

Analisis Prediktif Ketahanan Pangan Berbasis Data Spasial Dengan Metode *Random Forest* Dan *Cellular Automata* Di Provinsi Nusa Tenggara Timur

Yulia Shafira Butar-Butar, Opim Salim Sitompul*, Amalia Amalia

Magister Sains Data dan Kecerdasan Buatan, Fakultas Ilmu Komputer dan Teknologi Informasi,
Universitas Sumatera Utara, Medan, Indonesia

Email: ¹yuliashafira@students.usu.ac.id, ^{2*}opim@usu.ac.id, ³amalia@usu.ac.id

Email Penulis Korespondensi: opim@usu.ac.id

Submitted 15-10-2025; Accepted 31-10-2025; Published 31-10-2025

Abstrak

Ketahanan pangan menjadi salah satu perhatian utama dalam pembangunan berkelanjutan, terlebih di wilayah seperti Provinsi Nusa Tenggara Timur (NTT) yang rentan terhadap kekeringan dan perubahan penggunaan lahan. Penelitian ini mencoba menjawab tantangan tersebut dengan memanfaatkan data spasial dan algoritma prediktif untuk melihat potensi ketahanan pangan di tahun 2030. Dua pendekatan digunakan: model *Cellular Automata–Artificial Neural Network* (CA–ANN) untuk memetakan perubahan tutupan lahan, serta *Random Forest Regressor* untuk memperkirakan produktivitas padi berdasarkan kondisi lingkungan seperti NDVI, suhu permukaan, curah hujan, elevasi, dan kemiringan lereng. Hasil simulasi menunjukkan bahwa model CA–ANN mampu memprediksi perubahan lahan dengan akurasi spasial sebesar 87,6%, di mana terlihat adanya penurunan lahan pertanian di sejumlah wilayah. Sementara itu, model *Random Forest* menghasilkan prediksi dengan nilai R^2 sebesar 0,90 dan RMSE 1,74, menunjukkan kinerja yang baik dalam memetakan faktor-faktor yang memengaruhi hasil panen. Proyeksi tahun 2030 memperlihatkan adanya defisit beras sebesar 221 ribu ton. Temuan ini menjadi sinyal penting bagi pemerintah daerah dan pemangku kebijakan untuk mulai mempertimbangkan pendekatan berbasis data dalam menyusun strategi ketahanan pangan jangka panjang.

Kata Kunci: Ketahanan Pangan; Nusa Tenggara Timur; Prediksi Padi; Random Forest; Cellular Automata; Data Spasial

Abstract

Food security remains a key concern in sustainable development, especially in regions like East Nusa Tenggara (NTT) that are prone to drought and land conversion. This study aims to explore future food security in NTT by applying spatial data and predictive models to forecast conditions in 2030. Two main approaches were used: the Cellular Automata–Artificial Neural Network (CA–ANN) model to simulate land cover changes, and the Random Forest Regressor to predict rice productivity using environmental variables such as NDVI, land surface temperature, rainfall, elevation, and slope. The CA–ANN model showed strong spatial accuracy at 87.6%, with results indicating a decrease in cropland in several areas. The Random Forest model performed well with an R^2 of 0.90 and RMSE of 1.74, highlighting elevation and temperature as key drivers of productivity. By 2030, projections suggest a rice deficit of 221,000 tons, equivalent to more than 790 billion kilocalories. These findings underscore the urgency for local governments to adopt data-driven approaches when planning for sustainable food security in the years ahead.

Keywords: Food Security; East Nusa Tenggara; Rice Prediction; Random Forest; Cellular Automata; Spatial Data

1. PENDAHULUAN

Ketahanan pangan merupakan salah satu isu strategis nasional yang menjadi prioritas dalam agenda pembangunan berkelanjutan (*Sustainable Development Goals/SDGs*), khususnya pada tujuan 2 yaitu *Zero Hunger* [1]. Ketahanan pangan tidak hanya mencakup ketersediaan pangan, tetapi juga akses dan stabilitasnya dalam jangka panjang [2]. Dalam konteks pertumbuhan penduduk, perubahan iklim, dan alih fungsi lahan yang semakin masif, Indonesia menghadapi tantangan yang tidak ringan dalam menjaga ketahanan pangan, terutama di wilayah-wilayah rentan secara geografis dan ekonomi [3].

Salah satu wilayah yang menghadapi ancaman serius terhadap ketahanan pangan adalah Provinsi Nusa Tenggara Timur (NTT). Berdasarkan *Food Security and Vulnerability Atlas* (FSVA) yang diterbitkan oleh Bappenas bersama *World Food Programme* (WFP), NTT secara konsisten dikategorikan sebagai provinsi dengan tingkat kerentanan pangan tinggi. Beberapa kabupaten bahkan termasuk dalam kelompok defisit pangan kronis [4]. Faktor-faktor seperti curah hujan yang rendah dan tidak merata, kondisi lahan yang berbukit-bukit, serta keterbatasan infrastruktur distribusi pangan antarwilayah memperparah tantangan tersebut. Situasi ini menuntut adanya pendekatan analitis berbasis data spasial untuk memahami dan memetakan risiko ketahanan pangan secara lebih akurat [5].

Pemilihan Provinsi NTT sebagai wilayah studi dalam penelitian ini dilatarbelakangi oleh urgensi dan kompleksitas permasalahan yang dihadapi. Kondisi iklim semi-kering, keterbatasan lahan pertanian produktif, dan kerentanan terhadap kekeringan menjadikan NTT sebagai wilayah yang tepat untuk diterapkannya model prediktif ketahanan pangan berbasis data spasial [6]. Sebuah laporan dari *Resilience Development Initiative* (RDI) mencatat bahwa kekeringan ekstrem yang terjadi selama tahun 2023–2024 mengakibatkan gagal panen pada komoditas utama seperti padi dan jagung, serta kekurangan air untuk peternakan. Dampak lanjutannya adalah defisit beras sebesar lebih dari 211 ribu ton pada tahun 2022, yang memaksa pemerintah daerah mengandalkan pasokan dari luar wilayah [7].

Dalam menjawab tantangan tersebut, pendekatan berbasis *data science* menjadi semakin relevan. Penelitian ini mengintegrasikan dua pendekatan utama, yaitu algoritma *Random Forest* dan model *Cellular Automata*. *Random Forest* digunakan untuk memprediksi produktivitas padi berdasarkan data lingkungan seperti *Normalized Difference Vegetation*

Index (NDVI), *Land Surface Temperature* (LST), curah hujan, elevasi, dan kemiringan lereng (*slope*) [8]. Algoritma ini dipilih karena mampu menangani data kompleks dan menghasilkan prediksi yang andal dengan tingkat akurasi tinggi [9]. Sebelumnya, berbagai penelitian telah berhasil menggabungkan pendekatan data spasial, penginderaan jauh, dan metode statistik atau machine learning untuk memodelkan dan memprediksi aspek-aspek ketahanan pangan [10].

Penelitian oleh Virtriana et al. (2022) mengembangkan model prediksi ketahanan pangan di Provinsi Jawa Barat dengan mengintegrasikan regresi multivariat untuk memprediksi produktivitas padi dan CA-Markov untuk perubahan tutupan lahan sawah. Hasilnya menunjukkan penurunan sawah sebesar 31% dan prediksi defisit energi pada tahun 2030, dengan akurasi model yang tinggi [11]. Kemudian, Devkota et al. (2024) menggabungkan data penginderaan jauh, survei lapangan, dan algoritma Random Forest untuk memetakan kesenjangan hasil panen gandum di Maroko. Model prediksi memiliki akurasi tinggi ($R^2 > 0.75$) dan mampu mengidentifikasi faktor-faktor lingkungan yang signifikan. Lebih lanjut, Sarastika et al. (2023) menggunakan pendekatan *Artificial Neural Network–Cellular Automata* (ANN–CA) untuk memodelkan perubahan tutupan lahan pertanian, dan model mereka menunjukkan akurasi prediksi spasial hingga 90% [12].

Berdasarkan beberapa penelitian terdahulu tersebut, terlihat bahwa metode Cellular Automata baik dalam bentuk CA-Markov maupun CA-ANN telah terbukti efektif dalam memodelkan dinamika perubahan lahan secara spasial. Kemudian, model statistik dan machine learning seperti Regresi Linear dan Random Forest yang digunakan mampu memetakan faktor-faktor determinan produktivitas padi maupun ketahanan pangan dengan akurasi yang baik [13]. Meskipun demikian, sebagian besar penelitian sebelumnya masih terbatas pada wilayah dengan karakteristik agroklimat basah dan belum banyak yang mengaplikasikan integrasi model CA–ANN dan *Random Forest* pada wilayah semi-kering seperti Nusa Tenggara Timur (NTT). Selain itu, studi-studi terdahulu cenderung menggunakan satu pendekatan tunggal, seperti CA-Markov atau regresi spasial, tanpa menghubungkan perubahan tutupan lahan dengan prediksi produktivitas tanaman secara simultan [14].

Dengan demikian, penelitian ini memiliki perbedaan yang jelas dibandingkan dengan penelitian sebelumnya karena mengintegrasikan dua pendekatan utama, yaitu *Cellular Automata–Artificial Neural Network* (CA–ANN) dan Random Forest Regression, dalam satu kerangka analisis prediktif ketahanan pangan berbasis data spasial. Pendekatan ini diaplikasikan pada wilayah semi-arid dengan tingkat kerentanan tinggi, yakni Provinsi Nusa Tenggara Timur, untuk memproyeksikan kondisi ketahanan pangan tahun 2030. Integrasi dua model ini juga menjadi pembeda utama dari penelitian terdahulu yang umumnya hanya menggunakan model CA–Markov atau regresi multivariat secara terpisah. Oleh karena itu, penelitian ini diharapkan dapat memperluas pemahaman mengenai penerapan machine learning dan simulasi spasial untuk mendukung analisis ketahanan pangan di wilayah marginal serta memberikan dasar ilmiah bagi pengambilan keputusan berbasis data di tingkat daerah [15].

2. METODOLOGI PENELITIAN

2.1 Data

Penelitian ini menggunakan data yang dikumpulkan dari berbagai sumber terpercaya, seperti citra penginderaan jauh, data spasial batas administrasi kota/kabupaten, serta data statistik pertanian dan kependudukan di Provinsi Nusa Tenggara Timur. Data yang digunakan terdiri dari:

Tabel 1. Data yang Digunakan


No.	Jenis Data	Sumber	Format	Keterangan
1	NDVI (Normalized Difference Vegetation Index)	MODIS/006/MOD13 Q1	Raster (TIFF)	Resolusi asli 250 m, di-resample ke 500 m. Indikator kondisi vegetasi.
2	LST (Land Surface Temperature)	MODIS/006/MOD11 A2	Raster (TIFF)	Suhu permukaan tanah. Resolusi 1 km, disesuaikan ke 500 m.
3	Curah Hujan	UCSB-CHG/CHIRPS/DAILY	Raster (TIFF)	Resolusi ~5 km, diinterpolasi dan disesuaikan ke 500 m. Rata-rata tahunan.
4	Elevasi dan Kemiringan (Slope)	USGS/SRTMGL1_003	Raster (TIFF)	DEM resolusi 30 m. Kemiringan dihitung dan disesuaikan ke 500 m.
5	Produktivitas Padi (ku/ha)	Badan Pusat Statistik (BPS)	Tabular (CSV)	Data per kabupaten/kota 2018–2024. Target pada model Random Forest.
6	Tutupan Lahan Historis (2010, 2015, 2020)	MODIS/061/MCD12 Q1	Raster (TIFF)	Klasifikasi lahan global. Digunakan untuk pelatihan CA–ANN.
7	Data Penduduk	BPS	Tabular (CSV)	Proyeksi konsumsi pangan per kabupaten/kota tahun 2030.
8	Administrasi Wilayah	BIG (Badan Informasi Geospasial) Indonesia	Vektor (SHP)	Batas kabupaten/kota di Provinsi NTT.

9	Jaringan Jalan	BIG (Skala 1:250.000)	Vektor (SHP)	Untuk variabel pengaruh aksesibilitas dalam simulasi perubahan lahan.
---	----------------	-----------------------	--------------	---

Seluruh data spasial dalam penelitian ini telah dikonversi ke sistem koordinat WGS 84 (EPSG:4326) untuk menjaga konsistensi spasial dalam proses pemrosesan dan analisis data. Ukuran piksel raster disesuaikan menjadi 0,00449 derajat, yang secara spasial ekuivalen dengan resolusi 500 meter, guna memastikan keseragaman resolusi antar lapisan data spasial. Penyesuaian ini penting untuk menjaga validitas integrasi antar data, terutama dalam analisis regresi spasial dan pemodelan *Cellular Automata–Artificial Neural Network* (CA–ANN) [16].

2.2 Arsitektur Umum

Arsitektur umum yang dapat dilihat dari gambar 1. berikut ini:



Gambar 1. Arsitektur Umum

Berikut ini penjelasan dari Gambar 1.:

a. Pra-pemrosesan Data Tutupan Lahan

Data tutupan lahan untuk tahun 2010, 2015, dan 2020 diperoleh dari *Google Earth Engine* (GEE) menggunakan produk *MODIS Land Cover Type Yearly Global 500m* (MCD12Q1 Version 6.1) yang menyediakan klasifikasi tutupan lahan tahunan di seluruh dunia. Proses pemrosesan dilakukan untuk menyederhanakan klasifikasi lahan menjadi 8 kelas utama dan menyesuaikan format raster dengan kebutuhan analisis spasial.

1. Sumber Data

- Data batas wilayah Kota/Kabupaten di Provinsi Nusa Tenggara Timur diambil dari Badan Informasi Geospasial (BIG) Indonesia
- Dataset Tutupan Lahan: MODIS/061/MCD12Q1 diakses dari (https://developers.google.com/earth-engine/datasets/catalog/MODIS_061_MCD12Q1?hl=id)
- Resolusi spasial asli: 500 meter
- Jalur akses: *Google Earth Engine* (GEE)

2. Wilayah Cakupan

Data dibatasi menggunakan *shapefile* wilayah Provinsi Nusa Tenggara Timur (NTT) yang telah diunggah ke GEE (ntt_fixed). Kemudian dilakukan pemotongan (*clip*) berdasarkan *bounding box* untuk efisiensi pemrosesan dan ekspor data.

3. Klasifikasi Ulang (Reklasifikasi)

Berdasarkan dataset MODIS/061/MCD12Q1 layer LC_Type1 dari MODIS memiliki 17 kelas asli. Untuk kepentingan analisis, dilakukan reklasifikasi menjadi 8 kelas utama menggunakan fungsi remap() dalam GEE.

4. Ekspor dan Format

Citra hasil reklasifikasi diekspor dalam format GeoTIFF dengan resolusi 500 meter. Sistem koordinat menggunakan EPSG:4326 (WGS 84) untuk kompatibilitas dengan dataset lain. Proses ekspor dilakukan melalui perintah Export.image.toDrive() di *Google Earth Engine*. Selanjutnya, untuk menyamakan geometri dengan data file shp NTT yang sudah dimiliki, maka perlu dilakukan *Raster Extraction* pada setiap *Land Cover* yang sudah di-download

b. Pra-pemrosesan Data Elevasi dan Slope

1. Elevasi

Elevasi dan kemiringan lahan (*slope*) merupakan variabel fisiografis utama yang memengaruhi kesesuaian lahan untuk pertanian. Dalam konteks penelitian ini, data elevasi dan slope digunakan dalam dua skenario pemanfaatan sebagai *driving factors* dalam simulasi perubahan tutupan lahan menggunakan *Cellular Automata-Artificial Neural Network* (CA-ANN), dan sebagai variabel prediktor dalam model regresi produktivitas padi berbasis *Random Forest*.

2. Raster

Raster hasil (elevasi dan slope) kemudian diekspor dalam format .tif untuk digunakan dalam simulasi perubahan tutupan lahan di perangkat lunak GIS atau lingkungan pemrograman spasial seperti QGIS atau TerrSet. DEM (*Digital Elevation Model*).

c. Pra-pemrosesan Data Jaringan Jalan Nusa Tenggara Timur

Dalam penelitian ini, jaringan jalan digunakan sebagai salah satu *driving factor* dalam simulasi perubahan tutupan lahan menggunakan model *Cellular Automata – Artificial Neural Network* (CA-ANN). Aksesibilitas terhadap jalan merupakan faktor penting yang memengaruhi konversi lahan pertanian ke penggunaan lain, seperti permukiman atau kawasan pembangunan lainnya. Area yang dekat dengan jalan cenderung lebih rentan mengalami perubahan tutupan lahan karena lebih mudah dijangkau oleh pembangunan infrastruktur [17].

d. Pra-pemrosesan Variabel yang Mempengaruhi Produktivitas Padi

1. Elevasi

Berikut adalah daftar lengkap jenis data spasial dan tabular yang digunakan dalam penelitian ini beserta sumber, format, dan keterangan singkat.

Tabel 1. Nilai Rata-rata Elevasi

No	WADMKK	dem_mean
1	Alor	462,32
2	Belu	484,49
3	Flores Timur	298,3
...	...	...
22	Sumba Barat Daya	231,41

Tabel 1 merangkum seluruh dataset yang menjadi basis analisis: variabel input seperti NDVI, LST, curah hujan, elevasi, slope, produktivitas padi, tutupan lahan historis, data penduduk, batas administrasi, dan jaringan jalan. Kolom “Sumber” menunjukkan asal data (mis. MODIS, BPS, BIG), sedangkan kolom “Format” memberi informasi jenis file (raster/tiff, shp, csv) yang penting untuk prosedur pra-pemrosesan. Untuk pembacaan dan replikasi, perhatikan resolusi spasial dan penyesuaian yang disebut pada Tabel 1. informasi ini mengarahkan konversi dan re-proyeksi ke EPSG:4326 serta resampling ke resolusi 500 m. Tabel 1. berfungsi sebagai rujukan operasional ketika menjelaskan langkah pra-pemrosesan dan integrasi antar-lapisan dalam metodologi.

2. Slope

Tabel berikut menyajikan nilai rata-rata elevasi (dem_mean) untuk setiap kabupaten/kota di Provinsi Nusa Tenggara Timur.

Tabel 2. Nilai Digital Elevation Model NTT

No	WADMKK	Slope_Mean
1	Alor	9,19
2	Belu	5,21
3	Flores Timur	8,49
...	...	...
22	Sumba Barat Daya	2,5

Tabel 2 menampilkan rata-rata elevasi (meter) per wilayah administratif. Nilai-nilai ini digunakan sebagai prediktor fisik dalam model *Random Forest*. Elevasi berperan pada ketersediaan air, kesesuaian lahan, dan temperatur mikro faktor yang tepat untuk dijadikan variabel utama ketika mengaitkan kondisi fisiografis dengan produktivitas padi. Interpretasi pada hasil harus mengaitkan variabilitas produktivitas antar-kabupaten dengan perbedaan elevasi yang tertera pada Tabel 2.

3. *NDVI (Normalized Difference Vegetation Index)*

Tabel di bawah menunjukkan nilai NDVI tahunan (2010–2024) yang diambil untuk setiap kabupaten/kota sebagai indikator kondisi vegetasi.

Tabel 3. Nilai NDVI 2010-2024

No	WADMKK	NDVI							
		2010	2011	2012	2013	2014	2015	...	2024
1	Alor	0,7161	0,6613	0,6571	0,702	0,6609	0,6771	...	0,6173
2	Belu	0,6792	0,5935	0,593	0,6254	0,5797	0,5896	...	0,6392
3	Flores Timur	0,7473	0,6807	0,6841	0,7004	0,7094	0,6984	...	0,6393
...	...	...	...	...	...	...	...	...	...
22	Sumba Barat Daya	0,7223	0,6555	0,6733	0,6834	0,6666	0,6644	...	0,5525

Tabel 3 memuat rangkaian nilai NDVI yang telah di aggregrasi per tahun untuk tiap kabupaten. NDVI merefleksikan kesehatan tutupan vegetasi dan menjadi variabel penting dalam model *Random Forest* untuk memprediksi produktivitas padi. Pada pembahasan, rujuk perubahan tren NDVI pada Tabel 3. untuk menjelaskan fluktuasi nilai produktivitas historis atau anomali yang muncul pada periode tertentu (mis. pengurangan NDVI yang berkorespon dengan penurunan produktivitas). Pastikan pembaca diarahkan ke korelasi antar-NDVI dan hasil model seperti yang direpresentasikan di bagian Evaluasi dan *Feature Importance*.

4. *LST (Land Surface Temperature)*

Berikut tabel nilai rata-rata suhu permukaan (LST) tahunan untuk tiap kabupaten/kota selama periode 2010–2024.

Tabel 4. Nilai *Land Surface Temperatur* 2010-2024

No	WADMKK	LST							
		2010	2011	2012	2013	2014	2015	...	2024
1	Alor	26,59	27,37	27,94	27,38	28,3	28,33	...	25,98
2	Belu	28,76	30,6	31,1	30,1	31,57	31,76	...	28,9
3	Flores Timur	27,23	27,4	27,98	27,39	28,34	28,64	...	26,08
...	...	...	...	...	...	...	...	...	...
22	Sumba Barat Daya	28,47	29,78	30,19	29,63	30,77	30,94	...	28,08

Tabel 4 memperlihatkan deret waktu LST yang digunakan sebagai salah satu predictor dalam *Random Forest*. LST berpengaruh terhadap fisiologi tanaman dan potensi stres panas sehingga perubahan LST pada Tabel 4. harus dikaitkan dengan variabilitas produktivitas padi. Gunakan Tabel 4 untuk membenarkan mengapa *lst_mean* muncul sebagai salah satu fitur penting dalam model.

5. Curah Hujan

Tabel berikut menyajikan data curah hujan tahunan (2010–2024) yang telah diaggregrasi per kabupaten/kota.

Tabel 5. Nilai Rata-rata Curah Hujan 2010-2024

No	WADMKK	Curah Hujan							
		2010	2011	2012	2013	2014	2015	...	2024
1	Alor	1777,49	1689,41	1384,87	1576	1155,7	1069,76	...	1389,71
2	Belu	2541,08	2482,21	1736,42	2116,36	1474,35	1394,2	...	2024,61
3	Flores Timur	1832,11	1756,63	1487,94	1854,87	1283,76	1199,38	...	1524,37
...	...	...	...	...	...	...	...	...	...
22	Sumba Barat Daya	2402,69	2059,52	1871,63	2093,26	1410,96	1674,54	...	1781,46

Curah hujan (*rain_mean*) adalah variabel meteorologis penting yang mempengaruhi ketersediaan air untuk pertumbuhan padi. Tabel 5. memperlihatkan tren spasial dan temporal distribusi curah hujan. Dalam analisis, kaitkan nilai pada Tabel 5. dengan estimasi produktivitas padi 2010–2024 dan proyeksi 2030; fluktuasi hujan dapat menjelaskan sebagian variasi model dan menjadi basis interpretasi untuk simulasi defisit. Tabel ini juga berguna saat mendiskusikan keterbatasan data (mis. skala, interpolasi CHIRPS) dan asumsi pemrosesan.

Untuk menjaga keseragaman spasial dan format semua raster telah disesuaikan ke resolusi 500 meter. Sistem koordinat dikonversi ke EPSG:4326 (WGS 84) agar sesuai dengan data vektor administratif. Data hasil pemrosesan berupa tabel agregasi tahunan per kabupaten yang siap digunakan dalam pemodelan statistik dan spasial [18]. Tabel di

bawah merinci variabel yang diambil dari Google Earth Engine (GEE), termasuk seleksi band, skala konversi, dan transformasi yang dilakukan.

Tabel 6. Dataset yang Digunakan dari GEE

Variabel	Sumber Data	Seleksi Data	Konversi Data	Transformasi Data
NDVI	MODIS/006/MOD13A1	Filter tahun dan band NDVI	Skala dikalikan 0.0001	Rata-rata kabupaten/tahun, ekspor CSV
LST (°C)	MODIS/006/MOD11A2	Filter tahun dan band LST_Day_1km	Skala $\times 0.02$, -273.15 untuk konversi ke °C	Rata-rata kabupaten/tahun, ekspor CSV
Curah Hujan	UCSB-CHG/CHIRPS/DAILY	Filter tahun dan band precipitation	Agregasi total tahunan, skala spasial 500 m	Rata-rata kabupaten/tahun, ekspor CSV

Tabel 6 menjelaskan langkah-langkah transformasi data dari GEE — mis. nilai skala untuk NDVI, konversi LST, agregasi tahunan CHIRPS. Informasi ini penting untuk reproduksibilitas: pembaca akan mengetahui bagaimana nilai mentah dikonversi menjadi variabel siap-pakai (mis. NDVI $\times 0.0001$, LST offset -273.15). Hubungkan penjelasan Tabel 6. dengan bagian 2.1 Pra-pemrosesan dan jelaskan implikasi transformasi terhadap akurasi model (mis. penurunan resolusi, *smoothing*) pada bagian pembahasan.


2.3 Proses

Tahapan inti dalam penelitian ini melibatkan serangkaian proses pemodelan spasial dan prediktif untuk menghasilkan proyeksi ketahanan pangan tahun 2030 di Provinsi Nusa Tenggara Timur (NTT). Proses ini terdiri dari empat langkah utama, yaitu [19]:

- Simulasi perubahan tutupan lahan menggunakan *Cellular Automata–Artificial Neural Network* (CA–ANN)
- Prediksi produktivitas padi berbasis lingkungan dengan *Random Forest Regressor*.
- Estimasi ketersediaan energi pangan berdasarkan hasil produksi padi.
- Prediksi kebutuhan energi pangan berdasarkan proyeksi jumlah penduduk tahun 2030.

2.4 Input Data Tutupan Lahan dan Driving Factors

Gambar 2 menunjukkan *lapisan input* (*driving factors*) yang dimasukkan ke modul simulasi CA–ANN.




Gambar 2. Input Untuk Melakukan Simulasi Prediksi Tutupan Lahan

Gambar 2 memvisualisasikan peta-peta *input* seperti peta tutupan lahan historis, peta elevasi, peta *slope*, peta jaringan jalan, dan layer aksesibilitas yang digunakan sebagai *driving factors*. Gunakan Gambar 2. untuk menjelaskan bagaimana setiap layer mempengaruhi *transition potential modelling* (bagian 2.4–2.7). Dalam pembahasan, kaitkan fitur-fitur ini dengan hasil *evaluating correlation* (Gambar 4) dan berikan contoh bagaimana kedekatan dengan jalan (aksesibilitas) meningkatkan probabilitas konversi lahan. Setelah mengisi input pada *Molusce*, perlu dilakukan *check*

geometry untuk melihat apakah geometri masing-masing data peta raster yang telah di-input sama. Jika geometri tidak sesuai maka tidak bisa dilakukan proses lanjutan.

Gambar 3 memperlihatkan langkah pengecekan kesesuaian geometri antara lapisan raster sebelum proses lebih lanjut.




Gambar 3. Melakukan Pengecekan Geometry Data Raster

Gambar 3 menampilkan antarmuka (mis. Molusce/QGIS) saat melakukan pengecekan geometry. Penjelasan harus menyoroti pentingnya keseragaman extent, resolusi, dan CRS untuk menghindari kesalahan saat ekstraksi nilai dan overlay. Kaitkan Gambar 3 dengan prosedur pra-pemrosesan (bagian 2.1) dan jelaskan konsekuensi apabila geometri tidak disesuaikan (mis. pergeseran spasial yang menyebabkan mismatch antara variabel predictor dan target).

2.5 Evaluating Correlation

Selanjutnya masuk ke *evaluating correlation*, untuk mengidentifikasi dan mengukur seberapa kuat hubungan atau ketergantungan antara variabel-variabel pendorong perubahan lahan (*driving factors*) dengan perubahan penggunaan lahan itu sendiri [20]. Gambar 4 menampilkan matriks korelasi atau plot korelasi antara beberapa driving factors yang diuji pada tahap evaluasi korelasi.




Gambar 4. Hasil *Evaluating Correlation* diantara 3 *Driving Factors*

Gambar 4 menunjukkan hubungan statistik antar-variabel (mis. korelasi antara slope, dem_mean, ndvi, lst, rain). Dalam interpretasi, tunjukkan pasangan variabel yang berkorelasi tinggi dan jelaskan implikasinya (mis. multikolinearitas) terhadap pemilihan fitur di model *Random Forest* dan CA-ANN. Gambar 4. saat menjelaskan langkah *feature selection* atau transformasi lanjutan yang mungkin diperlukan.

2.6 Area Changes

Selanjutnya masuk ke *Area Changes*, yang digunakan untuk melihat dinamika perubahan penggunaan lahan historis sebelum melakukan pemodelan dan simulasi. Gambar 5 menyajikan statistik kelas tutupan lahan historis serta matriks transisi yang menunjukkan perubahan antar kelas dari 2010 ke 2015 dan 2015 ke 2020.




Gambar 5. Nilai Class Statistic dan Transition Matrix

Gambar 5 memberi ringkasan jumlah area per kelas (*class statistics*) dan probabilitas transisi antar-kelas (*transition matrix*). Jelaskan bagaimana matriks transisi menjadi input utama dalam *modelling* CA sehingga dapat mengestimasi kemungkinan konversi dari *cropland* ke kelas lain. Di pembahasan hasil, Gambar 5 untuk mendukung klaim tentang area yang paling rentan terhadap kehilangan lahan pertanian.

2.7 Transition Potensial Modelling

Tahap ini adalah inti dari pemodelan perubahan penggunaan lahan berbasis CA-ANN. Dengan kata lain, model ini belajar dari pola perubahan masa lalu untuk memprediksi di mana dan dengan probabilitas seberapa besar suatu perubahan lahan akan terjadi di masa depan. Gambar 6 memperlihatkan peta probabilitas (*transition potential*) yang dihasilkan oleh model pembelajaran (CA-ANN) bersama parameter-parameter kunci.




Gambar 6. Hasil dan Paramater Transition Potential Modelling

Gambar 6 memvisualkan peta potensi transisi, yang memberi probabilitas spasial terjadinya perubahan tutupan lahan di masa depan. Terangkan parameter CA-ANN yang ditetapkan (mis. jumlah iterasi, neighborhood rule, learning rate jika relevan) serta bagaimana peta ini digunakan sebagai dasar simulasi Cellular Automata. Kaitkan hasil ini dengan validasi spasial (Gambar 8) untuk menunjukkan konsistensi model.

2.8 Simulasi Cellular Automata

Gambar 7 menampilkan salah satu output simulasi tutupan lahan (contoh: hasil simulasi untuk tahun 2020) yang dibandingkan dengan peta referensi.



Gambar 7. Peta Raster Simulasi Tutupan Lahan 2020

Gambar 7 menunjukkan peta hasil simulasi CA-ANN (SR_dem_2020.tif) yang ditujukan untuk divalidasi terhadap peta rujukan (LULC_NTT_2020.tif). Gunakan Gambar 7 saat membahas akurasi spasial dan titik-titik area yang tumpang tindih atau salah prediksi, sebagai input pada sesi validasi. Peta ini dibandingkan dengan Peta Hasil Simulasi (SR_dem_2020.tif) yang merupakan luaran dari tahapan Cellular Automata Simulation. Validasi dilakukan dengan 5 iterasi, yang mengindikasikan bahwa proses perbandingan diulang beberapa kali untuk menghasilkan metrik yang lebih robust. Gambar 8 menyajikan hasil validasi model CA-ANN dalam bentuk kurva multi-resolusi dan metrik Kappa untuk menilai akurasi spasial.



Gambar 8. Validasi Model

Gambar 8 menampilkan grafik perbandingan observasi vs simulasi pada berbagai resolusi spasial dan metrik Kappa yang menunjukkan keselarasan klasifikasi. Interpretasikan posisi garis observasi (merah/ungu) terhadap garis simulasi (hijau) untuk menunjukkan performa model: garis observasi jauh diatas garis hijau mengindikasikan model baik. Sebutkan bagaimana metrik ini mendukung klaim akurasi 87,6% yang dicantumkan di kesimpulan. Jika ada variasi akurasi antar-resolusi, jelaskan implikasinya terhadap keandalan proyeksi 2030.

2.9 Prediksi Produktivitas Padi Tahun 2030 dengan *Random Forest*

Setelah diperoleh estimasi distribusi lahan pertanian tahun 2030, tahap berikutnya adalah memprediksi nilai produktivitas padi menggunakan algoritma *Random Forest Regressor*. Model ini digunakan karena keunggulannya dalam menangani hubungan *non-linear* dan data spasial multivariat tanpa memerlukan asumsi distribusi data. Data yang digunakan meliputi data produktivitas padi per kabupaten/kota di Provinsi Nusa Tenggara Timur (2010–2024), diperoleh dari Badan Pusat Statistik (BPS) dengan link akses <https://ntt.bps.go.id>. Tabel berikut menyajikan data produktivitas padi teragregasi (kuintal per hektar) untuk periode 2018–2024 setiap kabupaten/kota di NTT.

Tabel 7. Produktivitas Padi Nusa Tenggara Timur 2018-2024 (Ku/Ha)

No.	Kabupaten/Kota	Produktivitas (Ku/Ha)						
		2018	2019	2020	2021	2022	2023	2024
1	Alor	20,90	31,33	35,10	33,61	29,93	31,70	30,45
2	Belu	41,17	35,84	26,50	42,83	43,38	32,52	31,44
3	Flores Timur	34,42	32,40	34,06	25,96	22,89	21,23	20,36
...	...	...	...	...	...	...	...	...
22	Sumba Barat Daya	26,16	26,35	27,10	33,85	37,08	34,74	30,21

Tabel 7 adalah sumber nilai target (*dependent variable*) untuk pelatihan *Random Forest*. Tabel ini memungkinkan pembaca melihat variasi spasial dan temporal produktivitas, mendeteksi *outlier*, serta memahami distribusi target yang mempengaruhi performa model (R^2 dan RMSE). Saat merujuk ke validasi model dan metrik akurasi, Tabel 7. untuk konteks nilai-nilai aktual yang dibandingkan dengan prediksi 2030.

Pohon keputusan untuk regresi memilih pemisahan yang meminimalkan varians dari target (produktivitas) di setiap node. Langkah-langkahnya adalah:

a. Hitung Varians Awal:

Varians dari produktivitas di node akar:

$$\text{Varians} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$$

dengan y_i adalah nilai produktivitas dan $\bar{y}$ adalah rata-rata produktivitas.

Rata-rata produktivitas:

$$\bar{Y} = \frac{39.0577+39.7989+38.8995+38.8554+38.0995}{5} = 38.9422$$

- Varians =


$$\begin{aligned} & \frac{(39.0577-38.9422)^2+(39.7989-38.9422)^2+(38.8995-38.9422)^2+(38.8554-38.9422)^2+(38.0995-38.9422)^2}{5} \\ &= \frac{(0.1155)^2+(0.8567)^2+(-0.0427)^2+(-0.0868)^2+(-0.8427)^2}{5} \\ &= \frac{0.01333+0.7339+0.001823+0.007534+0.7103}{5} \\ &= \frac{1.4669}{5} = 0.2933 \end{aligned}$$

Contoh urutan data berdasarkan nilai *lst_mean* yang digunakan dalam ilustrasi perhitungan varians dan pemisahan node pada algoritma pohon keputusan untuk regresi.

Tabel 8. Urutan data berdasarkan *lst_mean*

<i>lst_mean</i>	produktivitas
26.59	39.0577
27.37	39.7989
27.38	38.8554
27.94	38.8995
28.30	38.0995

Tabel 8. berfungsi sebagai ilustrasi langkah numerik yang mendasari pembuatan pohon keputusan (bagian penjelasan internal model). Tabel ini menunjukkan bagaimana data disusun berdasarkan *lst_mean* saat menghitung varians awal dan pemisahan node.



Gambar 9. Hasil Validasi dan Akurasi *Random Forest*

Gambar 9 memvisualisasikan scatter plot nilai observasi versus prediksi model *Random Forest*, menunjukkan tingkat kecocokan dan distribusi residual. Interpretasikan $R^2 = 0.904$ dan $RMSE = 1.74$: tingginya R^2 menunjukkan model

menjelaskan sebagian besar variasi produktivitas, sedangkan RMSE menunjukkan kesalahan rata-rata prediksi dalam satuan ku/ha. Gunakan Gambar 9 untuk membahas area-area dimana model cenderung over/under-predict dan kaitkan dengan heterogenitas data di Tabel 7.

Tabel ringkasan berikut memuat nilai produktivitas padi yang diprediksi oleh model *Random Forest* untuk tahun 2030 per kabupaten/kota.

Tabel 9. Prediksi Produktivitas Padi 2030

No	WADMKK	Tahun	Ku/Ha
1	Ngada	2030	47,35
2	Kupang	2030	45,86
3	Manggarai	2030	45,86
...	...	...	...
22	Flores Timur	2030	27,35

Tabel 9 memaparkan keluaran model (prediksi ku/ha 2030). Gunakan tabel ini untuk menunjukkan distribusi prediksi mengidentifikasi wilayah dengan peningkatan signifikan (contoh: Ngada, Kupang, Manggarai) maupun yang stagnan/menurun (mis. Flores Timur). Di pembahasan, hubungkan nilai di Tabel 9 dengan hasil simulasi perubahan lahan (luas cropland dari CA-ANN) untuk menjelaskan perhitungan produksi total dan estimasi defisit energi pangan.

Berikut disajikan ranking kepentingan fitur (feature importance) hasil model *Random Forest* yang digunakan untuk memprediksi produktivitas padi.

Tabel 10. Feature Importance

Feature	Importance
dem_mean	0,2439
lst_mean	0,2147
rain_mean	0,2062
slope_mean	0,1315

Tabel 10 menunjukkan kontribusi relatif tiap variabel (dem_mean, lst_mean, rain_mean, slope_mean, ndvi_mean jika tercantum) terhadap prediksi. Interpretasi tabel ini harus mengaitkan peringkat pentingitas dengan fenomena fisik: misalnya, dominasi dem_mean menunjukkan pengaruh topografi terhadap produktivitas, sedangkan lst_mean dan rain_mean mencerminkan peran iklim. Dalam diskusi, gunakan Tabel 10 untuk mendukung klaim mengapa variabel-variabel tertentu menjadi fokus kebijakan atau intervensi. Dari analisis *Feature Importance*, elevasi rata-rata (dem_mean) merupakan faktor paling dominan yang memengaruhi produktivitas padi. Disusul secara signifikan oleh suhu permukaan lahan (lst_mean), curah hujan (rain_mean), dan indeks vegetasi (ndvi_mean), yang menunjukkan peran krusial kondisi iklim dan kesehatan tanaman. Sementara itu, kemiringan lahan (slope_mean) memiliki pengaruh paling rendah di antara fitur-fitur yang dievaluasi.


3. HASIL DAN PEMBAHASAN

3.1 Estimasi Produktivitas Padi 2030


Produktivitas padi diprediksi menggunakan *Random Forest* untuk masing-masing Kabupaten/Kota di Provinsi Nusa Tenggara Timur. Tabel ini memuat metrik kinerja model (R^2 historis dan RMSE historis) untuk setiap kabupaten/kota sebagai ukuran kecocokan antara prediksi historis dan data observasi. Hasil yang didapatkan per Kabupaten/Kota adalah:

Tabel 11. Evaluasi Estimasi Produktivitas Padi per Kabupaten/Kota

No.	Nama Kabupaten/Kota	No.	Nama Kabupaten/Kota
1	Alor (R^2 Historis: 0,87, RMSE Historis: 1,80)	12	Ende (R^2 Historis: 0,83, RMSE Historis: 2,25)




Produktivitas Padi di Alor
(R^2 Historis: 0,87, RMSE Historis: 1,80)




Produktivitas Padi di Ende
(R^2 Historis: 0,83, RMSE Historis: 2,25)


2 Belu (R^2 Historis: 0,89, RMSE Historis: 1,86)




13 Malaka (R^2 Historis: 0,81, RMSE Historis: 1,21)




3 Flores Timur (R^2 Historis: 0,92, RMSE Historis: 1,77)




14 Lembata (R^2 Historis: 0,83, RMSE Historis: 1,72)



11 Timor Tengah Utara (R^2 Historis: 0,78, RMSE Historis: 1,42)



22 Sumba Barat Daya (R^2 Historis: 0,78, RMSE Historis: 2,42)



Tabel 11 memberikan metrik evaluatif per wilayah sehingga pembaca dapat melihat performa model secara lokal. R^2 dan RMSE historis membantu menentukan daerah-daerah di mana model bekerja dengan baik (R^2 tinggi, RMSE rendah) versus daerah yang hasil prediksinya kurang andal. Penjelasan ini penting untuk membatasi generalisasi; misalnya, jika R^2 rendah di beberapa kabupaten, diskusikan penyebab potensial (data bising, skala agregasi, heterogenitas lahan) dan implikasinya pada proyeksi 2030. Secara keseluruhan, model prediksi produktivitas padi menunjukkan kinerja yang sangat baik, terbukti dari nilai R-squared (R^2) sebesar 0.904 dan RMSE 1.74. Ini berarti model mampu menjelaskan sebagian besar variasi produktivitas aktual dan memiliki tingkat kesalahan prediksi yang rendah. Distribusi *error* yang normal juga menegaskan keandalan model, tanpa adanya bias sistematis.

3.2 Estimasi Produktivitas Padi 2030

3.2.1 Estimasi Ketersediaan Energi Pangan Tahun 2030

Setelah produktivitas padi diprediksi, langkah selanjutnya adalah mengalikan produktivitas tersebut dengan luas lahan pertanian (hasil simulasi CA-ANN) untuk memperoleh total produksi padi:

$$\text{Produksi Padi (kg)} = \text{Luas Cropland (ha)} \times \text{Produktivitas (kg/ha)} \times 100$$

Hasil akhir dari tahap ini berupa total energi pangan yang tersedia dari produksi padi di masing-masing kabupaten untuk tahun 2030. Tabel berikut menunjukkan estimasi produksi padi (ton) dan nilai energi (kalori) yang dihasilkan per kabupaten untuk tahun 2030 berdasarkan kombinasi luas cropland hasil simulasi CA-ANN dan produktivitas prediksi Random Forest.


Tabel 12. Produksi Padi (Ton)

No	WADMKK	Tahun	Ton	Kal
1	Alor	2030	818,16	2.920.831.200
2	Belu	2030	15.089,69	53.870.193.300
3	Flores Timur	2030	5.006,87	17.874.525.900

...	...	...	...	...
22	Sumba Barat Daya	2030	41.534,34	148.277.593.800
		Total	562.910,69	2.009.591.163.300

Tabel 12 menggabungkan keluaran spasial (luas cropland 2030) dan nilai produktivitas per kabupaten untuk menghasilkan total produksi (ton) dan konversinya ke energi (kal). Ini adalah tabel kunci untuk menghitung ketersediaan energi pangan pada tahun 2030. Jelaskan langkah perhitungan ($\text{Produksi} = \text{Luas} \times \text{Produktivitas} \times 100$; konversi ke kalori menggunakan nilai kalori per kg/100 g beras) sehingga pembaca memahami asumsi konversi yang dipakai.

Gambar 10 memetakan estimasi ketersediaan energi pangan (dalam kalori atau ton beras) per kabupaten untuk tahun 2030 berdasarkan produksi padi yang diperkirakan.



Gambar 10. Peta Ketersediaan Pangan 2030

Gambar 10 adalah peta tematik yang menggabungkan output produksi (Tabel 12.) menjadi representasi spasial ketersediaan pangan. Jelaskan legenda peta (kelas surplus/defisit atau rentang ton/kalori), dan tunjukkan wilayah-wilayah dengan ketersediaan tinggi versus rendah. Rujuk peta ini ketika membahas wilayah prioritas intervensi kebijakan.

3.3 Prediksi Kebutuhan Energi Pangan Tahun 2030

Untuk mengukur kebutuhan energi pangan, digunakan metode yang dirujuk dari Virtriana et al. (2022). Kementerian Kesehatan Republik Indonesia merekomendasikan angka kecukupan gizi sebesar 2100 kalori per hari untuk masyarakat Indonesia, dengan 60% di antaranya dipenuhi dari sumber karbohidrat. Beras merupakan makanan pokok bagi masyarakat Indonesia, dan 100g beras menyediakan sekitar 357 kalori. Meskipun kebutuhan kalori tiap individu, seperti laki-laki, perempuan, dan anak-anak, memang berbeda-beda, penelitian ini menggunakan angka rata-rata yang telah ditetapkan tersebut untuk pemodelan kebutuhan pangan secara umum di wilayah kajian kebutuhan yaitu Nusa Tenggara Timur.

$$\text{Kebutuhan Energi (kal/tahun)} = \text{Populasi} \times 2100 \times 0.6 \times 365$$

Penjelasan:

- Populasi = Jumlah penduduk
- 2100 = rata-rata angka kecukupan gizi
- 0,6 = 60% karbohidrat
- 365 = jumlah hari/tahun

Jumlah penduduk tahun 2030 diproyeksikan menggunakan metode *regresi linier* berdasarkan data historis 2010–2024. Model menunjukkan bahwa total penduduk Provinsi NTT pada tahun 2030 diperkirakan mencapai ±6.088.124 jiwa. Dengan demikian, kebutuhan energi pangan dari padi dihitung sebagai:

$$6.088.124 \times 2.100 \times 0.6 \times 365 = 2.799.928.227.600 \text{ kal (784.293 Ton Beras)}$$


Tabel di bawah menunjukkan proyeksi populasi 2030 per kabupaten/kota dan estimasi kebutuhan energi pangan (kalori/tahun) yang dihitung berdasarkan asumsi angka kecukupan gizi nasional.

Tabel 13. Prediksi Kebutuhan Kalori Tahun 2030 Per Kab/Kota

No	Kota/Kabupaten	Prediksi Populasi 2030	Rata-rata Tingkat Pertumbuhan Tahunan (%)	Kebutuhan
1	Kota Kupang	538075	2,46	247.460.692.500
2	Timor Tengah Selatan	507521	0,88	233.408.907.900
3	Kupang	438544	1,67	201.686.385.600
...	...	...	...	...
22	Sumba Tengah	101555	2,87	46.705.144.500

Tabel 13 merinci prediksi populasi 2030 (metode regresi linier) beserta kebutuhan energi pangan dihitung sebagai: $\text{Populasi} \times 2100 \text{ kcal} \times 0.6 \times 365$. Tabel ini wajib dikaitkan dengan Tabel 12 untuk menghitung surplus/defisit pada masing-masing kabupaten. Tekankan asumsi 2100 kcal dan proporsi 60% dari karbohidrat; jika pembaca menanyakan skenario sensitif, arahkan mereka pada kemungkinan analisis sensitivitas (mis. variasi angka kecukupan) yang bisa memperbesar atau mengecilkan defisit.

Gambar 11 menunjukkan peta kebutuhan energi pangan (kalori/tahun) per kabupaten berdasarkan proyeksi populasi 2030.



Gambar 11. Peta Prediksi Kebutuhan Kalori 2030

Gambar 11. memvisualisasikan beban kebutuhan pangan spasial yang berasal dari Tabel 13. Bandingkan Gambar 11. dengan Gambar 10. (ketersediaan) untuk menilai kesenjangan spasial. Dalam pembahasan, gunakan kedua peta ini (Gambar 10 & 11) untuk menjelaskan indeks ketahanan pangan dan lokasi defisit terbesar.

3.4 Indeks Ketahanan Pangan

Berdasarkan metode yang menjadi rujukan *ISPRS International Journal of Geo-Information* dari Virtriana et al. (2022). Indeks ketahanan pangan dihitung dengan mencari selisih antara ketersediaan dan kebutuhan energi pangan:

$$\text{Indeks Ketahanan Pangan} = \text{Ketersediaan Energi} - \text{Kebutuhan Energi}$$

$$= 2.009.591.163.300 - 2.799.928.227.600 = -790.337.064.300 \text{ (-221383 Ton)}$$

Interpretasi indeks:


Indeks > 1 → Wilayah mengalami surplus energi pangan

Indeks = 1 → Kebutuhan dan ketersediaan seimbang

Indeks < 1 → Wilayah mengalami defisit energi pangan

Perhitungan dilakukan untuk seluruh kabupaten/kota di Provinsi NTT, sehingga diperoleh peta tematik ketahanan pangan tahun 2030.

Gambar 12 memperlihatkan peta tematik indeks ketahanan pangan (ketersediaan – kebutuhan) untuk Provinsi Nusa Tenggara Timur tahun 2030.



Gambar 12. Peta Raster Ketahanan Pangan Nusa Tenggara Timur 2030

Gambar 12 menyajikan hasil akhir analisis spasial: selisih antara ketersediaan energi dan kebutuhan (Indeks Ketahanan Pangan). Warna/kelas pada peta menunjukkan wilayah surplus, seimbang, dan defisit. Jelaskan kategori interpretasi (mis. Indeks > 0 = surplus; < 0 = defisit) dan arahkan pembaca ke nilai numerik ringkasan (total defisit 221.383 ton atau $-790.337.064.300$ kal) yang disajikan di Bab 3.4. Gunakan peta ini untuk merekomendasikan prioritas intervensi (peningkatan produksi lokal, distribusi antar-wilayah, dukungan impor sementara). Terlihat bahwa Manggarai Barat memiliki ketahanan pangan tertinggi, disusul dengan Manggarai dan Sumba Timur. Sementara untuk daerah lainnya masih dalam status rawan pangan, khususnya untuk daerah Timor Tengah Selatan, Kota Kupang, sangat butuh untuk disupport kebutuhan pangannya. Kebutuhan pangan ini juga didasari pada jumlah populasi yang ada pada daerah yang bersangkutan.

4. KESIMPULAN

Model CA-ANN mampu mensimulasikan perubahan tutupan lahan hingga tahun 2030 dengan akurasi validasi spasial yang cukup tinggi yaitu 87,6%. Proyeksi menunjukkan adanya penurunan lahan pertanian di sejumlah kabupaten akibat konversi lahan, terutama di wilayah perkotaan dan pesisir. Simulasi menggunakan data tahun 2010, 2015, dan 2020 menghasilkan prediksi tutupan lahan tahun 2030 yang digunakan sebagai dasar estimasi luas cropland. Model Random Forest menunjukkan performa yang baik dalam memprediksi produktivitas padi berbasis variabel lingkungan. Dengan R^2 validasi sebesar 0,90 dan RMSE sebesar 1,74, yang berarti model mampu mengidentifikasi hubungan yang signifikan antara NDVI, LST, curah hujan, elevasi, dan slope terhadap hasil produksi padi. Analisis *feature importance* menunjukkan elevasi rata-rata (*dem_mean*) merupakan faktor paling dominan yang memengaruhi produktivitas padi. Disusul secara signifikan oleh suhu permukaan lahan (*lst_mean*), curah hujan (*rain_mean*), dan indeks vegetasi (*ndvi_mean*), yang menunjukkan peran krusial kondisi iklim dan kesehatan tanaman. Sementara itu, kemiringan lahan (*slope_mean*) memiliki pengaruh paling rendah di antara fitur-fitur yang dievaluasi. Ketersediaan energi pangan dari produksi padi tahun 2030 diperkirakan tidak mencukupi kebutuhan populasi, terdapat deficit sebesar 221383 Ton Beras atau 790.337.064.300 Kal.

REFERENCES

- [1] W. S. Murni and H. Purnama, "Pengembangan Pola Tanam Tanaman Pangan dengan Introduksi Teknologi Kalender Tanam (KATAM) Terpadu," *Prosiding Seminar Nasional Lahan Suboptimal ke-8 Tahun 2020*, Oct. 2020.
- [2] N. Anwar and U. Jenderal Soedirman Jl Profesor, "INDONESIA'S REGIONAL FOOD SECURITY IN LIGHT OF THE IMPENDING GLOBAL FOOD CRISIS," *Trikonomika*, vol. 21, no. 2, pp. 101–110, 2022.
- [3] M. Amin, L. Budiman, and D. Suhendi, "RESILIENSI PENGUATAN KETAHANAN PANGAN DAERAH DI INDONESIA," *Jurnal Perlindungan Masyarakat Bestuur Praesidium*, vol. 01, no. 2, pp. 63–71, 2024.
- [4] G. Milligan, G. Nica-Avram, J. Harvey, and J. Goulding, "Foodinsecurity.london: Developing a food-insecurity prevalence map for London - a machine learning from food-sharing footprints," in *International Journal of Population Data Science*, Swansea University, 2024, p. 11. doi: 10.23889/ijpds.v9i4.2425.
- [5] M. G. Leto Bele, E. Mustikawati, P. Hermanto, and F. Fitriani, "Pemodelan Geographically Weighted Regression pada Kasus Stunting di Provinsi Nusa Tenggara Timur Tahun 2020," *Jurnal Statistika dan Aplikasinya*, vol. 6, no. 2, pp. 179–191, 2022.

- [6] K. P. Devkota, A. Bouasria, M. Devkota, and V. Nangia, "Predicting wheat yield gap and its determinants using remote sensing, machine learning, 2 and survey approaches in rainfed Mediterranean regions of Morocco 3 4." [Online]. Available: <https://ssrn.com/abstract=4732945>
- [7] R. Hidayat *et al.*, "Implementasi Algoritma Random Forest Regression Untuk Memprediksi Penjualan Produksi di Supermarket," *SIMKOM*, vol. 10, no. 1, pp. 101–109, Jan. 2025, doi: 10.51717/simkom.v10i1.703.
- [8] R. Arisandi, "PERBANDINGAN MODEL KLASIFIKASI RANDOM FOREST DENGAN RESAMPLING DAN TANPA RESAMPLING PADA PASIEN PENDERITA GAGAL JANTUNG," *Jurnal Gaussian*, vol. 12, no. 1, pp. 136–145, May 2023, doi: 10.14710/j.gauss.12.1.136-145.
- [9] B. Rizqi and M. D. M. Manessa, "TINJAUAN SISTEMATIS PRISMA: KONVERSI SAWAH MENGANCAM NERACA KETERSEDIAAN BERAS DI SUATU WILAYAH," *Jurnal Tanah dan Sumberdaya Lahan*, vol. 12, no. 2, pp. 333–346, Jul. 2025, doi: 10.21776/ub.jtsl.2025.012.2.11.
- [10] B. Janga, G. P. Asamani, Z. Sun, and N. Cristea, "A Review of Practical AI for Remote Sensing in Earth Sciences," Aug. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/rs15164112.
- [11] W. Setiawan, A. Habibi, A. R. Setiawan, C. Nathanael, N. Silvia, and A. Wahyudi, "Analisis Proyeksi Penggunaan Lahan Sawah untuk Kebutuhan dan Ketersediaan Beras di Kabupaten Jember Tahun 2032," *Tunas Agraria*, vol. 8, no. 2, pp. 219–235, May 2025, doi: 10.31292/jta.v8i2.440.
- [12] G. Mutiara Ayuningtias, T. Istnabi, and E. F. Rini, "Prediksi Perubahan Penggunaan Lahan pada Kawasan Pertanian Pangan Berkelanjutan di Suburban Selatan Kota Surakarta Menggunakan Pemodelan Spasial," *Desa-Kota: Jurnal Perencanaan Wilayah, Kota, dan Permukiman*, vol. 7, no. 1, pp. 175–187, 2025, doi: 10.20961/desa-kota.v7i1.91166.175-187.
- [13] S. Fadhilatun Nashriyah, M. Rahmaniati Makful, and Y. Puspita Devi, "GAMBARAN SPASIAL HUBUNGAN ANTARA FAKTOR LINGKUNGAN DAN EKONOMI DENGAN STUNTING BALITA DI PROVINSI NUSA TENGGARA TIMUR." [Online]. Available: <https://portalpk21.bkkbn.go.id/laporan/tabulasi>
- [14] H. Laksamana and E. Kurniati, "Analisis Faktor-Faktor yang Mempengaruhi Produksi Padi Petani Desa Sungai Solok Kecamatan Kuala Kampar Kabupaten Pelalawan," *AgriHumanis: Journal of Agriculture and Human Resource Development Studies*, vol. 3, no. 1, pp. 21–30, Apr. 2022, doi: 10.46575/agrihumanis.v3i1.133.
- [15] R. Virtriana *et al.*, "Development of Spatial Model for Food Security Prediction Using Remote Sensing Data in West Java, Indonesia," *ISPRS Int J Geoinf*, vol. 11, no. 5, May 2022, doi: 10.3390/ijgi11050284.
- [16] Y. Ngongo, N. Kotta, and P. R. Matitaputty, "Strengthening Archipelago Food Security and Food Sovereignty in ENT-Indonesia," in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, Jul. 2021. doi: 10.1088/1755-1315/803/1/012032.
- [17] M. Puspitasari, D. Akhmad, M. Peneliti, B. Pengkajian, T. Pertanian, and K. Barat, "ANALISIS FAKTOR YANG MEMENGARUHI PRODUKTIVITAS PADI DI KABUPATEN SAMBAS KALIMANTAN BARAT ANALYSIS OF FACTORS AFFECTING RICE PRODUCTIVITY IN SAMBAS DISTRICT, WEST KALIMANTAN," *Jurnal Pertanian Agros*, vol. 22, no. 2, 2020.
- [18] I. Y. Safitri, M. A. Tiro, and Ruliana, "Spatial Regression Analysis to See Factors Affecting Food Security at District Level in South Sulawesi Province," *ARRUS Journal of Mathematics and Applied Science*, vol. 2, no. 2, pp. 60–72, Mar. 2022, doi: 10.35877/mathscience740.
- [19] T. Sarastika, Yusuf Susena, and Dwi Kurniawan, "PREDIKSI KONVERSI LAHAN PERTANIAN BERBASIS ARTIFICIAL NEURAL NETWORK-CELLULAR AUTOMATA (ANN-CA) DI KAWASAN SLEMAN BARAT," *Jurnal Tanah dan Sumberdaya Lahan*, vol. 10, no. 2, pp. 471–482, Jul. 2023, doi: 10.21776/ub.jtsl.2023.010.2.30.
- [20] N. Chamidah *et al.*, "Spatial Modeling of Food Security Index in Central Java Using Mixed Geographically Weighted Regression," *ZERO: Jurnal Sains, Matematika dan Terapan*, vol. 9, no. 1, p. 247, Jul. 2025, doi: 10.30829/zero.v9i1.25044.