah dibanding daerah-daerah lain. Oleh karena itu, kekeringan yang berkepanjangan dapat menyebabkan berbagai dampak yang lebih buruk untuk masyarakat, maka diperlukan penelitian tentang gambaran tingkat kekeringan di NTT sehingga dapat dibuat identifikasi dan pemetaan kekeringan di berbagai wilayah di NTT yang selanjutnya dapat dijadikan salah satu acuan pemerintah dan masyarakat dalam meminimalisir dampak dari bencana kekeringan.

Penelitian sebelumnya oleh Hao dkk. (2016) memperoleh hasil bahwa diperoleh distribusi teoritis indeks gabungan linier (LDI), yang dapat digunakan untuk mengklasifikasikan kekeringan dengan pendekatan persentil berdasarkan indeks curah hujan terstandar (SPI), indeks kelembaban tanah terstandar (SSI), dan indeks limpasan terstandar (SRI) menggunakan data divisi iklim dari California, Amerika Serikat. Penelitian lain oleh Gu dkk., (2007) memperoleh hasil bahwa terdapat hubungan yang kuat antara NDVI, NDWI, dan kondisi kekeringan di padang rumput di ekoregion Flint Hills di Kansas dan Oklahoma. Kemudian penelitian Patil dkk., (2024) memperoleh hasil bahwa terdapat dampak signifikan dari pola curah hujan yang berbeda terhadap tingkat keparahan kekeringan meteorologis dan mengkategorikan kondisi vegetasi ke dalam empat kelas yaitu tidak ada kekeringan, kekeringan ringan, kekeringan sedang, dan kekeringan parah dengan menggunakan NDVI, NDWI, dan NDDI. Penelitian lain oleh Kuswanto & Naufal (2019) dengan menggunakan beberapa prediktor, analisis menemukan bahwa CART memiliki prediktabilitas yang lebih rendah dibandingkan Random Forest sebagai metode klasifikasi kekeringan melalui indikator 3-month Standardized Precipitation Index di Nusa Tenggara Timur. Pada penelitian ini menggunakan level kecamatan di Nusa Tenggara Timur untuk melihat klasifikasi kekeringan melalui indikator *Normalized Difference Drought Index* (NDDI) dan membandingkan tiga metode *Classification Advanced Methods* serta menambah beberapa variabel prediktor yang lain dengan menggunakan tahun 2023, sehingga berbeda dari penelitian terdahulu. Tujuan penelitian ini untuk mengetahui gambaran tingkat kekeringan pada level kecamatan melalui indikator *Normalized Difference Drought Index* (NDDI) dan membandingkan tiga *Classification Advanced Methods*, yaitu KNN, SVM, dan RF yang digunakan untuk menentukan metode klasifikasi



terbaik dalam mengidentifikasi setiap tingkat kekeringan dengan menggunakan berbagai indikator kekeringan berbasis satelit.

II. METODE PENELITIAN

2.1. Sumber Data

Penelitian ini memanfaatkan data satelit yang bersumber dari Google Earth Engine dalam rentang waktu Januari sampai Desember 2023. Lokus penelitian adalah Provinsi Nusa Tenggara Timur dengan unit analisis yaitu 309 kecamatan yang ada di provinsi tersebut. Terdapat tujuh variabel yang dipakai yaitu *Normalized Difference Drought Index* (NDDI), *Evapotranspirasi* (ET), *Normalized Difference Vegetation Index* (NDVI), *Soil Brightness Index* (SBI), *Normalized Difference Water Index* (NDWI), Curah Hujan (CH), dan suhu. Data NDDI, NDVI, NDWI, SBI diperoleh dari citra satelit Landsat 8. Sementara itu, data curah hujan diambil dari satelit CHIRPS. Sedangkan, data evapotranspirasi dan suhu rata-rata diambil dari citra MODIS.

2.2. Metode Klasifikasi

Penelitian ini akan membandingkan tiga dari *classification advanced methods* yaitu *K-Nearest Neighbor* (K-NN), *Support Vector Machine* (SVM), dan *Random Forest* (RF). Ketiga metode ini termasuk metode yang *advanced* karena memiliki penghitungan yang kompleks dengan memperhitungkan faktor ketetanggaan pada K-NN, memperhitungkan *hyperplane* pada SVM, dan memperhitungkan kombinasi *decision tree* pada RF. Pada pengklasifikasian ini data akan dipecah menjadi dua kelompok, yaitu data latih dan data uji. Pemilihan metode terbaik dengan melihat nilai dari akurasi, presisi, recall, dan skor F1 (Shah dkk, 2020). Akurasi, presisi, dan recall dihitung melalui nilai dari *True Negative* (TN), *True Positive* (TP), *False Negative* (FN), *False Positive* (FP). KNN, SVM, dan RF termasuk *supervised learning* karena pemberian nama label pada kelas sudah diketahui. Pada penelitian ini variabel NDDI sebagai dasar dari pemberian nama label kelas. Pengkategorian NDDI seperti pada tabel 1 yang mengacu pada jurnal *Elsevier* terkait eksplorasi dan pengembangan NDDI oleh Patil dkk pada tahun 2024.

Tabel 1. Kategori NDDI

NDDI	Kategori	Label
-1 - 0,2	Tidak Kering	1
0,2 - 0,3	Kekeringan Ringan	2
0,3 - 0,4	Kekeringan Sedang	3
0,4 - 0,5	Kekeringan Berat	4
0,5 - 1	Kekeringan Ekstrem	5
> 1	Tidak Terklasifikasi	6

2.2.1. K-NN

KNN adalah metode pengklasifikasian objek amatan yang didasarkan pada mayoritas kelas dari sejumlah tetangga terdekatnya sebanyak k (Kramer, 2013). Nilai k ditentukan sendiri oleh peneliti. Cross validation dapat digunakan untuk menentukan nilai k yang optimal. Tetangga terdekat ditentukan berdasarkan perhitungan jarak. Ada berbagai cara yang dapat digunakan untuk menghitung jarak diantaranya Euclidean, Manhattan, dan Minkowski. Namun, yang paling sering digunakan yaitu Euclidean. Perhitungan jarak *Euclidean* (1), *Manhattan* (2), dan *Minkowski* (3) dirumuskan sebagai berikut.



$$\sqrt{\sum_{i=1}^k x_i - x_j} \quad (1)$$

$$\sum_{i=1}^k |x_i - x_j| \quad (2)$$

$$\left(\sum_{i=1}^k (|x_i - x_j|^p) \right)^{1/p} \quad (3)$$

Keterangan :

x_i : data uji

x_j : data latih

p : parameter kontrol

Cara kerja pada pengklasifikasian metode KNN dapat dituliskan sebagai berikut :

1. Menentukan nilai dari k
2. Melakukan penghitungan jarak dari data latih dan data uji
3. Mengurutkan hasil penghitungan jarak
4. Memilih jarak yang paling dekat sampai urutan k
5. Menentukan kelas yang bersesuaian sebagai hasil klasifikasi

2.2.2. SVM

SVM merupakan metode yang *powerful* untuk klasifikasi (Gold & Sollich, 2003). SVM adalah bagian dari metode *machine learning* yang mengklasifikasikan data menggunakan fungsi pemisah atau *hyperplane*. Konsep utama SVM adalah untuk mencari dan mendapatkan *hyperplane* yang bisa memberikan margin maksimum agar dapat memberikan kapabilitas generalisasi terbaik. Margin merupakan jarak antara *hyperplane* dengan data terdekat. *Hyperplane* terbaik adalah *hyperplane* yang letaknya di tengah-tengah di antara dua bidang pembatas. *Hyperplane* dapat dirumuskan sebagai berikut.

$$w \cdot x + b = 0 \quad (4)$$

Keterangan :

w = vektor bobot

x = vektor data training

b = nilai bias

Cara kerja pada pengklasifikasian metode SVM dapat diuraikan sebagai berikut :

1. Data akan dipetakan pada ruang fitur berdimensi tinggi sehingga terbentuk titik-titik data yang dapat dikategorikan
2. Terbentuk pemisah data atau *hyperplane*
3. Hasil prediksi terbentuk berdasarkan *hyperplane* yang memiliki nilai margin maksimum

2.2.3 Random Forest

Random forest adalah bagian dari metode *machine learning* yang populer digunakan untuk pengklasifikasian. Metode ini merupakan penggabungan dari beberapa pohon keputusan atau *decision tree* sehingga termasuk *ensemble learning*. Setiap *decision tree* bergantung pada nilai-nilai vektor acak yang identik dan independen. Hasil dari setiap *decision tree* akan digabung untuk mendapatkan hasil



prediksi berdasarkan suara terbanyak. Random forest kerap memberikan nilai akurasi yang lebih tinggi dibandingkan *single decision tree* (Speiser, 2019). Proses *random forest* adalah sebagai berikut.

1. Membangun pohon prediksi melalui *decision tree* dengan *sampling bootstrap* yaitu pengambilan sampel acak secara berulang dengan penggantian
2. Setiap *decision tree* melakukan prediksi dengan prediktor acak
3. Masing-masing *decision tree* memiliki hasil prediksi
4. Hasil prediksi *decision tree* akan digabung atau dikombinasikan berdasarkan suara terbanyak atau *majority vote* sebagai hasil akhir dari prediksi

2.2.4. Akurasi

Akurasi adalah rasio dari pengamatan yang dapat diprediksi dengan benar terhadap total pengamatan yang dapat dituliskan dalam rumus berikut.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

2.2.5. Presisi

Presisi adalah rasio dari pengamatan yang diprediksi positif dengan benar terhadap total pengamatan yang diprediksi positif. Rumus perhitungan presisi sebagai berikut.

$$Presisi = \frac{TP}{TP + FP} \quad (6)$$

2.2.6. Recall

Recall merupakan rasio dari pengamatan yang diprediksi positif dengan benar terhadap total jumlah instance positif yang sebenarnya. Rumus recall adalah sebagai berikut.

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

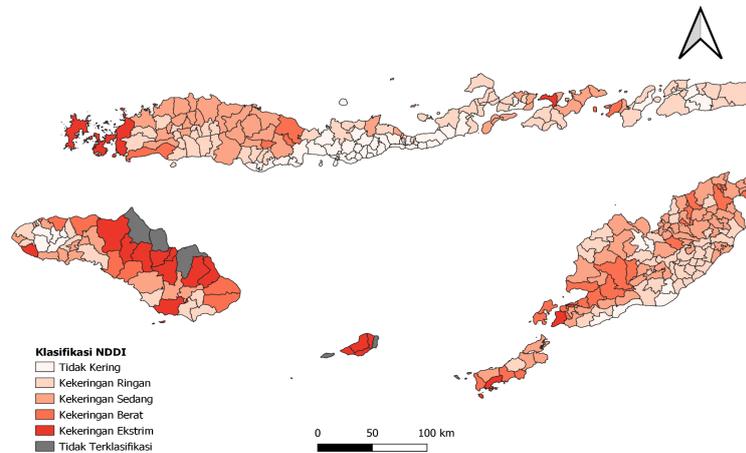
2.2.7. Skor F1

Skor F1 adalah rata-rata harmonik dari recall dan presisi yang dirumuskan sebagai berikut.

$$Skor F1 = \frac{2 * recall * precision}{recall + precision} \quad (8)$$

III. HASIL DAN PEMBAHASAN

Provinsi Nusa Tenggara Timur sebagian besar adalah wilayah yang tergolong dalam wilayah kering. Gambar 1 memberikan informasi persebaran kategori kekeringan di provinsi tersebut. Secara umum, sebagian besar kecamatan di NTT tergolong sebagai wilayah dengan tingkat kekeringan ringan dan sedang. Sementara itu, kekeringan berat dan kekeringan ekstrim banyak terjadi di daerah pinggir pulau. Wilayah dengan tingkat kekeringan ekstrim cukup banyak terlihat berada di bagian tenggara Provinsi NTT, khususnya Pulau Sumba.



Gambar 1. Peta Klasifikasi Kekeringan di Provinsi Nusa Tenggara Timur, 2023

Berdasarkan dataset yang digunakan, wilayah kering dapat diidentifikasi melalui beberapa parameter lingkungan. Secara khusus, wilayah yang menunjukkan tanda-tanda kekeringan umumnya memiliki nilai rata-rata SBI, NDWI, NDVI, dan curah hujan yang cenderung rendah serta rata-rata ET dan suhu udara yang tinggi. Oleh karena itu, berbagai parameter tersebut dapat dimanfaatkan sebagai variabel-variabel prediktor dalam membentuk model klasifikasi untuk mengidentifikasi dan memetakan tingkat kekeringan di berbagai wilayah. Tabel 2 memberikan informasi nilai rata-rata SBI, NDWI, NDVI, ET, Suhu, dan Curah Hujan untuk masing-masing kategori tingkat kekeringan.

Tabel 2. Nilai Rata-rata Variabel Prediktor

Label NDDI	SBI	NDWI	NDVI	ET	Suhu	CH
1	37.745,64	0,17	0,21	29,32	27,27	1.527,46
2	34.916,82	0,15	0,24	30,61	28,34	1.600,05
3	33.803,48	0,12	0,24	31,47	30,04	1.575,65
4	34.049,13	0,09	0,21	29,67	31,81	1.368,20
5	33.808,85	0,07	0,21	28,78	31,91	1.273,69
6	34.171,61	0,01	0,20	24,11	32,81	972,26

Selanjutnya, model klasifikasi dijalankan menggunakan *Classification Advanced Methods*, yakni KNN, SVM, dan RF. Tabel 3 memberikan informasi nilai akurasi untuk setiap metode klasifikasi yang digunakan dalam penelitian ini. Metode SVM menghasilkan akurasi terbesar, yakni 0,911. Artinya, sebesar 91,1 persen dataset mampu diklasifikasikan secara benar. Sementara itu, metode K-NN dengan nilai k optimum sebesar 5 menghasilkan akurasi terendah, yakni hanya sebesar 0,433.

Temuan ini sama halnya dengan hasil penelitian Sabri, dkk (2022) yang menyatakan bahwa metode klasifikasi SVM memiliki performa terbaik, kemudian diikuti oleh metode RF dan KNN. Selain itu, penelitian Murugan, dkk (2019) mengenai klasifikasi lesi kulit juga memiliki kesimpulan bahwa metode SVM memberikan akurasi tertinggi dibandingkan dengan metode RF dan KNN. Ditambah lagi, penelitian Noi dan



Kappas (2017) juga menunjukkan bahwa, melalui dataset satu sampai tujuh, metode SVM selalu memberikan hasil yang paling akurat, kemudian diikuti oleh metode RF, serta metode KNN di urutan ketiga.

Tabel 3. Perbandingan Akurasi Masing-masing Metode Klasifikasi

No	Metode	Akurasi
1	K-NN	0,433
2	SVM	0,911
3	RF	0,8

Tidak hanya akurasi, kebaikan metode klasifikasi juga dapat dilihat berdasarkan nilai presisi, *recall*, dan skor F1. Ketiga indikator tersebut diukur untuk setiap kategori indeks kekeringan. Perbandingan nilai presisi antar metode pada setiap kategori label ditampilkan melalui Tabel 4.

Tabel 4. Perbandingan Presisi, *Recall*, dan Skor F1 Masing-masing Metode Klasifikasi

Kategori	Presisi			<i>Recall</i>			Skor F1		
	K-NN	SVM	RF	K-NN	SVM	RF	K-NN	SVM	RF
1	0,692	1,000	1,000	0,529	0,882	0,706	0,600	0,938	0,828
2	0,429	0,897	0,714	0,429	0,929	0,893	0,429	0,912	0,794
3	0,425	0,933	0,828	0,586	0,966	0,828	0,493	0,949	0,828
4	0,000	0,800	0,750	0,000	0,889	0,667	NaN	0,842	0,706
5	0,000	0,800	0,800	0,000	0,667	0,667	NaN	0,727	0,727
6	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000

Secara umum, metode SVM memiliki nilai presisi, *recall*, dan skor F1 yang lebih besar dibandingkan dengan metode KNN dan RF. Namun, untuk kategori enam, ketiga metode mampu mengklasifikasikan data secara tepat. Di sisi lain, metode KNN sama sekali tidak mampu mengklasifikasikan data secara tepat untuk kategori empat dan lima. Sementara itu, metode KNN selalu memiliki nilai presisi, *recall*, dan skor F1 yang cenderung rendah untuk setiap kategori dibandingkan dengan kedua metode lainnya.

Ukuran-ukuran kebaikan di atas menunjukkan bahwa metode SVM merupakan metode terbaik untuk melakukan klasifikasi kekeringan berdasarkan label NDDI di Provinsi Nusa Tenggara Timur pada tahun 2023. SVM adalah metode *machine learning* yang *powerful* dalam klasifikasi (Gold & Sollich, 2003). Hasil klasifikasi metode SVM ditampilkan pada Tabel 5.

Tabel 5. Tabel Klasifikasi dari Metode SVM

Prediksi	Data Asli					
	1	2	3	4	5	6
1	15	0	0	0	0	0
2	2	26	1	0	0	0
3	0	2	28	0	0	0



Prediksi	Data Asli					
	1	2	3	4	5	6
4	0	0	0	8	2	0
5	0	0	0	1	4	0
6	0	0	0	0	0	1

Dalam penelitian ini, model klasifikasi dibentuk untuk mengidentifikasi karakteristik wilayah berdasarkan tingkat kekeringan yang diamati melalui indikator berbasis satelit. Dengan demikian, kondisi keparahan bencana kekeringan dapat dipantau secara berkelanjutan. Pemerintah ataupun pengambil kebijakan lainnya dapat merancang program penanggulangan bencana kekeringan sampai satuan wilayah terkecil dengan membentuk skala prioritas berdasarkan klasifikasi tingkat kekeringan. Hal ini menjadi penting karena Provinsi NTT mengalami musim kemarau yang lebih parah dibanding biasanya, sehingga provinsi ini diperkirakan akan mengalami bencana kekeringan.

IV. KESIMPULAN

Sebagian besar kecamatan di Provinsi Nusa Tenggara Timur tergolong sebagai wilayah kering. Hal ini dikarenakan, dalam satu tahun, wilayah-wilayah di NTT hanya memiliki durasi empat bulan basah, sedangkan delapan bulan sisanya kering. Tingkat kekeringan di wilayah ini dikategorikan berdasarkan indikator NDDI (*Normalized Difference Drought Index*), sehingga tingkat kekeringan terdiri atas lima kategori, yakni tidak kering, kekeringan ringan, kekeringan sedang, kekeringan berat, dan kekeringan ekstrem. Provinsi NTT didominasi oleh kecamatan-kecamatan dengan tingkat kekeringan ringan dan sedang. Wilayah yang menunjukkan tanda-tanda kekeringan umumnya memiliki nilai rata-rata SBI, NDWI, NDVI, dan curah hujan yang cenderung rendah serta rata-rata ET dan suhu udara yang tinggi. Kemudian, hasil proses klasifikasi menunjukkan bahwa metode SVM merupakan metode terbaik untuk melakukan klasifikasi kekeringan berdasarkan label NDDI di Provinsi Nusa Tenggara Timur pada tahun 2023.

REFERENSI

1. A. Dinar, "Water policy reforms: Information needs and implementation obstacles," *Water Policy*, vol. 1, no. 4, pp. 367-382, 1998. [Online]. Available: [https://doi.org/10.1016/S1366-7017\(99\)00005-7](https://doi.org/10.1016/S1366-7017(99)00005-7)
2. A. K. Mishra and V. P. Singh, "A review of drought concepts," *Journal of Hydrology*, vol. 391, no. 1-2, pp. 202-216, 2010. [Online]. Available: <https://doi.org/10.1016/j.jhydrol.2010.07.012>
3. A. Murugan, S. A. H. Nair, and K. S. Kumar, "Detection of skin cancer using SVM, random forest and kNN classifiers," *Journal of Medical Systems*, vol. 43, no. 8, p. 269, 2019.
4. C. Gold and P. Sollich, "Model selection for support vector machine classification," **Neurocomputing**, vol. 55, no. 1-2, pp. 221-249, 2003.
5. J. L. Speiser, M. E. Miller, J. Tooze, and E. Ip, "A comparison of random forest variable selection methods for classification prediction modeling," *Expert Systems with Applications*, vol. 134, pp. 93-101, 2019.
6. J. R. .E. Harger, "Air-Temperature..Variations..and ENSO..Effects in Indonesia, The..Philippines..and El Salvador. ENSO..Patterns and..Changes from 1866-1993," *Atmospheric..Environment*, vol. 29, no. 16, p. 1976, 1995.



7. Kuswanto, H., & Naufal, A. (2019). Evaluation of performance of drought prediction in Indonesia based on TRMM and MERRA-2 using machine learning methods. *MethodsX*, 6(March), 1238–1251. <https://doi.org/10.1016/j.mex.2019.05.029>
8. Le Comte, D. (1994). "Highlights Around the World," *Weatherwise*, vol. 47, no. 1, pp. 23-26, 1994. [Online]. Available: <https://doi.org/10.1080/00431672.1994.9925303>
9. M. A. Abu-zeid, "Water and sustainable development: the vision for world water, life and the environment," *Water Policy*, vol. 1, pp. 9-19, 1998.
10. O. Kramer and O. Kramer, "K-nearest neighbors," **Dimensionality reduction with unsupervised nearest neighbors**, pp. 13-23, 2013.
11. P. P. Patil, M. P. Jagtap, N. Khatri, H. Madan, A. A. Vadduri, and T. Patodia, "Exploration and advancement of NDDI leveraging NDVI and NDWI in Indian semi-arid regions: A remote sensing-based study," **Case Studies in Chemical and Environmental Engineering**, vol. 9, p. 100573, 2024.
12. P. Thanh Noi and M. Kappas, "Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery," *Sensors*, vol. 18, no. 1, p. 18, 2017.
13. R. D'Arrigo, R. Allan, R. Wilson, J. Palmer, J. Sakulich, J. E. Smerdon, S. Bijaksana, and L. O. Ngkoimani, "The impact of the positive Indian Ocean dipole on Zimbabwe droughts Tropical climate is understood to be dominated by," *International Journal of Climatology*, vol. 2029, pp. 2011-2029, Mar. 2008. [Online]. Available: <https://doi.org/10.1002/joc>
14. R. D'Arrigo, R. Wilson, J. Palmer, P. Krusic, A. Curtis, J. Sakulich, S. Bijaksana, S. Zulaikah, and L. O. Ngkoimani, "Monsoon drought over Java, Indonesia, during the past two centuries," *Geophysical Research Letters*, vol. 33, no. 4, pp. 4-7, 2006. [Online]. Available: <https://doi.org/10.1029/2005GL025465>
15. Riebsame, W. E., Changnon, S. A., & Karl, T. R. (1990). "Drought and Natural Resources Management in the United States: Impacts and Implications of 1987-89 Drought," *Bulletin of the Russian Federal Service for Supervision of Consumer Rights Protection and Human Well-Being*, vol. 4, no. 1.
16. Shah, K., Patel, H., Sanghvi, D., and Shah, M., "A comparative analysis of logistic regression, random forest and KNN models for the text classification," *Augmented Human Research*, vol. 5, no. 1, p. 12, 2020.
17. Surmaini, E., Hadi, T. W., Subagyo, K., & Puspito, N. T. (2015). Early detection of drought impact on rice paddies in Indonesia by means of Niño 3.4 index. *Theoretical and Applied Climatology*, 121(3–4), 669–684. <https://doi.org/10.1007/s00704-014-1258-0>
18. T. Sabri, O. El Beggar, and M. Kissi, "Comparative study of Arabic text classification using feature vectorization methods," *Procedia Computer Science*, vol. 198, pp. 269-275, 2022.
19. Y. Gu, J. F. Brown, J. P. Verdin, and B. Wardlow, "A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States," **Geophysical Research Letters**, vol. 34, no. 6, 2007.
20. Z. Hao, F. Hao, V. P. Singh, Y. Xia, W. Ouyang, and X. Shen, "A theoretical drought classification method for the multivariate drought index based on distribution properties of standardized drought indices," *Advances in Water Resources*, vol. 92, pp. 240-247, 2016. [Online]. Available: <https://doi.org/10.1016/j.advwatres.2016.04.010>