

PENGEMBANGAN SISTEM PERINGATAN DINI, PREDIKSI, DAN PRAKIRAAN DAMPAK KERUGIAN KEKERINGAN BERBASIS INTEGRASI INDEKS VEGETASI, CURAH HUJAN, DAN KELEMBABAN TANAH UNTUK PENENTUAN PRIORITAS INTERVENSI TINGKAT DESA

ABSTRAK

Kekeringan merupakan bencana hidrometeorologi yang berkembang secara perlahan, memiliki cakupan spasial luas, dan dapat berdampak langsung terhadap produktivitas pertanian, ketersediaan air, serta ketahanan pangan. Penelitian ini mengembangkan LBS Drought Early Warning System sebagai sistem monitoring, prediksi, prakiraan dampak, dan pendukung keputusan tingkat desa berbasis integrasi CHIRPS, MODIS, ERA5-Land, serta geometri Lahan Baku Sawah (LBS). Kerangka monitoring menggunakan Standardized Precipitation Index (SPI), standardized NDVI anomaly, dan standardized soil-moisture anomaly untuk membentuk LBS Drought Index (LDI), sementara Composite Drought Priority Index (CDPI) digunakan untuk pemeringkatan prioritas intervensi. Subsystem prediksi menggunakan direct multi-horizon supervised regression untuk memprakirakan LDI H+1 sampai H+5 melalui temporal hindcast dan pemilihan model per horizon. Penelitian selanjutnya menambahkan modul prakiraan dampak kerugian yang memisahkan jalur aktual berbasis drought coverage dan severity dari jalur forecast berbasis Forecast LDI. Dampak fisik dinyatakan sebagai luas LBS terpapar, Drought Equivalent Area, serta potential production loss; dampak ekonomi dihitung sebagai potential economic loss menggunakan produktivitas baseline dan harga gabah yang konsisten satuannya. Untuk forecast, LDI dipetakan ke fungsi hazard kontinu tanpa menciptakan predicted coverage atau predicted severity sintetis, sedangkan RMSE hindcast digunakan untuk membentuk screening uncertainty band, bukan confidence interval probabilistik. Seluruh nilai dampak diposisikan sebagai estimasi skenario yang memerlukan kalibrasi terhadap produktivitas, puso, fase tanaman, irigasi, dan harga regional sebelum digunakan sebagai kerugian terverifikasi.

Kata kunci: kekeringan; drought forecasting; machine learning; direct multi-horizon; SPI; NDVI anomaly; soil moisture anomaly; CHIRPS; MODIS; ERA5-Land; LDI; CDPI; Drought Equivalent Area; potential production loss; potential economic loss; WebGIS; hindcast; impact forecasting.

Abstract

Drought is a slow-onset hydrometeorological hazard with broad spatial extent and potentially substantial effects on agricultural productivity, water availability, and food security. This study extends the LBS Drought Early Warning System into an integrated village-level monitoring, forecasting, impact-estimation, and decision-support framework based on CHIRPS, MODIS, ERA5-Land, and Lahan Baku Sawah (LBS) polygons. The monitoring framework uses the Standardized Precipitation Index (SPI), standardized NDVI anomaly, and standardized soil-moisture anomaly to construct the LBS Drought Index (LDI), while the Composite Drought Priority Index (CDPI) supports intervention ranking. A direct multi-horizon supervised-regression subsystem forecasts LDI from H+1 to H+5 using temporal hindcasting and horizon-specific model selection. An impact-loss

module is added with two deliberately separated pathways: current impacts use drought coverage and severity, whereas forecast impacts use village-level Forecast LDI without fabricating future pixel coverage or severity. Physical impacts are expressed as exposed LBS area, Drought Equivalent Area, and potential production loss; economic impacts are expressed as potential economic loss using unit-consistent baseline yield and paddy price. Forecast LDI is transformed into a continuous hazard-response function, and horizon-specific hindcast RMSE is propagated into a screening uncertainty band rather than interpreted as a formal probabilistic confidence interval. The resulting values are scenario-based potential losses that require calibration against observed yield loss, crop failure, crop stage, irrigation conditions, and regional prices before being treated as verified disaster losses.

Keywords: drought; drought forecasting; machine learning; direct multi-horizon forecasting; SPI; NDVI anomaly; soil moisture anomaly; CHIRPS; MODIS; ERA5-Land; LDI; CDPI; Drought Equivalent Area; potential production loss; potential economic loss; WebGIS; hindcast; impact forecasting.

1. PENDAHULUAN

1.1 Latar Belakang

Kekeringan merupakan fenomena kompleks yang dapat muncul sebagai kekeringan meteorologis, pertanian, hidrologis, maupun sosial-ekonomi. Berbeda dari bencana yang terjadi secara tiba-tiba, kekeringan berkembang secara bertahap sehingga awal dan akhir kejadiannya relatif sulit ditentukan. Wilhite dan Glantz (1985) menekankan bahwa kekeringan tidak memiliki satu definisi universal karena karakteristiknya bergantung pada tujuan analisis, komponen sistem yang terdampak, dan skala waktu yang diamati. Kompleksitas tersebut menyebabkan pemantauan kekeringan membutuhkan lebih dari satu indikator.

Curah hujan merupakan pemicu awal yang paling langsung untuk mendeteksi kekeringan meteorologis. Namun, rendahnya curah hujan pada suatu periode belum tentu langsung menghasilkan kerusakan vegetasi. Kondisi vegetasi dipengaruhi pula oleh cadangan air tanah, jenis tanaman, fase pertumbuhan, irigasi, karakteristik tanah, dan kondisi atmosfer. Demikian juga kelembaban tanah dapat menunjukkan respons yang berbeda terhadap defisit curah hujan bergantung pada kedalaman tanah, evapotranspirasi, dan kapasitas penyimpanan air. Oleh karena itu, integrasi indikator meteorologi, vegetasi, dan kelembaban tanah berpotensi memberikan gambaran kekeringan yang lebih komprehensif dibandingkan penggunaan parameter tunggal.

Perkembangan data penginderaan jauh dan reanalisis iklim memungkinkan pemantauan kekeringan dalam cakupan wilayah luas dengan kontinuitas temporal yang relatif tinggi. CHIRPS menyediakan seri curah hujan jangka panjang dengan resolusi spasial yang sesuai untuk analisis regional (Funk et al., 2015). Produk MODIS menyediakan indikator vegetasi yang dapat digunakan untuk mengidentifikasi penyimpangan kondisi vegetasi terhadap keadaan historis (Didan, 2015). ERA5 dan ERA5-Land menyediakan data reanalisis atmosfer dan daratan yang dapat digunakan untuk menggambarkan kondisi kelembaban tanah secara konsisten (Hersbach et al., 2020; Muñoz-Sabater et al., 2021).

Meskipun demikian, tersedianya peta kekeringan belum otomatis menghasilkan informasi yang siap digunakan oleh pengambil keputusan. Pemerintah daerah dan lembaga penanggulangan

bencana memerlukan informasi yang menjawab pertanyaan operasional: **wilayah mana yang harus diperhatikan terlebih dahulu, seberapa luas daerah terdampak, apakah kondisi memburuk, dan seberapa kuat bukti antarindikator terhadap kejadian tersebut?** Kebutuhan tersebut menuntut transformasi dari *drought monitoring* menjadi *drought decision support*.

Penelitian ini mengembangkan LBS Drought Early Warning System dengan menjadikan desa sebagai unit administrasi akhir. Sistem tidak hanya menghasilkan kelas kekeringan, tetapi juga menghitung cakupan wilayah terdampak, luas terdampak, persistensi, tren perubahan, tingkat kesepakatan antarindikator, kepercayaan data, dan indeks prioritas intervensi. Pendekatan ini ditujukan untuk menjembatani kesenjangan antara analisis lingkungan berbasis raster dan kebutuhan operasional berbasis wilayah administrasi. Pengembangan terbaru menambahkan subsistem prediksi direct multi-horizon sehingga sistem tidak hanya menjawab kondisi kekeringan saat ini, tetapi juga mengestimasi kecenderungan kondisi desa satu sampai lima bulan ke depan. Prediksi diposisikan sebagai dukungan antisipatif yang harus selalu dibaca bersama metrik hindcast dan kelengkapan data, bukan sebagai kepastian deterministik.

1.2 Rumusan Masalah

Penelitian dirumuskan melalui pertanyaan berikut:

1. Bagaimana mengintegrasikan indikator curah hujan, kondisi vegetasi, dan kelembaban tanah ke dalam satu indeks kekeringan spasial yang memiliki arah interpretasi konsisten?
2. Bagaimana mengatasi perbedaan resolusi spasial dan temporal antara CHIRPS, MODIS, dan ERA5-Land tanpa menimbulkan interpretasi ketelitian spasial yang berlebihan?
3. Bagaimana menerjemahkan indeks kekeringan berbasis raster menjadi statistik operasional tingkat desa?
4. Bagaimana menyusun indeks prioritas yang mampu membedakan tingkat keparahan, cakupan, dan luas wilayah terdampak?
5. Bagaimana mengembangkan mekanisme peringatan dini yang mempertimbangkan kondisi terkini, tren, persistensi, dan kesepakatan antarindikator?
6. Bagaimana membangun model prediksi kekeringan tingkat desa untuk horizon H+1 sampai H+5 tanpa menggunakan informasi masa depan sebagai predictor?
7. Bagaimana mengevaluasi kemampuan generalisasi model prediksi melalui temporal hindcast, memilih model terbaik per horizon, dan menyajikan ketidakpastian secara transparan?
8. Bagaimana menerjemahkan kondisi kekeringan aktual dan Forecast LDI menjadi prakiraan dampak fisik serta potensi kehilangan produksi dan nilai ekonomi tanpa menciptakan variabel spasial masa depan yang tidak diprediksi model?

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. mengembangkan model indeks kekeringan berbasis integrasi parameter meteorologis, vegetasi, dan kelembaban tanah;
2. menghasilkan peta spasial kekeringan melalui LBS Drought Index;

3. mengembangkan metode agregasi dan karakterisasi kekeringan pada unit administrasi desa;
4. mengembangkan Composite Drought Priority Index sebagai dasar pemeringkatan desa prioritas;
5. membangun mekanisme peringatan dini berdasarkan severity, coverage, persistence, trend, agreement, dan confidence; serta
6. mengimplementasikan hasil analisis dalam WebGIS, dashboard eksekutif, dan laporan operasional.
7. mengembangkan model machine learning direct multi-horizon untuk memprediksi LDI dan kelas kekeringan satu sampai lima bulan ke depan;
8. mengevaluasi model prediksi menggunakan temporal hindcast dan metrik regresi serta klasifikasi; dan
9. mengintegrasikan hasil prediksi ke dalam CSV, raster, GeoJSON, WebGIS, dan dashboard sebagai informasi anticipatory early warning.
10. mengembangkan metode estimasi luas LBS terpapar dan Drought Equivalent Area yang menghindari double-counting antara coverage dan severity;
11. mengembangkan model potential production loss dan potential economic loss untuk kondisi aktual serta forecast H+1 sampai H+5;
12. menyajikan ketidakpastian prakiraan dampak melalui screening band berbasis RMSE hindcast dan sensitivity analysis parameter dampak; dan
13. mengintegrasikan indikator dampak ke WebGIS untuk mendukung penentuan wilayah yang berpotensi mengalami kehilangan produksi terbesar.

1.4 Manfaat Penelitian

Secara ilmiah, penelitian memberikan kerangka integrasi multiindikator yang menghubungkan kekeringan meteorologis, kelembaban tanah, dan respons vegetasi. Secara praktis, penelitian menghasilkan informasi yang dapat digunakan untuk memprioritaskan pemantauan lapangan, distribusi air, koordinasi lintas wilayah, dan perencanaan intervensi. Secara teknis, penelitian menyediakan rancangan pipeline yang dapat diperbarui secara periodik dan diintegrasikan dengan sistem informasi spasial. Penambahan prediksi memberikan manfaat tambahan berupa lead time bagi perencanaan verifikasi lapangan, kesiapan sumber air, penjadwalan koordinasi, dan penyusunan prioritas wilayah sebelum dampak kekeringan meningkat.

1.5 Ruang Lingkup

Ruang lingkup penelitian dibatasi pada aspek berikut:

- Kekeringan dianalisis sebagai kondisi bahaya lingkungan berbasis tiga indikator utama: curah hujan, vegetasi, dan kelembaban tanah.
- Unit keluaran administratif adalah desa, sedangkan resolusi informasi tetap mengikuti karakteristik sumber data masing-masing.
- CDPI pada penelitian ini merupakan **indeks prioritas intervensi**, bukan indeks risiko sosial-ekonomi, karena belum memasukkan secara eksplisit exposure dan vulnerability penduduk.

- Hasil implementasi awal menggunakan 83.486 unit desa dan distribusi kelas yang telah diperoleh dari sistem.
- Validasi empiris dengan laporan kejadian lapangan, gagal panen, distribusi air, atau data stasiun dijelaskan sebagai protokol metodologis dan tidak diberi nilai performa numerik apabila data validasi belum tersedia.

Forecast menggunakan pendekatan statistik direct multi-horizon berbasis observasi historis sampai Juli 2026 untuk horizon Agustus-Desember 2026; model ini bukan seasonal climate forecast dinamis dari model atmosfer.

Unit administrasi sumber berjumlah 83.486 polygon; sebanyak 86 record tanpa ID desa resmi dikeluarkan dari panel time series, sehingga unit analisis forecast berjumlah 83.400 desa.

Forecast CDPI tidak dipaksakan apabila riwayat target CDPI, coverage, dan affected area belum memadai untuk pelatihan; dalam kondisi tersebut ranking prediktif menggunakan Forecast LDI dan kelas kekeringan.

Modul dampak kerugian dibangun terpisah dari CDPI. CDPI tetap didefinisikan sebagai indeks prioritas kondisi fisik, sedangkan potential production loss dan potential economic loss merupakan estimasi dampak pertanian berbasis LBS.

Luas LBS tidak identik dengan luas tanam atau luas panen pada suatu bulan. Jika data proporsi areal yang sedang ditanami tidak tersedia, faktor eksposur tanaman G ditetapkan 1,00 sebagai skenario screening konservatif dan wajib diberi label sebagai asumsi.

Produktivitas dan harga harus konsisten satuan. Karena baseline nasional awal menggunakan ton GKG/ha, harga ekonomi yang digunakan idealnya harga GKG tingkat produsen pada wilayah dan periode yang sama; penggunaan GKP atau harga beras memerlukan konversi yang terdokumentasi.

Nilai kerugian yang dihasilkan merupakan potential/scenario-based loss, bukan kerugian aktual terverifikasi dan bukan estimasi kerusakan aset infrastruktur pertanian.

2. TINJAUAN PUSTAKA

2.1 Konsep Kekeringan

Kekeringan umumnya dibedakan menjadi kekeringan meteorologis, pertanian, hidrologis, dan sosial-ekonomi. Kekeringan meteorologis berkaitan dengan kekurangan presipitasi terhadap kondisi normal dalam periode tertentu. Kekeringan pertanian berkaitan dengan ketidakcukupan kelembaban tanah untuk memenuhi kebutuhan tanaman. Kekeringan hidrologis berkaitan dengan berkurangnya aliran sungai, simpanan waduk, atau air tanah. Kekeringan sosial-ekonomi muncul ketika keterbatasan sumber daya air memengaruhi permintaan dan pasokan barang atau jasa (Mishra & Singh, 2010; Van Loon, 2015).

Hubungan antarjenis kekeringan bersifat berurutan tetapi tidak selalu linier. Defisit hujan dapat menjadi sinyal awal, diikuti penurunan kelembaban tanah dan kemudian tekanan vegetasi. Karena terdapat *lag time*, sistem multiindikator dapat membantu mengidentifikasi fase kejadian secara lebih baik daripada satu indikator.

2.2 Standardized Precipitation Index

SPI diperkenalkan oleh McKee et al. (1993) untuk menilai defisit atau surplus curah hujan pada berbagai skala waktu. Kelebihan utama SPI adalah sifatnya yang terstandarisasi sehingga kondisi pada lokasi dengan karakteristik curah hujan berbeda dapat dibandingkan dalam satu skala probabilitik. WMO kemudian merekomendasikan SPI sebagai salah satu indeks utama untuk pemantauan kekeringan meteorologis.

SPI-1 lebih sensitif terhadap perubahan jangka pendek, sedangkan SPI-3 dapat menggambarkan akumulasi defisit selama beberapa bulan dan relevan untuk kekeringan pertanian musiman. Penggunaan lebih dari satu skala membantu membedakan sinyal awal dari kondisi yang telah persisten.

2.3 NDVI dan Anomali Vegetasi

Normalized Difference Vegetation Index memanfaatkan perbedaan reflektansi kanal inframerah-dekat dan merah untuk menggambarkan kehijauan vegetasi (Rouse et al., 1974). NDVI absolut berbeda menurut tipe vegetasi dan musim, sehingga perbandingan nilai aktual terhadap baseline klimatologis pada bulan yang sama lebih tepat untuk mengidentifikasi tekanan vegetasi.

Dalam penelitian ini digunakan standardized NDVI anomaly agar hasil lebih mudah dibandingkan lintas wilayah. Nilai negatif pada NDVI anomaly berarti vegetasi berada di bawah kondisi historis normal. Untuk konsistensi fusion, arah indikator kemudian dibalik sehingga nilai positif selalu menunjukkan kondisi yang lebih kering.

2.4 Soil Moisture sebagai Indikator Kekeringan Pertanian

Kelembaban tanah menghubungkan kondisi meteorologis dengan respons vegetasi. Penurunan curah hujan dapat mengurangi kelembaban tanah, tetapi responsnya tergantung pada tekstur tanah, evapotranspirasi, kedalaman lapisan tanah, dan penyimpanan air. ERA5-Land menyediakan representasi variabel permukaan daratan dengan resolusi yang lebih detail dibanding ERA5 global dan memungkinkan analisis kelembaban tanah pada beberapa lapisan (Muñoz-Sabater et al., 2021).

Untuk aplikasi yang berorientasi pertanian, penggunaan lapisan akar (*root-zone*) lebih representatif dibanding hanya permukaan 0–7 cm, karena akar tanaman memanfaatkan air dari lapisan yang lebih dalam.

2.5 Multi-Indicator Drought Assessment

Indeks komposit dikembangkan karena tidak ada satu indikator yang dapat menggambarkan seluruh dimensi kekeringan. Integrasi indeks memungkinkan informasi penyebab, keadaan medium, dan respons lingkungan dipertimbangkan secara bersama. Pendekatan multivariat juga digunakan pada sejumlah studi kekeringan untuk meningkatkan konsistensi deteksi dan mengurangi ketergantungan pada satu variabel (Hao & AghaKouchak, 2013).

Namun, fusion menimbulkan tantangan berupa perbedaan skala, arah interpretasi, distribusi statistik, serta bobot antarindikator. Oleh karena itu, normalisasi dan uji sensitivitas bobot menjadi bagian penting dalam metodologi.

2.6 Sistem Peringatan Dini dan Decision Support

Sistem peringatan dini bukan hanya sistem visualisasi. Suatu sistem disebut operasional apabila mampu mengidentifikasi perubahan kondisi, menentukan threshold, memberikan tingkat peringatan, dan menghubungkan informasi tersebut dengan tindakan yang dapat diprioritaskan. Dalam konteks penelitian ini, LDI berfungsi sebagai indikator kondisi/hazard, sedangkan CDPI berfungsi sebagai indeks prioritas intervensi administratif.

2.7 Prediksi Kekeringan Berbasis Machine Learning

Prediksi kekeringan dapat dirumuskan sebagai masalah supervised time-series forecasting ketika kondisi masa lalu digunakan untuk mengestimasi kondisi pada horizon mendatang. Model berbasis pohon keputusan relevan karena mampu menangkap hubungan nonlinier, interaksi antarindikator, dan efek threshold tanpa mengharuskan bentuk hubungan parametrik yang kaku. Random Forest mengurangi varians melalui ensemble banyak pohon (Breiman, 2001), sedangkan gradient boosting membangun model secara bertahap untuk memperbaiki residual sebelumnya (Friedman, 2001). XGBoost menambahkan regularisasi dan optimasi komputasi yang efisien untuk dataset berskala besar (Chen & Guestrin, 2016).

Untuk multi-step forecasting, pendekatan direct multi-horizon melatih model terpisah untuk setiap horizon. Strategi ini dipilih agar kesalahan prediksi H+1 tidak secara otomatis diteruskan ke H+2, H+3, dan seterusnya seperti pada recursive forecasting. Validasi dilakukan berdasarkan urutan waktu, bukan random split, karena pemisahan acak dapat mencampurkan informasi masa depan ke data pelatihan dan menghasilkan estimasi performa yang terlalu optimistis. Prinsip yang sama berlaku untuk data spasial-temporal yang memiliki autocorrelation (Roberts et al., 2017).

Dalam penelitian ini, machine learning tidak menggantikan definisi indikator kekeringan. Model digunakan untuk mempelajari hubungan temporal antara indikator historis, dinamika LDI, seasonality, dan karakteristik lokasi terhadap kondisi LDI pada horizon berikutnya. Dengan demikian, interpretabilitas sistem tetap berakar pada SPI, NDVI, soil moisture, trend, dan persistence.

2.8 Respons Hasil Tanaman terhadap Defisit Air dan Penilaian Kerugian Pertanian

Hubungan kekurangan air dan kehilangan hasil tanaman telah lama digunakan dalam analisis pertanian. Kerangka FAO yield response to water menghubungkan penurunan hasil relatif dengan defisit evapotranspirasi melalui crop yield response factor (Ky). Pendekatan tersebut menunjukkan bahwa tekanan air dapat diterjemahkan menjadi konsekuensi produksi, tetapi koefisien harus dikalibrasi terhadap komoditas, fase pertumbuhan, dan kondisi setempat (Steduto et al., 2012). Dalam penelitian ini, koefisien sensitivitas β tidak disamakan dengan Ky karena LDI bukan rasio defisit evapotranspirasi. β didefinisikan sebagai parameter empiris sistem yang

menghubungkan intensitas hazard LBS dengan potential yield loss dan harus dikalibrasi menggunakan data hasil panen/puso historis.

FAO Damage and Loss Assessment Methodology membedakan kerusakan aset (damage) dari kehilangan arus produksi (loss). Modul LBS pada tahap ini menaksir potential production loss dan nilai ekonomi produksi yang berpotensi tidak terealisasi; kerusakan aset seperti jaringan irigasi, pompa, gudang, atau alat mesin pertanian berada di luar cakupan model (Conforti, Markova, & Tochkov, 2020). Pemisahan ini penting agar istilah kerugian ekonomi tidak disalahartikan sebagai total damage and loss sektor pertanian.

2.9 Lahan Baku Sawah, Produktivitas, dan Harga sebagai Basis Eksposur

Lahan Baku Sawah digunakan sebagai exposure base spasial karena menyediakan geometri sawah yang konsisten untuk menghubungkan hazard kekeringan dengan aset produksi pertanian. Namun, seluruh LBS tidak selalu ditanami padi pada saat yang sama. Oleh karena itu, model memperkenalkan faktor tanaman G untuk merepresentasikan proporsi LBS yang sedang terekspos produksi. Data Kerangka Sampel Area (KSA) BPS secara nasional juga mengamati fase vegetatif, generatif, potensi gagal panen, bera, dan penggunaan nonpadi sehingga dapat digunakan untuk memperbaiki faktor G dan crop-stage sensitivity ketika tersedia pada resolusi yang sesuai.

Sebagai fallback nasional, produktivitas screening dapat diturunkan dari statistik resmi. BPS melaporkan luas panen padi 2025 sekitar 11,32 juta ha dan produksi 60,21 juta ton GKG, setara sekitar 5,32 ton GKG/ha. Angka tersebut bukan konstanta nasional untuk seluruh desa, tetapi hanya baseline sementara ketika produktivitas kabupaten/provinsi yang lebih representatif belum tersedia. Harga gabah harus mengikuti basis produk yang sama dan menggunakan periode/wilayah sedekat mungkin dengan horizon analisis.

3. Data dan Sumber Data

3.1 Ringkasan Dataset

Tabel 1 merangkum data utama yang digunakan.

Tabel 1. Ringkasan data dan fungsi dalam model

Dataset	Variabel Utama	Resolusi Temporal	Resolusi Spasial Representatif	Fungsi dalam Model
CHIRPS	Curah hujan	Harian/bulanan	$\pm 0,05^\circ$	Perhitungan SPI, rainfall anomaly, dan predictor forecast
MODIS MOD13Q1	NDVI dan QA	16 harian	250 m	Vegetation stress, anomaly, lag/trend, dan predictor forecast
ERA5-Land	Volumetric soil water	Sub-harian/harian	grid daratan ± 9 km; distribusi CDS sekitar $0,1^\circ$	Soil moisture deficit, anomaly, agreement, dan predictor forecast

Dataset	Variabel Utama	Resolusi Temporal	Resolusi Spasial Representatif	Fungsi dalam Model
Batas administrasi	Provinsi, kabupaten, kecamatan, desa	Relatif statis	Vektor	Agregasi dan reporting
BPS/Kementan/Statistik harga	Produktivitas padi, luas tanam/panen atau fase tanaman, harga GKG/GKP	Bulanan/tahunan	Nasional hingga kabupaten/provinsi sesuai ketersediaan	Baseline hasil, faktor tanaman, kalibrasi dampak, dan valuasi ekonomi

Catatan: resolusi dataset harus didokumentasikan berdasarkan produk dan versi yang digunakan pada saat replikasi. Resampling tidak dianggap meningkatkan resolusi informasi asli.

3.2 Data Curah Hujan CHIRPS

CHIRPS digunakan sebagai sumber curah hujan karena memiliki seri historis panjang dan cakupan spasial luas. Data harian dapat diagregasikan menjadi total bulanan. Pada implementasi, versi produk dan tanggal pengunduhan perlu dicatat untuk memastikan reproducibility.

3.3 Data MODIS NDVI

MOD13Q1 digunakan untuk mengidentifikasi respons vegetasi. Selain layer NDVI, layer Quality Assurance harus digunakan untuk memfilter observasi berkualitas rendah, awan, salju, dan pixel tidak valid sebelum agregasi bulanan.

3.4 Data ERA5-Land Soil Moisture

ERA5-Land digunakan sebagai representasi kelembaban tanah. Penelitian mengutamakan kombinasi lapisan 0–7 cm dan 7–28 cm untuk membentuk representasi 0–28 cm. Lapisan lebih dalam dapat digunakan pada uji sensitivitas.

3.5 Data Administrasi Desa

Batas administrasi berfungsi sebagai unit pelaporan. Data harus memiliki kode wilayah yang konsisten agar dapat dihubungkan dengan atribut kabupaten, kecamatan, dan provinsi. Geometri perlu diperiksa terhadap masalah seperti polygon invalid, overlap, gap, dan multipart geometry.

3.6 Baseline Klimatologis

Perhitungan anomali dilakukan berdasarkan bulan kalender yang sama. Sebagai contoh, kondisi Agustus dibandingkan terhadap seluruh observasi Agustus pada periode baseline, bukan terhadap rata-rata Januari-Desember. Pada implementasi penelitian, baseline ditetapkan 1981-2020 untuk CHIRPS serta 2001-2020 untuk MODIS dan ERA5-Land. Baseline dibuat tetap selama proses hindcast dan inference agar tidak terjadi leakage dari periode target ke parameter klimatologi.

3.7 Panel Historis untuk Prediksi

Dataset prediksi dibentuk pada unit desa-bulan. CHIRPS tersedia sejak 1981 untuk pembentukan baseline SPI, sedangkan common analysis period untuk integrasi MODIS, ERA5-Land, dan target model adalah Januari 2001 sampai Juli 2026. Dengan 307 bulan dan 83.400 desa ber-ID valid, panel teoritis maksimum berjumlah 25.603.800 record desa-bulan sebelum memperhitungkan missing indicator. Missing value tidak diisi dengan nilai fiktif; pipeline mempertahankan missingness dan model menggunakan median imputation serta missing-data flags pada fitur yang relevan.

3.8 Horizon Prediksi dan Cut-off Observasi

Cut-off observasi operasional ditetapkan Juli 2026. Dari satu base month yang sama, sistem menghasilkan lima horizon secara langsung: H+1 Agustus 2026, H+2 September 2026, H+3 Oktober 2026, H+4 November 2026, dan H+5 Desember 2026. Tidak ada prediksi bulan antara yang digunakan sebagai input untuk horizon berikutnya; setiap horizon memiliki modelnya sendiri.

3.9 Data Pendukung Prakiraan Dampak Kerugian

Modul dampak memerlukan empat kelompok input tambahan: (1) luas polygon LBS sebagai exposure base; (2) produktivitas baseline Y dalam ton/ha; (3) harga gabah P dalam Rp/kg yang konsisten dengan basis produktivitas; dan (4) parameter sensitivitas β . Jika tersedia, faktor tanaman G, fase pertumbuhan, jenis irigasi, varietas, serta data puso/kehilangan hasil historis digunakan untuk mengurangi bias dan mengkalibrasi parameter.


Hierarki sumber produktivitas mengikuti prinsip finest reliable geography: kabupaten/kota diprioritaskan, kemudian provinsi, dan terakhir baseline nasional. Nilai nasional 2025 sekitar 5,32 ton GKG/ha dapat digunakan sebagai fallback screening yang dihitung dari 60,21 juta ton GKG dibagi 11,32 juta ha luas panen (BPS, 2026). Harga sebaiknya menggunakan harga produsen GKG pada bulan dan wilayah yang sama; bila hanya GKP tersedia, basis produksi harus dikonversi atau hasil diberi label berbeda.

Setiap parameter dampak disimpan bersama metadata sumber, tahun/bulan referensi, satuan, level administrasi, tanggal pembaruan, dan status fallback. Prinsip ini memungkinkan audit serta mencegah pencampuran produktivitas GKG dengan harga GKP/beras tanpa konversi.

4. Metodologi Penelitian

4.1 Desain Penelitian

Penelitian menggunakan pendekatan kuantitatif-spasial berbasis **multi-indicator drought assessment**. Analisis dilakukan pada dua tingkatan. Tingkat pertama adalah analisis raster untuk menghasilkan kondisi kekeringan spasial melalui LDI. Tingkat kedua adalah analisis administrasi desa untuk menghasilkan statistik dampak dan prioritas intervensi melalui CDPI.



Gambar 1. Kerangka metodologi monitoring, agregasi desa, dan prioritas intervensi.

Alur umum terdiri atas akuisisi data, quality control, harmonisasi temporal, harmonisasi spasial, perhitungan indikator, standardisasi, fusion, klasifikasi, agregasi desa, perhitungan prioritas, early warning, validasi, dan penyajian pada sistem informasi. Subsisitem prediksi ditambahkan setelah pembentukan panel historis, dengan alur feature engineering, temporal hindcast, seleksi model per horizon, refit model final, inference H+1 sampai H+5, serta penyajian forecast pada unit desa.

4.2 Quality Control dan Preprocessing

Tahap preprocessing meliputi:

1. pemeriksaan ketersediaan tanggal dan missing value;
2. masking kualitas pada MODIS;
3. validasi rentang nilai fisik;
4. reprojection dan grid alignment;
5. pemotongan sesuai wilayah studi;
6. penanganan NoData;
7. dokumentasi versi, tanggal akuisisi, dan checksum bila diperlukan; serta
8. pembentukan metadata pemrosesan agar setiap output dapat ditelusuri kembali ke sumber data.

4.3 Harmonisasi Temporal

Semua indikator dikonversi menjadi representasi bulanan agar satu periode analisis membandingkan kondisi temporal yang konsisten.

4.3.1 Agregasi Curah Hujan

Total curah hujan bulanan dihitung sebagai:

$$P_m = \sum_{d=1}^n P_d$$

Dengan P_m adalah total curah hujan pada bulan ke- m , P_d adalah curah hujan harian, dan n adalah jumlah hari dalam bulan.

Untuk SPI skala k , curah hujan diakumulasi sebagai:

$$X_t^{(k)} = \sum_{i=0}^{k-1} P_{t-i}$$

Penelitian menggunakan SPI-1 sebagai sinyal jangka pendek dan SPI-3 sebagai indikator utama kondisi defisit hujan akumulatif.

4.3.2 Agregasi MODIS NDVI

Setelah Quality Assurance masking, observasi valid dalam bulan yang sama diagregasikan menggunakan median:

$$NDVI_m = \text{median}(NDVI_1, NDVI_2, \dots, NDVI_n)$$

Median dipilih untuk mengurangi pengaruh observasi ekstrem dan residual cloud contamination.

4.3.3 Agregasi Soil Moisture

Nilai soil moisture bulanan dihitung sebagai rata-rata observasi valid:

$$SM_m = \frac{1}{n} \sum_{t=1}^n SM_t$$

Untuk membentuk estimasi kelembaban tanah 0–28 cm dari dua lapisan ERA5-Land digunakan pembobotan ketebalan lapisan:

$$SM_{0-28} = \frac{7SM_1 + 21SM_2}{28}$$

Dengan SM_1 mewakili lapisan 0–7 cm dan SM_2 mewakili lapisan 7–28 cm.

4.4 Harmonisasi Spasial

Perbedaan resolusi spasial merupakan isu metodologis penting. Seluruh data tidak langsung dinaikkan ke resolusi 250 m karena proses tersebut dapat menciptakan **pseudo-spatial precision**. Sebaliknya, analisis fusion dilakukan pada *common analysis grid* yang mempertimbangkan resolusi terkasar variabel utama. Resampling diposisikan sebagai kebutuhan grid alignment, bukan peningkatan informasi.

Variabel kontinu dapat menggunakan bilinear interpolation pada tahap alignment, sedangkan layer kategorikal menggunakan nearest-neighbor. Untuk perhitungan luas, raster dan

batas desa diproyeksikan ke sistem koordinat equal-area yang sesuai agar estimasi luas tidak bias akibat distorsi lintang-bujur.

4.5 Meteorological Drought Indicator

SPI tidak dihitung sebagai z-score sederhana dari curah hujan. Akumulasi curah hujan terlebih dahulu dipasangkan pada distribusi probabilitas, lazimnya distribusi gamma untuk curah hujan positif:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta}$$

Dengan α sebagai *shape parameter* dan β sebagai *scale parameter*. Probabilitas kumulatif kemudian ditransformasikan ke distribusi normal baku:

$$SPI = \Phi^{-1}[H(x)]$$

Nilai SPI negatif menunjukkan kondisi lebih kering daripada kondisi historis. Agar seluruh indikator memiliki arah interpretasi yang sama pada proses fusion, digunakan:

$$D_{SPI} = -SPI$$

Dengan demikian, nilai D_{SPI} yang semakin tinggi menunjukkan kondisi meteorologis yang semakin kering.

4.6 Vegetation Stress Indicator

Untuk setiap bulan kalender dihitung rata-rata dan standar deviasi NDVI historis. Standardized NDVI anomaly dihitung sebagai:

$$Z_{NDVI} = \frac{NDVI_{current} - \mu_{NDVI,m}}{\sigma_{NDVI,m}}$$

Karena nilai negatif merepresentasikan vegetasi lebih buruk dari normal, orientasi dibalik:

$$D_{NDVI} = -Z_{NDVI}$$

Pendekatan bulan-kalender mengurangi bias seasonality karena NDVI secara alami memiliki pola musiman.

4.7 Soil Moisture Drought Indicator

Standardized soil moisture anomaly dihitung dengan:

$$Z_{SM} = \frac{SM_{current} - \mu_{SM,m}}{\sigma_{SM,m}}$$

Orientasi indikator kemudian dibalik:

$$D_{SM} = -Z_{SM}$$

Semakin tinggi D_{SM} , semakin besar defisit kelembaban tanah relatif terhadap kondisi historis bulan yang sama.

4.8 Pengembangan LBS Drought Index

Ketiga indikator digabungkan menggunakan weighted linear fusion:

$$LDI_{raw} = w_p D_{SPI} + w_v D_{NDVI} + w_s D_{SM}$$

Dengan kendala:

$$w_p + w_v + w_s = 1$$

Model baseline menggunakan bobot sama, yaitu $w_p = w_v = w_s = 1/3$. Bobot tersebut tidak dianggap sebagai bobot final, tetapi menjadi baseline untuk dibandingkan dengan skenario bobot lain melalui sensitivity analysis, expert judgement, atau optimasi terhadap data kejadian historis.

Karena hasil weighted sum tidak otomatis mengikuti distribusi normal baku, LDI_{raw} distandardisasi kembali terhadap baseline historis:

$$LDI_z = \frac{LDI_{raw} - \mu_{LDI,m}}{\sigma_{LDI,m}}$$

Nilai positif yang lebih besar menunjukkan kondisi lebih kering daripada baseline historis.

4.9 Klasifikasi Kekeringan

Threshold awal LDI-Z ditetapkan seperti Tabel 2. Threshold bersifat *initial operational threshold* dan perlu dikalibrasi menggunakan kejadian historis.

Tabel 2. Klasifikasi awal LBS Drought Index

LDI-Z	Kelas	Kategori
< 0,50	0	Normal
0,50–0,99	1	Waspada
1,00–1,49	2	Kering Ringan
1,50–1,99	3	Kering Sedang
2,00–2,49	4	Kering Berat
≥ 2,50	5	Ekstrem

4.10 Multi-Indicator Agreement

Untuk memperlihatkan konsistensi bukti antarindikator, dihitung jumlah indikator yang melewati threshold kekeringan:

$$\text{Agreement} = I(D_{SPI} \geq T_p) + I(D_{NDVI} \geq T_v) + I(D_{SM} \geq T_s)$$

Nilai 0/3 menunjukkan tidak ada sinyal, 1/3 menunjukkan indikasi lemah, 2/3 menunjukkan dukungan cukup kuat, dan 3/3 menunjukkan kesepakatan tinggi. Layer ini tidak menggantikan LDI, tetapi menjadi indikator confidence interpretatif.

4.11 Agregasi Tingkat Desa

Raster kelas kekeringan dioverlay dengan batas desa menggunakan **area-weighted zonal statistics**. Pendekatan area-weighted diperlukan untuk pixel yang terpotong oleh batas desa.

4.11.1 Mean Severity

Mean Severity desa dihitung sebagai:

$$S_v = \frac{\sum_{j=1}^n A_j K_j}{5 \sum_{j=1}^n A_j}$$

Dengan K_j adalah kelas kekeringan pixel, A_j adalah luas bagian pixel dalam desa, dan pembagi 5 menormalisasi severity ke rentang 0–1.

4.11.2 Dominant Severity

Dominant Severity adalah kelas yang mencakup luas terbesar di dalam desa. Indikator ini digunakan untuk komunikasi sederhana, tetapi tidak menjadi satu-satunya dasar prioritas karena area berat yang lebih kecil dapat hilang apabila hanya modus kelas yang dilaporkan.

4.11.3 Drought Coverage

Drought Coverage dihitung sebagai proporsi area valid yang mengalami minimal Kering Ringan:

$$C_v = \frac{A(K \geq 2)}{A_{valid}} \times 100$$

4.11.4 Severe Drought Coverage

Untuk mengidentifikasi area minimal Kering Sedang dihitung:

$$C_{severe,v} = \frac{A(K \geq 3)}{A_{valid}} \times 100$$

4.11.5 Drought Area

Luas kekeringan desa dihitung sebagai:

$$DA_v = A_v \times \frac{C_v}{100}$$

Nilai dapat dilaporkan dalam hektare atau kilometer persegi.

4.12 Data Confidence Tingkat Desa

Keluaran desa juga memuat jumlah pixel valid, proporsi area valid, agreement, dan indikator kelengkapan data. Hal ini penting karena beberapa desa berukuran lebih kecil daripada footprint data terkasar. Oleh sebab itu, istilah “tingkat desa” dalam penelitian berarti **unit agregasi dan pengambilan keputusan**, bukan klaim bahwa seluruh input memiliki resolusi fisik setingkat desa.

4.13 Composite Drought Priority Index

CDPI dirancang untuk membedakan kondisi kekeringan dari prioritas intervensi. Tiga komponen digunakan: severity, coverage, dan drought area.

Severity dinormalisasi melalui $S^* = S_v$, sedangkan coverage dinormalisasi sebagai $C^* = C_v/100$. Karena luas desa sangat bervariasi dan dapat mendominasi indeks, komponen area ditransformasikan secara logaritmik:

$$A^* = \frac{\ln(1 + DA_v)}{\ln(1 + DA_{max})}$$

CDPI dihitung sebagai:

$$CDPI_v = 100(w_S S^* + w_C C^* + w_A A^*)$$

Dengan:

$$w_S + w_C + w_A = 1$$

Skenario awal menggunakan $w_S = 0,50$, $w_C = 0,30$, dan $w_A = 0,20$. Severity diberi bobot terbesar agar wilayah sangat luas tetapi hanya sedikit terdampak tidak otomatis mendominasi ranking. Bobot diuji melalui sensitivity analysis.

Interpretasi awal CDPI ditunjukkan pada Tabel 3.

Tabel 3. Interpretasi awal Composite Drought Priority Index

CDPI	Prioritas
0–20	Rendah
>20–40	Sedang
>40–60	Tinggi
>60–80	Sangat Tinggi
>80–100	Kritis

Selain kelas, sistem menghasilkan national rank dan provincial rank sehingga sumber daya yang terbatas dapat diarahkan kepada Top-N desa.

4.14 Persistensi Kekeringan

Persistensi dihitung sebagai jumlah periode berurutan ketika LDI melampaui threshold:

$$\text{Persistence}_v = \sum_{i=0}^n I(\text{LDI}_{t-i} \geq T)$$

Kondisi satu periode diperlakukan sebagai kejadian baru, dua periode sebagai persistent drought, dan tiga periode atau lebih sebagai prolonged drought. Nilai operasional akhir harus disesuaikan dengan frekuensi pembaruan sistem.

4.15 Analisis Tren

Perubahan kondisi dihitung dengan:

$$\Delta LDI = LDI_t - LDI_{t-1}$$

Nilai positif menunjukkan kondisi memburuk, nilai mendekati nol menunjukkan stabil, dan nilai negatif menunjukkan perbaikan. Trend memberikan konteks temporal sehingga dua desa dengan severity sama dapat memiliki urgensi berbeda.

4.16 Mekanisme Early Warning

Mekanisme peringatan dini mengkombinasikan LDI, trend, persistence, coverage, dan agreement. Struktur awal dijelaskan pada Tabel 4.

Tabel 4. Struktur awal level peringatan dini

Level	Nama	Contoh Aturan Operasional
0	Normal	Tidak ada sinyal kekeringan berarti
1	Watch	SPI-1 defisit, LDI Waspada, atau tren memburuk dua periode
2	Warning	LDI minimal Kering Ringan dan/atau minimal 2 dari 3 indikator kering
3	Severe Warning	LDI minimal Kering Sedang, coverage melewati threshold, agreement $\geq 2/3$
4	Critical	Kering Berat/Ekstrem dengan cakupan tinggi dan CDPI Kritis

Aturan final tidak ditetapkan hanya berdasarkan expert judgement, tetapi dikalibrasi terhadap kejadian historis untuk mengendalikan false alarm dan missed detection.

4.17 Desain Subsistem Prediksi Multi-Horizon

Subsistem prediksi dirancang sebagai direct multi-horizon supervised regression. Satu snapshot fitur pada bulan t dipetakan secara langsung ke target LDI pada $t+h$. Lima model horizon dilatih secara independen untuk $h = 1, 2, 3, 4$, dan 5 . Strategi direct dipilih untuk mengurangi propagasi error karena hasil prediksi $H+1$ tidak menjadi input wajib bagi model $H+2$ dan seterusnya.

$$LDI_{v,t+h}^F = f_h(X_{v,t}), \quad h \in \{1,2,3,4,5\}$$

4.18 Definisi Target Forecast Operasional

Kerangka monitoring tetap menggunakan tiga indikator sebagai evidence kekeringan. Untuk forecast engine yang diimplementasikan saat ini, target regresi operasional dibuat dari komponen meteorologis akumulatif dan respons vegetasi yang memiliki panel historis paling konsisten, sedangkan soil moisture anomaly dipertahankan sebagai predictor, indikator agreement, dan informasi confidence. Pemisahan target dan predictor ini juga menghindari penggunaan soil moisture secara ganda di dalam target dan fitur model.

$$LDI_{v,t}^F = 0.50(-SPI3_{v,t}) + 0.50(-NDVI_{anom_{v,t}})$$

Definisi tersebut merupakan target forecast operasional pada implementasi saat ini dan tidak menghilangkan peran soil moisture dalam kerangka multiindikator. Apabila pada tahap kalibrasi berikutnya tersedia target historical LDI tiga-indikator yang telah tervalidasi secara konsisten, forecast target dapat diganti tanpa mengubah arsitektur direct multi-horizon.

4.19 Pembentukan Dataset Supervised dan Pencegahan Leakage

Untuk setiap desa v dan base month t , predictor hanya menggunakan informasi yang tersedia pada atau sebelum t . Target dibentuk dari LDI pada $t+h$. Observasi yang targetnya belum tersedia tidak digunakan untuk training. Climatological baseline tetap menggunakan periode historis yang telah ditentukan sebelumnya dan tidak dihitung ulang dengan memasukkan tahun validasi atau forecast. Koordinat geografis bersifat statis, sedangkan month encoding hanya menggunakan identitas kalender dan tidak mengandung observasi masa depan.

Pada implementasi komputasional, panel nasional berukuran sangat besar sehingga training menggunakan event-enriched sampling: observasi kering ($LDI \geq 1,00$) dipertahankan dengan proporsi lebih tinggi bersama sampel acak dari kondisi lain. Batas ukuran data digunakan untuk efisiensi RAM dan waktu komputasi, sedangkan inference final tetap dilakukan untuk seluruh 83.400 desa. Karena validation sample juga dipadatkan untuk komputasi, metrik hindcast harus ditafsirkan sebagai evaluasi pada sampel validasi dan sebaiknya dilengkapi full-population evaluation pada pengembangan berikutnya.

4.20 Rekayasa Fitur Prediksi

Feature engineering dibangun untuk menangkap kondisi saat ini, memori temporal, arah perubahan, persistensi, seasonality, dan posisi spasial. Semua fitur numerik disusun pada base month yang sama sebelum model horizon diterapkan.

Kelompok	Fitur Utama	Fungsi
Meteorologis	SPI-1, SPI-3, rainfall anomaly t , lag 1-3	Sinyal defisit jangka pendek dan akumulatif
Vegetasi	NDVI anomaly t , lag 1-3, trend 1 bulan, rolling mean 3 bulan	Respons vegetasi dan momentum perubahan
Soil moisture	SM anomaly t , lag 1-3, trend 1 bulan, rolling mean 3 bulan	Kondisi medium penyimpanan air dan predictor pertanian
Hazard historis	LDI t , lag 1-3, LDI trend	Memori kondisi kekeringan terdahulu
Persistensi	Jumlah tiga periode terakhir dengan $LDI \geq 1,00$	Membedakan kejadian baru dan menetap
Temporal	sin/cos current month dan target month	Representasi seasonality tanpa diskontinuitas Desember-Januari
Spasial & kualitas	latitude, longitude, NDVI-missing flag, SM-missing flag	Konteks lokasi dan transparansi kelengkapan input
Forecast	forecast month, horizon, Forecast LDI, forecast class, model	
Model validation	hindcast RMSE, MAE, R2, accuracy, macro precision/recall/F1	
Forecast quality	baseline agreement, input completeness, CDPI status	

Tabel 7. Kelompok fitur pada subsistem prediksi multi-horizon.

4.21 Penanganan Missing Value

Missing value yang berasal dari cloud contamination, NoData, atau keterbatasan coverage tidak diubah menjadi angka observasi semu. Di dalam pipeline model, SimpleImputer dengan strategi median digunakan setelah temporal split, sedangkan missing-data flags mempertahankan informasi bahwa suatu predictor awalnya tidak tersedia. Target LDI yang tidak valid tidak digunakan sebagai label training.

4.22 Kandidat Model dan Seleksi per Horizon

Tiga keluarga model dibandingkan: HistGradientBoostingRegressor sebagai gradient-boosting baseline yang efisien untuk data besar, RandomForestRegressor sebagai bagging ensemble yang robust terhadap nonlinearitas, dan XGBoost apabila paket tersedia pada lingkungan komputasi. Model dibandingkan secara terpisah untuk setiap horizon karena tingkat kesulitan forecast dapat berubah seiring bertambahnya lead time.

$$m_h^* = \arg \min RMSE_h(m)$$

RMSE digunakan sebagai kriteria utama karena mempertahankan penalti lebih besar terhadap kesalahan ekstrem. MAE dan R2 dilaporkan sebagai metrik regresi pendukung. Predicted LDI juga dikonversi menggunakan threshold kelas yang sama untuk menghitung accuracy, macro precision, macro recall, dan macro F1. Macro-F1 digunakan sebagai informasi tambahan agar performa pada kelas minoritas tidak tertutup oleh dominasi kelas Normal.


4.23 Temporal Hindcast 2025

Temporal hindcast dipakai sebagai validasi utama forecasting. Untuk setiap horizon, training-tuning menggunakan target yang tanggalnya tidak melewati Desember 2024, sedangkan target sepanjang 2025 diperlakukan sebagai data yang belum diketahui. Model memprediksi target 2025 dari fitur historis sebelum target tersebut, kemudian hasilnya dibandingkan dengan observasi aktual 2025. Struktur ini meniru kondisi operasional forecast dan mencegah random time leakage.

Seleksi model dilakukan per horizon berdasarkan RMSE hindcast terendah. Nilai performa dicatat secara terpisah untuk H+1 sampai H+5 karena error secara teoritis dapat meningkat pada horizon yang lebih panjang. Setelah keluarga model terpilih, model validasi tidak langsung digunakan untuk inference final; model dibangun ulang menggunakan data historis yang lebih lengkap.

4.24 Refit Model Final dan Inference Agustus-Desember 2026

Setelah model terbaik per horizon ditentukan, keluarga model yang sama dilatih ulang menggunakan seluruh pasangan predictor-target observasional yang tersedia sampai Juli 2026. Base month inference adalah Juli 2026. Satu matriks fitur Juli 2026 kemudian dikirim ke lima model horizon untuk menghasilkan prediksi Agustus sampai Desember 2026 secara paralel.



Gambar 2. Kerangka direct multi-horizon forecasting pada LBS Drought Engine.

Horizon	Base Month	Target	Model
H+1	Jul 2026	Aug 2026	Model horizon 1
H+2	Jul 2026	Sep 2026	Model horizon 2
H+3	Jul 2026	Oct 2026	Model horizon 3
H+4	Jul 2026	Nov 2026	Model horizon 4
H+5	Jul 2026	Dec 2026	Model horizon 5

Tabel 8. Hubungan base month, horizon, dan target forecast.

4.25 Klasifikasi Forecast dan Ranking Desa

Nilai Forecast LDI dikonversi ke enam kelas menggunakan threshold yang sama dengan LDI operasional: Normal, Waspada, Kering Ringan, Kering Sedang, Kering Berat, dan Ekstrem. Setiap output desa menyimpan forecast month, horizon, nilai LDI, kelas, nama model terpilih, serta metrik hindcast model horizon tersebut. Ranking prediktif disusun berdasarkan Forecast LDI dari nilai tertinggi ke terendah untuk mengidentifikasi desa yang memerlukan perhatian awal.

Forecast ranking berbeda dari CDPI. LDI menggambarkan severity/hazard yang diperkirakan, sedangkan CDPI memerlukan informasi coverage dan affected area. Oleh karena itu, keduanya tidak dipertukarkan secara terminologis.

4.26 Ketidakpastian Forecast dan Safeguard CDPI

Ketidakpastian forecast disajikan melalui metrik hindcast per horizon, kelengkapan input, baseline indicator agreement, dan lead time. Sistem tidak menginterpretasikan model output sebagai probabilitas kejadian apabila model belum menghasilkan probabilistic prediction interval. Secara operasional, confidence cenderung menurun ketika horizon semakin panjang atau input aktual semakin tidak lengkap.

Forecast CDPI hanya diaktifkan apabila tersedia riwayat observasional CDPI atau komponen severity, coverage, dan affected area dalam panjang seri yang memadai untuk membangun target supervised. Pada implementasi saat ini digunakan safeguard minimum riwayat target sebelum forecast CDPI diizinkan. Apabila syarat tidak terpenuhi, kolom Forecast CDPI dibiarkan kosong dan diberi status eksplisit, sehingga sistem tidak menciptakan nilai prioritas sintetis yang tidak dapat divalidasi.

4.27 Validasi Terpadu Monitoring, Forecast, dan Prakiraan Dampak Kerugian

Validasi dilakukan pada lima level: indikator, LDI monitoring, CDPI monitoring, model forecast, dan model prakiraan dampak kerugian.

Pertama, validasi indikator. SPI dibandingkan dengan stasiun hujan atau indeks resmi apabila tersedia. NDVI anomaly dibandingkan dengan laporan vegetation stress atau kondisi tanaman. Soil moisture dibandingkan dengan observasi kelembaban tanah atau dataset alternatif.

Kedua, validasi LDI. LDI dapat dibandingkan dengan laporan kejadian kekeringan, gagal panen/puso, distribusi air bersih, kondisi reservoir, atau indikator independen lain. Untuk data kontinu dapat digunakan Pearson/Spearman correlation dan RMSE bila tersedia reference value. Untuk klasifikasi digunakan confusion matrix, precision, recall, F1-score, accuracy, dan Cohen's Kappa.

Ketiga, validasi CDPI. CDPI dievaluasi berdasarkan kemampuan ranking mengidentifikasi wilayah yang benar-benar memperoleh atau memerlukan intervensi. Salah satu ukuran yang relevan adalah Top-K Hit Rate, misalnya persentase desa terdampak aktual yang ditemukan pada Top 10, Top 50, atau Top 100 ranking CDPI. Keempat, validasi forecast dilakukan melalui temporal hindcast per horizon. Nilai prediksi LDI dibandingkan dengan LDI aktual menggunakan RMSE, MAE,

dan R2; setelah thresholding, kelas prediksi dievaluasi menggunakan accuracy, precision, recall, dan macro-F1. Metrik wajib dilaporkan per horizon karena performa H+1 tidak boleh diasumsikan sama dengan H+5.

Kelima, validasi dampak. Potential production loss dibandingkan dengan perubahan produktivitas, produksi, luas puso/gagal panen, atau laporan kerusakan tanaman pada periode dan wilayah yang sesuai. Parameter β dan fungsi transformasi hazard dikalibrasi pada data historis dan dievaluasi pada periode/wilayah holdout. Metrik yang dapat digunakan meliputi MAE, RMSE, bias, MAPE/sMAPE bila denominator memadai, korelasi, serta kemampuan ranking Top-K wilayah dengan kehilangan terbesar. Potential economic loss divalidasi setelah konsistensi basis harga dan unit produksi dipastikan.

4.28 Spatial dan Temporal Cross-Validation

Random split antar-pixel dihindari karena spatial autocorrelation dapat menyebabkan hasil validasi terlalu optimistis. Validasi dilakukan melalui temporal holdout, event-based validation, serta perbandingan performa antarwilayah atau zona iklim. Pendekatan ini membantu menguji kemampuan generalisasi model pada kejadian dan wilayah yang tidak digunakan saat kalibrasi. Pada forecast engine, temporal holdout operasional menggunakan target 2025 sebagai hindcast, kemudian model terpilih direfit menggunakan observasi sampai Juli 2026. Untuk pengembangan lanjutan disarankan rolling-origin evaluation lintas beberapa tahun agar variasi kondisi basah-kering tercakup lebih luas.

4.29 Sensitivity Analysis

Sensitivity analysis dilakukan pada:

- bobot LDI;
- skala SPI-1 dan SPI-3;
- kedalaman soil moisture;
- baseline period;
- threshold klasifikasi; dan
- bobot CDPI.

pemilihan fitur lag dan rolling window;

keluarga model dan hyperparameter; serta

lead time H+1 sampai H+5.

koefisien sensitivitas dampak β ;

baseline produktivitas Y dan level administrasi sumber;

harga gabah P serta basis GKG/GKP;

faktor tanaman G;

fungsi transfer Forecast LDI ke normalized forecast hazard; dan

propagasi RMSE hindcast ke rentang loss rendah-tinggi.

Model dianggap lebih robust apabila variasi parameter yang wajar tidak menyebabkan perubahan ekstrem pada pola utama kekeringan dan ranking desa prioritas.

4.30 Analisis Ketidakpastian

Confidence indicator dibentuk dari kelengkapan data, valid area, agreement antarindikator, konsistensi temporal, dan kestabilan ranking pada sensitivity analysis. Hasil dapat disajikan sebagai High, Medium, atau Low Confidence. Indikator ini membantu pengguna membedakan sinyal kuat dari wilayah yang memerlukan verifikasi lapangan lebih lanjut. Untuk hasil prediksi, confidence juga mempertimbangkan error hindcast model pada horizon terkait. Confidence tidak boleh ditafsirkan sebagai probabilitas formal kecuali model probabilistik atau prediction interval telah dikalibrasi secara eksplisit. Pada modul dampak, ketidakpastian tambahan berasal dari produktivitas baseline, harga, faktor tanaman, koefisien β , dan fungsi transfer LDI ke hazard. Ketidakpastian tersebut dianalisis dengan skenario low-base-high atau sensitivity analysis dan tidak digabungkan menjadi confidence interval formal apabila distribusi probabilistik parameter belum tersedia.

4.31 Kerangka Metode Prakiraan Dampak Kerugian

Prakiraan dampak dikembangkan sebagai lapisan analitik setelah hazard monitoring dan forecast. Tujuannya bukan menggantikan CDPI, tetapi menerjemahkan hazard menjadi besaran fisik dan ekonomi yang lebih mudah digunakan untuk perencanaan intervensi. Dua jalur dihitung secara terpisah karena struktur datanya berbeda: jalur aktual menggunakan drought coverage dan mean severity hasil agregasi pixel, sedangkan jalur forecast menggunakan Forecast LDI tingkat desa. Pendekatan ini mencegah penciptaan predicted coverage atau predicted severity yang tidak dihasilkan oleh model forecasting.

Empat keluaran utama adalah: LBS terpapar (ha), Drought Equivalent Area/DEA (ha-eq), Potential Production Loss/PPL (ton), dan Potential Economic Loss/PEL (Rp). Seluruh keluaran diberi label potential/scenario-based estimate sampai kalibrasi terhadap observasi hasil panen dan kejadian puso dilakukan.

4.32 Definisi Variabel dan Parameter Dampak

Notasi utama ditunjukkan pada Tabel 9. Parameter β adalah koefisien sensitivitas empiris sistem dan bukan crop yield response factor K_y FAO. Nilai default pada aplikasi dapat digunakan untuk simulasi, tetapi nilai operasional harus dikalibrasi. Faktor tanaman G memungkinkan model membedakan luas LBS dari luas yang benar-benar sedang ditanami; $G = 1$ digunakan hanya sebagai screening conservative exposure ketika informasi luas tanam tidak tersedia.

Tabel 9. Variabel utama model prakiraan dampak kerugian

Simbol	Variabel	Satuan/Skala	Aturan Operasional
A_i	Luas polygon LBS	ha	Exposure base spasial.
C_i	Drought coverage aktual	0–1	coverage (%) / 100.
S_i, H_i	Mean severity; normalized hazard aktual	0–5; 0–1	$H_i = S_i/5$.
$G_{i,t}$	Faktor areal yang sedang ditanami/terekspose	0–1	Gunakan data tanam/fase bila tersedia; fallback screening = 1.
$Y_{i,t}$	Produktivitas baseline	ton GKG/ha	Prioritas kabupaten/provinsi; fallback nasional dapat memakai statistik BPS.

$\beta_{i,t}$	Koefisien sensitivitas hasil	0–1	Dikalibrasi terhadap kehilangan hasil/puso; bukan Ky FAO.
$P_{i,t}$	Harga gabah	Rp/kg	Harus konsisten dengan basis hasil (ideal GKG jika Y berbasis GKG).
$LDI_{i,h}^f$	Forecast LDI horizon h	indeks	Output direct multi-horizon H+1–H+5.
$RMSE_h$	RMSE hindcast horizon h	unit LDI	Digunakan untuk screening uncertainty band.

4.33 Estimasi Exposure dan Drought Equivalent Area Aktual

Untuk setiap polygon LBS i , coverage dinormalisasi menjadi C_i dan mean severity dinormalisasi menjadi H_i . Karena mean severity operasional telah dihitung terhadap seluruh pixel valid, coverage tidak boleh dikalikan kembali langsung dengan severity dalam satu indeks intensitas. Pendekatan kondisional berikut digunakan untuk menghindari double-counting.

$$C_i = \text{coverage}_i / 100 \quad ; \quad H_i = \text{severity}_i / 5$$

Luas LBS terpapar aktual adalah:

$$A_{E,i} = A_i \times C_i$$

Intensitas rata-rata pada bagian polygon yang benar-benar kering didefinisikan sebagai:

$$I_i = \min(1, H_i / C_i) \text{ untuk } C_i > 0; \quad I_i = 0 \text{ untuk } C_i = 0$$

Drought Equivalent Area (DEA) menyatakan luas ekuivalen apabila intensitas kekeringan dinormalkan terhadap kondisi maksimum. Secara aljabar DEA dapat dihitung tanpa menggandakan coverage:

$$A_{DEA,i} = A_i \times H_i = A_{E,i} \times I_i$$

DEA berbeda dari luas fisik terpapar. Contoh: 100 ha LBS dengan coverage 60% dan intensitas kondisional 50% memiliki 60 ha terpapar, tetapi 30 ha-eq DEA.

4.34 Estimasi Potential Production Loss Aktual

Estimasi kehilangan produksi menggunakan luas terpapar, proporsi areal yang sedang ditanami, produktivitas baseline, dan damage rate. Damage rate dibentuk dari koefisien sensitivitas β dan intensitas kekeringan kondisional. Formulasi ini merupakan fungsi respons empiris untuk screening dan wajib dikalibrasi menggunakan kehilangan hasil/puso historis.

$$D_i = \min(1, \beta_i \times I_i)$$

$$PPL_i = A_{E,i} \times G_{i,t} \times Y_{i,t} \times D_i$$

Jika data faktor tanaman belum tersedia, implementasi dapat menggunakan $G = 1$ sebagai skenario upper-exposure screening. Hasil wajib diberi label bahwa seluruh LBS diasumsikan sedang terekspos produksi; angka tersebut tidak boleh langsung diperlakukan sebagai kehilangan hasil aktual.

4.35 Estimasi Potential Economic Loss Aktual

Potential Economic Loss menilai nilai produksi yang berpotensi tidak terealisasi. Karena PPL dinyatakan dalam ton, konversi ke kilogram dilakukan sebelum dikalikan harga gabah.

$$PEL_i = PPL_i \times 1000 \times P_{i,t}$$

Jika Y menggunakan ton GKG/ha, P harus menggunakan harga GKG Rp/kg atau terlebih dahulu dilakukan konversi yang terdokumentasi. Harga konsumen beras tidak boleh langsung digunakan sebagai pengganti harga gabah karena merepresentasikan tahap rantai nilai yang berbeda.

4.36 Prakiraan Dampak Berbasis Forecast LDI

Forecast engine menghasilkan LDI desa untuk horizon h, bukan distribusi kelas pixel masa depan. Oleh karena itu, model tidak membangkitkan predicted coverage atau predicted severity sintetis. Forecast LDI ditransformasikan menjadi normalized forecast hazard H^f menggunakan fungsi kontinu yang memetakan threshold Waspada 0,50 menjadi hazard 0 dan threshold Ekstrem 2,50 menjadi hazard 1.

$$H_{i,h}^f = \text{clamp}((LDI_{i,h}^f - 0,50) / 2,00, 0, 1)$$

Transformasi tersebut memberi interpretasi: LDI 1,00 $\approx$ hazard 0,25; LDI 1,50 $\approx$ 0,50; LDI 2,00 $\approx$ 0,75; dan LDI $\geq 2,50 = 1,00$. Fungsi ini adalah transfer function operasional yang harus diuji melalui sensitivity analysis dan kalibrasi dampak; bukan probabilitas puso.

Forecast Drought Equivalent Area dan forecast damage rate dihitung sebagai:

$$A_{FDEA,i,h} = A_i \times H_{i,h}^f$$

$$D_{i,h}^f = \min(1, \beta_i \times H_{i,h}^f)$$

Selanjutnya potensi kehilangan produksi dan nilai ekonomi pada horizon h adalah:

$$PPL_{i,h}^f = A_i \times G_{i,t+h} \times Y_{i,t+h} \times D_{i,h}^f$$

$$PEL_{i,h}^f = PPL_{i,h}^f \times 1000 \times P_{i,t+h}$$

Apabila G, Y, atau P masa depan belum tersedia, sistem menggunakan nilai skenario yang terdokumentasi (misalnya nilai terakhir, climatological/annual baseline, atau fallback administrasi) dan menandai sumber fallback pada metadata.

4.37 Screening Uncertainty Band Forecast

Ketidakpastian model forecast dipropagasikan menggunakan RMSE hindcast pada horizon yang sama. Untuk Forecast LDI utama, batas screening rendah dan tinggi dibentuk sebagai berikut:

$$LDI_{i,h}^- = LDI_{i,h}^f - RMSE_h \quad ; \quad LDI_{i,h}^+ = LDI_{i,h}^f + RMSE_h$$

Kedua nilai kemudian dimasukkan kembali ke fungsi H^f dan seluruh persamaan dampak untuk menghasilkan PPL/PEL low dan high. Rentang ini disebut screening uncertainty band, bukan confidence interval atau prediction interval formal, karena RMSE horizon merupakan ringkasan error historis dan tidak menyatakan distribusi probabilistik error individual tiap desa.

Selain error LDI, sensitivity analysis dilakukan terhadap β , G, Y, dan P dengan skenario low-base-high. Dengan demikian dashboard dapat membedakan uncertainty model forecast dari uncertainty parameter dampak.

4.38 Agregasi Spasial dan Ranking Dampak

Untuk level desa, kecamatan, kabupaten, provinsi, dan nasional, besaran ekstensif seperti A_E, DEA, PPL, dan PEL dijumlahkan antar-polygon yang unik. Besaran intensif seperti LDI, H^f , atau loss rate tidak dijumlahkan; nilai ringkas dihitung menggunakan rata-rata berbobot luas atau exposure sesuai tujuan analisis. Ranking dampak utama menggunakan PPL ketika harga belum tersedia dan PEL ketika harga terverifikasi tersedia.

Agregasi harus memastikan setiap polygon LBS hanya dihitung sekali pada satu snapshot periode. Jika satu desa mempunyai beberapa polygon LBS, seluruh polygon dijumlahkan terlebih dahulu untuk memperoleh nilai desa sebelum ranking administratif dilakukan.

4.39 Kalibrasi dan Validasi Parameter Dampak

Kalibrasi β dan transfer function LDI→hazard dilakukan menggunakan pasangan historis hazard-dampak. Target yang disarankan meliputi anomali produktivitas/produksi, luas puso, laporan gagal panen, atau observasi hasil petak yang dapat diselaraskan secara temporal dan spasial. Kalibrasi dilakukan pada periode training dan dievaluasi pada temporal/spatial holdout untuk mencegah overfitting.

Model dampak dilaporkan menggunakan MAE, RMSE, bias, korelasi, dan MAPE/sMAPE ketika sesuai. Selain akurasi numerik, kemampuan ranking wilayah kerugian terbesar dievaluasi menggunakan Top-K Hit Rate atau rank correlation. Parameter tidak boleh dikalibrasi hanya untuk menghasilkan angka ekonomi yang tinggi atau rendah; objective function harus ditetapkan sebelum evaluasi.

4.40 Safeguard Interpretasi Kerugian


Sistem menerapkan empat safeguard. Pertama, tidak membuat predicted coverage/severity jika forecast engine tidak memprediksinya. Kedua, tidak menampilkan PEL apabila harga tidak tersedia atau basis unit tidak konsisten. Ketiga, membedakan potential loss dari verified actual loss. Keempat, memisahkan production loss dari asset damage. Nilai rupiah pada WebGIS harus menampilkan sumber produktivitas, harga, β , faktor tanaman, dan status skenario agar pengguna dapat menelusuri asumsi yang membentuk estimasi.

Pada penggunaan operasional awal, parameter default hanya berfungsi sebagai scenario screening. Keputusan kompensasi, klaim kerugian, atau perhitungan damage-and-loss resmi memerlukan validasi lapangan dan prosedur statistik/administratif yang sesuai.

5. IMPLEMENTASI SISTEM

5.1 Arsitektur Sistem

Sistem dikembangkan dalam empat lapisan utama: data, processing, analytics, dan serving. Output disajikan melalui WebGIS, dashboard, dan operational report.



Gambar 3. Arsitektur konseptual implementasi monitoring dan serving system.

5.2 Data Layer

Data layer menyimpan raw data, processed data, batas administrasi, metadata, dan riwayat versi. Untuk reproducibility, setiap periode pemrosesan idealnya memiliki timestamp, source version, processing version, dan status quality control.

5.3 Processing Layer

Processing layer menjalankan preprocessing, agregasi temporal, baseline calculation, SPI, NDVI anomaly, soil moisture anomaly, harmonisasi grid, fusion LDI, dan klasifikasi. Proses dapat diotomasi menggunakan job scheduler sesuai frekuensi update. Untuk forecast, layer ini juga membentuk panel time series, lag, rolling feature, trend, persistence, cyclical month encoding, dan missing-data flags sebelum pemodelan.

5.4 Analytics Layer

Analytics layer menjalankan zonal statistics, CDPI, ranking, trend, persistence, agreement, dan confidence. Hasil disimpan dalam tabel spasial desa sehingga dashboard tidak harus menghitung ulang raster setiap kali pengguna membuka halaman. Forecast analytics menyimpan model per horizon, metrik hindcast, forecast LDI, forecast class, dan ranking sehingga dashboard dapat berpindah antarbulan tanpa menjalankan ulang training. Impact analytics menghitung exposed LBS area, DEA, potential production loss, potential economic loss, forecast impact per horizon, serta screening uncertainty band dan menyimpan provenance parameter Y , P , β , dan G .

5.5 WebGIS

WebGIS menyediakan:

- peta LDI dan kelas kekeringan;
- layer desa prioritas;
- pencarian desa/kecamatan/kabupaten;
- popup detail indikator;
- filter level peringatan;
- visualisasi perubahan antarperiode; dan
- layer confidence untuk mendukung interpretasi.

popup potensi dampak per polygon/desa: LBS terpapar, DEA, PPL, dan PEL;

mode forecast impact H+1 sampai H+5 beserta screening uncertainty band; dan

ranking Top-N desa/kecamatan/kabupaten berdasarkan potential production/economic loss.

5.6 Executive Dashboard

Dashboard eksekutif menampilkan KPI yang ringkas, antara lain persentase desa per kelas, jumlah wilayah severe/critical, Top-N prioritas, perubahan dari periode sebelumnya, distribusi per provinsi, dan ringkasan confidence. Setelah modul dampak aktif, KPI ditambah total LBS terpapar, DEA, potential production loss (ton), potential economic loss (Rp), dan Top-N wilayah dampak untuk kondisi aktual serta forecast horizon terpilih.

5.7 Operational Report

Laporan operasional dapat diekspor ke Excel dan PDF. Kolom minimum yang disarankan ditunjukkan pada Tabel 5.

Tabel 5. Struktur atribut minimum laporan operasional

Kelompok	Atribut
Identitas	kode desa, desa, kecamatan, kabupaten, provinsi
Indikator	SPI-1, SPI-3, NDVI anomaly, soil moisture anomaly
Hazard	LDI, kelas, dominant severity, mean severity
Dampak spasial	drought coverage, severe coverage, drought area
Temporal	trend, persistence
Confidence	agreement, valid area, confidence level
Prioritas	CDPI, national rank, provincial rank, warning level
Dampak produksi & ekonomi	exposed_lbs_ha, drought_equivalent_area_haeq, potential_production_loss_ton, potential_economic_loss_rp, impact_parameter_source, forecast_loss_low/high

5.8 Forecast Engine

Forecast engine menjalankan lima tahap utama: audit input historis, feature engineering, temporal hindcast dan model selection, refit model final, serta inference H+1 sampai H+5. Model disimpan sebagai artefak serialisasi per horizon bersama daftar fitur dan metrik validasi. Output desa diekspor sebagai CSV dan Parquet, kemudian dapat dikonversi ke GeoJSON dan raster berbasis polygon desa untuk kebutuhan WebGIS.

5.9 Dashboard Prediksi dan Monthly Update

Dashboard prediksi menyediakan pemilihan bulan forecast, ringkasan jumlah desa per kelas, mean/max Forecast LDI, Top-N ranking, dan peta interaktif. Arsitektur dibuat agar update berikutnya dapat menggunakan mekanisme resume/reuse: aset historis, weight cache, dan model yang masih valid tidak dihitung ulang tanpa kebutuhan. Pada saat data observasi bulan baru tersedia, pipeline dapat diperbarui dan model direfit sesuai kebijakan validasi yang ditetapkan.

5.10 Impact Loss Engine

Impact Loss Engine menjalankan dua jalur perhitungan. Jalur aktual membaca luas LBS, drought coverage, dan mean severity untuk menghitung exposed area dan DEA sebelum menerapkan Y , G , β , dan P . Jalur forecast membaca Forecast LDI serta RMSE per horizon, mentransformasikannya menjadi normalized forecast hazard, lalu menghitung FDEA, forecast PPL, forecast PEL, dan low-high screening range. Semua parameter disimpan bersama source level dan timestamp agar hasil dapat direproduksi.

5.11 Dashboard Prakiraan Dampak Kerugian

Dashboard dampak menyajikan empat KPI inti: LBS terpapar/at risk, Drought Equivalent Area, potential production loss, dan potential economic loss. Pada mode aktual, popup polygon menggunakan coverage dan severity; pada mode forecast, popup menggunakan Forecast LDI dan RMSE horizon. Ketika harga belum diisi/tersedia, ranking tetap berjalan menggunakan ton kehilangan produksi tanpa membuat nilai rupiah. Setiap nilai ekonomi diberi label skenario dan sumber parameter untuk mencegah false precision.

6. HASIL DAN PEMBAHASAN

6.1 Cakupan Implementasi

Sumber batas administrasi memuat 83.486 record polygon. Quality control menemukan 86 record tanpa ID desa resmi yang dapat digunakan secara konsisten sebagai kunci time series. Record tersebut tidak diberi ID sintetis dan dikeluarkan dari panel prediksi, sehingga subsistem forecast menggunakan 83.400 desa. Pemisahan ini penting untuk menjaga integritas join antarbulan dan mencegah tercampurnya unit administratif.

6.2 Distribusi Tingkat Kekeringan Monitoring Awal

Distribusi hasil klasifikasi monitoring awal yang tersedia pada dokumen sumber ditunjukkan pada Tabel 6. Nilai pada tabel ini merupakan snapshot monitoring dan tidak boleh dibaca sebagai distribusi forecast Agustus-Desember 2026.

Tabel 6. Distribusi desa berdasarkan kategori kekeringan

Kategori	Persentase
Normal	76,14%
Waspada	14,14%
Kering Ringan	6,16%
Kering Sedang	2,18%
Kering Berat	1,29%
Ekstrem	0,10%

Catatan: total persentase dapat berbeda sangat kecil dari 100% akibat pembulatan.

Sebagian besar desa berada pada kategori Normal, yaitu 76,14%. Meskipun demikian, sekitar seperempat unit analisis berada pada kategori Waspada hingga Ekstrem. Dari perspektif pengambilan keputusan, kondisi ini menunjukkan bahwa statistik nasional saja tidak cukup: kategori dengan persentase kecil seperti Kering Berat dan Ekstrem tetap memerlukan perhatian karena dapat terkonsentrasi pada lokasi tertentu dan memiliki coverage tinggi di tingkat desa.

6.3 Nilai Tambah Multiindikator

Penggunaan tiga indikator memberikan interpretasi yang lebih kaya. SPI mengindikasikan tekanan meteorologis, soil moisture menggambarkan kondisi medium penyimpanan air, sedangkan NDVI menunjukkan respons vegetasi. Kombinasi ini memungkinkan sistem membedakan kondisi seperti: defisit hujan baru yang belum memengaruhi vegetasi, tanah kering tetapi vegetasi relatif stabil, atau vegetation stress yang tidak sepenuhnya dijelaskan oleh curah hujan.

Multi-indicator agreement juga mengurangi risiko interpretasi tunggal. Sebuah desa dengan LDI tinggi dan agreement 3/3 memiliki dukungan bukti yang lebih kuat dibanding desa dengan nilai serupa tetapi hanya satu indikator yang ekstrem. Meskipun demikian, disagreement bukan selalu kesalahan data; kondisi tersebut dapat merepresentasikan fase transisi atau *lag response* antarvariabel.

6.4 Interpretasi Tingkat Desa

Penggunaan desa sebagai unit agregasi memberikan keuntungan administratif, tetapi membutuhkan kehati-hatian. Desa kecil dapat berada di dalam satu atau beberapa footprint grid soil moisture yang sama. Oleh karena itu, sistem tidak mengklaim bahwa ERA5-Land memiliki resolusi desa. Sebaliknya, sistem mengagregasikan bukti lingkungan yang tersedia ke unit keputusan administratif. Penyajian valid area dan confidence merupakan mekanisme untuk menjaga transparansi terhadap keterbatasan tersebut.

Mean Severity dan Dominant Severity digunakan secara bersamaan karena keduanya menjawab pertanyaan berbeda. Dominant Severity memberikan ringkasan yang mudah dipahami, sedangkan Mean Severity mempertahankan informasi heterogenitas kelas berdasarkan proporsi area. Drought Coverage dan Severe Coverage selanjutnya menunjukkan seberapa luas kondisi tersebut terjadi di dalam desa.

6.5 Peran CDPI dalam Prioritas Intervensi

CDPI mengubah hasil hazard menjadi urutan prioritas operasional. Dua desa dapat memiliki severity yang sama, tetapi desa dengan coverage lebih tinggi memperoleh prioritas lebih besar. Sebaliknya, penggunaan luas absolut tanpa transformasi dapat menyebabkan desa yang besar selalu mendominasi. Transformasi logaritmik mengurangi efek ukuran wilayah sekaligus tetap mempertahankan informasi kebutuhan intervensi yang berhubungan dengan luas area terdampak.

Pemilihan bobot 0,50 untuk severity, 0,30 untuk coverage, dan 0,20 untuk area merupakan desain awal yang berorientasi pada urgensi kondisi. Karena bobot dapat memengaruhi ranking, sensitivity analysis merupakan syarat penting sebelum CDPI digunakan untuk alokasi sumber daya secara nyata.

6.6 Peringatan Dini: Dari Kondisi ke Arah Perubahan

Peta satu periode hanya menunjukkan keadaan saat observasi. Penambahan trend dan persistence mengubah sistem menjadi lebih mendekati early warning. Desa yang berada pada kategori Kering Ringan tetapi memburuk selama dua periode dapat lebih perlu dipantau daripada desa Kering Sedang yang sedang membaik. Persistensi juga membantu membedakan anomali jangka pendek dari kejadian yang berlangsung lama.

SPI-1 berfungsi sebagai leading signal karena dapat berubah sebelum vegetation stress terlihat. SPI-3 memberikan konteks akumulatif. Soil moisture dan NDVI kemudian berperan sebagai konfirmasi perkembangan dampak. Struktur ini mendukung konsep **detection → confirmation → prioritization**.

6.7 Relevansi Operasional WebGIS dan Dashboard

Nilai utama WebGIS bukan hanya visualisasi peta, tetapi kemampuan pengguna menelusuri dari skala wilayah besar menuju desa dan membaca indikator pembentuk keputusan. Dashboard eksekutif menyediakan ringkasan nasional/provinsi, sedangkan operational report memberi daftar yang dapat digunakan oleh tim lapangan. Dengan demikian, satu sumber analisis mendukung kebutuhan pengguna yang berbeda tanpa mengubah metode inti.

6.8 Validasi yang Diperlukan Sebelum Implementasi Penuh

Hasil klasifikasi dan distribusi desa menunjukkan bahwa pipeline telah menghasilkan keluaran operasional, tetapi akurasi tidak dapat disimpulkan hanya dari pola visual atau distribusi kelas. Sebelum penggunaan sebagai dasar keputusan kritis, diperlukan validasi independen terhadap

kejadian historis dan laporan lapangan. Validasi tersebut juga diperlukan untuk mengkalibrasi threshold LDI, aturan early warning, dan bobot CDPI.

6.9 Keluaran Prediksi Multi-Horizon

Implementasi forecast menghasilkan lima set keluaran desa untuk Agustus, September, Oktober, November, dan Desember 2026. Setiap bulan memuat Forecast LDI, kelas kekeringan, model horizon terpilih, metrik hindcast, serta atribut kualitas input. Keluaran gabungan memungkinkan analisis trajectory per desa dari kondisi aktual Juli 2026 menuju lima bulan forecast.

Dokumen ini tidak menambahkan angka forecast atau nilai akurasi yang tidak tersedia di file sumber yang dilampirkan. Nilai numerik final harus diambil langsung dari FORECAST_VILLAGE_AUG_DEC_2026.csv dan FORECAST_MODEL_ACCURACY.csv hasil pipeline agar pembahasan tetap reproducible dan tidak menggunakan nilai ilustratif sebagai hasil penelitian.

Secara interpretatif, perubahan kelas antarhorizon harus dibaca bersama error hindcast per horizon. Forecast H+5 dengan severity tinggi tetapi error hindcast besar memerlukan verifikasi lebih kuat dibanding H+1 dengan performa historis yang stabil. Prinsip ini mencegah dashboard prediksi diperlakukan sebagai kepastian absolut.

6.10 Keluaran Prakiraan Dampak Kerugian

Modul dampak menghasilkan keluaran per polygon dan agregasi administrasi berupa exposed LBS area, Drought Equivalent Area, potential production loss, serta potential economic loss. Untuk forecast, keluaran tersedia per horizon H+1 sampai H+5 dan disertai low-high screening band berbasis RMSE hindcast. Nilai tersebut dapat dipakai untuk screening wilayah yang memerlukan verifikasi/intervensi lebih awal, tetapi tidak diperlakukan sebagai kerugian aktual terverifikasi.

Dokumen ini tidak memasukkan angka kerugian nasional atau daerah sebagai hasil empiris apabila parameter produktivitas regional, harga periode terkait, faktor tanaman, dan kalibrasi β belum tersedia dalam data penelitian. Baseline nasional 5,32 ton GKG/ha hanya berfungsi sebagai fallback scenario. Prinsip ini menjaga agar visualisasi rupiah pada sistem tidak menciptakan presisi semu.

Nilai tambah utama forecast impact adalah kemampuan membandingkan trajectory risiko produksi antarhorizon. Desa dengan Forecast LDI moderat tetapi luas LBS sangat besar dapat memiliki PPL lebih tinggi daripada desa dengan Forecast LDI lebih ekstrem namun area kecil. Karena itu, ranking impact melengkapi—bukan menggantikan—ranking hazard dan CDPI.

7. KETERBATASAN PENELITIAN

Penelitian memiliki beberapa keterbatasan yang perlu dinyatakan secara eksplisit.

Pertama, input memiliki resolusi spasial berbeda. Resampling tidak menciptakan informasi baru sehingga tingkat desa harus dipahami sebagai unit agregasi. Kedua, NDVI tidak hanya dipengaruhi kekeringan, tetapi juga perubahan penggunaan lahan, panen, kebakaran, hama, dan

aktivitas manusia. Ketiga, soil moisture reanalysis merupakan hasil model dan tidak identik dengan pengukuran lapangan. Keempat, SPI berbasis curah hujan tidak memasukkan pengaruh temperatur dan atmospheric evaporative demand. Kelima, CDPI belum memasukkan exposure dan vulnerability sosial-ekonomi sehingga tidak boleh diposisikan sebagai drought risk index yang lengkap. Keenam, threshold dan bobot masih memerlukan kalibrasi empiris sesuai karakter agroklimatologi wilayah. Ketujuh, forecast saat ini merupakan statistical direct multi-horizon forecast berbasis indikator historis dan belum menggunakan seasonal climate forecast dinamis sebagai predictor masa depan. Kedelapan, uncertainty belum berupa prediction interval probabilistik; metrik hindcast digunakan sebagai indikator performa per horizon. Kesembilan, temporal validation utama menggunakan target tahun 2025 sehingga robustness lintas banyak kejadian ekstrem masih perlu diuji dengan rolling-origin hindcast. Kesepuluh, forecast CDPI belum boleh diinterpretasikan apabila historical target coverage/affected area belum cukup untuk pelatihan. Kesembilan, modul dampak bergantung pada asumsi produktivitas, harga, faktor areal yang ditanami, dan koefisien sensitivitas; tanpa kalibrasi lapangan, angka PPL/PEL adalah scenario-based potential loss. Kesepuluh, $RMSE \pm$ pada forecast impact hanya screening uncertainty band, bukan interval probabilistik. Kesebelas, model belum menghitung asset damage terhadap irigasi, alat mesin, atau infrastruktur pertanian.

8. PENGEMBANGAN LANJUTAN

Pengembangan selanjutnya diarahkan pada sembilan area. Pertama, mengintegrasikan seasonal climate forecast sebagai exogenous predictors. Kedua, menambahkan evapotranspirasi atau SPEI. Ketiga, melakukan rolling-origin hindcast multi-tahun dan full-population validation. Keempat, mengkalibrasi β dan fungsi transfer $LDI \rightarrow \text{hazard}$ menggunakan produktivitas, produksi, puso, dan observasi lapangan historis. Kelima, mengintegrasikan faktor luas tanam/fase tanaman berbasis KSA atau data operasional agar exposure LBS tidak diasumsikan 100%. Keenam, memasukkan jenis irigasi, varietas, kalender tanam, dan crop-stage sensitivity. Ketujuh, menghubungkan harga gabah regional/bulanan yang konsisten basisnya serta melakukan scenario/sensitivity analysis. Kedelapan, mengembangkan probabilistic forecast atau conformal/prediction interval yang terkalibrasi untuk dampak. Kesembilan, apabila diperlukan, memperluas potential production loss menjadi kerangka FAO damage-and-loss yang juga menilai asset damage dan kebutuhan pemulihan secara terpisah.

Jika exposure dan vulnerability tersedia, kerangka konseptual risiko dapat diperluas menjadi:

$$\text{Drought Risk} = \text{Hazard} \times \text{Exposure} \times \text{Vulnerability}$$

Pengembangan tersebut harus dilakukan sebagai model lanjutan agar CDPI saat ini tetap memiliki definisi yang jelas sebagai prioritas berdasarkan kondisi fisik kekeringan.

9. KESIMPULAN

LBS Drought Early Warning System dikembangkan sebagai kerangka terintegrasi untuk mengubah data klimatologi, penginderaan jauh, reanalisis, dan geometri LBS menjadi informasi monitoring, prediksi, prakiraan dampak, dan pendukung keputusan pada tingkat administrasi desa. Sistem

menggunakan CHIRPS, MODIS, dan ERA5-Land untuk membentuk SPI, NDVI anomaly, soil moisture anomaly, LDI, serta atribut pendukung seperti trend, persistence, agreement, dan confidence. Direct multi-horizon machine learning memprakirakan LDI H+1 sampai H+5, sedangkan Impact Loss Engine menerjemahkan kondisi aktual dan forecast menjadi exposed LBS area, Drought Equivalent Area, potential production loss, serta potential economic loss.

Hasil LDI diterjemahkan ke desa melalui area-weighted zonal statistics sehingga menghasilkan severity, drought coverage, severe drought coverage, dan drought area. CDPI kemudian mengkombinasikan severity, coverage, dan luas terdampak menjadi indeks prioritas intervensi. Penambahan trend, persistence, agreement, dan confidence memperluas fungsi sistem dari pemetaan keadaan menuju early warning dan decision support. Pada subsistem forecast, historical indicator, lag, rolling mean, trend, persistence, seasonality, koordinat, dan missingness digunakan sebagai predictor. Model dipilih melalui temporal hindcast 2025 dan direfit menggunakan observasi sampai Juli 2026 untuk menghasilkan forecast Agustus-Desember 2026. Pada modul dampak, jalur aktual menggunakan coverage dan severity tanpa double-counting, sedangkan jalur forecast menggunakan transformasi kontinu Forecast LDI ke normalized hazard tanpa menciptakan predicted coverage/severity sintetis. Produktivitas, faktor tanaman, koefisien β , dan harga digunakan secara transparan sebagai parameter skenario yang dapat diganti menurut wilayah/periode.

Sumber administrasi mencakup 83.486 polygon, sedangkan panel forecast menggunakan 83.400 desa ber-ID valid. Distribusi monitoring awal yang tercantum pada dokumen sumber tetap dipertahankan sebagai informasi snapshot dan tidak dianggap sebagai hasil forecast. Keluaran prediksi dihasilkan dalam bentuk tabel desa, raster, GeoJSON, dan WebGIS sehingga pengguna dapat membandingkan trajectory antarbulan dan memprioritaskan verifikasi lapangan berdasarkan severity yang diperkirakan serta performa hindcast model horizon terkait.

Sebelum digunakan sebagai dasar alokasi sumber daya secara penuh, model perlu divalidasi menggunakan kejadian historis dan observasi independen. Validasi tersebut menjadi dasar kalibrasi threshold, bobot LDI, bobot CDPI, dan aturan level peringatan. Untuk forecast, validasi harus dilanjutkan melalui rolling-origin hindcast, event-based evaluation, dan observasi independen. Forecast CDPI hanya boleh digunakan setelah target historical coverage/affected area memadai; prinsip no fabricated target dipertahankan sebagai safeguard metodologis. Prakiraan dampak juga harus dikalibrasi terhadap produktivitas, produksi, puso, serta harga historis; nilai default tidak boleh diposisikan sebagai kerugian resmi. RMSE hindcast dapat digunakan sebagai screening uncertainty band, tetapi interval probabilistik memerlukan metode kalibrasi tersendiri.

DAFTAR PUSTAKA

- Didan, K. (2015). *MOD13 User Guide: MODIS Vegetation Index Product Series, Collection 6*. NASA EOSDIS Land Processes DAAC.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., & Michaelsen, J. (2015). The climate hazards infrared precipitation with

- stations—A new environmental record for monitoring extremes. *Scientific Data*, 2, 150066. <https://doi.org/10.1038/sdata.2015.66>
- Hao, Z., & AghaKouchak, A. (2013). Multivariate standardized drought index: A parametric multi-index model. *Advances in Water Resources*, 57, 12–18.
- Hersbach, H., Bell, B., Berrisford, P., et al. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999–2049.
- Kogan, F. N. (1995). Application of vegetation index and brightness temperature for drought detection. *Advances in Space Research*, 15(11), 91–100.
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology* (pp. 179–184). American Meteorological Society.
- Mishra, A. K., & Singh, V. P. (2010). A review of drought concepts. *Journal of Hydrology*, 391(1–2), 202–216.
- Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., et al. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13, 4349–4383.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. In *Third Earth Resources Technology Satellite-1 Symposium* (pp. 309–317). NASA.
- Svoboda, M., LeCompte, D., Hayes, M., et al. (2002). The Drought Monitor. *Bulletin of the American Meteorological Society*, 83(8), 1181–1190.
- Van Loon, A. F. (2015). Hydrological drought explained. *WIREs Water*, 2(4), 359–392.
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The Standardized Precipitation Evapotranspiration Index. *Journal of Climate*, 23(7), 1696–1718.
- Wilhite, D. A., & Glantz, M. H. (1985). Understanding the drought phenomenon: The role of definitions. *Water International*, 10(3), 111–120.
- World Meteorological Organization. (2012). *Standardized Precipitation Index User Guide (WMO-No. 1090)*. Geneva: WMO.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232.
- Roberts, D. R., Bahn, V., Ciuti, S., Boyce, M. S., Elith, J., Guillerá-Arroita, G., et al. (2017). Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, 40(8), 913–929. <https://doi.org/10.1111/ecog.02881>

Badan Pusat Statistik. (2026). Luas Panen dan Produksi Padi di Indonesia 2025. Jakarta: BPS-Statistics Indonesia. Nomor Publikasi 05100.26019.

Conforti, P., Markova, G., & Tochkov, D. (2020). FAO's methodology for damage and loss assessment in agriculture. FAO Statistics Working Paper Series No. 19-17. Rome: Food and Agriculture Organization of the United Nations. ISBN 978-92-5-131961-1.

Steduto, P., Hsiao, T. C., Fereres, E., & Raes, D. (2012). Crop Yield Response to Water. FAO Irrigation and Drainage Paper 66. Rome: Food and Agriculture Organization of the United Nations.