

PERMODELAN DAN PREDIKSI PRODUKSI PADI DI SUMATERA MENGGUNAKAN TEMPORAL CONVOLUTIONAL NETWORK (TCN) BERBASIS DATA IKLIM

SEPTIAN NUNO ZILDJIAN¹

¹Program Studi Sains Data , Fakultas Sains & Teknologi, Universitas Terbuka, Jakarta, Indonesia

Info Artikel

Riwayat Artikel:

Diterima 15, Juni, tahun

Perbaikan 30, Juni, 2026

Disetujui 17, Juli, 2026

Keywords:

Deep Learning

Temporal Convolutional

Network

Produksi Padi

Data Iklim

Permodelan Time Series

ABSTRAK

Produksi padi di Sumatera dipengaruhi oleh kombinasi luas panen dan faktor iklim seperti curah hujan, kelembapan, dan suhu rata-rata, yang berhubungan secara non-linear dan bersifat dinamis dari tahun ke tahun. Penelitian ini bertujuan membangun model permodelan dan prediksi produksi padi menggunakan Temporal Convolutional Network (TCN), sebuah arsitektur deep learning berbasis dilated causal convolution yang belum banyak digunakan pada kasus permodelan pertanian di Indonesia. Data yang digunakan berasal dari delapan provinsi di Sumatera periode 1993-2020, mencakup produksi, luas panen, curah hujan, kelembapan, dan suhu rata-rata. Data dinormalisasi per provinsi kemudian dibentuk menjadi sekuens empat tahun untuk memprediksi produksi tahun berikutnya, dengan lima tahun terakhir tiap provinsi dijadikan data uji. Model TCN yang dibangun terdiri atas tiga blok residual dengan dilated convolution dan dilatih menggunakan optimizer Adam selama 200 epoch. Hasil pengujian menunjukkan model mampu menjelaskan variasi produksi padi antarprovinsi dengan nilai R-squared sebesar 0,70, RMSE sebesar 770.702 ton, dan MAPE sebesar 37,17 persen, meskipun akurasi pada beberapa provinsi dengan fluktuasi tinggi masih terbatas akibat jumlah data uji yang kecil. Temuan ini menunjukkan bahwa TCN merupakan alternatif yang layak untuk permodelan produksi pertanian berbasis data iklim dan dapat dikembangkan lebih lanjut dengan menambah panjang historis data atau variabel pendukung lain.

ABSTRACT

Rice production in Sumatra is influenced by a combination of harvested area and climate factors such as rainfall, humidity, and average temperature, which interact non-linearly and vary dynamically across years. This study aims to build a modeling and prediction approach for rice production using a Temporal Convolutional Network (TCN), a deep learning architecture based on dilated causal convolution that has rarely been applied to agricultural modeling cases in Indonesia. The data used cover eight provinces in Sumatra from 1993 to 2020, including production, harvested area, rainfall, humidity, and average temperature. The data were normalized per province and transformed into four-year sequences to predict the following year's production, with the last five years of each province used as test data. The constructed TCN model consists of three residual blocks with dilated convolutions and was trained using the Adam optimizer for 200 epochs. The test results show that the model can explain variation in rice production across provinces with an R-squared of 0.70, an RMSE of 770,702 tons, and a MAPE of 37.17 percent, although accuracy for several high-fluctuation provinces remains limited due to the small number of test

samples. These findings indicate that TCN is a viable alternative for climate-based agricultural production modeling and can be further developed by extending the historical data length or adding other supporting variables.

Ini adalah artikel akses terbuka di bawah lisensi CC BY-SA.



Penulis Korespondensi:

Septian Nuno Zildjian

Program Studi Sains Data, Fakultas Sains & Teknologi, Universitas Terbuka

Alamat:

Jl. Jenderal Ahmad Yani No.43, RT.5/RW.4, Utan Kayu Sel., Kec. Matraman, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta 13230

Email: septiannunozildjian@gmail.com

1. PENDAHULUAN

Padi merupakan komoditas pangan strategis di Indonesia, dan Sumatera menjadi salah satu wilayah produsen utama yang produksinya dipengaruhi oleh interaksi kompleks antara luas panen dan kondisi iklim seperti curah hujan, kelembapan, serta suhu rata-rata. Variabilitas iklim yang semakin tinggi menjadikan hubungan antara faktor iklim dan produksi padi bersifat non-linear dan dinamis dari tahun ke tahun, sehingga sulit dimodelkan dengan pendekatan statistik linear konvensional [1], [2]. Pemanfaatan pembelajaran mendalam (deep learning) semakin masif diterapkan pada analisis data deret waktu lintas sektor, tak terkecuali di bidang agrikultur. Kepopuleran ini didasari oleh keandalannya dalam memetakan korelasi yang tidak linear serta kemampuannya mengidentifikasi pola ketergantungan antarwaktu dalam periode pengamatan yang panjang. Meskipun arsitektur Long Short-Term Memory (LSTM) sering menjadi pilihan utama dalam memprediksi komoditas agrikultur, kinerjanya kerap terhambat oleh proses komputasi yang berurutan. Hal ini tidak hanya memakan waktu komputasi yang lebih lama, tetapi juga memicu risiko hilangnya gradien (vanishing gradient) saat sistem harus memproses deret data historis berskala besar. Sebagai alternatif, Temporal Convolutional Network (TCN) menggunakan dilated causal convolution yang memproses seluruh sekuens secara paralel sekaligus memperluas jangkauan reseptif secara eksponensial, dan pada berbagai benchmark deret waktu menunjukkan performa yang kompetitif dibandingkan recurrent network [7], [8].

Meskipun TCN telah banyak diterapkan pada domain seperti pengenalan aksi video dan peramalan keuangan [8], [9], penerapannya pada permodelan produksi pertanian berbasis data iklim di Indonesia masih terbatas dibandingkan LSTM atau pendekatan statistik klasik. Kesenjangan ini menjadi dasar penelitian: apakah arsitektur TCN dapat digunakan secara layak untuk memodelkan dan memprediksi produksi padi di tingkat provinsi menggunakan data luas panen dan variabel iklim historis.

Penelitian ini bertujuan: (1) menganalisis karakteristik dan korelasi antara produksi padi dengan luas panen serta variabel iklim di delapan provinsi Sumatera periode 1993-2020, dan (2) membangun serta mengevaluasi model TCN untuk memprediksi produksi padi berdasarkan data historis tersebut. Kontribusi utama makalah ini adalah penerapan TCN, sebagai arsitektur yang relatif belum umum digunakan, pada konteks permodelan produksi pertanian regional, beserta evaluasi performanya secara keseluruhan dan per provinsi


2. METODE

Penelitian ini menggunakan pendekatan eksperimental kuantitatif dengan tahapan: pengumpulan data, eksplorasi data (EDA), praproses dan pembentukan sekuens, perancangan model TCN, pelatihan, serta

evaluasi

performa


model.



2.1. Data Penelitian

Data yang digunakan adalah data tahunan produksi padi delapan provinsi di Sumatera (Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, dan Lampung) periode 1993-2020, sehingga total terdapat 224 observasi (28 tahun x 8 provinsi). Variabel yang digunakan adalah Produksi (ton), Luas Panen (ha), Curah Hujan (mm), Kelembapan (%), dan Suhu rata-rata (°C). Tidak ditemukan data hilang (missing value) pada seluruh variabel.

Tren produksi padi tiap provinsi sepanjang periode pengamatan ditunjukkan pada Gambar 1, yang memperlihatkan perbedaan skala produksi yang cukup besar antarprovinsi serta fluktuasi tahunan yang dipengaruhi kondisi iklim dan kebijakan pertanian setempat.



Gambar 1. Tren produksi padi per provinsi di Sumatera (1993-2020)

2.2. Praproses Data

Setiap provinsi diperlakukan sebagai deret waktu terpisah agar pola temporal tidak tercampur antarwilayah. Guna menyeragamkan skala pengukuran antarfitur, nilai dari setiap variabel ditransformasikan ke dalam interval nol hingga satu memanfaatkan teknik MinMaxScaler. Proses pembobotan ulang ini diaplikasikan secara independen pada masing-masing wilayah provinsi. Data kemudian dibentuk menjadi sekuens menggunakan teknik sliding window dengan panjang jendela (window size) empat tahun untuk

PERMODELAN DAN PREDIKSI PRODUKSI PADI DI SUMATERA MENGGUNAKAN TEMPORAL CONVOLUTIONAL NETWORK (TCN) BERBASIS DATA IKLIM (SEPTIAN NUNO ZILDJIAN)

memprediksi nilai produksi pada tahun kelima. Pembagian data latih dan uji dilakukan secara time-based per provinsi, dengan lima tahun terakhir setiap provinsi dijadikan data uji, sehingga tidak terjadi kebocoran informasi masa depan ke proses pelatihan.

2.3. Arsitektur Model TCN


Model dibangun menggunakan PyTorch dengan tiga TemporalBlock yang masing-masing terdiri dari dua lapis dilated causal convolution berukuran kernel 2, diikuti normalisasi melalui fungsi aktivasi ReLU, dropout 0,2, dan koneksi residual. Faktor dilasi pada tiap blok meningkat secara eksponensial (1, 2, 4) sehingga jangkauan reseptif model bertambah tanpa menambah jumlah parameter secara drastis [7]. Jumlah channel pada tiap blok berturut-turut adalah 16, 32, dan 32, dengan representasi langkah waktu terakhir diteruskan ke dua lapis fully connected sebagai regressor keluaran tunggal (nilai produksi terprediksi). Model dilatih menggunakan fungsi rugi Mean Squared Error (MSE) dan optimizer Adam dengan learning rate 0,001 serta weight decay $1e-5$, selama 200 epoch dan ukuran batch 16. Performa model dievaluasi menggunakan metrik Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan koefisien determinasi (R-squared), yang dihitung baik secara keseluruhan maupun per provinsi setelah hasil prediksi dikembalikan ke skala aslinya (denormalisasi).

3. HASIL DAN PEMBAHASAN


3.1. Karakteristik dan Korelasi Data

Hasil eksplorasi data menunjukkan bahwa Luas Panen memiliki korelasi paling kuat dan positif terhadap Produksi dibandingkan variabel iklim lainnya, sementara curah hujan, kelembapan, dan suhu rata-rata menunjukkan hubungan yang lebih lemah dan tidak selalu linear terhadap produksi. Pola ini konsisten dengan kondisi nyata bahwa produksi padi lebih banyak ditentukan oleh luas areal tanam, sementara faktor iklim berperan sebagai pengubah produktivitas per satuan luas yang bersifat non-linear, sehingga pendekatan deep learning seperti TCN relevan digunakan untuk menangkap hubungan tersebut [2], [4].

Provinsi	RMSE (ton)	MAE (ton)	MAPE (%)	R2
Riau	61.772	53.439	18,70	-1,41
Aceh	383.489	313.851	15,28	-0,73
Jambi	158.681	150.056	37,31	-0,10
Lampung	814.399	770.447	28,63	-0,11
Bengkulu	240.310	210.943	65,26	-0,65
Sumatera Barat	760.488	682.370	42,36	-0,69
Sumatera Utara	1.499.216	1.425.409	58,45	-0,56
Sumatera Selatan	1.014.305	987.839	31,38	0,03
Rata-rata Keseluruhan	770.703	574.294	37,17	0,70



Gambar 2. Kurva training dan testing loss model TCN



Gambar 3. Aktual vs prediksi produksi padi pada data uji

3.2. Proses Pelatihan Model

Kurva pelatihan pada Gambar 2 menunjukkan bahwa nilai training loss dan testing loss menurun secara konsisten pada awal epoch dan mulai stabil setelah sekitar epoch ke-100, mengindikasikan model berhasil konvergen tanpa indikasi overfitting yang signifikan pada rentang epoch yang digunakan.

3.3. Evaluasi Performa Model

Tabel 1 menyajikan hasil evaluasi model TCN secara keseluruhan dan per provinsi. Secara keseluruhan, model memperoleh R-squared sebesar 0,70, RMSE sebesar 770.702 ton, MAE sebesar 574.294 ton, dan MAPE sebesar 37,17 persen. Nilai R-squared keseluruhan yang cukup tinggi terutama dipengaruhi oleh kemampuan model menangkap perbedaan skala produksi antarprovinsi, sementara performa pada level provinsi individual lebih beragam.

Provinsi Riau dan Aceh memiliki MAPE terendah (18,70% dan 15,28%), menunjukkan prediksi yang relatif akurat, sementara provinsi dengan fluktuasi produksi tinggi seperti Bengkulu dan Sumatera Utara memiliki MAPE yang lebih besar. Nilai R-squared per provinsi yang negatif pada beberapa kasus terjadi karena ukuran data uji yang kecil (lima tahun per provinsi), sehingga sangat sensitif terhadap simpangan prediksi pada tahun-tahun tertentu. Hal ini menjadi keterbatasan utama penelitian dan menunjukkan perlunya data historis yang lebih panjang untuk evaluasi per provinsi yang lebih stabil.

Visualisasi hasil prediksi terhadap nilai aktual pada Gambar 3 memperlihatkan bahwa titik-titik prediksi tersebar mengikuti garis ideal, terutama pada rentang produksi menengah, dengan penyimpangan yang lebih besar pada provinsi dengan volume produksi tinggi seperti Sumatera Utara. Temuan ini sejalan dengan studi sebelumnya yang menunjukkan bahwa model berbasis convolutional dapat menangkap pola umum deret waktu dengan baik, namun tetap memerlukan data yang cukup panjang untuk menstabilkan estimasi pada deret dengan variansi besar [7], [8]. Dibandingkan pendekatan LSTM yang umum digunakan pada penelitian sejenis [5], TCN menawarkan proses pelatihan yang lebih cepat karena komputasi paralel pada dimensi waktu, sehingga dapat menjadi alternatif yang efisien untuk permodelan

produksi pertanian regional, khususnya pada skenario dengan banyak provinsi atau wilayah yang perlu dimodelkan secara bersamaan.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa Temporal Convolutional Network (TCN) dapat digunakan untuk memodelkan dan memprediksi produksi padi di delapan provinsi Sumatera berdasarkan data luas panen dan variabel iklim historis. Model yang dibangun mencapai R-squared sebesar 0,70 pada data uji secara keseluruhan, dengan performa terbaik pada provinsi Riau dan Aceh, serta performa yang lebih terbatas pada provinsi dengan fluktuasi produksi tinggi akibat keterbatasan jumlah data uji per provinsi.

Hasil ini mengonfirmasi bahwa TCN merupakan alternatif arsitektur deep learning yang layak digunakan untuk permodelan data pertanian berbasis time series, dengan keunggulan komputasi yang lebih efisien dibandingkan model recurrent. Penelitian lanjutan disarankan untuk memperpanjang rentang data historis, menambahkan variabel pendukung lain seperti penggunaan pupuk atau indeks kekeringan, serta membandingkan TCN dengan arsitektur lain seperti GRU atau Transformer untuk memperkuat validitas temuan ini.

REFERENSI

- [1] S. Bai, J. Z. Kolter, and V. Koltun, "An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling," arXiv preprint, arXiv:1803.01271, 2018.
- [2] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [3] G. Nguyen et al., "Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey," *Artif. Intell. Rev.*, vol. 52, no. 1, pp. 77-124, 2019.
- [4] B. Lim and S. Zohren, "Time-series forecasting with deep learning: a survey," *Philos. Trans. R. Soc. A*, vol. 379, no. 2194, 2021.
- [5] S. Khaki and L. Wang, "Crop Yield Prediction Using Deep Neural Networks," *Front. Plant Sci.*, vol. 10, 2019.
- [6] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [7] C. Lea, M. D. Flynn, R. Vidal, A. Reiter, and G. D. Hager, "Temporal Convolutional Networks for Action Segmentation and Detection," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2017, pp. 156-165.
- [8] A. Vaswani et al., "Attention is All You Need," in *Proc. Adv. Neural Inf. Process. Syst. (NeurIPS)*, 2017, pp. 5998-6008.
- [9] K. Cho et al., "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation," in *Proc. Conf. Empir. Methods Nat. Lang. Process. (EMNLP)*, 2014, pp. 1724-1734.
- [10] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019.