

ANALISIS DAMPAK IKLIM TERHADAP PRODUKTIVITAS TANAMAN PANGAN DENGAN MODEL VAR DAN GLM

Fitria✉, Roni Yunis

Fakultas Informatika, Universitas Mikroskil, Medan, Indonesia

Email: fitria@mikroskil.ac.id

ABSTRACT

Food crops are essential for ensuring food security and combating hunger. Climate change has emerged as a significant obstacle that is impacting the long-term viability of the agricultural industry, particularly in relation to food crops. The objective of this study is to examine the influence of climate conditions on the efficiency of food crop production in Sumatra. This will be accomplished through the utilization of VAR and GLM models, in addition to the OSEM framework. The VAR model study shows that wind speed has a statistically significant influence on peanut production (p-value 0.000563). Similarly, the GLM model analysis reveals that wind speed has a statistically significant impact on rice (p-value 0.00095) and maize (p-value 0.000686) productivity. Based on the MAPE metric, the GLM model demonstrates superior performance compared to the VAR model in accurately predicting soybean production with an accuracy rate of 9.05% and peanut productivity with an accuracy rate of 8.84%. This study aims to provide assistance in reducing the effects of climate change and adapting to them in the agricultural industry, while also improving the production of food crops..

Keyword: Climate Variables, Food Crop, Vector Autoregression (VAR), Generalized Linear Model (GLM).

ABSTRAK

Tanaman pangan berperan krusial dalam menjaga ketahanan pangan serta kekurangan gizi, namun perubahan iklim telah menjadi tantangan sentral yang mempengaruhi keberlanjutan sektor pertanian termasuk sektor tanaman pangan. Penelitian ini bertujuan menganalisis dampak iklim terhadap produktivitas tanaman pangan di pulau Sumatera menggunakan model VAR dan GLM serta kerangka kerja OSEM. Hasil analisis model VAR menunjukkan bahwa kecepatan angin berdampak sangat signifikan terhadap produktivitas kacang tanah (p-value 0,000563) serta analisis model GLM mengidentifikasi kecepatan angin berdampak sangat signifikan terhadap produktivitas padi (p-value 0,00095) dan jagung (p-value 0,000686). Berdasarkan metrik MAPE menunjukkan bahwa model GLM lebih baik kinerjanya daripada VAR dalam memprediksi produktivitas kacang kedelai dengan nilai akurasi tinggi sebesar 9,05% dan prediksi produktivitas kacang tanah dengan nilai akurasi tinggi sebesar 8,84%. Penelitian ini diharapkan dapat mendukung mitigasi dan adaptasi perubahan iklim di sektor pertanian serta meningkatkan produktivitas tanaman pangan.

Kata Kunci: Variabel Iklim, Tanaman Pangan, Vector Autoregression (VAR), Generalized Linear Model (GLM).

PENDAHULUAN

Indonesia dikenal sebagai negara agraris yang memiliki kekayaan sumber daya alam dan lahan pertanian yang melimpah. Sektor pertanian memiliki kontribusi besar dalam pertumbuhan ekonomi nasional, berdasarkan data BPS PDB pertanian tumbuh 16,24 persen pada triwulan-II tahun 2020 tetap berkontribusi positif yakni tumbuh 2,19% (Humas ditjen hortikultura, 2020). Dalam berbagai subsektor pertanian, subsektor tanaman pangan berkontribusi sebesar 2,60% terhadap PDB nasional tahun 2021, yang menempati posisi kedua setelah sektor tanaman perkebunan (Kusnandar, 2022). Hal ini dikarenakan tanaman pangan menjadi sumber utama dalam penyediaan pangan pokok dan karbohidrat dasar bagi masyarakat, seperti padi,

kacang-kacangan, dan umbi-umbian (Wijaya & Manurung, 2023). Tanaman pangan memiliki peran yang sangat penting dalam pemenuhan kebutuhan pangan global yang terus meningkat, berdasarkan *food and agriculture organization (FAO)* memprediksikan bahwa kebutuhan bagi negara-negara berkembang akan meningkat sekitar 60% pada tahun 2030 dan 120% di tahun 2050 (Syarif, 2022). Ketersediaan pangan berperan krusial dalam menjaga ketahanan pangan bagi penduduk serta mengurangi risiko kelaparan dan kekurangan gizi (Hussain & Chaudhry, 2021). Selain itu, sektor pertanian dan komoditas tanaman pangan juga berkontribusi dalam memberikan kesempatan kerja dan menghasilkan pendapatan bagi petani dan industri pertanian, dimana BPS tahun 2021 menyatakan

penyerapan tenaga kerja di sektor pertanian mengalami pertumbuhan positif, dengan distribusi penduduk yang bekerja mencapai 29,96% atau sekitar 1,86 juta orang per tahun (Catriana & Ika, 2022).

Perubahan iklim menjadi salah satu isu global, fenomena ini terjadi akibat meningkatnya konsentrasi gas rumah kaca yang disebabkan oleh aktivitas manusia seperti pembakaran bahan bakar fosil, penggundulan hutan, dan perubahan penggunaan lahan (Kassaye et al., 2021). Perubahan iklim telah menjadi tantangan sentral yang mempengaruhi keberlanjutan sektor pertanian di seluruh dunia. Perubahan iklim mempengaruhi cuaca, pola curah hujan, suhu dan fenomena alam lainnya, salah satu dampak perubahan iklim yang paling signifikan adalah meningkatnya frekuensi dan intensitas kejadian cuaca ekstrem, seperti badai tropis yang lebih kuat, gelombang panas yang lebih panjang, banjir, dan kekeringan (Khumalo, 2021). Curah hujan berlebihan dapat menyebabkan banjir sehingga menyebabkan kondisi yang mendukung serangan jamur pada daun, akar dan umbi-umbian, sedangkan curah hujan minim dapat menyebabkan kekeringan hingga kemarau (Ngoune Liliane & Shelton Charles, 2020). Peningkatan suhu udara yang berlebihan dapat menyebabkan stres panas pada tanaman, mengurangi ketersediaan air tanah, mempercepat penguapan air dari tanah dan kejadian cuaca ekstrem mengakibatkan kerusakan pada lahan pertanian (Ngoune Liliane & Shelton Charles, 2020). Semua hal tersebut memberikan tekanan tambahan pada ekosistem alam, ketahanan pangan, dan kehidupan sehari-hari masyarakat. Melihat kompleksitas tantangan ini, pemahaman yang mendalam tentang keterkaitan antara variabel iklim dan tanaman pangan menjadi sangat penting. Analisis data iklim dapat memberikan wawasan yang diperlukan untuk merumuskan strategi adaptasi yang efektif di sektor tanaman pangan. Dengan melakukan analisis dampak iklim terhadap produktivitas tanaman pangan memungkinkan pemerintah untuk merencanakan alokasi sumber daya yang tepat guna mengoptimalkan produktivitas tanaman pangan.

Dalam penelitian ini, akan digunakan model *vector autoregression* (VAR) dan *generalized linear model* (GLM). Model VAR dipilih karena kemampuannya dalam memodelkan, memprediksi, dan menganalisis hubungan simultan antar variabel deret waktu (Lestari et al., 2021). Sebagai tolak ukur keakuratan, pada penelitian sebelumnya menggunakan model VAR untuk menganalisis hubungan produksi perikanan tangkap laut, suhu permukaan laut, dan curah hujan di Provinsi NTT dengan hasil MAPE sebesar 16,17% dan 3,08%, mengindikasikan model VAR

relevan dalam memahami dampak suhu permukaan laut terhadap produksi perikanan tangkapan laut dan curah hujan di NTT (Ramli et al., 2019). Selain itu dalam penelitian (Rajab et al., 2022) menggunakan model VAR dan berhasil mencapai tingkat akurasi yang sangat tinggi, dengan tingkat *error* MAPE sebesar 0,35% dalam memprediksi jumlah kasus baru harian *covid* di UAE. Selain model VAR dalam penelitian ini menggunakan GLM, model GLM dipilih karena pendekatan statistik yang digunakan dalam pemodelan dan prediksi untuk mengidentifikasi hubungan antara variabel dependen dengan berbagai variabel independen (Mohammadinia et al., 2019)(Mohammed et al., 2020). Keunggulan model GLM dapat menangani data yang tidak memenuhi asumsi-asumsi model *linier* tradisional, sehingga dapat digunakan untuk analisis data yang lebih kompleks (Akram et al., 2023). Penelitian sebelumnya (Martines et al., 2021) menunjukkan bahwa GLM dapat mengidentifikasi hubungan antara faktor ketidaksetaraan sosial ekonomi dan risiko relatif *covid-19* di kota-kota Brasil. GLM menunjukkan bahwa indeks GINI, *social vulnerability index* (SVI), dan tingkat kematian berdampak signifikan pada risiko relatif (RR), dengan setiap kenaikan satu unit pada indeks GINI meningkatkan risiko relatif sebesar 2,02, sementara dampak SVI adalah 0,82, dan tingkat kematian 0,021. Urgensi penggunaan kedua model ini dibandingkan model lain adalah kemampuan VAR dalam menangkap dinamika interdependen antar variabel deret waktu dan kemampuan GLM dalam menangani data dengan distribusi yang tidak normal dan hubungan *non-linier*. Dengan menggunakan kedua model ini, penelitian ini dapat mengeksplorasi hubungan deret waktu dan menangani hubungan *non-linier* yang mungkin ada dalam dataset. Penelitian ini juga bertujuan untuk membandingkan tingkat akurasi prediksi antara model VAR dan GLM, sehingga dapat diharapkan kedua model mampu mencapai tingkat akurasi yang tinggi dalam menganalisis hubungan dan dampak, sehingga hal ini menjadi alasan yang kuat untuk mengadopsi model tersebut dalam penelitian ini. Penelitian akan menggunakan *framework* OSEM (obtaining, scrubbing, exploring, modeling, interpreting) untuk mengatur langkah-langkah penelitian secara terstruktur (Kumari et al., 2020). Keputusan menggunakan *framework* OSEM didasarkan pada keunggulannya dalam memberikan metodologi yang terstruktur, memfasilitasi analisis dan interpretasi data yang efisien, serta mengungkapkan pola dan tren yang akan memberikan wawasan penting untuk mendukung pengambilan keputusan berdasarkan hasil penelitian.

METODE PENELITIAN

Data Penelitian

Data yang digunakan dalam penelitian ini adalah dataset penyinaran matahari, kelembapan, suhu, dan kecepatan angin, diambil dari website (<https://www.bps.go.id>) dan website (https://dataonline.bmkg.go.id/data_iklim), dataset curah hujan untuk wilayah pulau Sumatera, diambil dari (<https://climateserv.servirglobal.net>) pada periode 2006-2015 dan dataset produktivitas tanaman pangan di pulau Sumatera periode 2006-2015 dari website (<https://www.bps.go.id>).

Tabel 1. Variabel Penelitian

No	Variabel	Contoh Data
1.	Tahun	2015
2.	Provinsi	Sumatera utara
3.	Jenis komoditi	Ubi kayu
4.	Produktivitas	338.54
5.	Kecepatan angin	2.38
6.	Kelembapan	86.90
7.	Suhu	27.40
8.	Penyinaran matahari	51.86
9.	Curah hujan	6.64286

Metode OSEM N

OSEMN adalah singkatan dari obtain, scrub, explore, model dan interpret. OSEM N merupakan kerangka kerja atau tahapan analisis data dalam menyelesaikan masalah dalam proses penelitian analisis data (Kumari et al., 2020)(Atanasova & Dineva, 2018). Tahapan OSEM N dapat dilihat pada gambar di bawah ini:



Gambar 1. Metode OSEM N

Obtain

Obtain merupakan tahap pengumpulan data penelitian yang kemudian akan dianalisis. Dalam penelitian ini, dataset tanaman pangan diambil dari

badan pusat statistik (BPS) Indonesia (<https://www.bps.go.id>), yang berisi data produktivitas tanaman pangan seperti padi, jagung, ubi kayu, ubi jalar, kacang kedelai, kacang hijau, dan kacang tanah. Dataset tanaman pangan mencakup 10 Provinsi di pulau Sumatera, data tersebut didapatkan dari tahun 2006 sampai tahun 2015 dan disimpan dalam format excel (xlsx). Dataset iklim seperti suhu, penyinaran matahari, kecepatan angin, dan kelembapan diambil dari BPS Indonesia (<https://www.bps.go.id>) dan BMKG indonesia (<https://dataonline.bmkg.go.id>), berisikan data iklim dari 10 provinsi yang ada di pulau Sumatera serta disimpan dalam format excel. Dataset curah hujan diperoleh dari website ClimateSERV (<https://climateserv.servirglobal.net/>) disimpan dalam format excel, total keseluruhan dataset pada penelitian ini terdiri dari 668 baris dan 9 kolom.

Scrub

Scrub adalah proses pembersihan data atau normalitas dari data yang telah dikumpulkan sebelumnya. Scrub melibatkan tindakan seperti menggabungkan kolom data tanaman pangan dan data iklim yang masih terpisah menjadi satu tabel, merubah tipe data double pada variabel produktivitas, kecepatan angin, kelembapan, suhu, penyinaran matahari, dan curah hujan menjadi numeric, menghapus nilai yang tidak valid dengan menggunakan fungsi `na.omit()` yang ada di R-studio, penghapusan duplikat data, menormalkan data menggunakan z-score normalization pada dataset.

Explore

Explore atau Exploratory Data Analysis (EDA) adalah sebuah proses analisis dan memvisualisasikan data untuk mendapatkan wawasan dan mengidentifikasi pola atau tren. EDA mencakup mempelajari data mentah, visualisasi data, menemukan hubungan antar variabel sehingga tahap EDA membantu memilih pendekatan terbaik untuk melakukan analisis (Atanasova & Dineva, 2018).

Model

Pada tahap pemodelan melibatkan penggunaan algoritma atau penggunaan teknik machine learning tertentu untuk menganalisa dan memprediksi data (Atanasova & Dineva, 2018). Pemodelan pada penelitian digunakan sebagai alat untuk memahami hubungan antara variabel dan menemukan temuan penelitian yang relevan. Tahapan penelitian ini akan menggunakan model VAR dan GLM untuk mengetahui hubungan variabel iklim terhadap produktivitas

tanaman pangan beserta dampak dan membandingkan kedua model.

Model vector autoregression (VAR) memperlakukan semua variabel sebagai variabel endogen. Analisis respons impuls dan uji kausalitas granger adalah alat yang telah diusulkan untuk membantu memahami hubungan antara variabel dalam model autoregresi vektor (Feng et al., 2019). Model VAR adalah algoritma peramalan multivariat yang digunakan untuk menganalisis hubungan dengan memperkirakan hubungan antara beberapa variabel yang saling mempengaruhi satu sama lain secara bersamaan (Wu & Koop, 2023)(Hou et al., 2023). Tujuan dari pemodelan adalah untuk menganalisis mekanisme pengaruh antar variabel, mengukur tingkat pengaruh, dan memprediksi (Jiang et al., 2023). Setiap variabel dimodelkan berdasarkan fungsi dari nilai masa lalu, atau nilai deret waktu yang mengalami lag, yang dipertimbangkan oleh model autoregresi. Dengan demikian model VAR dirumuskan sebagai persamaan perbedaan stokastik, yang merupakan suatu bentuk persamaan deret waktu linier yang melibatkan sejumlah nilai lag yang diintegrasikan. Sekumpulan nilai lag dimanfaatkan untuk meramalkan nilai variabel pada waktu sekarang dan masa mendatang (Hou et al., 2023). Persamaan umum model VAR merujuk pada persamaan (1) berikut.

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t(1)$$

Dimana Y_t adalah nilai variabel pada waktu t , α adalah intersep atau konstanta, β adalah koefisien lag dari $t - 1$ hingga p atau koefisien yang mengukur dampak variabel masa lalu pada variabel saat ini, p adalah nilai p -lag dari Y dan merupakan prediktor dalam persamaan dan ϵ_t adalah error term.

Sementara itu, Model GLM adalah kerangka kerja statistik yang digunakan untuk menganalisis hubungan antara satu atau lebih variabel independen dengan variabel dependen (Mohammed et al., 2020). GLM merupakan pendekatan statistik yang efektif untuk mengatasi hubungan non-linear antara variabel respons dan variabel prediktor dalam konteks analisis data ekologi. Model GLM digunakan ketika variabel tidak berdistribusi normal dan dapat dipilih dari berbagai distribusi statistik (Akram et al., 2023). Dalam GLM, distribusi variabel dependen bisa berbeda-beda, tidak harus selalu normal. Model GLM dirancang untuk menangani berbagai jenis distribusi, seperti binomial, Poisson, atau gamma, tergantung pada jenis variabel dependen dan hubungan antara variabel independen

dan dependen. Berikut merupakan persamaan umum model GLM.

$$E(y) = \beta_0 + \sum_{j=1}^p X_j \cdot \beta_j \dots\dots\dots(2)$$

Dimana $E(y)$ adalah nilai rata-rata dari variabel dependen y , β_0 adalah intersep atau konstanta dalam persamaan linear, β_j adalah koefisien regresi untuk variabel independen ke- j , X_j adalah variabel independen ke- j , \sum adalah simbol sigma yang digunakan untuk menunjukkan penjumlahan. p adalah jumlah total variabel independen dalam model.

Interpretasi

Tahap interpretasi adalah proses menafsirkan hasil analisis, yang melibatkan pengetahuan dan pemahaman mendalam untuk menarik kesimpulan dan menghasilkan wawasan yang bermakna (Atanasova & Dineva, 2018). Tahap ini termasuk mengidentifikasi dan menjawab rumusan masalah, seperti apakah terdapat hubungan iklim terhadap produktivitas tanaman pangan di 10 provinsi yang ada di pulau sumatera. Hasil interpret harus berdasarkan objektif, kritis, pemahaman mendalam sebelum menghasilkan kesimpulan penelitian. Dalam interpretasi hasil penelitian dapat divisualisasikan melalui grafik, plot, line, dan bar. Visualisasi hasil membantu mengkomunikasikan data dan temuan penelitian yang kompleks agar memudahkan untuk memahami hasil baik bagi peneliti maupun non-ahli (Hehman & Xie, 2021). Proses interpretasi juga mencakup evaluasi model dengan membandingkan hasil prediksi dengan data aktual. Dalam penelitian ini, metrik MAPE akan digunakan untuk menguji keakuratan hasil prediksi. Mean Absolute Percentage Error (MAPE) adalah metrik yang digunakan untuk mengevaluasi keakuratan pemodelan propagasi dalam penelitian ini (Alfaresi et al., 2020). Ini mengukur perbedaan persentase rata-rata antara nilai yang diprediksi dan aktual. MAPE dihitung dengan mengambil perbedaan absolut antara nilai prediksi dan aktual, membaginya dengan nilai aktual, dan kemudian rata-ratanya. MAPE pada persamaan (3) didefinisikan sebagai rata-rata perbedaan persentase absolut antara nilai yang diprediksi dan aktual serta memberikan ukuran kesalahan relatif dalam persentase, memungkinkan perbandingan di seluruh kumpulan data yang berbeda.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100 \dots\dots\dots (3)$$

Dimana n adalah jumlah sampel, y_i adalah nilai sebenarnya dari variabel dependen pada titik data ke- i , \hat{y}_i adalah nilai yang diprediksi oleh model pada titik

data ke-I, adalah $|y_i - \hat{y}_i| / y_i \times 100$ adalah nilai absolut dari kesalahan.

HASIL DAN PEMBAHASAN

Hasil Analisis Model VAR

Dalam proses analisis data, untuk memastikan validitas prediksi dan menguji akurasi prediksi model pada data, data dibagi menjadi dua subset yaitu data pelatihan dan data pengujian. Data dibagi menjadi 70% data pelatihan dan 30% data pengujian, kemudian data diurutkan berdasarkan waktu. Untuk mendukung analisis model VAR, data harus diubah ke dalam format *time series* (ts). Format *time series* penting karena model VAR memerlukan data yang berurutan secara temporal untuk dapat menangkap dinamika waktu. Proses identifikasi model VAR dimulai dengan pemilihan *lag* optimal untuk memastikan bahwa model dapat menangkap dinamika temporal dari data. Pemilihan *lag* dilakukan dengan menggunakan beberapa kriteria informasi seperti *akaike information criterion* (AIC), *bayesian information criterion* (BIC), *final prediction Error* (FPE) dan *hannan-quinn criterion* (HC). Suatu variabel berdampak terhadap variabel lain dalam model VAR dapat ditentukan berdasarkan hasil *output* dari fungsi *summary()*. Koefisien yang signifikan statistik menunjukkan adanya hubungan yang signifikan antara variabel yang satu dengan yang lain. Koefisien dengan nilai *p-value* yang kecil (umumnya *p-value* < 0,05) menunjukkan bahwa hubungan tersebut tidak terjadi secara kebetulan dan dapat dianggap signifikan secara statistik.

Tabel 2. Hasil analisis dampak dengan model VAR

Komoditas	Variabel	Estimate	P-value
Padi	Penyinaran_ Matahari.11	-0,24354	0,04093 *
Jagung	Penyinaran_ Matahari.14	-0,41826	0,0436*
Ubi Jalar	Kecepatan_ Angin.12	-942,620	0,01095 *
Ubi Kayu	Kecepatan_ Angin.13	1,183,807	0,0041 **
	Penyinaran_ Matahari.15	-189,774	0,0436 *
Kedelai	Kecepatan_ Angin.13	-0,307431	0,04304 *
	Curah_ hujan.13	-0,911123	0,00906 **
	Suhu.13	0,758879	0,02009 *
	Penyinaran_ Matahari.14	-0,088604	0,02156 *
	Curah_hujan.15	0,754974	0,01908 *

Kacang Hijau	Penyinaran_ Matahari.11	0,044957	0,02051 *
	Kecepatan_ Angin.13	-0,190422	0,00278 **
	Penyinaran_ Matahari.13	0,043066	0,02589 *
	Suhu.14	0,355260	0,01369 *
	Kecepatan_ Angin.15	-0,163235	0,02535 *
Kacang Tanah	Curah_ hujan.11	5.27E+02	0,03179 0 *
	Kecepatan_ Angin.14	4.99E+02	0,00056 3 ***

Berdasarkan Tabel 2, menunjukkan bahwa variabel iklim yang berdampak terhadap produktivitas padi adalah variabel penyinaran matahari di *lag* 1 dengan *p-value* 0,04093 karena memiliki *p-value* < 0,05 dan nilai estimasi dari -0,24354 menunjukkan bahwa jika penyinaran matahari pada periode sebelumnya (*lag* 1) meningkat satu satuan, maka produktivitas padi akan menurun sebesar 0,24354 satuan. Variabel iklim yang berdampak terhadap produktivitas jagung adalah variabel penyinaran matahari di *lag* 4 dengan *p-value*nya 0,0436 dan nilai estimasi dari -0,41826 menunjukkan bahwa jika penyinaran matahari pada 4 periode sebelumnya (*lag* 4) meningkat satu satuan, maka produktivitas jagung akan menurun sebesar 0,41826 satuan. Variabel iklim yg berdampak terhadap produktivitas ubi jalar adalah variabel kecepatan angin pada *lag* 2 (*p-value* 0,01095) dan nilai estimasi -9,42620 menunjukkan bahwa jika variabel kecepatan angin pada 2 periode sebelumnya (*lag* 2), maka akan mengurangi produktivitas ubi jalar sebesar 9,42620 satuan. Variabel iklim yang berdampak terhadap produktivitas ubi kayu adalah variabel kecepatan angin pada *lag* 3 (dengan *p-value*nya 0,0041), dan penyinaran matahari pada *lag* 5 (*p-value* 0,0436). Nilai estimasi menunjukkan bahwa jika terjadi peningkatan satu satuan pada kecepatan angin di 3 periode sebelumnya (*lag* 3) akan meningkatkan produksi ubi kayu sebesar 11,83807, sementara peningkatan satu satuan variabel penyinaran matahari pada *lag* 5 akan menurunkan produksi ubi kayu sebesar 1,89774 satuan.

Variabel iklim yang berdampak terhadap produktivitas kacang kedelai adalah variabel kecepatan angin pada *lag* 3 (dengan *p-value* 0,04304), suhu pada *lag* 3 (*p-value* 0,02009), curah hujan pada *lag* 3 dan 5 (dengan *p-value* 0,00906 dan 0,01908) dan penyinaran matahari pada *lag* 4 (*p-value* 0,02156). Nilai estimasi menunjukkan bahwa jika terjadi peningkatan satu satuan pada curah hujan di *lag* 3 dan 5 akan menurunkan produktivitas sebesar 0,911123 di *lag* 3 dan akan meningkatkan produktivitas 0,754974 satuan

pada lag 5, sementara peningkatan satu satuan variabel suhu akan meningkatkan produktivitas kacang kedelai sebesar 0,758879 satuan, dan peningkatan satu satuan variabel kecepatan angin dan penyinaran matahari akan menurunkan produktivitas masing-masing sebesar 0,307431 dan 0,088604 satuan. Variabel iklim yang berdampak terhadap produktivitas kacang hijau adalah variabel penyinaran matahari pada lag 1 (*p*-*valu*nya 0,02051), dan lag 3 (*p*-*valu*nya 0,02589), kecepatan angin pada lag 3 (*p*-*valu*nya 0,00278), dan lag 5 (*p*-*valu*e 0,02535) dan suhu pada lag 4 (*p*-*valu*e 0,01369). Nilai estimasi menunjukkan bahwa jika terjadi peningkatan satu satuan pada variabel penyinaran matahari pada lag 1 dan lag 3 akan meningkatkan produktivitas masing-masing sebesar 0,044957 dan 0,043066 satuan, sementara peningkatan satu satuan variabel kecepatan angin pada lag 3 dan 5 akan menurunkan produktivitas masing-masing sebesar 0,190422 dan 0,163235 satuan.

Peningkatan satu satuan variabel suhu akan meningkatkan produktivitas kacang hijau sebesar 0,355260 satuan. Variabel iklim yg berdampak terhadap produktivitas kacang tanah adalah variabel curah hujan pada lag 1 (*p*-*valu*e 0,031790) dan kecepatan angin pada lag 4 (*p*-*valu*e 0,000563). Nilai estimasi dari 5,271e-01 menunjukkan bahwa jika curah hujan pada periode sebelumnya (lag 1) meningkat satu satuan, maka produktivitas kacang tanah akan meningkat sebesar 5,271e-01 satuan. Nilai estimasi dari 4,992e-01 menunjukkan bahwa jika kecepatan angin pada 4 periode sebelumnya (lag 4) meningkat satu satuan, maka produktivitas kacang tanah akan meningkat sebesar 4,992e-01 satuan.

Hasil Analisis Model GLM

Dalam analisis dampak variabel iklim terhadap produktivitas tanaman pangan dengan model GLM dilakukan pembagian data untuk memastikan validitas prediksi dan menguji akurasi prediksi model. Data dibagi menggunakan fungsi *sample.split()* dari paket *caTools()*. *Sample.split()* membagi dataset berdasarkan rasio yang ditentukan 70% pelatihan dan 30% pengujian dengan pengambilan data secara acak. Dalam membangun model GLM, digunakan fungsi *glm()* yang terdapat di dalam *library stats()* atau *glm2()*. Argumen *family* menentukan distribusi kesalahan dan fungsi *link* yang digunakan dalam model GLM, untuk respons yang berdistribusi normal menggunakan *gaussian(link = "identity")* dan *control = list(epsilon = 1e-8, maxit = 100)* adalah argumen opsional yang dapat disesuaikan untuk mengontrol toleransi konvergensi (*epsilon*) dan jumlah iterasi maksimum saat proses estimasi model.

Tabel 3. Hasil Analisis Dampak dengan Model GLM

Jenis komoditas	Variabel iklim	Estimasi	Produktivitas
Padi	Kecepatan angin	-3,23115	0,00095 ***
	Curah hujan	-2,90500	0,02174 *
Jagung	Kecepatan angin	-3,25796	0,000686 ***
	Kelembapan	-0,69084	0,042948 *
Ubi jalar	Kecepatan angin	-13,019	0,00959 **
Ubi Kayu	Kecepatan angin	-13,1561	0,0337 *
Kacang kedelai	Kecepatan angin	-0,28245	0,06214
Kacang hijau	Curah hujan	-1,34192	0,0174 *
Kacang tanah	Kecepatan angin	-0,49648	0,00262 **

Berdasarkan Tabel 3, variabel iklim yang menunjukkan dampak signifikan terhadap produktivitas padi adalah curah hujan dan kecepatan angin karena nilai *p*-*valu*e lebih kecil dari 0,05, yaitu dengan *p*-*valu*e curah hujan dan kecepatan angin masing-masing adalah 0,02174 dan 0,00095. Nilai koefisien -3,23115 menunjukkan bahwa setiap peningkatan satu satuan curah hujan diprediksi akan menyebabkan penurunan produktivitas sebesar 3,23115 satuan dan nilai koefisien -2,90500 pada variabel kecepatan angin menunjukkan bahwa setiap peningkatan satu satuan akan menyebabkan penurunan produktivitas sebesar 2,90500 satuan. Variabel iklim yang menunjukkan dampak signifikan terhadap produktivitas jagung adalah variabel kecepatan angin dan kelembapan karena nilai *p*-*valu*e untuk variabel kecepatan angin dengan nilai *p*-*valu*e sekitar 0,000686 dan kelembapan dengan nilai *p*-*valu*e 0,042948 yang lebih kecil dari 0,05. Nilai koefisien -3,25796 pada variabel kecepatan angin menunjukkan bahwa setiap peningkatan satu satuan akan menyebabkan penurunan produktivitas sebesar 3,25796 satuan dan nilai koefisien -0,68084 pada variabel kelembapan menunjukkan jika terjadi peningkatan satu satuan akan menyebabkan penurunan produktivitas sebesar 0,68084 satuan.

Variabel iklim yang menunjukkan dampak signifikan terhadap produktivitas ubi jalar adalah variabel kecepatan angin karena memiliki *p*-*valu*e lebih kecil dari 0,05 yaitu sebesar 0,00959 dan nilai koefisien -13,019 pada variabel kecepatan angin menunjukkan bahwa setiap peningkatan satu satuan akan menyebabkan penurunan produktivitas sebesar 13,019 satuan. Variabel iklim yang menunjukkan dampak signifikan terhadap produktivitas ubi kayu adalah variabel kecepatan angin karena nilai *p*-*valu*e kecepatan angin dengan nilai *p*-*valu*e sekitar 0,0337 yang lebih kecil dari 0,05 dan nilai koefisien -13,1561

pada variabel kecepatan angin menunjukkan bahwa setiap peningkatan satu satuan akan menyebabkan penurunan produktivitas sebesar 13,1561 satuan. Pada produktivitas kacang kedelai, semua variabel iklim tidak berdampak karena semua variabel iklim memiliki *p-value* di atas 0,05.

Variabel iklim yang menunjukkan dampak signifikan terhadap produktivitas kacang hijau adalah variabel curah hujan karena nilai *p-value* curah hujan dengan nilai *p* sekitar 0,0174 yang lebih kecil dari 0,05. Nilai koefisien - 1,34192 pada variabel curah hujan menunjukkan bahwa setiap peningkatan satu satuan curah hujan akan menyebabkan penurunan produktivitas kacang hijau sebesar 1,34192 satuan. Variabel iklim berdampak terhadap produktivitas kacang tanah adalah variabel kecepatan angin karena nilai *p-value* kecepatan angin dengan

nilai *p-value* 0,00262 yang lebih kecil dari 0,05. Nilai koefisien -0,49648 pada variabel kecepatan angin menunjukkan bahwa setiap peningkatan satu satuan akan menyebabkan penurunan produktivitas kacang tanah sebesar 0,49648 satuan.

Perbandingan Tingkat Akurasi Model VAR dan GLM

Secara umum untuk melihat keakuratan metrik MAPE dilihat dari nilai MAPE, jika nilai MAPE yang didapatkan <10% akurasi tinggi atau sangat baik, 10-20% akurasi baik, 20-50% akurasi wajar dan >50% peramalan tidak akurat.

Tabel 4. Perbandingan Tingkat Akurasi Model VAR dan GLM terhadap Produktivitas Pangan

Komoditas	MAPE_VAR	MAPE_GLM
Produktivitas Padi	16.88%	10.76%
Produktivitas Jagung	35.06%	18.15%
Produktivitas Ubi Jalar	35.49%	23.76%
Produktivitas Ubi Kayu	31.29%	22.79%
Produktivitas Kedelai	16.20%	9.05%
Produktivitas Kacang Hijau	509.41%	955.19%
Produktivitas Kacang Tanah	884.39%	8.84%

Secara keseluruhan hasil dari Tabel 4 dapat dijelaskan bahwa model GLM lebih akurat dibandingkan model VAR dalam memprediksi produktivitas mayoritas komoditas. Namun, ada anomali yang signifikan pada prediksi produktivitas kacang hijau dan kacang tanah, di mana model VAR

menghasilkan MAPE yang sangat tinggi untuk kacang tanah, sedangkan GLM memiliki MAPE yang sangat tinggi untuk kacang hijau. Hal ini bisa menunjukkan ketidakstabilan atau ketidaksesuaian model dalam menangani data tertentu untuk komoditas-komoditas tersebut.

KESIMPULAN

Berdasarkan hasil analisis data iklim dan dampaknya terhadap tanaman pangan di pulau Sumatera dengan model VAR dan GLM, maka dapat disimpulkan sebagai berikut:

1. Variabel kecepatan angin berdasarkan model VAR berdampak sangat signifikan terhadap produktivitas kacang tanah dengan *p-value* 0,000563.
2. Variabel kecepatan angin berdasarkan model GLM berdampak sangat signifikan terhadap produktivitas padi dengan *p-value* 0,00095 dan produktivitas jagung dengan *p-value* 0,000686.
3. Berdasarkan hasil metrik evaluasi kinerja model dengan MAPE menunjukkan bahwa model GLM memiliki kinerja yang lebih baik daripada model VAR.

Penelitian kedepan diharapkan dapat melakukan analisis terhadap anomali yang signifikan pada prediksi produktivitas kacang hijau dan kacang tanah dengan menggunakan model yang lebih tepat.

DISEMINASI

Artikel ini telah diseminasikan pada Seminar Nasional Teknologi Informasi dan Komunikasi (SEMNASTIK) APTIKOM Tahun 2024 yang diselenggarakan oleh Universitas Methodist Indonesia pada tanggal 24-26 Oktober 2024.

DAFTAR PUSTAKA

- Akram, M., Cerin, E., Lamb, K. E., & White, S. R. (2023). Modelling count, bounded and skewed continuous outcomes in physical activity research: beyond linear regression models. *International Journal of Behavioral Nutrition and Physical Activity*, 20(1), 1–11. <https://doi.org/10.1186/s12966-023-01460-y>
- Alfaresi, B., Barlian, T., Ardianto, F., & Hurairah, M. (2020). Path loss propagation evaluation and modelling based ECC-Model in Lowland Area on 1800 MHz. *Journal of Robotics and Control (JRC)*, 1(5), 167–171. <https://doi.org/10.18196/jrc.1534>
- Atanasova, T., & Dineva, K. (2018). Osemn Process for Working Over Data Acquired By Iot Devices Mounted in Beehives. *Current Trends in Natural Sciences (on-Line)*, 7(13), 47–53.
- Catriana, E., & Ika, A. (2022). *Data BPS: Sektor Pertanian Serap Lapangan Kerja Tertinggi di Tahun 2022*. Kompas.

- <https://money.kompas.com/read/2022/05/09/170000926/data-bps--sektor-pertanian-serap-lapangan-kerja-tertinggi-di-tahun-2022>
- Feng, X., Zhang, X., Feng, Z., & Wei, Y. (2019). Analyzing moisture-heat coupling in a wheat-soil system using data-driven vector autoregression model. *PeerJ*, 2019(6), 1–22. <https://doi.org/10.7717/peerj.7101>
- Helman, E., & Xie, S. Y. (2021). Doing Better Data Visualization. *Advances in Methods and Practices in Psychological Science*, 4(4). <https://doi.org/10.1177/25152459211045334>
- Hou, P. S., Fadzil, L. M., Manickam, S., & Al-Shareeda, M. A. (2023). Vector Autoregression Model-Based Forecasting of Reference Evapotranspiration in Malaysia. *Sustainability (Switzerland)*, 15(4). <https://doi.org/10.3390/su15043675>
- Humas ditjen hortikultura. (2020). *PDB Triwulan II 2020, Sektor Pertanian Tumbuh Paling Tinggi*. Kementerian Pertanian Direktorat Jenderal Hortikultura. <https://hortikultura.pertanian.go.id/pdb-triwulan-ii-2020-sektor-pertanian-tumbuh-paling-tinggi/>
- Hussain, S., & Chaudhry, I. S. (2021). Impact of Climate Change on Yield of Major Food Crops in Pakistan. *Review of Applied Management and Social Sciences*, 4(4), 849–861. <https://doi.org/10.47067/ramss.v4i4.189>
- Jiang, M., Wu, Z., Guo, X., Wang, H., & Zhou, Y. (2023). Study on the Contribution of Land Use and Climate Change to Available Water Resources in Basins Based on Vector Autoregression (VAR) Model. *Water (Switzerland)*, 15(11). <https://doi.org/10.3390/w15112130>
- Kassaye, A. Y., Shao, G., Wang, X., Shifaw, E., & Wu, S. (2021). Impact of climate change on the staple food crops yield in Ethiopia: implications for food security. *Theoretical and Applied Climatology*, 145(1–2), 327–343. <https://doi.org/10.1007/s00704-021-03635-8>
- Khumalo, T. F. (2021). Social issues related to climate change and food production (crops). In *The Impacts of Climate Change: A Comprehensive Study of Physical, Biophysical, Social, and Political Issues*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-822373-4.00012-4>
- Kumari, K., Bhardwaj, M., & Sharma, S. (2020). OSEMN Approach for Real Time Data Analysis. *International Journal of Engineering and Management Research*, 10(02), 107–110. <https://doi.org/10.31033/ijemr.10.2.11>
- Kusnandar, V. B. (2022). *Ini Kontribusi Sektor Pertanian terhadap Ekonomi RI Tahun 2021*. Databoks.Katadata.Co.Id.
- Lestari, I. G. A. M., Sumarjaya, I. W., & Widana, I. N. (2021). Peramalan Produksi Padi Di Kabupaten Badung, Gianyar, Dan Tabanan Dengan Metode Vector Autoregression (Var). *E-Jurnal Matematika*, 10(1), 32. <https://doi.org/10.24843/mtk.2021.v10.i01.p317>
- Martines, M. R., Ferreira, R. V., Toppa, R. H., Assunção, L. M., Desjardins, M. R., & Delmelle, E. M. (2021). Detecting space–time clusters of COVID-19 in Brazil: mortality, inequality, socioeconomic vulnerability, and the relative risk of the disease in Brazilian municipalities. *Journal of Geographical Systems*, 23(1), 7–36. <https://doi.org/10.1007/s10109-020-00344-0>
- Mohammadinia, A., Saeidian, B., Pradhan, B., & Ghaemi, Z. (2019). Prediction mapping of human leptospirosis using ANN, GWR, SVM and GLM approaches. *BMC Infectious Diseases*, 19(1), 1–18. <https://doi.org/10.1186/s12879-019-4580-4>
- Mohammed, S., Al-Ebraheem, A., Holb, I. J., Alsafadi, K., Dikkeh, M., Pham, Q. B., Linh, N. T. T., & Szabo, S. (2020). Soil management effects on soil water erosion and runoff in Central Syria-A comparative evaluation of general linear model and random forest regression. *Water (Switzerland)*, 12(9). <https://doi.org/10.3390/w12092529>
- Ngoune Liliane, T., & Shelton Charles, M. (2020). Factors Affecting Yield of Crops. *Agronomy - Climate Change and Food Security*, 1–16. <https://doi.org/10.5772/intechopen.90672>
- Rajab, K., Kamalov, F., & Cherukuri, A. K. (2022). Forecasting COVID-19: Vector Autoregression-Based Model. *Arabian Journal for Science and Engineering*, 47(6), 6851–6860. <https://doi.org/10.1007/s13369-021-06526-2>
- Ramli, R. L., Sumarjaya, I. W., & Sari, K. (2019). Analisis Hubungan Produksi Perikanan Tangkap Laut, Curah Hujan, Dan Suhu Permukaan Laut Dengan Model Vector Autoregressive (Var). *E-Jurnal Matematika*, 8(2), 155. <https://doi.org/10.24843/mtk.2019.v08.i02.p247>
- Syarif, D. (2022). *Krisis Pangan Yang Akan Datang*. Kompasiana. <https://www.kompasiana.com/dydhaaa06/62a95055bb448666df620192/krisis-pangan-yang-akan-datang>
- Wijaya, J., & Manurung, M. S. (2023). *Regency / City Clustering in North Sumatra Based on Food Crop Productivity*. 2(2), 36–51. <https://doi.org/https://doi.org/10.4590/jarsic.v2i2.23>
- Wu, P., & Koop, G. (2023). Estimating the ordering of variables in a VAR using a Plackett–Luce prior. *Economics Letters*, 230, 111247. <https://doi.org/10.1016/j.econlet.2023.111247>