

Prediksi Kerentanan Kekeringan Perkotaan Menggunakan Machine Learning: Pendekatan untuk Perencanaan Kota Tangguh di Kota Kupang

Eglantyne Lidya Subnafeul^{1*}, Mohammad Reza², Ardiyanto Maksimilianus Gai³, Firman Afrianto⁴

¹²³ Program Studi Perencanaan Wilayah dan Kota, Institut Teknologi Nasional Malang, Jl. Sigura-gura, Kelurahan Sumber Sari, Kecamatan Lowokwaru, Kota Malang, Indonesia, 65145

⁴ Ikatan Ahli Perencanaan Jawa Timur, Perumahan Griya Shanta, J 295, Kelurahan Mojolangu, Kecamatan Lowokwaru, Kota Malang, Indonesia 65142

e-mail: ¹*2224026@scholar.itn.ac.id, ²rz.abang@gmail.com, ³ardy_06pl@yahoo.co.id,

⁴firmanafrianto@mail.ugm.ac.id

*Corresponding author

Submitted Date: Maret 15, 2024

Revised Date: April 14, 2025

Reviewed Date: Maret 30, 2024

Accepted Date: April 30, 2025

Abstract

The city of Kupang in East Nusa Tenggara faces increasingly serious drought challenges due to climate change and rapid urbanization, prompting the need for this study to predict drought vulnerability in the region. This study aims to develop a drought vulnerability prediction model using a machine learning approach that combines Normalized Difference Drought Index (NDDI) data, built-up areas, and population data in the last five (5) years. The methods used include NDDI calculations from satellite imagery, a zonal statistical analysis, and drought vulnerability simulations using models such as Random Forest, Support Vector Machine, and Artificial Neural Network. The results show that the Random Forest model provides the best prediction with the highest R Squared value, and indicates an increased risk of drought in several villages in 2030 and 2040, especially in areas with rapid population growth and expansion of built-up areas. The conclusion of this study confirms that the developed approach is able to provide a more accurate picture of drought-prone areas, so that it can be an important guide in more resilient and sustainable urban planning, and recommends strengthening water management and spatial planning policies with early intervention in the most vulnerable areas.

Keywords: NDDI; Drought Vulnerability; Machine Learning; Resilient City.

Abstrak

Kota Kupang di Nusa Tenggara Timur menghadapi tantangan kekeringan yang semakin serius akibat perubahan iklim dan urbanisasi yang pesat, mendorong perlunya penelitian ini untuk memprediksi kerentanan kekeringan di wilayah ini. Penelitian ini bertujuan untuk mengembangkan model prediksi kerentanan kekeringan dengan menggunakan pendekatan machine learning yang menggabungkan data *Normalized Difference Drought Index* (NDDI), area terbangun, dan data populasi penduduk dalam lima (5) tahun terakhir. Metode yang digunakan meliputi perhitungan NDDI dari citra satelit, analisis zonal statistics, serta simulasi kerentanan kekeringan menggunakan model seperti *Random Forest*, *Support Vector Machine*, dan *Artificial Neural Network*. Hasilnya menunjukkan bahwa model *Random Forest* memberikan prediksi terbaik dengan nilai *R Squared* tertinggi, serta mengindikasikan peningkatan risiko kekeringan di beberapa kelurahan pada tahun 2030 dan 2040, terutama di daerah dengan pertumbuhan populasi dan perluasan area terbangun yang pesat. Kesimpulan penelitian ini menegaskan bahwa pendekatan yang dikembangkan mampu memberikan gambaran yang lebih akurat tentang wilayah yang rentan terhadap kekeringan, sehingga dapat menjadi panduan penting dalam perencanaan kota yang lebih



tangguh dan berkelanjutan, serta merekomendasikan penguatan kebijakan pengelolaan air dan tata ruang dengan intervensi dini di wilayah yang paling rentan.

Kata Kunci: NDDI; Kerentanan Kekeringan; Machine Learning; Kota Tangguh

1. Pendahuluan

Kerentanan kekeringan perkotaan (*Urban Drought Vulnerability/UDV*) merupakan isu kritis yang mempengaruhi pembangunan berkelanjutan di kota-kota di seluruh dunia. Dampaknya tidak hanya dirasakan pada ketersediaan air, tetapi juga pada berbagai aspek kehidupan yang berkaitan dengan tujuan Pembangunan Berkelanjutan. Kota-kota kini menghadapi berbagai jenis kekeringan, termasuk kekeringan air tanah, kelembaban tanah, air terbuka, dan pasokan air. Setiap jenis kekeringan ini membawa dampak unik dan memerlukan pendekatan terintegrasi untuk penanganannya (Machairas & Ven, 2023).

Urbanisasi memperburuk situasi ini dengan menaikkan suhu permukaan dan mengubah pola curah hujan, menjadikannya tantangan besar dalam perencanaan kota yang berkelanjutan (Marelle, et al., 2020). Kekeringan berdampak pada sumber daya air, degradasi lahan, dan kesehatan masyarakat, dengan perubahan iklim memperburuk frekuensi dan keparahan kekeringan, mempengaruhi keamanan air, sanitasi, pangan, dan kualitas lingkungan (Sena & Ebi, 2020).

Kota Kupang, sebagai salah satu kota besar di Nusa Tenggara Timur, menghadapi tantangan kekeringan yang semakin serius akibat urbanisasi yang cepat dan perubahan iklim yang berdampak pada pola curah hujan dan suhu permukaan. Kota ini terletak di wilayah dengan iklim yang cukup kering, dengan rata-rata curah hujan tahunan sekitar 1.250 mm per tahun (Krisnayanti, Bunganaen, Frans, Seran, & Legono, 2021). Kota Kupang termasuk dalam kategori wilayah yang mengalami kekeringan ekstrem, disebabkan oleh periode hari tanpa hujan yang sangat panjang. Durasi hari tanpa hujan yang berkepanjangan di Kota Kupang secara signifikan meningkatkan potensi terjadinya kekeringan di wilayah tersebut (Krisnayanti, Bunganaen, Frans, Seran, & Legono, 2021). Kekeringan di wilayah kota Kupang juga telah mengakibatkan gagal panen, kerusakan lahan pertanian, penurunan debit air, serta penurunan kualitas air baku yang ditandai dengan bau lumpur (Koroh, Hidayati, & Widodo, 2017). Kondisi ini menjadikan Kota Kupang dan sekitarnya sangat rentan terhadap masalah kekeringan, yang semakin

diperparah oleh peningkatan kebutuhan air seiring dengan pertumbuhan populasi dan tekanan pada lahan terbangun.

Dengan meningkatnya kebutuhan air untuk populasi yang terus berkembang serta tekanan yang semakin besar pada lahan terbangun, diperlukan pendekatan inovatif untuk memprediksi dan mengelola kerentanan kekeringan. Teknologi machine learning telah muncul sebagai salah satu solusi efektif dalam menghadapi tantangan ini. Algoritma *machine learning* seperti *Random Forest* (RF), *Support Vector Machine* (SVM), dan *Artificial Neural Network* (ANN) telah terbukti mampu menganalisis data kompleks dan memberikan prediksi yang lebih akurat dibandingkan metode konvensional (Zha, et al., 2020). *Machine learning* telah terbukti sangat efektif dalam memprediksi kekeringan karena kemampuannya mengolah berbagai jenis data yang kompleks, seperti informasi atmosfer, tanah, dan citra satelit. Model seperti *neural networks*, *decision trees*, dan *support vector machines* telah menghasilkan prediksi yang akurat tentang kondisi kekeringan (Sundararajan, et al., 2021). Teknologi ini tidak hanya memungkinkan prediksi yang lebih tepat waktu, tetapi juga dapat diandalkan dalam mengidentifikasi zona-zona yang paling rentan terhadap kekeringan, sebuah aspek yang sangat penting dalam perencanaan kota tangguh.

Dalam penelitian ini, peneliti memanfaatkan data satelit dan algoritma *machine learning* untuk memprediksi kerentanan kekeringan di Kota Kupang, dengan menggunakan *Normalized Difference Drought Index* (NDDI) untuk mengidentifikasi indeks kekeringan (Affandy & Iranata, 202), serta data populasi dan area terbangun sebagai variabel kunci. NDDI, yang menggabungkan parameter vegetasi hijau (NDVI) dan kelembaban vegetasi (NDWI), menawarkan pendekatan yang lebih komprehensif dalam memetakan kerentanan kekeringan di wilayah perkotaan.

Penggunaan *machine learning* dalam penelitian ini didukung oleh kemampuannya untuk menangani data spasial yang besar dan kompleks serta memberikan prediksi yang relevan dan tepat waktu bagi pengambil kebijakan. Dengan



mengintegrasikan NDDI, penelitian ini berupaya mengembangkan model yang dapat mengidentifikasi zona rentan kekeringan dengan akurasi tinggi, memberikan alat bantu yang esensial bagi perencanaan kota dalam mengembangkan strategi adaptasi yang lebih baik dan efektif.

Sejalan dengan tantangan global yang dihadapi kota-kota di wilayah tropis dan semi-arid, penelitian ini bertujuan untuk menghasilkan model prediktif yang tidak hanya relevan bagi Kota Kupang, tetapi juga dapat diaplikasikan di wilayah lain dengan karakteristik serupa. Contoh wilayah lain yang mungkin bisa menerapkan model ini adalah kota-kota di kawasan Nusa Tenggara, yang memiliki karakteristik iklim dan tantangan urbanisasi yang serupa. Model ini diharapkan dapat menjadi alat bantu yang sangat penting bagi perencanaan kota dalam mengembangkan strategi adaptasi yang lebih efektif, guna meningkatkan ketahanan kota terhadap kekeringan.

Selain itu, penelitian ini diharapkan dapat memberikan wawasan yang lebih mendalam bagi pembuat kebijakan dalam merancang kebijakan mitigasi kekeringan yang lebih terukur dan berbasis bukti, sehingga mampu mengurangi dampak negatif yang ditimbulkan oleh kekeringan terhadap sumber daya air, lahan, dan kesejahteraan masyarakat. Dengan demikian, penelitian ini tidak hanya berkontribusi pada literatur ilmiah mengenai mitigasi kekeringan, tetapi juga pada upaya praktis dalam perencanaan kota yang lebih tangguh dan berkelanjutan.

A. Bahan dan Metode Penelitian

Penelitian ini berlokasi di Kota Kupang, Provinsi Nusa Tenggara Timur. Wilayah Kota Kupang memiliki letak geografis 10°36'14"-10°39'58" LS dan 123°32'23" - 123°37'01"BT; Batas Wilayah Utara berbatasan dengan Teluk Kupang, Timur berbatasan dengan Kab. Kupang, Barat berbatasan dengan Selat Semau dan Kab. Kupang, sedangkan Selatan berbatasan dengan Kabupaten Kupang. Lokasi Penelitian dapat dilihat pada Gambar 1.

B. Data

Penelitian ini memanfaatkan data yang diperoleh dari berbagai sumber. Rincian data yang digunakan dalam penelitian ini disajikan dalam Tabel 1.

Tabel 1. Spesifikasi dan Sumber Data

No	Data	Sumber
1	Populasi Penduduk Menurut Kelurahan di Kota Kupang Tahun 2019-2023	Badan Pusat Statistik Kota Kupang
2	Data Area Terbangun di Kota Kupang Tahun 2019-2023	Website <i>Impactobservatory.com</i> via <i>EO Browser</i>
3	Data Raster NDVI 2019-2023 Skala 1: 25.000	Website <i>ClimateEngine.org</i>
4	Data Raster NDWI 2019-2023 Skala 1: 25.000	Website <i>ClimateEngine.org</i>

2. Metode Penelitian

A. Normalized Difference Drought Index

Normalized Difference Drought Index (NDDI) adalah alat yang digunakan untuk mengukur tingkat kekeringan disuatu daerah dengan menggabungkan dua indeks utama yaitu, *Normalized Difference Vegetation Index* (NDVI) dan *Normalized Difference Water Index* (NDWI) (Rahman, Sukmono, & Yuwono, 2017). NDVI memberikan gambaran tentang seberapa sehat dan hijau vegetasi diarea tersebut, sementara NDWI menunjukkan seberapa lembab tanahnya. Dengan menggabungkan kedua indeks ini, kita dapat lebih baik memahami seberapa banyak air yang tersedia di tanah dan kondisi kesehatan vegetasi di wilayah tersebut.

NDVI menggambarkan tingkat kehijauan vegetasi dan dihitung dengan rumus:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

dimana *NIR* adalah pantulan cahaya inframerah dekat dan *Red* adalah pantulan cahaya merah.

NDWI menunjukkan kandungan air atau kelembaban pada vegetasi, dihitung dengan rumus:

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (2)$$

dimana *Green* adalah pantulan cahaya hijau.

NDDI kemudian diperoleh dengan menggabungkan NDVI dan NDWI menggunakan formula :

$$NDDI = \frac{NDVI - NDWI}{NDVI + NDWI} \quad (3)$$

Rumus ini menggabungkan indeks vegetasi (NDVI) dan indeks air (NDWI) untuk memetakan tingkat kekeringan. Nilai NDDI yang semakin tinggi menunjukkan tingkat kekeringan yang lebih parah karena menandakan vegetasi mengalami stres akibat kekurangan air.



Klasifikasi Tingkat Kekeringan Lahan menurut Renza dkk (2010) dapat dilihat melalui tabel 2.

Tabel 2. Klasifikasi Tingkat Kekeringan

Nilai NDDI	Tingkat Kekeringan
-0,05 – 0,01	Normal
0,01 – 0,15	Kekeringan Ringan
0,15 – 0,25	Kekeringan Sedang
0,25 – 1	Kekeringan Berat
> 1	Kekeringan Sangat Berat

B. Zonal Statistics

Salah satu operasi umum yang menggabungkan data raster dan vektor berskala besar adalah *zonal statistics*, yang bertugas menghitung berbagai statistik untuk setiap poligon dalam dataset vektor (Singla & Eldawy, 2020). *Zonal Statistics* merupakan salah satu teknik dalam analisis data raster maupun vector berskala besar, terutama dibidang penginderaan jauh. Penelitian terbaru telah mengembangkan algoritma yang lebih efisien untuk mengolah dataset besar. Singla dan Eldawy (2020) memperkenalkan *Zonal Statistics*, sebuah metode terdistribusi yang mampu memproses data dalam skala petabyte tanpa memerlukan prapemrosesan atau pengindeksan, sehingga cocok untuk kueri ad-hoc. Pendekatan ini menunjukkan peningkatan kinerja yang signifikan dibandingkan sistem yang ada.

Haag et al. (2020) memperkenalkan algoritma *Fast Zonal Statistics* (FZS), yang menawarkan kompleksitas komputasi konstan berdasarkan panjang perimeter poligon, sehingga meningkatkan efisiensi waktu eksekusi pada analisis poligon sederhana. Kemajuan dalam algoritma *zonal statistics* ini memungkinkan pemrosesan data geospasial berskala besar dengan lebih efisien, memberikan manfaat signifikan dalam bidang pemantauan lingkungan dan perencanaan kota.

Dalam analisis ini, metode *zonal statistics* digunakan untuk menghitung rata-rata nilai NDDI (*Normalized Difference Drought Index*) dan luas area terbangun di setiap kelurahan. *Zonal statistics* memungkinkan perhitungan rata-rata dari data raster (seperti NDDI dan area terbangun) untuk setiap zona, yang dalam konteks ini adalah berupa data *vector* batas kelurahan. Selain itu, data populasi juga dianalisis untuk menghitung rata-rata populasi per kelurahan selama periode 2019-2023. Penambahan data populasi ini memberikan informasi tambahan mengenai tekanan populasi di setiap kelurahan, sehingga dapat membantu dalam

memahami hubungan antara tekanan populasi, kerentanan kekeringan, dan luas area terbangun di setiap kelurahan sehingga ketiga variabel ini menjadi kunci dalam penelitian ini.

C. Simulasi Kerentanan Kekeringan

Metode Simulasi Kerentanan Kekeringan yang digunakan bertujuan untuk mengukur kerentanan dengan menghitung skor yang mengintegrasikan tiga faktor utama yaitu, NDDI (*Normalized Difference Drought Index*), populasi, dan area terbangun. NDDI memberikan indikasi kondisi kekeringan vegetasi, populasi mencerminkan jumlah penduduk yang berpotensi terdampak, dan area terbangun menunjukkan luas wilayah yang telah dikembangkan. Skor kerentanan ini kemudian digunakan sebagai variabel target dalam model *machine learning* untuk memprediksi risiko kekeringan dimasa depan.

Pemilihan variabel populasi, area terbangun, dan indeks kekeringan (NDDI) dalam 5 tahun terakhir dalam penelitian prediksi kekeringan untuk tahun 2030 dan 2040 didasarkan pada relevansi yang didukung oleh penelitian terkini. Variabel populasi dalam penelitian terkait kekeringan menunjukkan hubungan kompleks antara demografi dan kerentanan terhadap kekeringan. Meskipun perubahan iklim dianggap sebagai pendorong utama peningkatan kekeringan global (Smirnov, et al., 2016), pertumbuhan populasi tetap menjadi faktor penting dalam konteks kelangkaan air dan dampaknya terhadap kekeringan. Penelitian menunjukkan bahwa dengan pertumbuhan populasi yang signifikan, terutama diarea yang sudah rawan kekeringan, tekanan terhadap sumber daya air meningkat, yang dapat memperburuk dampak kekeringan.

Justifikasi terkait hubungan antara variabel perubahan area terbangun dan kekeringan didasarkan pada bukti bahwa ekspansi perkotaan dapat memperburuk kondisi kekeringan. Penelitian di Cape Town menunjukkan bahwa peningkatan area terbangun bertepatan dengan penurunan vegetasi dan badan air, yang memperburuk kekeringan (Orimoloye, et al., 2019). Di Vadodara, peningkatan area terbangun juga terkait dengan penurunan indeks vegetasi dan air (Mistry & Suryanarayana, 2023). Di Faisalabad, urbanisasi menyebabkan penurunan level air tanah sebesar 1 kaki karena penambahan area terbangun (Zia, -u-Minallah, Tahir, & Hanif, 2022). Temuan ini menunjukkan bahwa konversi lahan alami menjadi



area terbangun mengurangi kemampuan lanskap untuk menyerap dan menyimpan air, memperburuk kekeringan. Oleh karena itu, penting untuk mempertimbangkan dampak ekspansi perkotaan dalam perencanaan dan manajemen sumber daya air untuk mengurangi risiko kekeringan.

Selanjutnya, hubungan antara variabel indeks kekeringan dalam prediksi kekeringan didasarkan pada peran krusial indeks kekeringan dalam memantau dan meramalkan kondisi kekeringan. Penelitian menunjukkan bahwa indeks kekeringan dapat memberikan gambaran yang akurat tentang kondisi kekeringan. Misalnya, algoritma *Machine Learning* seperti *Random Forests* dan *Long Short-Term Memory Networks* telah terbukti efektif dalam memprediksi nilai indeks kekeringan, sehingga menunjukkan potensi metode ini untuk meningkatkan akurasi prediksi kekeringan (Krishna, et al., 2023).

Indeks kekeringan memungkinkan penilaian yang konsisten dan komprehensif terhadap kondisi kekeringan diberbagai wilayah dengan memanfaatkan data historis dan model prediktif. Dengan menerapkan indeks kekeringan dalam model prediksi, kita dapat mengidentifikasi pola kekeringan, memantau perubahan dalam tren kekeringan, dan merencanakan strategi mitigasi yang lebih baik. Oleh karena itu, penggunaan indeks kekeringan dalam prediksi kekeringan memberikan keuntungan dalam hal kesederhanaan, kecepatan, dan akurasi, dibandingkan dengan metode prediksi dinamis lainnya, dan merupakan komponen penting dalam upaya mitigasi kekeringan yang efektif (Hao, 2017).

D. Evaluasi Kinerja Model Machine Learning

Dalam metode ini, akan dievaluasi terlebih dahulu tiga model *machine learning* yaitu yang hendak digunakan yaitu, *Random Forest* (RF), *Support Vector Machine* (SVM), dan *Artificial Neural Network* (ANN). *Random Forest* (RF) adalah sebuah model *machine learning* statistik yang dikemukakan oleh LeoBreiman pada tahun 2001. Dibandingkan dengan metode lain, perkiraan *Random Forest* lebih akurat dan operasi lebih cepat dibandingkan dengan algoritma *machine learning* lainnya. Model *Random Forest* (RF) telah menunjukkan hasil yang menjanjikan dalam memprediksi kekeringan dan menilai kerentanannya. Penelitian menunjukkan bahwa RF dapat meramalkan tingkat kekeringan dengan

sangat akurat, bahkan lebih baik daripada metode tradisional seperti ARIMA (Wu & Chen, 2017). Keunggulan RF terletak pada kemampuannya menangani hubungan nonlinier dan memberikan estimasi ketidakpastian statistik, membuatnya sangat berguna untuk peramalan kekeringan (Wu & Chen, 2017). Menariknya, model RF juga telah digunakan untuk memprediksi area dengan kekeringan parah tanpa perlu bergantung pada data meteorologi, memberikan informasi yang berguna untuk manajemen sumber daya air (Park, 2019).

Selanjutnya, Model *Support Vector Machine* (SVM) adalah metode pembelajaran mesin yang digunakan untuk klasifikasi dan regresi. Prinsip dasar SVM adalah menemukan hyperplane terbaik yang memisahkan data ke dalam dua kelas dengan margin maksimum. Penelitian terbaru telah mengeksplorasi teknik pembelajaran mesin untuk memprediksi kekeringan, dengan *Support Vector Machine* (SVM) menjadi salah satu pendekatan yang paling menonjol. SVM telah menunjukkan keunggulan dalam menangkap karakteristik temporal dan spasial kekeringan dibandingkan dengan metode lain seperti *Artificial Neural Networks* dan *k-Nearest Neighbors* (Khan, 2020).

Disisi Lain, Model *Artificial Neural Networks* (ANN) telah muncul sebagai pendekatan yang kuat untuk prediksi kekeringan karena kemampuannya dalam menangkap hubungan non-linier dalam sistem hidro-meteorologi yang kompleks (Dikshit, 2021). Berbagai model ANN, termasuk *Multilayer Perceptron Neural Networks*, telah digunakan untuk memprediksi kekeringan jangka pendek dan jangka Panjang. Model ANN telah menunjukkan kinerja tinggi dalam memprediksi indeks kekeringan dengan nilai R^2 melebihi 0,98 dalam beberapa kasus (Dayal, 2023). Penerapan ANN dalam peramalan kekeringan dapat memberikan wawasan berharga untuk manajemen sumber daya air dan strategi adaptasi terhadap perubahan (Dikshit, 2021).

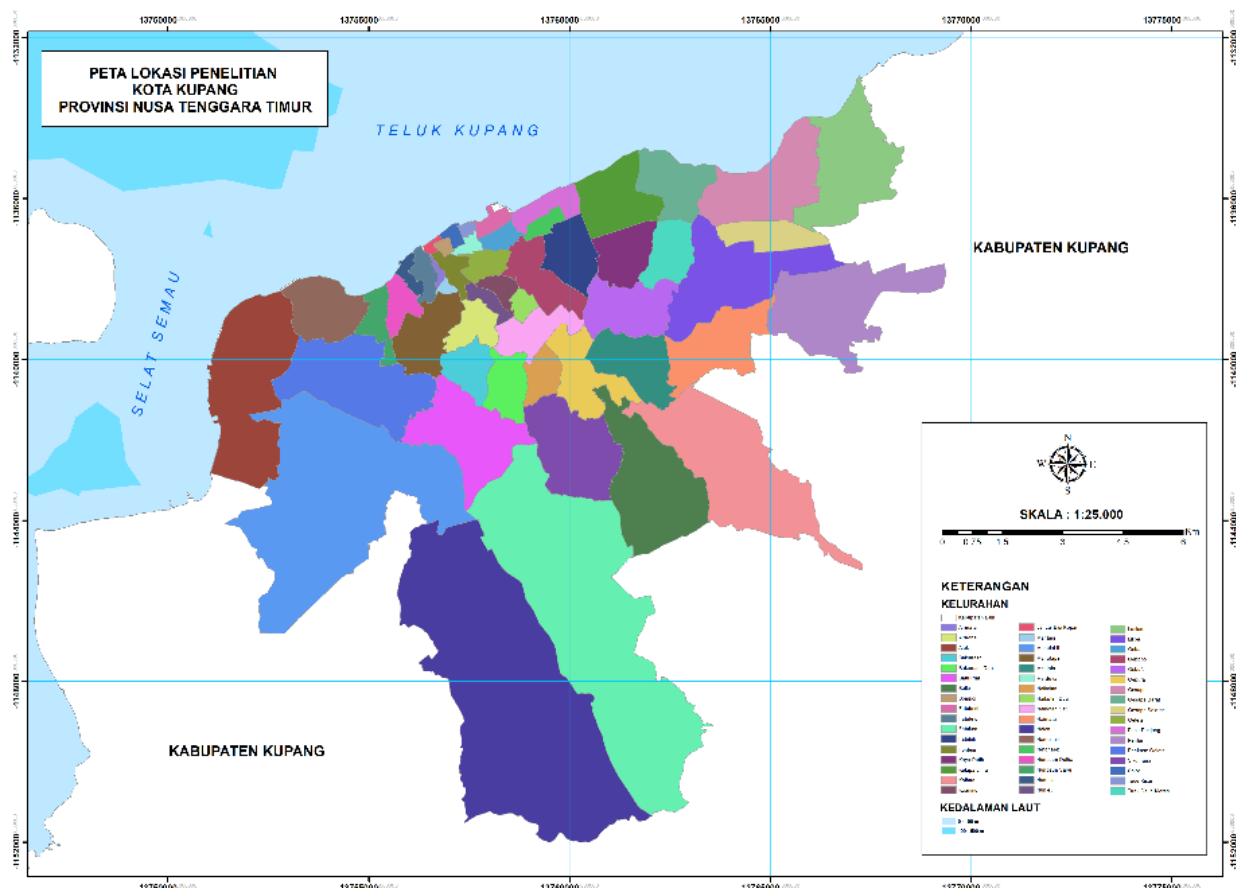
Ketiga model ini kemudian dilatih menggunakan data zonal dari tahun 2023. Evaluasi kinerja model dilakukan dengan membandingkan nilai *R Squared* mereka, di mana *R Squared* mengukur akurasi tertinggi prediksi dengan membandingkan nilai yang diprediksi dengan nilai aktual. Model yang menunjukkan nilai *R Squared* tertinggi dianggap sebagai model terbaik, karena menunjukkan kemampuan prediksi yang paling akurat. Nilai *R-Squared* negatif pada model SVM menunjukkan bahwa model tidak mampu

menjelaskan variabilitas data dan kinerjanya lebih buruk dibandingkan prediksi rata-rata. Hal ini mengindikasikan bahwa SVM kurang sesuai untuk kasus kerentanan kekeringan di Kota Kupang.

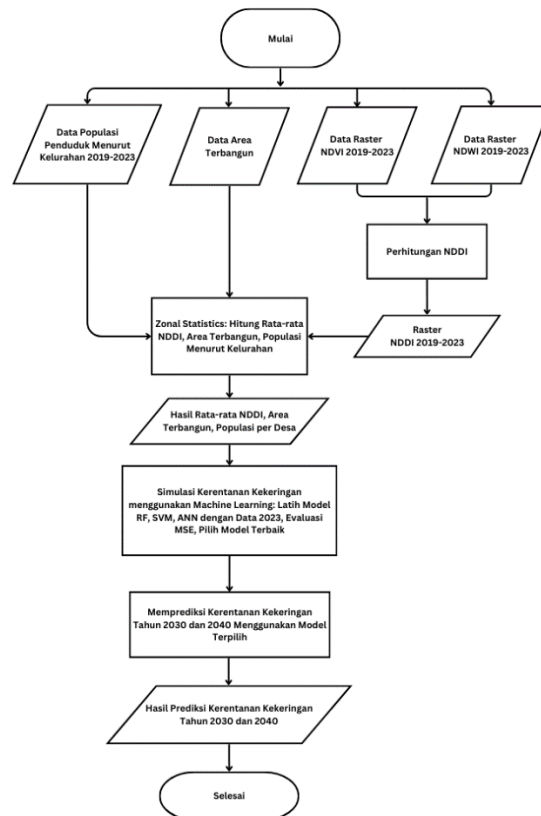
E. Prediksi Kerentanan Kekeringan

Setelah memilih model *machine learning* terbaik berdasarkan nilai *R Squared* tertinggi, model tersebut digunakan untuk memprediksi kerentanan kekeringan pada tahun 2030 dan 2040.

Dengan menggunakan model yang telah terbukti paling akurat, prediksi ini bertujuan untuk memberikan estimasi yang lebih andal tentang risiko kekeringan di masa depan, memungkinkan perencanaan dan mitigasi yang lebih efektif untuk menghadapi potensi dampak kekeringan pada tahun-tahun mendatang. Alur pengolahan data dalam penelitian ini digambarkan melalui diagram alir yang dapat dilihat pada Gambar 2.



Gambar 1. Peta Lokasi Penelitian



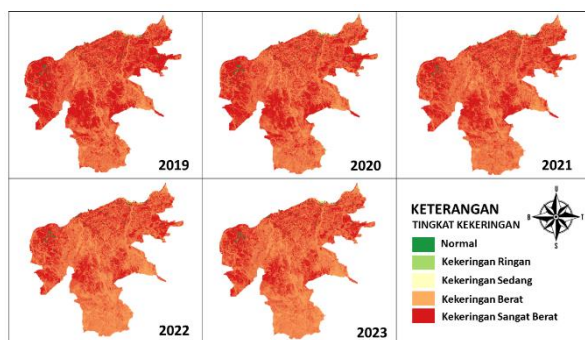
Gambar 2. Tahapan Pengolahan Data

3. Hasil dan Pembahasan

Normalized Difference Drought Index (NDDI) merupakan hasil dari penggabungan dua indeks penting, yaitu *Normalized Difference Vegetation Index* (NDVI) dan *Normalized Difference Water Index* (NDWI). NDVI berfungsi untuk mengukur seberapa sehat vegetasi dengan melihat perbedaan antara cahaya merah yang diserap oleh klorofil dan cahaya inframerah dekat yang dipantulkan kembali oleh tanaman. Vegetasi yang sehat cenderung memiliki nilai NDVI yang tinggi karena menyerap lebih banyak cahaya merah dan memantulkan lebih banyak cahaya inframerah. Disisi lain, NDWI digunakan untuk mengukur kandungan air pada tanaman dengan membandingkan cahaya inframerah dekat dan cahaya hijau yang dipantulkan. nilai NDWI yang tinggi menunjukkan bahwa tanaman memiliki kandungan air yang baik.

NDDI dihitung dengan mengurangi NDWI dari NDVI, kemudian membaginya dengan jumlah keduanya, menghasilkan nilai yang mencerminkan kondisi kekeringan. Nilai NDDI yang tinggi menunjukkan kondisi kekeringan yang tinggi, karena menunjukkan rendahnya kelembapan air dan tingginya stres pada vegetasi.

Nilai *R-Squared* negatif pada model SVM menjelaskan bahwa model tidak mampu menjelaskan variabilitas data dan kinerjanya lebih buruk dibandingkan prediksi rata-rata. Hal ini mengindikasikan bahwa SVM kurang sesuai untuk kasus kerentanan kekeringan di Kota Kupang. Dengan cara ini, NDDI memberikan gambaran yang lebih komprehensif dalam memantau dan mendeteksi kekeringan dibandingkan jika hanya menggunakan NDVI atau NDWI secara terpisah. Hasil Perhitungan dan pengolahan NDDI tahun 2019 - 2023 dapat dilihat pada Gambar 3 dibawah.



Gambar 3. Hasil NDDI Kota Kupang Tahun 2019-2023

Selama periode 2019 hingga 2023, Kota Kupang secara konsisten menghadapi kondisi kekeringan yang sangat parah. Peta NDDI menunjukkan bahwa hampir seluruh wilayah kota mengalami kekeringan berat dan sangat berat setiap tahunnya, ditandai dengan dominasi warna merah tua pada peta. Tidak ada perubahan signifikan yang terlihat dari tahun ke tahun, yang mengindikasikan bahwa kondisi kekeringan ini bersifat kronis dan berlanjut tanpa adanya perbaikan yang berarti. Kondisi ini menekankan pentingnya tindakan segera dalam perencanaan dan pengelolaan sumber daya air untuk mengurangi dampak kekeringan dan meningkatkan ketahanan kota di masa mendatang.

A. Zonal Statistics

Dalam analisis ini, metode *Zonal Statistics* digunakan untuk menghitung rata-rata nilai NDDI (*Normalized Difference Drought Index*) dan luas area terbangun di setiap kelurahan di Kota Kupang. Metode ini memungkinkan perhitungan nilai rata-rata dari data raster (seperti NDDI dan area terbangun) berdasarkan batas-batas administrasi kelurahan yang telah ditentukan sebagai zona. Dengan menggunakan *Zonal Statistics*, peneliti dapat memperoleh gambaran yang lebih spesifik tentang kondisi kekeringan dan tingkat populasi di

masing-masing kelurahan. Selain itu, data populasi juga ditambahkan ke dalam analisis ini untuk memberikan konteks lebih lanjut mengenai tekanan populasi di setiap kelurahan. Penggabungan data populasi dengan hasil *zonal statistics* membantu dalam mengidentifikasi kelurahan-kelurahan yang mungkin paling rentan terhadap kekeringan karena kombinasi antara intensitas kekeringan, luasnya

area terbangun, dan tekanan populasi yang tinggi. Selengkapanya, tabel rata-rata indeks kekeringan (NDDI), Area Terbangun, dan Populasi hasil *zonal statistics* untuk 10 kelurahan dengan hasil tertinggi disajikan melalui tabel 3.

Tabel 3. Rata-rata Indeks Kekeringan, area terbangun, dan Populasi di Kota Kupang

Kelurahan	Rata-Rata		
	Indeks Kekeringan (NDDI)	Area Terbangun	Populasi
Tuak Daun			
Merah	1,08	6,62	10825
Tode Kisar	5,78	7,00	1259
Solor	3,01	6,94	3074
Penfui	1,05	3,03	6894
Fatubesi	3,34	6,66	5622
Lasiana	1,09	6,49	15993
Merdeka	1,10	7,00	2196
Naikoten Satu	12,38	5,90	3921
Oebufu	1,11	6,96	18804
Pasir Panjang	1,15	6,88	8599

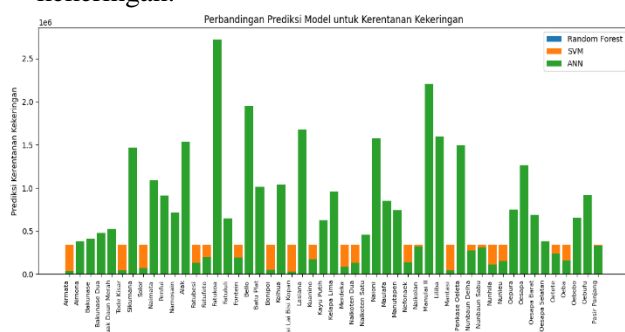
B. Simulasi Kerentanan Kekeringan

Simulasi kerentanan kekeringan dilakukan dengan menghitung skor kerentanan berdasarkan tiga faktor utama yang masing-masing diberi bobot berbeda: NDDI (*Normalized Difference Drought Index*), populasi, dan area terbangun. Dalam simulasi ini, NDDI, yang mengukur tingkat kekeringan dengan membandingkan data vegetasi (NDVI) dan kelembaban tanah (NDWI), berkontribusi sebesar 40% terhadap skor akhir. Populasi dan area terbangun masing-masing memberikan kontribusi sebesar 30%.

Proses perhitungan dimulai dengan mengalikan nilai rata-rata NDDI di setiap zona dengan bobot 0.4, nilai populasi dengan bobot 0.3, dan nilai area terbangun dengan bobot 0.3. Pemilihan bobot 40% (NDDI), 30% (populasi), dan 30% (area terbangun) didasarkan pada penelitian sebelumnya yang menekankan peran dominan kondisi vegetasi terhadap kekeringan (Smirnov, et al., 2016), serta disesuaikan dengan konteks perkotaan Kupang. Pemberian bobot 40% untuk NDDI, 30% untuk populasi, dan 30% untuk area terbangun ditetapkan berdasarkan asumsi peneliti dengan mempertimbangkan temuan penelitian sebelumnya yang menekankan faktor-faktor utama penyebab kekeringan di kawasan perkotaan. Bobot

ini juga dipertimbangkan secara konseptual oleh peneliti sesuai kondisi lokal. Langkah selanjutnya adalah menjumlahkan hasilnya untuk memperoleh skor kerentanan kekeringan. Skor akhir ini mencerminkan sejauh mana setiap zona rentan terhadap kekeringan berdasarkan kombinasi ketiga faktor tersebut.

Skor kerentanan yang dihasilkan dari simulasi ini digunakan sebagai variabel target dalam model *machine learning*. Model ini dilatih untuk memahami dan memprediksi kerentanan kekeringan di berbagai zona berdasarkan skor yang telah dihitung, sehingga dapat memberikan wawasan yang lebih mendalam dan mendukung upaya perencanaan serta mitigasi risiko kekeringan.



Grafik 1. Perbandingan Prediksi Model *Machine Learning* untuk Kerentanan Kekeringan

C. Evaluasi Kinerja Model *Machine Learning*

Dalam proses *machine learning* untuk memprediksi skor kerentanan kekeringan, tiga model—*Random Forest* (RF), *Support Vector Machine* (SVM), dan *Artificial Neural Network* (ANN)—dilatih menggunakan data zonal dari tahun 2023. Evaluasi model dilakukan dengan mengukur *R-squared* (R^2) dari setiap model. Tabel *R Squared* dari tiap model *Machine Learning* dapat dilihat pada tabel 4.

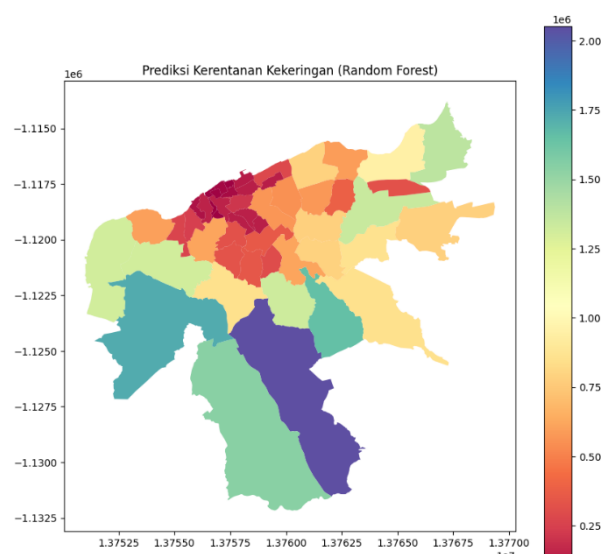
Tabel 4. Evaluasi Kinerja Model *Machine Learning* Berdasarkan *R-squared* (R^2)

Model <i>Machine Learning</i>	<i>R-Squared</i> (R^2)
<i>Random Forest</i>	0.9871
<i>Support Vector Machine</i> (SVM)	-0.2614
<i>Artificial Neural Network</i> (ANN)	0.9003

Hasilnya menunjukkan bahwa model *Random Forest* memiliki R^2 sebesar 0.987, yang menunjukkan kinerja prediksi yang sangat akurat dengan kesalahan yang relatif kecil dan kemampuan menjelaskan variansi data yang tinggi. Sebaliknya, model SVM memiliki R^2 negatif (-0.261), menunjukkan performa yang buruk dalam memprediksi skor kerentanan. Model ANN memiliki R^2 sebesar 0.900, menunjukkan kinerja yang baik tetapi tidak sebaik *Random Forest*. Berdasarkan evaluasi ini, model *Random Forest* dipilih sebagai model terbaik karena memiliki R^2 tertinggi, yang menandakan akurasi dan keandalan prediksi yang superior. Justifikasi Pemilihan Model *Machine Learning* juga dapat dilihat melalui Grafik 1 berikut.

D. Prediksi Kerentanan Kekeringan Kota Kupang

Prediksi Kerentanan Kekeringan Kota Kupang didapatkan setelah melalui tahapan pelatihan dan evaluasi terhadap beberapa model *Machine Learning*. Hasil menunjukkan bahwa model *Random Forest* memberikan performa terbaik dengan nilai *R-Squared* (R^2) paling tinggi dibandingkan dengan model *Support Vector Machine* (SVM) dan *Artificial Neural Network* (ANN). Berdasarkan kinerja ini, model *Random Forest* dipilih untuk digunakan dalam memprediksi kerentanan terhadap kekeringan di masa depan. Visualisasi prediksi kerentanan kekeringan disajikan melalui Gambar 4.



Gambar 4. Prediksi Kerentanan Kekeringan Menggunakan Model *Random Forest*

Hasil prediksi menunjukkan bahwa beberapa wilayah di Kota Kupang memiliki risiko kekeringan yang relatif rendah, yang ditandai dengan warna hijau pada peta. Wilayah-wilayah seperti Naioni, Manulai II, dan Fatukoa termasuk dalam kategori ini. Faktor-faktor yang mendukung ketahanan di wilayah-wilayah ini meliputi ketersediaan sumber daya air yang lebih baik, populasi yang lebih rendah, dan area terbangun yang terbatas. Kondisi ini memungkinkan tanah untuk mempertahankan kelembapan lebih lama, mengurangi risiko kekeringan yang parah. Wilayah-wilayah ini memiliki potensi yang lebih baik untuk menghadapi kondisi kekeringan, meskipun pemantauan dan pengelolaan sumber daya air tetap diperlukan untuk menjaga ketahanan ini.

Selanjutnya, wilayah dengan risiko kekeringan menengah di Kota Kupang ditandai dengan warna kuning pada peta dan mencakup daerah seperti Kolhua, Bello, dan Sikumana. Meskipun tidak berada dalam kategori risiko tertinggi, wilayah-wilayah ini masih memerlukan perhatian khusus. Populasi yang cukup signifikan dan area terbangun yang berkembang pesat dapat meningkatkan tekanan pada sumber daya air dan tanah di wilayah-wilayah ini. Oleh karena itu, diperlukan tindakan preventif dan strategi pengelolaan air yang efektif untuk mengurangi risiko kekeringan yang mungkin meningkat di masa depan.

Beberapa wilayah di Kota Kupang, seperti Kelurahan Airmata, Manutapen, Bonipoi, dan Oepura, menunjukkan risiko kekeringan yang tinggi, yang ditandai dengan warna merah dan oranye pada peta. Tingginya populasi dan luasnya area terbangun di wilayah-wilayah ini berkontribusi signifikan terhadap rendahnya kapasitas tanah untuk menyimpan air, yang pada gilirannya meningkatkan kerentanan terhadap kekeringan. Urbanisasi yang cepat dan padatnya penduduk memperburuk situasi, membuat wilayah-wilayah ini sangat rentan terhadap kekeringan. Oleh karena itu, diperlukan intervensi segera dalam bentuk strategi mitigasi dan adaptasi iklim yang lebih kuat, serta perencanaan tata ruang yang lebih bijak untuk mengurangi dampak kekeringan di wilayah-wilayah ini.

Sedangkan, Wilayah Batuplat, Namosain, dan Kelurahan Oetete menempati posisi sebagai wilayah dengan risiko kekeringan sangat tinggi,

yang ditandai dengan warna oranye kemerahan pada peta. Kondisi di wilayah-wilayah ini sangat memprihatinkan, terutama karena kombinasi dari urbanisasi yang masif dan kepadatan penduduk yang tinggi. Faktor-faktor ini mengurangi kemampuan tanah untuk menyimpan air, meningkatkan risiko kekeringan secara signifikan. Wilayah-wilayah ini memerlukan perhatian yang sangat serius dalam hal pengelolaan sumber daya air dan penerapan strategi mitigasi yang intensif. Tindakan yang cepat dan tepat diperlukan untuk mengurangi dampak potensial dari kekeringan yang parah di masa mendatang.

Selengkapnya hasil prediksi tingkat kerentanan kekeringan di Kota Kupang berdasarkan Kelurahan dapat dilihat melalui Tabel 5.

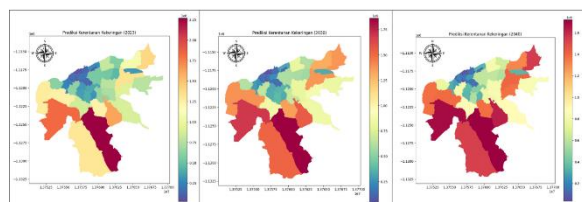
Tabel 5. Distribusi Prediksi Tingkat Kerentanan Kekeringan di Kota Kupang (2019-2023)

No	Kelurahan	Tingkat Kerentanan Kekeringan
1	Manulai 2	Rendah
2	Alak	Rendah
3	Manutapen	Tinggi
4	Mantasi	Tinggi
5	Fatufeto	Rendah
6	Nunhila	Rendah
7	Nunbaun Delha	Rendah
8	Nunbaun Sabu	Rendah
9	Namosain	Sangat Tinggi
10	Penkase Oeleta	Tinggi
11	Batuplat	Rendah
12	Naioni	Rendah
13	Fatukoa	Sedang
14	Sikumana	Sedang
15	Bello	Sedang
16	Kolhua	Sedang
17	Penfui	Rendah
18	Naimata	Sedang
19	Maulafa	Sedang
20	Oepura	Tinggi
21	Naikolan	Rendah
22	Oetete	Sangat Tinggi
23	Oebobo	Tinggi
24	Fatululi	Tinggi
25	Oebufu	Sedang
26	TDM	Tinggi



No	Kelurahan	Tingkat Kerentanan Kekeringan
27	Kayu Putih	Sedang
28	Liliba	Sedang
29	Bakunase	Sedang
30	Bakunase II	Sedang
31	Airmona	Sedang
32	Naikoten I	Tinggi
33	Naikoten II	Sangat Tinggi
34	Kuanino	Sangat Tinggi
35	Nunleu	Tinggi
36	Fontein	Tinggi
37	Kelapa Lima	Sedang
38	Oesapa	Rendah
39	Oesapa Barat	Sedang
40	Oesapa Selatan	Sedang
41	Lasiana	Rendah
42	Air Mata	Sangat Tinggi
43	LLBK	Tinggi
44	Bonipoi	Tinggi
45	Merdeka	Tinggi
46	Solor	Tinggi
47	Tode Kisar	Tinggi
48	Oeba	Sedang
49	Fatubesi	Tinggi
50	Nefonaik	Rendah
51	Pasir Panjang	Tinggi

Selanjutnya, untuk memahami potensi dampak kekeringan pada tahun 2023, dan tahun-tahun yang akan datang yaitu pada tahun 2030, dan 2040, peneliti menyajikan visualisasi hasil prediksi yang telah dikembangkan. Visualisasi ini menyajikan data secara komprehensif, menggambarkan pola distribusi dan tingkat kekeringan di berbagai wilayah kelurahan di Kota Kupang. Visualisasi Prediksi Kekeringan pada tahun 2023, 2030 dan 2040 dapat dilihat melalui Gambar 5.



Gambar 5. Prediksi Kerentanan Kekeringan Tahun 2023, 2030, dan 2040

Peta prediksi kerentanan kekeringan di Kota Kupang untuk tahun 2023 menunjukkan variasi tingkat kerentanan berdasarkan skala warna, di mana semakin rendah warnanya (merah), semakin tinggi kerentanannya, dan sebaliknya, semakin tinggi warnanya (hijau), semakin rendah kerentanannya. Peta ini didasarkan pada tiga variabel utama: NDDI (*Normalized Difference Drought Index*) yang menyumbang 40% dalam perhitungan skor kerentanan, populasi dengan kontribusi 30%, dan area terbangun yang juga memberikan kontribusi 30%. NDDI memberikan gambaran mengenai kondisi kelembaban tanah dan ketersediaan air, sementara populasi dan area terbangun mencerminkan tekanan manusia terhadap sumber daya air.

Dari peta pada gambar 5, terlihat bahwa wilayah bagian utara dan tengah seperti Maulafa, Oesapa, dan Namosain memiliki kerentanan kekeringan yang sangat tinggi, ditunjukkan dengan warna merah. Hal ini kemungkinan besar disebabkan oleh kombinasi NDDI yang rendah, populasi padat, dan area terbangun yang luas. Sebaliknya, wilayah bagian selatan seperti Naioni, Fatukoa, dan Manulai II menunjukkan kerentanan kekeringan yang rendah, yang ditandai dengan warna hijau, yang mungkin terkait dengan kondisi kelembaban tanah yang lebih baik, populasi yang lebih sedikit, atau area terbangun yang lebih sedikit. Wilayah lain seperti Alak, Kolhua, dan Bello menunjukkan kerentanan sedang dengan warna kuning hingga ungu, yang menunjukkan kondisi yang berada diantara kedua ekstrem tersebut.

Analisis ini mengindikasikan bahwa wilayah dengan kerentanan tinggi perlu mendapat perhatian khusus dalam manajemen air, termasuk program konservasi air dan peningkatan infrastruktur irigasi. Selain itu, perencanaan pembangunan di daerah rentan harus dilakukan secara hati-hati untuk menghindari peningkatan kerentanan, sementara di wilayah dengan populasi tinggi dan kerentanan tinggi, langkah-langkah pengurangan tekanan pada sumber daya air sangat diperlukan. Pemahaman mengenai distribusi kerentanan kekeringan ini sangat penting untuk merancang kebijakan mitigasi risiko yang efektif di Kota Kupang.

Berdasarkan hasil kerentanan kekeringan di Kota Kupang Tahun 2030, dapat dilihat bahwa bagian utara Kota Kupang memiliki tingkat

kerentanan kekeringan yang sangat tinggi, ditunjukkan oleh warna merah yang dominan. Wilayah seperti Bakunase, Bakunase II, Naikoten I, Naikoten II, dan Airnona berada di antara daerah dengan kerentanan tertinggi. Tingginya kerentanan di wilayah-wilayah ini disebabkan oleh kombinasi dari nilai NDDI yang rendah, populasi yang padat, dan area terbangun yang luas, yang meningkatkan risiko kekeringan.

Di sisi lain, wilayah yang berwarna oranye hingga kuning seperti Oebobo, Pasir Panjang, dan Kayu Putih menunjukkan tingkat kerentanan yang sedang. Meskipun risiko kekeringan masih ada, daerah-daerah ini memiliki sedikit lebih banyak ketersediaan air atau tekanan yang lebih rendah dibandingkan dengan daerah yang berwarna merah.

Sementara itu, bagian barat laut seperti Namosain dan Penkase Oeleta yang berwarna hijau menunjukkan kerentanan kekeringan yang lebih rendah. Ini mungkin karena kondisi NDDI yang lebih baik dan kemungkinan populasi serta pembangunan yang lebih rendah di wilayah ini, yang memungkinkan tanah untuk tetap mempertahankan kelembapannya.

Ilustrasi ini memperlihatkan bahwa wilayah tengah dan utara Kota Kupang memerlukan perhatian khusus dalam hal manajemen air dan mitigasi risiko kekeringan. Wilayah-wilayah yang lebih rentan harus difokuskan pada pengembangan strategi pengelolaan air yang efektif dan upaya konservasi untuk mengurangi dampak kekeringan yang semakin parah di masa depan.

Secara keseluruhan, hasil prediksi untuk tahun 2030 menekankan perlunya fokus mitigasi di wilayah-wilayah dengan kerentanan tinggi di bagian utara dan tengah Kota Kupang. Strategi seperti pengelolaan air yang lebih baik, kontrol pertumbuhan populasi, dan perencanaan pembangunan yang berkelanjutan akan sangat penting untuk mengurangi risiko kekeringan. Sementara itu, wilayah dengan kerentanan rendah harus dipertahankan melalui upaya konservasi lingkungan yang berkelanjutan dan pengelolaan air yang efisien untuk memastikan mereka tetap terlindungi dari potensi kekeringan di masa depan.

Sedangkan pada peta prediksi kekeringan di Kota Kupang tahun 2040 secara jelas mengidentifikasi wilayah-wilayah dengan tingkat kerentanan kekeringan yang bervariasi. Wilayah dengan warna merah tua, seperti Oebobo, Oetete, Airnona, dan Bakunase, diindikasikan akan menghadapi risiko kekeringan yang paling tinggi.

Faktor-faktor yang berkontribusi terhadap tingginya kerentanan ini kemungkinan besar meliputi skor NDDI (*Normalised Difference Drought Index*) yang tinggi, populasi yang padat, dan tingkat pembangunan yang intensif. Sementara itu, wilayah dengan warna merah, seperti Oebufu dan Kayu Putih, juga menunjukkan kerentanan yang tinggi, meskipun sedikit lebih rendah dibandingkan daerah merah tua. Daerah yang diwarnai oranye, seperti Naikoten I dan II serta Oepura, memiliki kerentanan kekeringan menengah, yang mengindikasikan risiko kekeringan yang moderat.

Di sisi lain, wilayah dengan warna kuning seperti Kolhua, Bello, dan Sikumana diprediksi memiliki kerentanan yang lebih rendah, sementara daerah dengan warna hijau muda seperti Penfui dan Naimata menunjukkan kerentanan yang rendah. Terakhir, wilayah yang diwarnai hijau tua hingga biru, seperti Naioni, Lasiana, Manulai II, dan Alak, memiliki kerentanan terendah terhadap kekeringan.

Secara keseluruhan, peta ini mengindikasikan bahwa bagian tengah dan timur Kota Kupang akan memerlukan perhatian khusus dalam mitigasi risiko kekeringan, sementara bagian barat dan selatan lebih resisten terhadap kekeringan. Analisis ini penting untuk perencanaan kebijakan adaptasi iklim dan pengelolaan sumber daya air yang lebih baik di masa depan. Tren ini menggarisbawahi pentingnya perencanaan yang lebih baik dan penerapan strategi adaptasi, termasuk pengelolaan sumber daya air yang efektif dan peningkatan kesadaran masyarakat terhadap risiko kekeringan. Meskipun ada beberapa kelurahan yang tingkat kerentanannya relatif stabil, pemantauan dan mitigasi risiko tetap penting untuk mencegah peningkatan kerentanan di masa mendatang.

4. Kesimpulan

Penerapan data geospasial dan algoritma *machine learning*, khususnya model *Random Forest*, telah terbukti efektif dalam memprediksi kerentanan kekeringan di Kota Kupang. Model ini memberikan estimasi yang akurat mengenai risiko kekeringan di berbagai wilayah kota, sesuai dengan tujuan penelitian untuk mengidentifikasi daerah-daerah yang paling rentan. Temuan menunjukkan bahwa kelurahan Namosain dan Oetete memiliki risiko kekeringan yang sangat tinggi pada tahun 2023 dan diperkirakan akan tetap berisiko tinggi pada tahun 2030 dan 2040. Selain itu, kelurahan



seperti Manulai II dan Naioni menunjukkan kerentanan yang rendah pada periode yang sama, dengan risiko yang diperkirakan akan tetap rendah di masa depan.

Temuan ini menekankan pentingnya penerapan strategi mitigasi dan adaptasi yang lebih intensif di wilayah-wilayah dengan kerentanan tinggi. Hasil prediksi ini dapat dijadikan dasar untuk merancang kebijakan pengelolaan sumber daya air yang lebih efisien, perlindungan ruang terbuka hijau, dan perencanaan urban yang lebih responsif terhadap risiko lingkungan. Hal ini menjadi krusial untuk mengurangi dampak kekeringan di masa depan.

Ke depan, peluang terbuka untuk mengembangkan model yang lebih kompleks dengan memasukkan variabel tambahan atau menerapkan pendekatan serupa di wilayah lain yang menghadapi risiko kekeringan. Penelitian ini juga mendorong kolaborasi dengan pemangku kepentingan lokal dalam implementasi strategi mitigasi berbasis hasil temuan, guna memperkuat ketahanan Kota Kupang terhadap dampak perubahan iklim dan memastikan keberlanjutan perencanaan kota yang adaptif, berkelanjutan, dan tangguh.

Daftar Pustaka

- Affandy, N. A., & Iranata, D. (202). Assessment of Agricultural Drought Using the Normalized Difference Drought Index (NDDI) to Prediction Drought at Corong River Basin. *ITS*, 378-393.
- Dayal, K. D. (2023). Drought Modelling Based on Artificial Intelligence and Neural Network Algorithms: A Case Study in Queensland, Australia. *The Science of the total environment*, 867.
- Dikshit, A. P. (2021). Artificial neural networks in drought prediction in the 21st century-A scientometric analysis. *Applied Soft Computing*, 114.
- Gu, Y., Brown, J., Verdin, J., & Wardlow, B. (2007). 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*.
- Haag, S., Tarboton, D., Smith, M., & Shokoufandeh, A. (2020). Fast Summarizing Algorithm for Polygonal Statistics Over a Regular Grid. *Computers & Geosciences Volume 142*, 12-29.
- Hao, Z. H. (2017). An integrated package for drought monitoring, prediction and analysis to aid drought modeling and assessment. *Environ. Model. Softw.*, 91, 199-209.
- Khan, N. S. (2020). Prediction of droughts over Pakistan using machine learning algorithms. *Advances in Water Resources*, 139.
- Koroh, D.-J., Hidayati, N., & Widodo, W. (2017). *Perumusan Zonasi Bencana Kekeringan di Kabupaten Kupang*. Malang: Institut Teknologi Nasional Malang.
- Krishna, P. S., Krishna, B. Y., Nafisa, S., Sravani, T. R., Madhuri, J. R., & Vanditha, C. (2023). Prediction of Droughts using SPEI. *2023 IEEE 12th International Conference on Communication Systems and Network Technologies (CSNT)*, (hal. 839-845). Bhopal.
- Krisnayanti, D., Bunganaen, W., Frans, J., Seran, Y., & Legono, D. (2021). Curve Number Estimation for Ungauged Watershed in Semi-Arid Region. *Civil Engineering Journal*.
- Machairas, & Ven, v. d. (2023). An urban drought categorization framework and the vulnerability of a lowland city to groundwater urban droughts. *Natural Hazards*.
- Marelle, L., Myhre, G., Steensen, B., Hodnebrog, O., Alterskjær, K., & Sillmann, J. (2020). Urbanization in megacities increases the frequency of extreme precipitation events far more than their intensity. *Environmental Research Letters*.
- Mistry, P., & Suryanarayana, T. (2023). Assessment & Monitoring of Agricultural Drought Indices Using Remote Sensing Techniques and their Inter-Comparison. *Ecological Perspective*, 2-6.
- Orimoloye, I., Ololade, O., Mazinyo, S., Kalumba, A., Ekundayo, O., Busayo, E., . . . Nel, W. (2019). Spatial assessment of drought severity in Cape Town area, South Africa. *Heliyon*, 1-9.
- Park, H. K. (2019). Prediction of Severe Drought Area Based on Random Forest: Using Satellite Image and Topography Data. *Water*, 12.
- Rahman, F., Sukmono, A., & Yuwono, B. (2017). ANALISIS KEKERINGAN PADA LAHAN PERTANIAN MENGGUNAKAN METODE NDDI DAN PERKA BNPB NOMOR 02 TAHUN 2012 (Studi Kasus : Kabupaten Kendal Tahun 2015). *Jurnal Geodesi Undip*, 274-284.
- Renza, D., E, M., Arquero, A., & J, S. (2010). Drought Estimation Maps by Means of Multidate Landsat Fused Images. *Remote Sensing for Science, Education and Natural and Cultural Heritage*, 775-782.
- Sena, A., & Ebi, K. (2020). When Land Is Under Pressure Health Is Under Stress. *International Journal Of Environmental Research and Public Health*.



- Singla, S., & Eldawy, A. (2020). Raptor Zonal Statistics: Fully Distributed Zonal Statistics Of Big Raster + Vector Data. *IEEE International Conference on Big Data (Big Data)*, 571-580.
- Smirnov, O., Zhang, M., T, X., Orbell, J., A, L., & J, G. (2016). The relative importance of climate change and population growth for exposure to future extreme droughts. *Climatic Change*, 41-53.
- Sundararajan, K., Garg, L., Srinivasan, K., A, B., Kaliappan, J., Ganapathy, G., . . . Meena, T. (2021). A Contemporary Review on Drought Modeling Using Machine Learning Approaches. *Computer Modeling in Engineering & Sciences*.
- Verbeke, W., Dejaeger, K., Martens, D., Hur, J., & Baesens, B. (2012). New Insights into Churn Prediction in the Telecommunication Sector: A Profit Driven Data Mining Approach. *European Journal of Operational Research*, 218(1), 211-229. doi:10.1016/j.ejor.2011.09.031
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques* (3rd ed.). Burlington: Morgan Kaufmann.
- Wu, J., & Chen, Y. (2017). Research of using RF model to drought forecast on Huaihe River. *IOP Conference Series: Earth and Environmental Science*, 82.
- Yap, B. W., Rani, K. A., Rahman, H. A., Fong, S., Khairudin, Z., & Abdullah, N. N. (2014). An Application of Oversampling, Undersampling, Bagging and Boosting in Handling Imbalanced Datasets. *Proceedings of the First International Conference on Advanced Data and Information Engineering (DaEng-2013)*. 285, hal. 13-22. Singapore: Springer. doi:10.1007/978-981-4585-18-7_2
- Zha, H., Miao, Y., Wang, T., Li, Y., Zhang, J., Sun, W., . . . Kusnierek, K. (2020). Improving Unmanned Aerial Vehicle Remote Sensing-Based Rice Nitrogen Nutrition Index Prediction with Machine Learning. *Remote Sens*.
- Zia, S., -u-Minallah, M., Tahir, M., & Hanif, A. (2022). Impact Assessment of Urban Built-up Area on Groundwater Level of District Faisalabad, Pakistan. *International Journal of Economic and Environmental Geology*, 33-36.



