

# Prediksi Risiko Krisis Pangan di Nusa Tenggara Timur Menggunakan XGBoost

Desi Trisianti<sup>1</sup>, Mohammad Idhom<sup>2</sup>,  
Kartika Maulida Hindrayani<sup>3</sup>

<sup>123</sup>Universitas Pembangunan Nasional “Veteran” Jawa Timur  
<sup>123</sup>Surabaya, Indonesia

Email: <sup>1</sup>[22083010037@student.upnjatim.ac.id](mailto:22083010037@student.upnjatim.ac.id), <sup>2</sup>[idhom@upnjatim.ac.id](mailto:idhom@upnjatim.ac.id),  
<sup>3</sup>[kartika.maulida.ds@upnjatim.ac.id](mailto:kartika.maulida.ds@upnjatim.ac.id)

## Abstract

*The food crisis is one of the strategic issues that directly impacts social, economic, and public health stability, especially in highly vulnerable regions such as East Nusa Tenggara (NTT). The arid geographical conditions, high poverty rates, and climate variability make this region vulnerable to disruptions in food availability and access. This study aims to develop a food crisis risk prediction model in NTT using the Extreme Gradient Boosting (XGBoost) algorithm, utilizing climate and socio-economic data from 2020 to 2024. The variables used include rainfall, air temperature, soil surface temperature, vegetation index (NDVI), soil moisture, number of rainy days, rice prices, and spatial information such as district/city and month of observation. The test results show that the XGBoost model is capable of producing 93.75% accuracy with the best performance in the Safe and Emergency classes. These findings indicate that XGBoost is effective as an early prediction tool for mapping food insecurity in NTT.*

**Keywords:** Food Crisis, NTT, NDVI, LST, XGBoost

## Abstraksi

*Krisis pangan merupakan salah satu isu strategis yang berdampak langsung terhadap stabilitas sosial, ekonomi, dan kesehatan masyarakat, terutama di wilayah dengan tingkat kerentanan tinggi seperti Nusa Tenggara Timur (NTT). Kondisi geografis yang kering, tingginya angka kemiskinan, serta variabilitas iklim menjadikan wilayah ini rentan terhadap gangguan ketersediaan dan akses pangan. Penelitian ini bertujuan untuk membangun model prediksi risiko krisis pangan di NTT menggunakan algoritma Extreme Gradient Boosting (XGBoost) dengan memanfaatkan data iklim dan sosial-ekonomi dari periode 2020 hingga 2024. Variabel yang digunakan mencakup curah hujan, suhu udara, suhu permukaan tanah, indeks vegetasi (NDVI), kelembapan tanah, jumlah hari hujan, harga beras, serta informasi spasial seperti kabupaten/kota dan bulan pengamatan. Hasil pengujian menunjukkan bahwa model XGBoost mampu menghasilkan akurasi 93.75% dengan performa terbaik pada kelas Aman dan Darurat. Temuan ini menunjukkan bahwa XGBoost efektif digunakan sebagai alat prediksi dini untuk memetakan kerawanan pangan di NTT.*

**Kata Kunci:** Krisis pangan, NTT, NDVI, LST, XGBoost

## **1. PENDAHULUAN**

Krisis pangan adalah kondisi ketika terjadi gangguan serius dan berkepanjangan pada ketersediaan, akses, atau konsumsi pangan yang menyebabkan populasi tidak mampu memenuhi kebutuhan pangan untuk hidup sehat. Krisis pangan ditandai oleh terjadinya kesenjangan konsumsi pangan yang signifikan, meningkatnya malnutrisi serta penggunaan sragi bertahan hidup ekstrem seperti mengurangi frekuensi makan atau menjual aset penting [1]. Krisis pangan atau ketahanan pangan menjadi isu global yang berdampak besar terhadap stabilitas sosial, ekonomi, dan politik suatu negara. Hal ini muncul ketika pasokan pangan tidak mencukupi kebutuhan masyarakat, baik karena keterbatasan produksi maupun hambatan distribusi[2].

Menurut data Badan Pusat Statistik (BPS) pada tahun 2020 terdapat sebanyak 19,16 juta orang atau sekitar 7,38% dari total penduduk Indonesia yang mengalami krisis pangan. Angka ini lebih tinggi dibandingkan dengan tahun sebelumnya yaitu sebesar 9,8 juta orang atau sekitar 3,76% dari total penduduk pada tahun 2019 [3]. Berdasarkan prevalensi ketidakcukupan konsumsi pangan yang dilakukan oleh Badan Pusat Statistik (BPS), melaporkan bahwa pada tahun 2023 ketidakcukupan konsumsi pangan dengan persentase terbesar sebesar 35,63% adalah provinsi Papua, diikuti oleh Maluku sebesar 30,27% dan Nusa Tenggara Timur sebesar 14,98%. Hasil tersebut menunjukkan bahwa provinsi Nusa Tenggara Timur memiliki kerentanan pangan yang tergolong tinggi di Indonesia[4].

Nusa Tenggara Timur menjadi salah satu provinsi di Indonesia yang memiliki tingkat kerentanan pangan tinggi dengan 12 kabupaten wilayah NTT termasuk daerah yang rentan terhadap kerawanan pangan. Kerentanan pangan di Nusa Tenggara Timur terjadi karena beberapa faktor, seperti bencana kekeringan dan kemiskinan. Kekeringan sering terjadi karena NTT terletak di selatan khatulistiwa, tepatnya di 8°-12° Lintang Selatan dan 118°-125° Bujur Timur, hal ini menyebabkan provinsi NTT memiliki kondisi wilayah yang kering karena pengaruh dari angin muson timur[5][6]. Menurut laporan Badan Pusat Statistik, kekeringan telah terjadi di lima dari 22 kabupaten/kota di NTT yang masuk kategori darurat kekeringan pada Juli 2019, dan kondisi ini berdampak pada sebanyak 63,5 Ha lahan dari 689 hektare lahan padi mengalami gagal panen [7]. Selain itu tingkat kemiskinan di Nusa Tenggara Timur juga berdampak pada kerentanan pangan, tingkat kemiskinan yang mencapai 21,21% pada tahun 2020 turut memperkuat kerentanan pangan rumah tangga, mengingat keterbatasan daya beli berpengaruh langsung terhadap kemampuan masyarakat mengakses pangan bergizi.

Penelitian ini sebelumnya telah membahas mengenai upaya prediksi terhadap ketahanan pangan yang terjadi di beberapa negara bahkan kota. Salah satu studi yang dilakukan oleh Joris J.L. Wettersveld dkk, memanfaatkan data terbuka dari berbagai repositori global yang mencakup 130 variabel prediktor (iklim, lahan, pasar, konflik, infrastruktur, demografi, dan karakteristik zona mata pencaharian) di Ethiopia, dalam periode 2010 hingga 2018. Tujuan utama penelitian adalah untuk memprediksi transisi kondisi keamanan pangan, apakah membaik, tetap, atau memburuk dengan

menggunakan algoritma Extreme Gradient Boosting (XGBoost). Hasil model menunjukkan bahwa kinerjanya lebih baik dalam prediksi jangka panjang (hingga 7 bulan, skor F1 rata-rata 0,61) dibandingkan dengan jangka pendek (3 bulan, skor F1 rata-rata 0,51)[8].

Berdasarkan penelitian sebelumnya, maka dalam penelitian ini akan dilakukan pengembangan model prediksi risiko krisis pangan menggunakan algoritma XGBoost dengan optimalisasi. Berbeda dari penelitian sebelumnya yang berfokus pada transisi keamanan pangan di Ethiopia dengan menggunakan data global berskala luas, penelitian ini memberikan kontribusi orisinal dengan menerapkan XGBoost pada konteks lokal Indonesia, khususnya Nusa Tenggara Timur. Penelitian ini menggabungkan data iklim dari Google Earth Engine dengan data harga beras lokal, dengan variabel numerik seperti *precip* (curah hujan), *tempm* (temperature/suhu udara), *LST* (Land Surface Temperature/suhu permukaan tanah), *NDVI* (Normalized Difference Vegetation Index/indeks vegetasi), *rain* (jumlah hari hujan dalam sebulan), *soilm* (Soil Moisture / kelembapan tanah), dan harga pasar komoditas beras. Selain itu, terdapat variabel kategorik seperti bulan dan nama kota/kab yang ada di Nusa Tenggara Timur, sehingga menghasilkan model prediksi risiko krisis pangan yang lebih terarah dan sesuai dengan karakteristik wilayah setempat. Output yang akan dihasilkan dari penelitian ini adalah sistem prediksi yang digunakan untuk memprediksi risiko krisis pangan dan pemetaan wilayah yang memiliki risiko rawan krisis pangan.

## **2. TINJAUAN PUSTAKA**

Ketahanan pangan merupakan salah satu isu strategis di Indonesia, terutama di wilayah yang memiliki tingkat kerentanan ekologis tinggi seperti Provinsi Nusa Tenggara Timur (NTT). Di Indonesia, rawan pangan didefinisikan dalam Undang-Undang No. 18 Tahun 2012 sebagai keadaan ketika kebutuhan pangan masyarakat tidak terpenuhi karena ketersediaan yang tidak cukup[9][10].

Pada penelitian yang dilakukan oleh Frederic Morado Saragih dan Wahyu Catur tahun 2025 menggunakan skor indeks keamanan pangan (FSI), perbandingan konsumsi dan persediaan pangan, persentase penduduk miskin dari periode tahun 2018 hingga 2024 sebagai atribut data analisis. Penelitian ini dilakukan untuk mengembangkan dan mengevaluasi model machine learning yang akurat dalam memprediksi Indeks Keamanan Pangan Indonesia. Hasil penelitian menunjukkan bahwa metode XGBoost merupakan model terbaik dalam prediksi FSI Indonesia dengan nilai  $R^2$  sebesar 0.978, RMSE sebesar 0.024, dan MAE sebesar 0.016[11]. Dalam artikel tersebut, terdapat persamaan pada penggunaan metode XGBoost, namun berfokus pada skala nasional & indeks FSI, sedangkan penelitian ini fokus pada NTT dan menggunakan variabel iklim (GEE) dan harga beras serta menghasilkan label risiko krisis pangan.

Penelitian oleh Ruben Cartuyvels, dkk menggunakan citra satelit Landsat-8 yang mencakup sekitar 800 ribu tile gambar dari 35 ribu lokasi di Somalia, dengan rentang waktu Mei 2013 hingga Maret 2020. Tujuan utama penelitian adalah untuk memprediksi tingkat ketidakamanan pangan (skor IPC) dengan pendekatan spatiotemporal self-

supervised learning (SSSL) yang memanfaatkan keterkaitan spasial dan temporal dalam citra satelit. Hasil model menunjukkan bahwa metode ini mampu meningkatkan kinerja prediksi secara signifikan dibandingkan baseline, dengan macro F1 mencapai 65,4%, atau meningkat 24% dibandingkan fitur buatan (handcrafted features)[12]. Perbedaan penelitian ini dengan penelitian kali ini terletak pada data yang digunakan, pada penelitian di atas menggunakan citra satelit resolusi tinggi & deep learning, serta dengan pendekatan spasiotemporal. Sedangkan pada penelitian kali ini menggunakan variabel iklim dan harga, serta model machine learning tabular (XGBoost).

Penelitian lain oleh Vida Faiza dan Vita Ratnasari yang berfokus pada ketahanan pangan di Jawa Timur dengan menggunakan delapan variable predictor dan satu variable respon yang berifat kategori ketahanan pangan. Penelitian ini bertujuan untuk memodelkan dan memetakan tingkat ketahanan pangan di kabupaten/kota di Jawa Timur, serta memahami faktor-faktor yang mempengaruhi ketahanan pangan. Berdasarkan penelitian ini diketahui bahwa model GWOLR menjadi model terbaik dengan tingkat akurasi klasifikasi sebesar 94,7%, model ini menyatakan bahwa terdapat lima variabel predictor yang berpengaruh signifikan terhadap tingkat ketahanan pangan di Jawa Timur[13]. Penelitian ini memiliki kesamaan yang berfokus pada ketahanan pangan, namun berbeda dalam metode dan fokus wilayah penelitian. Penelitian tersebut berfokus pada ketahanan pangan Jawa Timur & variabel FSVA, sedangkan penelitian kali ini memprediksi berbasis variabel iklim dan harga beras, serta dikembangkan menggunakan metode XGBoost. Sebagai referensi dalam penelitian ini, beberapa perbandingan penelitian terdahulu diuraikan dalam Tabel 1.

Tabel 1. Perbandingan Penelitian Terdahulu

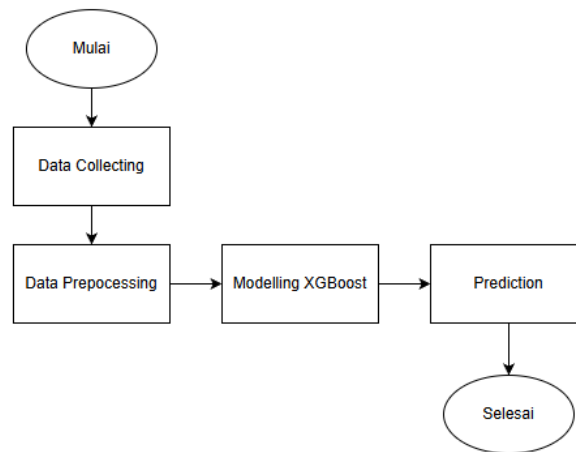
No	Peneliti	Metode	Hasil
1.	Frederic Morado Saragih dan Wahyu Catur	XGBoost	Akurasi tinggi ( $R^2$ 0.978) untuk prediksi FSI nasional
2.	Ruben Cartuyvels, dkk	SSSL (Deep Learning, Citra Landsat)	Macro F1 65,4%; peningkatan 24% dari baseline
3.	Vida Faiza dan Vita Ratnasari	GWOLR	Akurasi 94,7% untuk ketahanan pangan Jawa Timur

Berdasarkan beberapa penelitian yang telah dilakukan, penelitian ini berfokus pada prediksi krisis pangan di Provinsi Nusa Tenggara Timur dengan tujuan memprediksi kota/kabupaten di Nusa Tenggara Timur yang termasuk kategori rawan krisis pangan atau tidak, sehingga dapat digunakan sebagai himbuan dan mengambil solusi preventif.

### 3. METODE PENELITIAN

Penelitian ini dilakukan untuk memprediksi krisis pangan di kota/kabupaten Nusa Tenggara Timur menggunakan metode XGBoost dengan beberapa variabel yang berpengaruh terhadap prediksi krisis pangan, meliputi Kota/Kab, NDVI, LST, dan harga pangan. Secara keseluruhan penelitian, yang terdiri dari lima tahapan utama, yaitu pengumpulan data, praproses data, pemodelan, evaluasi, dan prediksi daerah krisis

pangan. Proses dimulai dengan pengumpulan data satelit dan ekonomi, kemudian dilanjutkan dengan praproses data yang meliputi penanganan data hilang, encoding, serta pengecekan keseimbangan data. Secara sistematis alur penelitian digambarkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

### 3.1. Data Collecting

*Data collecting* atau pengumpulan data dilakukan secara sekunder dengan melakukan *scrapping* dari Google Earth Engine (GEE), serta data harga pangan untuk Provinsi Nusa Tenggara Timur yang dapat diakses dan diunduh dari situs resmi Badan Pangan Nasional (BPN). Kedua data ini memiliki karakteristik yang berbeda, dimana data satelit memberikan informasi spasial dan temporal mengenai kondisi lingkungan, sementara data harga pangan mencerminkan kondisi ekonomi atau pasar dengan ketersediaan serta stabilitas pangan di wilayah Nusa Tenggara Timur. Kemudian setelah data diperoleh, dilakukan rekapitulasi data dengan menyatukan kedua data tersebut dalam satu tabel terstruktur. Seluruh proses ini dilakukan untuk mempermudah proses analisis lanjutan dan memastikan bahwa sumber data dapat diolah secara bersamaan.

### 3.2. Data Preprocessing

Data Preprocessing atau data praproses merupakan tahap mengolah data mentah menjadi data yang siap digunakan untuk analisis, pada tahap ini dilakukan beberapa perlakuan antara lain:

#### 3.2.1. Pemeriksaan kesalahan data

Missing value adalah kondisi nilai hilang pada data, sehingga perlu dilakukan perlakuan khusus. Pada data penelitian ini dilakukan penanganan missing value pada tabel harga bahan pangan dengan menghitung rata-rata harga untuk mengisi nilai harga yang kosong. Selain missing value, juga dilakukan pengecekan pada data duplikasi. Penanganan yang dilakukan yakni menghapus salah satu data duplikasi agar tidak terjadi keranduan dalam proses analisis. Proses ini bertujuan untuk memastikan bahwa data

yang digunakan dalam analisis bersifat akurat, konsisten, dan dapat dipertanggungjawabkan sehingga hasil penelitian lebih reliabel.

### 3.2.2. Pembentukan kategori

Setelah data sudah dipastikan bersih dan dapat diandalkan, maka tahap selanjutnya adalah melakukan pembentukan kategori ketahanan pangan. Pembagian kategori ketahanan pangan dalam penelitian ini dilakukan dengan pendekatan kuantitatif berbasis Z-Score untuk menilai tingkat penyimpangan setiap variabel dari kondisi normalnya. Variabel-variabel seperti curah hujan (precip), NDVI, kelembapan tanah, suhu permukaan (LST), dan harga beras dihitung nilai Z-Score-nya, kemudian diberi skor biner (0 = normal, 1 = bermasalah) berdasarkan ambang batas yang mencerminkan kondisi stres, misalnya  $NDVI\_z < -0.5$  atau  $harga\_z > 1$  yang menunjukkan gangguan signifikan. Setiap variabel selanjutnya diberikan bobot sesuai kontribusinya terhadap kerawanan pangan: ketersediaan (NDVI dan curah hujan) masing-masing 0.4, faktor lingkungan (kelembapan tanah dan LST) masing-masing 0.3, serta akses pangan melalui harga sebesar 0.3. Skor terintegrasi ini dinormalisasi menjadi rentang 0–100 untuk menghasilkan *Composite Score*, yang kemudian dipetakan ke kategori mirip klasifikasi IPC: <25 (Aman), 25–49 (Waspada), 50–74 (Krisis), dan  $\geq 75$  (Darurat). Kategori tersebut memberikan gambaran tingkat keparahan risiko krisis pangan berbasis indikator objektif dan terukur..

### 3.2.3. Imbalanced data

Dalam penelitian ini, penulis akan memastikan bahwa distribusi data antara antarkategori dalam proporsi yang seimbang sesuai kebutuhan analisis. Selanjutnya, pada setiap kategori, dilakukan eksplorasi dengan melakukan pengecekan proporsi tiap kategori. Informasi mengenai banyaknya jumlah distribusi tiap kategori tersebut kemudian dijadikan dasar dalam proses penyeimbangan kelas menggunakan metode SMOTE.

## 3.3. Modelling XGBoost

Dalam penelitian ini menggunakan algoritma XGBoost karena kemampuannya dalam menangani berbagai jenis variabel baik numerik maupun kategorik. Berikut tahapan pembangunan model XGBoost untuk prediksi krisis pangan di Nusa Tenggara Timur:

#### a. Pembagian dataset

Pembagian dataset dilakukan dengan metode hold out, yaitu memisahkan dataset ke dalam dua subset utama. Pemisahan ini terdiri dari data pelatihan dan data pengujian dengan perbandingan 80% banding 20%. Data pelatihan digunakan untuk membangun dan menyesuaikan model, sedangkan data pengujian dimanfaatkan untuk menilai sejauh mana model mampu melakukan prediksi terhadap data yang belum diketahui (data yang tidak termasuk dalam proses pelatihan).

#### b. Evaluasi model

Setelah pemisahan model, maka model mulai dibangun dan selanjutnya adalah melakukan evaluasi model untuk mengetahui performa atau kinerja model dalam

analisis data dan memprediksi krisis pangan. Pada tahap ini, *confusion matrix* digunakan untuk menghitung berbagai metrik evaluasi, seperti akurasi, presisi, recall, dan F1-score, yang memberikan gambaran seberapa baik model dalam memprediksi kondisi pangan di wilayah Nusa Tenggara Timur.

#### 4. HASIL DAN PEMBAHASAN

Dalam penelitian ini dilakukan pemodelan prediksi risiko krisis pangan di Provinsi Nusa Tenggara Timur, hasil yang ditampilkan meliputi kinerja model dan hasil prediksi pada data aktual. Dalam penelitian ini, data yang akan digunakan adalah data sekunder yang dikumpulkan melalui proses scraping data satelit yang tersedia di Google Earth Engine serta data harga pangan Provinsi Nusa Tenggara Timur yang diunduh dari situs resmi Badan Pangan Nasional. Data tersebut kemudian direkap dalam bentuk tabel dengan menyatukannya dalam satu data agar lebih mudah dianalisis. Tabel yang digunakan dalam penelitian ini memuat berbagai variabel penting yang berkaitan dengan krisis pangan. Variabel-variabel tersebut akan diuraikan dalam Tabel 2.

Tabel 2. Variabel Data Penelitian

No	Variabel	Tipe Data	Keterangan
1.	Kab/Kota	String	Kab/Kota di NTT
2.	Bulan	String	Periode waktu penelitian
3.	Precip	Integer	Curah hujan rata-rata
4.	Temp	Integer	Suhu rata-rata
5.	LST	Integer	Suhu permukaan tanah
6.	NDVI	Integer	Indeks vegetasi
7.	Rainfall	Integer	Jumlah curah hujan bulanan
8.	Soil	Integer	Jenis tanah pada wilayah pengamatan
9.	Harga Pangan	Integer	Harga rata-rata komoditas pangan
10.	Kategori	String	Kategori/kelas krisis pangan

Data yang digunakan dalam penelitian ini terdiri dari variabel-variabel yang mewakili dua aspek utama, yaitu aspek iklim dan aspek sosial-ekonomi. Setelah seluruh data dikumpulkan dari berbagai sumber, dilakukan proses penggabungan sehingga diperoleh satu set data terpadu yang berjumlah 961 baris untuk periode tahun 2020 hingga 2024. Selanjutnya, data tersebut melalui tahap *preprocessing* yang mencakup pemeriksaan serta penanganan *missing value* dan duplikasi data. *Missing value* pada variabel harga pangan ditangani menggunakan metode imputasi rata-rata, yaitu dengan menghitung nilai rata-rata harga komoditas pada bulan yang sama untuk mengisi data yang hilang. Tahap ini dilakukan untuk memastikan kualitas dan konsistensi data sebelum masuk ke proses pemodelan. Pengelompokan kelas dilakukan dengan menggunakan dua tahap, yakni dengan Z-Score untuk mengidentifikasi kondisi stres pada masing-masing indikator, seperti rendahnya NDVI, curah hujan, atau tingginya harga beras. dengan rumus

$$Z = \frac{x - \mu}{\sigma}$$

dimana:

$x$ : nilai data individu

$\mu$ : mean

$\sigma$ : standar deviasi

Dalam penelitian ini proses ini diawali dengan perhitungan Z-Score untuk menstandarkan seluruh variabel, setiap variabel kemudian diberi skor berdasarkan ambang batas yang mewakili tiga aspek utama: ketersediaan, keterpaparan, dan akses. Skor tersebut digabungkan menggunakan bobot tertentu hingga menghasilkan skor komposit dalam rentang 0–100. Berdasarkan skor akhir ini, kondisi ketahanan pangan diklasifikasikan ke dalam empat kategori, yaitu aman sebanyak 373, waspada sebesar 119, krisis sebanyak 74, dan darurat sebanyak 202.

Penyeimbangan data dilakukan dengan menggunakan SMOTE pendekatan *versampling*, yakni dengan menambahkan data untuk kelas minoritas. Teknik ini berfungsi untuk memperbanyak sampel pada kategori dengan jumlah data yang lebih sedikit sehingga distribusi antar kelas menjadi lebih proporsional. Dengan adanya tahap penyeimbangan ini, diharapkan model prediksi dapat bekerja secara lebih adil dan menghasilkan keluaran yang akurat untuk setiap kategori krisis pangan. Pada tahap ini dihasilkan setelah *oversampling* jumlah distribusi kelas adalah 373, nilai ini sudah seimbang antara seluruh kategori.

Pembentukan model dilakukan menggunakan perbandingan 80% data pelatihan dan 20% data uji, dan dihasilkan akurasi sebesar 93%. Nilai ini mengindikasikan bahwa model berhasil mengklasifikasikan kondisi ketahanan pangan dengan tingkat kesalahan yang relatif rendah dengan performa model dijabarkan dalam Gambar 2.

Classification report:				
	precision	recall	f1-score	support
Aman	0.98	0.97	0.97	93
Darurat	0.93	0.97	0.95	29
Krisis	0.80	0.84	0.82	19
Waspada	0.92	0.90	0.91	51
accuracy			0.94	192
macro avg	0.91	0.92	0.91	192
weighted avg	0.94	0.94	0.94	192

Gambar 2 Performa Model

Secara lebih rinci, *classification report* memperlihatkan bahwa kategori Aman memiliki performa terbaik dengan precision 0,98 dan recall 0,97, yang mencerminkan bahwa model mampu mengenali kelas ini dengan sangat konsisten. Hal ini dapat terjadi karena kelas Aman memiliki jumlah sampel terbesar sehingga pola datanya lebih mudah dipelajari oleh model. Pembahasan terhadap hasil penelitian dan pengujian yang diperoleh disajikan dalam bentuk uraian teoritis, baik secara kualitatif maupun kuantitatif.



Untuk kategori darurat, model menunjukkan hasil yang kuat dengan f1-score 0,95, menandakan kemampuan identifikasi yang sangat baik meskipun jumlah sampelnya lebih sedikit. Sementara itu, kategori Krisis memiliki nilai precision 0,80 dan recall 0,84, yang merupakan performa terendah di antara seluruh kelas. Kondisi ini dapat disebabkan oleh jumlah data Krisis yang jauh lebih sedikit sehingga variasi pola lebih terbatas, serta adanya kemiripan karakteristik dengan kelas Waspada atau Darurat yang meningkatkan risiko misclassification. Kategori waspada sendiri memperoleh f1-score 0,91, menunjukkan bahwa model cukup efektif dalam membedakan kondisi wilayah yang berada dalam zona kewaspadaan.

Selain itu nilai *Confusion matrix* pada Gambar 3 mengonfirmasi pola tersebut, dimana model mampu mengklasifikasikan mayoritas data secara tepat dan kesalahan prediksi terbesar terjadi pada kategori Krisis, di mana sebagian kecil data diklasifikasikan sebagai Waspada atau Darurat. Selain itu, terdapat juga beberapa kasus Waspada yang salah diklasifikasikan sebagai Aman, yang mengindikasikan adanya potensi tumpang tindih indikator pada dua kondisi tersebut.

**Confusion Matrix:**  

$$\begin{bmatrix} 90 & 0 & 0 & 3 \\ 0 & 28 & 1 & 0 \\ 0 & 2 & 16 & 1 \\ 2 & 0 & 3 & 46 \end{bmatrix}$$

Gambar 3. Confusion Matrix


Hal lain juga ditunjukkan dalam Tabel 3, dimana perbandingan antara nilai aktual dan hasil prediksi pada data uji juga menunjukkan konsistensi performa model. Sebagian besar label prediksi sesuai dengan kondisi aktual, terutama pada kategori Aman, Waspada, dan Krisis. Hanya satu kasus misclassification yang cukup signifikan, yaitu data Darurat pada tahun 2020 bulan Mei yang diprediksi sebagai Krisis. Hal ini menunjukkan bahwa model terkadang menempatkan kondisi Darurat dan Krisis dalam spektrum risiko yang berdekatan.

Tabel 3. Hasil Prediksi Krisis Pangan

tahun	bulan	Aktual	Prediksi
2020	4	Aman	Aman
2021	5	Waspada	Waspada
2023	1	Aman	Aman
2024	3	Aman	Aman

.	.	.	.
.	.	.	.
.	.	.	.
2020	5	Darurat	Krisis
2021	11	Aman	Aman
2022	1	Aman	Aman
2023	2	Aman	Aman

Setelah model konsisten dalam melakukan prediksi, maka dilakukan analisis *feature importance* XGBoost untuk mengidentifikasi variabel-variabel yang paling berpengaruh dalam prediksi krisis pangan. Berdasarkan Gambar 4 diketahui bahwa faktor yang paling dominan memengaruhi variabel target adalah Soil\_z, diikuti oleh NDVI\_z dan precip\_z. Hal ini mengindikasikan bahwa kondisi tanah dan vegetasi memberikan kontribusi terbesar terhadap variasi target.



Gambar 4. Feature Importance Model

Selain analisis tersebut, ditampilkan pula visualisasi geospasial pada Gambar 5 yang memberikan gambaran persebaran kondisi risiko krisis pangan pada setiap kabupaten/kota di Nusa Tenggara Timur.

Peta Risiko Krisis Pangan di Provinsi Nusa Tenggara Timur (Prediksi XGBoost)



Gambar 5. Visualisasi Geospasial Hasil Prediksi Risiko Krisis Pangan

Secara keseluruhan, hasil ini membuktikan bahwa model XGBoost efektif digunakan untuk memprediksi tingkat risiko krisis pangan. Kinerja model yang tinggi menunjukkan bahwa variabel-variabel yang digunakan mampu menggambarkan dinamika kerawanan pangan dengan baik. Meski demikian, performa pada kelas dengan jumlah sampel sedikit masih perlu ditingkatkan, salah satunya melalui penyeimbangan data (*resampling*) atau penambahan variabel yang lebih representatif.

## 5. KESIMPULAN

Penelitian ini mengembangkan model prediksi risiko krisis pangan menggunakan algoritma XGBoost dengan hasil pemodelan menggunakan XGBoost menunjukkan bahwa algoritma ini memiliki kemampuan prediksi yang sangat baik dalam mengklasifikasikan tingkat risiko krisis pangan di Nusa Tenggara Timur, dengan akurasi mencapai 93.75%. Model mampu mengenali kategori Aman dan Darurat dengan sangat tinggi, sementara kategori Krisis memiliki akurasi lebih rendah karena keterbatasan jumlah sampel dan kemiripan karakteristik dengan kelas lain. Confusion matrix menegaskan bahwa sebagian besar data berhasil diprediksi secara tepat, sehingga model ini unggul dalam konsistensi dan sensitivitas terhadap pola kerawanan pangan. Namun demikian, performanya masih terbatas pada kelas dengan data yang tidak seimbang. Ke depannya, penelitian dapat dikembangkan melalui penyeimbangan dataset, penambahan variabel lingkungan dan sosial yang lebih komprehensif, serta pengujian model lain untuk meningkatkan akurasi pada kategori risiko tinggi seperti Krisis.

## DAFTAR PUSTAKA

- [1] FAO, IFAD, UNICEF, WFP, and WHO, "The state of food security and nutrition in the world 2021," Food and Agriculture Organization, 2021.
- [2] FAO, *An introduction to the basic concepts of food security*. Food and Agriculture Organization of the United Nations, 2008.
- [3] Sa. Winata and S. Rado, "Tantangan pangan dan energi indonesia masa depan," 2020.
- [4] T. Ditinjau and D. Ketersediaan, "PROYEKSI KETAHANAN PANGAN PROVINSI NUSA TENGGARA TIMUR," vol. 18, no. 1, pp. 80–91, 2021.
- [5] R. Pratama, N. Januriyadi, and R. Pamungkas, "Analisis Indeks Kekeringan Provinsi Nusa Tenggara Timur ( NTT )," vol. 1, no. 1, pp. 24–34, 2022, doi:

- <https://doi.org/10.61078/jsi.v1i1.4>.
- [6] N. Anna and Kadir, "Determinan Status Kerawanan Pangan Rumah Tangga di Nusa Tenggara Timur 2021," no. 2020, pp. 257–266, 2021, doi: 10.5300/JSTAR.V3I01.38.
  - [7] Y. P. K. Suni, J. Sujono, and P. D. Severity, "Analisis kekeringan menggunakan metode spi dan pdsi pada daerah aliran sungai liliba," vol. 11, no. 1, pp. 91–104, 2022.
  - [8] J. J. L. Westerveld, M. J. C. Van Den Homberg, G. Guimarães, D. L. J. Van Den Berg, A. D. Teklesadik, and S. M. Stuit, "Science of the Total Environment Forecasting transitions in the state of food security with machine learning using transferable features," *Sci. Total Environ.*, vol. 786, p. 147366, 2021, doi: 10.1016/j.scitotenv.2021.147366.
  - [9] N. Zahra and R. Ramadani, "Analisis yuridis terhadap undang-undang no . 18 tahun 2012 tentang ketahanan pangan pada keluarga miskin dalam perspektif maqasid syariah," vol. 9, no. 2, pp. 683–691, 2023.
  - [10] R. Indonesia, *Undang-Undang Nomor 18 Tahun 2012 tentang Pangan*. 2012. [Online]. Available: <https://bphn.go.id/data/documents/12uu018.pdf>
  - [11] F. M. Saragih and W. C. Wibowo, "Analysis of Food Security Index Predictions in Indonesia using Machine Learning Approach," *J. Agro*, 2025, doi: <https://doi.org/10.37637/ab.v8i2.2302>.
  - [12] R. Cartuyvels, T. Fierens, E. Coppieters, M. Moens, and D. Sileo, "Spatiotemporal self-supervised pre-training on satellite imagery improves food insecurity prediction," pp. 1–25, 2023, doi: 10.1017/eds.2023.42.
  - [13] V. Faiza and V. Ratnasari, "Pemodelan Ketahanan Pangan di Jawa Timur Ordinal Logistic Regression ( GWOLR )," vol. 8, no. 2, 2019, doi: 10.12962/j23373520.v8i2.47021.