

Perbaikan Angka Potensi Produksi Padi dengan Metode *Hybrid*

Oleh Prof. Dr. Ir. Bustanul Arifin M.Sc.¹, Ir. Warsono. MS., Ph.D.², Dian Kurniasari S.Si., M.Sc.²

Highlight Key

- Metode KSA diterapkan pada estimasi produksi padi Indonesia tahun 2024, memasuki tahun keenam.
- Server KSA mengelompokkan potret digital dari 25,493 segmen sampel menjadi 8 jenis fase tumbuh padi.
- Deviasi angka potensi luas panen dan produksi padi dengan angka aktual semakin membaik sejak Maret 2023.
- Model *Hybrid* VAR-LSTM diusulkan untuk meningkatkan akurasi peramalan luas panen dan produksi padi.
- Model *Hybrid* VAR-LSTM menunjukkan performa yang sangat baik dalam memprediksi data dengan tingkat kesalahan rendah dan akurasi tinggi.

Pendahuluan

Pada tahun 2024 metode kerangka sampel area (KSA) yang diterapkan pada estimasi produksi padi Indonesia akan memasuki tahun keenam. Badan Pusat Statistik (BPS) secara resmi mengumumkan estimasi produksi padi dengan metode KSA dua kali setahun, yaitu setiap bulan Maret dan bulan Oktober. Puluhan ribu petugas lapangan dikerahkan untuk melakukan pengukuran luas panen padi pada pekan terakhir setiap bulan, dengan basis kerangka sampel luas lahan, bukan kerangka sampel rumah tangga.

Petugas lapang itu memotret luas padi yang menjadi sampel menggunakan telepon pintar Android, lalu mengirimkan potret digital fase tumbuh itu ke server KSA yang dikelola oleh BPS Pusat di Jakarta. Server mengelompokkan potret digital dari 25.493 segmen sampel di seluruh Indonesia menjadi 8 jenis fase tumbuh padi, yaitu: vegetatif awal (V1), vegetatif akhir (V2), generatif (G), panen (P), persiapan lahan (PL), potensi gagal panen (PGP), lahan diberakan (Bera) dan tanaman lain selain padi (Lain-lain). Server kemudian mengolah potret hasil foto digital tersebut menjadi estimasi data luas panen pada setiap fase tumbuh padi.

Petugas lapang BPS juga melakukan pengukuran produktivitas padi dengan teknik pengukuran klasik metode ubinan dengan luas sampel 2,5 x 2,5 meter di sekitar lokasi segmen sampel padi. Lokasi persis sampel ubinan umumnya dirahasiakan dari petugas atau pegawai Pemerintah Daerah untuk menghindari

subjektivitas melalui intervensi tertentu. Lokasi sampel ubinan berjumlah sekitar 23 ribu yang tersebar di sekitar titik amatan fase tumbuh padi di atas. Metode ubinan dimaksudkan untuk mengukur produktivitas padi dengan satuan ton per hektar (ton/ha). Estimasi produksi padi adalah perkalian data luas panen dengan metode spasial-digital dan data produktivitas dengan metode pengukuran ubinan tersebut.

Sebagaimana diketahui, estimasi produksi padi Indonesia pada tahun 2023 turun lebih satu juta ton, terutama karena kekeringan ekstrem El-Nino. Dari data rilis BPS itu, produksi padi Indonesia turun dari 54,75 juta ton gabah kering giling (GKG) pada 2022 menjadi 53,51 juta ton GKG pada 2023 atau turun 2,26 persen. Jika dikonversi dalam bentuk beras, produksi turun dari 31,54 juta ton pada 2022 menjadi 30,81 juta ton pada 2023 atau 2,28 persen. Akibat El-Nino, musim tanam padi mundur menjadi November-Desember, sehingga musim panen raya juga diperkirakan mundur menjadi April 2024.

Luas panen padi Indonesia pada tahun 2023 turun sekitar 300 ribu hektare, dari 10,45 juta hektare tahun 2022 menjadi 10,17 juta hektare tahun 2023 atau turun 2,65 persen. Hampir seluruh sentra produksi padi di Indonesia mengalami penurunan, karena luas panen turun signifikan, kecuali Lampung, Sumatera Barat, Nusa Tenggara Barat, Jawa Timur dan Sulawesi Tengah. Daerah-daerah ini umumnya memanfaatkan lahan kering, lahan rawa dan sumber-sumber air swadaya.

¹ Guru Besar UNILA, Ekonom Senior INDEF dan Ketua Forum Masyarakat Statistik Periode 2023-2024

Di samping angka-angka aktual luas panen dan produksi padi yang telah diumumkan resmi, sebenarnya terdapat angka potensi luas panen dan potensi produksi padi pada metode KSA yang diturunkan dari data fase tumbuh padi. Angka potensi produksi ini tidak diumumkan resmi, tapi hanya menjadi bahan diskusi internal untuk meningkatkan akurasi ke depan. Angka potensi luas panen dan potensi produksi umumnya disajikan untuk tiga bulan ke depan, untuk memberikan gambaran awal bagi Kementerian/Lembaga (K/L) yang relevan, khususnya Kementerian Pertanian, Badan Pangan Nasional, Kementerian Perencanaan Pembangunan Nasional atau Badan Perencanaan Pembangunan Nasional (Bappenas) dan Dinas Pertanian di Tingkat Provinsi dan Kabupaten/Kota.

Artikel ini menganalisis angka potensi luas panen dan potensi produksi padi tersebut dan menawarkan metode *hybrid* untuk meningkatkan akurasi atau setidaknya mendekati angka aktual. Setelah Pendahuluan ini, pembahasan dilanjutkan tentang Angka Potensi Produksi pada Metode KSA, sedikit penjelasan tentang metode *hybrid*, yang menggabungkan metode statistika klasik dengan metode *machine learning*. Hasil perhitungan dan pengolahan beberapa model perhitungan potensi produksi akan disampaikan, sebelum ditutup dengan Kesimpulan dan

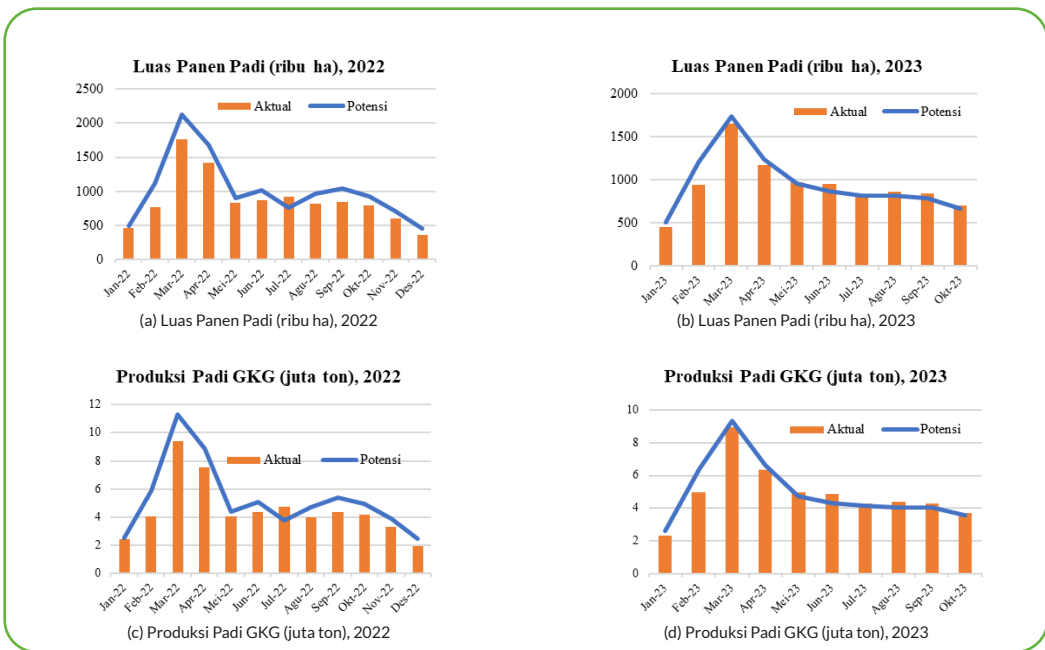
Rekomendasi ke Depan.

Angka Potensi Produksi pada Metode KSA

Sebagaimana disebutkan sebelumnya, angka potensi produksi cukup berbeda dengan angka aktual produksi, bahkan telah berbeda sejak angka potensi luas panen, yang berbeda dengan angka aktual luas panen. Hal yang perlu dicatat adalah bahwa deviasi angka potensi semakin membaik sejak bulan Maret 2023. Artinya, bahwa angka potensi luas panen dan potensi produksi semakin mendekati angka aktualnya sejak Maret 2023, tidak pada bulan-bulan sebelumnya. Gambar 1 menampilkan grafik angka potensi luas panen padi dengan angka aktual serta angka potensi produksi padi GKG dengan angka aktual, pada tahun 2022 dan 2023.

Beberapa kemungkinan penyebab deviasi angka potensi luas panen dan produksi padi dengan angka aktualnya dapat diikhtisarkan sebagai berikut:


Pertama, variabel penyusun produktivitas padi dan perubahan teknologi produksi tidak dapat “tertangkap” sepenuhnya dalam metode KSA yang berlaku saat ini (lihat Arifin, 2021, 2022). Sekian macam intervensi program Pemerintah untuk meningkatkan luas tambah tanam (LTT) dan perluasan areal tanam baru



Sumber : KSA BPS, November 2023
 Gambar 1. Deviasi Potensi dengan Aktual Luas Panen dan Produksi Padi, 2022-2023

(PATB) belum menghasilkan tambahan luas panen padi yang signifikan. Demikian pula, sekian macam bantuan program Pemerintah untuk benih, varietas baru, pupuk dan pemupukan, penanganan hama dan penyakit terpadu untuk intensifikasi produksi padi belum menghasilkan tambahan produktivitas. Selama satu dekade terakhir, produktivitas padi hanya naik 2,31 persen dari 4,17 ton/ha tahun 2012 menjadi 5,24 ton/ha pada tahun 2022. Bahkan, selama 2 tahun terakhir, produktivitas padi naik lebih lambat lagi, dari 5,23 ton/ha pada 2021, menjadi 5,24 ton/ha pada 2022 dan 5,26 ton/ha pada 2023. Benar, bahwa inovasi produksi dan penerapan teknologi padi Indonesia tertinggal dari Vietnam dan Filipina yang telah melesat dengan pertanian presisi dan sebagian *smart farming*.

Akan tetapi, proses estimasi luas panen dan produksi padi tersebut masih mungkin terjadi bias pengumpulan data luas panen oleh petugas lapangan yang memotret fase tumbuh padi dan bias petugas lapangan yang melakukan pengukuran produktivitas dengan metode ubinan. Kesalahan jenis pertama (*type I error*) sangat mungkin terjadi pada saat observasi di lapang tersebut. Demikian pula, kesalahan jenis kedua (*type II error*) juga sangat mungkin terjadi, karena kesalahan pengolahan, interpretasi, penarikan kesimpulan dan lain-lain. Akibat yang paling mencolok adalah tidak terdapat keteraturan hubungan antara angka potensi luas panen dan produksi dengan angka aktualnya.



Sumber: KSA BPS, November 2023

Gambar 2. Luas Setiap Fase Tumbuh Padi Bulanan di Indonesia, 2022-2023

Kedua, ketidakteraturan hubungan luas areal pada setiap fase tumbuh padi disebabkan oleh faktor stokastik atau faktor eksternal lain yang tidak dapat dikendalikan. Pada masa El-Nino tahun 2023, Gambar 2 secara jelas menunjukkan bahwa luas vegetatif awal padi (V1) secara umum jauh lebih kecil dari V1 pada tahun 2022. Demikian pula, dinamika perubahan pada setiap fase tumbuh padi semakin tidak teratur dan tidak berpola, karena kekeringan

ekstrem El-Nino yang melanda Indonesia. Luas alih fungsi lahan sawah menjadi kegunaan lain (Lain-Lain, warna hijau tua) pada tahun 2023 terlihat cukup besar, sehingga menjadi salah satu penjelasan tambahan dari menurunnya produksi padi GKG hingga lebih dari satu juta ton.

Data series bulanan pada luas areal setiap fase tumbuh padi ini ternyata tidak lolos uji stasioneritas, bahkan hingga 3 tahap *differencing*. Artinya, kualitas data yang diperoleh dari lapangan tidak terlalu baik, sehingga mempengaruhi deviasi angka potensi luas panen dan produksi dengan angka aktualnya. Tidak hanya itu, estimasi angka produksi padi dengan metode KSA yang digunakan saat ini tampak terlalu banyak dipengaruhi oleh variabel luas panen dibandingkan dengan variabel intensifikasi budidaya pertanian dan perubahan teknologi atau inovasi pertanian yang menggambarkan kinerja produktivitas pertanian.

Metode Hybrid Statistika Klasik dengan Machine Learning

Metode statistika klasik telah lama diketahui, berkembang pesat dan telah dimanfaatkan untuk melakukan peramalan (*forecasting*) beberapa variabel yang bersifat *multivariate*. Pendekatan untuk mengakomodasi hubungan dinamis antara beberapa variabel yang saling terkait dalam satu sistem yang paling sering digunakan adalah dengan pendekatan model *Vector Autoregressive (VAR)*. Model VAR yang didasarkan pada distribusi normal biasanya menjadi pilihan yang populer untuk menggambarkan perilaku data *multivariate time series*. Akan tetapi, pemilihan model *time series* yang akurat untuk *forecasting* luas panen padi dan produksi beras bukanlah masalah yang sederhana.

Pergerakan data luas panen dan produksi beras sering dipengaruhi oleh berbagai faktor eksternal yang kompleks, seperti kondisi iklim atau faktor musiman. Salah satu pendekatan yang populer adalah menggunakan model metode *Autoregressive Integrated Moving Average (ARIMA)* yang dikembangkan Box dan Jenkins pada era 1970an (Lihat Wei, 2018). Meskipun sederhana dan fleksibel, model ARIMA memiliki keterbatasan yang serius, yaitu struktur linearitas dari model tersebut, dan model tersebut akan mengalami penurunan keakuratan apabila terdapat komponen nonlinier pada data *time series*. Model ARIMA khusus digunakan

untuk data *univariate time series*, data variabel tunggal (Zhang, 2003).

Namun demikian, seperti halnya model ARIMA, model VAR mengalami penurunan akurasi dalam peramalan jangka panjang data *multivariate time series* yang berpola nonlinear, seperti pada data multivariat harga saham. Keterbatasan utama dalam model VAR adalah menjadikan linearitas sebagai asumsi dan residual yang dihasilkan masih terdapat unsur nonlinear. Metode VAR memiliki akurasi tinggi dalam peramalan jangka pendek, namun akurasi akan menurun ketika digunakan dalam peramalan jangka panjang.

Sementara itu, model *deep learning* bekerja dengan baik ketika digunakan untuk memodelkan data *univariate* dan *multivariate time series* yang berpola nonlinear. Model *deep learning* yang sering digunakan untuk peramalan adalah model *Long Short-Term Memory* (LSTM) dan Model *Gated Recurrent Unit* (GRU). Metode LSTM merupakan salah satu pengembangan dari metode *Recurrent Neural Network* (RNN), arsitektur ini pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada akhir 1990an (Lihat Manaswi, 2018). Metode LSTM dibangun untuk mengatasi masalah pada RNN, yaitu pada saat pemrosesan data sekuensial jangka panjang RNN tidak dapat menghubungkan informasi baru dengan informasi lama karena memori lama yang tersimpan akan semakin tidak berguna dan tertimpa dengan memori yang baru, sedangkan LSTM mampu mengatasi masalah tersebut karena dapat mengatur memori pada setiap masukannya dengan menggunakan *memory cell* dan *gate units*. LSTM dapat menghubungkan interval waktu dalam jangka yang panjang tanpa kehilangan informasi. LSTM mengganti lapisan RNN dengan *memory cell* menggunakan mekanisme gerbang yang terdiri dari *forget gate*, *input gate*, dan *output gate*.

Model GRU merupakan modifikasi dari RNN yang dibuat agar terhindar dari masalah ketergantungan jangka panjang pada RNN. Tujuan utama GRU adalah untuk membuat setiap *recurrent unit* untuk dapat menangkap *dependencies* dalam skala waktu yang berbeda-beda secara adaptif. Metode GRU dapat mengingat informasi jangka panjang sama seperti RNN, GRU juga terdiri dari modul pemrosesan berulang. Metode GRU serupa dengan LSTM dimana GRU juga menggunakan sistem gerbang, namun arsitektur GRU lebih sederhana dibandingkan dengan LSTM. GRU

dapat melakukan proses komputasi lebih cepat dari LSTM karena memiliki jumlah *gate* lebih sedikit. Metode GRU memiliki dua *gate*, yaitu *reset gate* dan *update gate*. *Reset gate* pada GRU akan menentukan bagaimana menggabungkan input baru dengan informasi masa lalu, sedangkan *update gate* akan menentukan berapa banyak informasi masa lalu yang harus tetap disimpan.

Model campuran atau *hybrid* digunakan untuk mengatasi beberapa keterbatasan pada statistika klasik dan model *deep learning*, atau dikenal dengan Model *Hybrid VAR-Deep Learning*, yaitu model *Hybrid VAR-LSTM* dan model *Hybrid VAR-GRU*. Permasalahan pada data *multivariate time series* itu sendiri seringkali sulit ditentukan apakah berpola linear atau nonlinear. Pola data *multivariate time series* lebih sering mengandung keduanya, yakni berpola campuran linear dan nonlinear. Jika hal tersebut terjadi, maka penggunaan metode peramalan tunggal dinilai kurang efektif karena tidak dapat menangkap pola campuran. Berikut ini beberapa alasan yang mendasari dikembangkannya metode *hybrid*:

Pertama, sulit untuk menentukan apakah *time series* yang dianalisis mengandung pola linier atau non-linier sehingga penggunaan lebih dari satu metode dianggap lebih baik, Setidaknya mampu dibandingkan untuk mendapatkan hasil yang paling akurat. Untuk mengatasi hal tersebut, maka dilakukan penggabungan metode yang berbeda sehingga permasalahan seleksi model dapat diminimalisir.

Kedua, permasalahan *time series* yang murni linier atau non-linier sangat jarang terjadi. Pola data lebih sering mengandung keduanya. Jika hal tersebut terjadi, maka penggunaan metode tunggal dinilai kurang efektif karena tidak dapat menangkap pola campuran.

Metode *hybrid* merupakan pengembangan metode peramalan dengan menggabungkan dua metode atau lebih. Metode *hybrid* ini diharapkan dapat bekerja sesuai dengan keandalan masing-masing metode sehingga dapat mengatasi kelemahan salah satunya. Kemudian model yang dihasilkan dapat memberikan prediksi dan peramalan yang lebih akurat dibanding model individual. Diasumsikan bahwa model kombinasi deret waktu terdapat dua komponen dasar, yaitu komponen linier dan non-linier, yaitu:

$$y_t = C_t - G_t \tag{1}$$

dalam hal ini y_t data *time series* awal; C_t komponen linear dan G_t komponen nonlinear.

Komponen linear diduga oleh model VAR dan akan menghasilkan galat atau residual $e_t = y_t - \hat{C}_t$, dalam hal ini \hat{C}_t nilai prediksi waktu ke- t dengan VAR dari data y_t .

Residual dan prediksi yang dihasilkan dari model VAR merupakan data input untuk metode LSTM dan GRU, sehingga dihasilkan peramalan melalui persamaan

$$\hat{y}_t = \hat{C}_t - \hat{G}_t \quad (2)$$


Singkatnya, model *Hybrid VAR-LSTM* dan model *Hybrid VAR-GRU* yang ditawarkan di sini merupakan model kombinasi *multivariate time series-deep learning* yang inovatif dan solutif dalam menangani data *multivariate time series* yang memiliki pola linear dan atau nonlinear. Komponen model VAR digunakan untuk memodelkan data yang berpola linier. Sedangkan LSTM dan GRU digunakan untuk memperhitungkan pola dan informasi jangka panjang dalam data deret waktu yang berpola non-linier. Proses *forecasting* dengan penggabungan kedua model dilakukan dengan menggabungkan *output* model VAR sebagai *input* model *deep learning* LSTM dan GRU.

Hasil Peramalan Potensi dengan Model Hybrid

Berikut ini diikhtisarkan hasil peramalan potensi luas panen dengan tiga model yang berbeda, yaitu menggunakan (1) *Vector Autoregressive (VAR)*, (2) *Vector Autoregressive-Gated Recurrent Unit (VAR-GRU)* dan (3) *Vector Autoregressive-Long Short-Term Memory (VAR-LSTM)*. Angka luas panen dan produksi aktual padi yang diolah di dalam ketiga model berjumlah 68 observasi dari Januari 2018 hingga Agustus 2023. Ketiga model ini menyajikan angka peramalan untuk empat bulan ke depan, yaitu September-Desember 2023.

(1) Model *Vector Autoregressive (VAR)*


Model VAR menghasilkan prakiraan luar panen dan produksi GKG setelah Agustus 2023 seperti terlihat pada Gambar 3. Luas panen dan produksi padi mula-mula naik kemudian mendatar dan turun pada akhir tahun 2023. Secara umum, luas panen dan produksi padi pada akhir tahun umumnya menurun, karena nyaris di hampir seluruh sentra produksi padi baru saja tanam untuk musim rendeng untuk periode Oktober-Maret.



Gambar 3. Prakiraan Luas Panen dan Produksi Padi GKG menggunakan VAR

(2) Model *Vector Autoregressive-Gated Recurrent Unit (VAR-GRU)*


Model VAR-GRU menghasilkan prakiraan luar panen dan produksi GKG setelah Agustus 2023 sangat berfluktuatif seperti terlihat pada Gambar 4. Luas panen dan produksi padi mula-mula naik kemudian turun tajam, kemudian naik kembali hingga akhir tahun 2023. Di Indonesia, luas panen dan produksi padi pada akhir tahun biasanya menurun, sehubungan dengan musim tanam padi yang baru dimulai untuk dipanen kelak pada Maret-April 2024.



Gambar 4. Prakiraan Luas Panen dan Produksi Padi GKG menggunakan VAR-GRU

(3) Model *Vector Autoregressive-Long Short-Term Memory (VAR-LSTM)*

Model VAR-LSTM menghasilkan prakiraan luar panen setelah Agustus 2023 yang cukup stabil, walau menunjukkan penurunan signifikan pada bulan kedua, kemudian kembali naik pada bulan ketiga dan keempat. Hasil prakiraan produksi padi GKG juga menunjukkan dengan pola yang mirip, walau dengan magnitudo yang lebih besar. Produksi padi GKG turun signifikan pada bulan kedua, kemudian terus naik pada bulan ketiga dan keempat, seperti terlihat pada Gambar 5.



Gambar 5. Prakiraan Luas Panen dan Produksi Padi GKG menggunakan VAR-LSTM

Hasil prakiraan luas panen dan produksi padi GKG menggunakan ketiga model yang dijelaskan sebelumnya dapat dilihat pada Tabel 1 berikut.

Tabel 1. Perbandingan Prakiraan Luas Panen dan Produksi Padi pada Ketiga Model

Bulan	VAR		Hybrid VAR-GRU		Hybrid VAR-LSTM	
	Luas Panen	Pro-duksi	Luas Panen	Pro-duksi	Luas Panen	Pro-duksi
Sept 2023	1,06	4,28	1,18	5,38	0,90	4,02
Okt 2023	1,29	4,32	0,72	3,79	0,81	3,62
Nov 2023	1,13	4,29	1,24	6,44	0,85	4,30
Des 2023	0,89	4,25	1,34	6,49	0,96	4,47

Sumber : Hasil pengolahan

Model *Hybrid* dengan VAR-LSTM menghasilkan prakiraan luas panen dan produksi padi yang lebih konsisten, sesuai dengan karakteristik di dunia nyata. Mode *Hybrid* VAR-LSTM memiliki performa yang sangat baik dalam memprediksi data, dengan tingkat kesalahan yang rendah dan akurasi yang tinggi. Untuk meningkatkan akurasi angka potensi luas panen dan produksi padi, KSA layak mempertimbangkan metode *Hybrid* VAR-LSTM atau metode *Hybrid* lain yang mampu menggambarkan kondisi aktual yang akan terjadi.

Hal yang perlu diingat adalah bahwa pada analisis prakiraan angka luas panen dan produksi padi yang telah dilakukan memiliki keterbatasan jumlah observasi, karena data bulanan yang tersedia hanya dimulai pada Januari 2018. Ke depan, analisis prakiraan luas panen dan produksi padi dapat dilakukan dengan data serupa pada tingkat provinsi di seluruh Indonesia. Misalnya, data panel bulanan untuk seluruh provinsi itu dapat dianalisis dengan model *Hybrid* PVAR-LSTM dengan data *panel multivariate*.

Kesimpulan dan Rekomendasi

Artikel ini telah menyajikan upaya untuk memperbaiki angka potensi luas panen dan produksi padi pada metode kerangka sampel area (KSA) dengan metode *hybrid* atau campuran metode statistika klasik dengan *Vector Autoregressive* (VAR) dengan *machine learning* atau tepatnya LSTM atau dikenal dengan model

Hybrid VAR-LSTM. Estimasi luas panen dan produksi padi yang digunakan saat ini sebenarnya merupakan metode yang efektif untuk mengumpulkan data lapangan, tetapi beberapa kekurangan, inkonsistensi dan faktor stokastik yang masih besar masih dapat diperbaiki. Dengan jumlah observasi yang cukup terbatas, metode *Hybrid* VAR-LSTM terbukti menjadi metode yang terbaik yang menggabungkan pendekatan statistika klasik dengan *machine learning*.

Pendekatan ini memungkinkan untuk penyesuaian dan perincian data yang diperoleh dari KSA, sehingga mendapatkan perkiraan luas panen yang lebih akurat dan relevan. Pendekatan atau model *hybrid* mampu meningkatkan performa seiring dengan peningkatan jumlah data yang tersedia. Angka potensi luas panen dan produksi padi yang lebih baik dan mendekati aktual akan sangat membantu proses perencanaan dan kebijakan pertanian.

Para peneliti terapan, khususnya bidang ekonomi pertanian dan ilmu statistika dapat terus melakukan analisis data seluruh fase tumbuh padi yang dikumpulkan menggunakan metode KSA untuk mengetahui dinamika perubahan lahan pertanian. Jika pola hubungan antar fase tumbuh atau antar perubahan status tanaman padi dapat dipetakan dengan baik, maka angka potensi luas panen akan dapat diketahui lebih pasti. Demikian pula, jika pola hubungan di tingkat lapangan antara luas panen dan produktivitas padi di sekitar titik observasi dalam segmen sampel dapat dipetakan dengan baik, maka dimensi produktivitas padi dan perubahan teknologi atau inovasi baru dapat diketahui dengan lebih jelas. Data yang berkualitas akan menentukan kualitas kebijakan pembangunan ke depan.

Daftar Pustaka

Arifin, Bustanul. 2021. *Pertanian Bantalan Resesi*. Jakarta: Pustaka INDEF. 237 halaman

Arifin, Bustanul. 2022. "Dinamika Produktivitas Padi pada Metode KSA". *Statistical and Policy Brief of FMS*, Edisi 19, Agustus 2022. Jakarta: Forum Masyarakat Statistik (FMS). <https://fmsindonesia.id/wp-content/uploads/2023/02/Rev-1-Buletin-FMS-Edisi-19-Agustus-2022.pdf>

Badan Pusat Statistik. 2023. "Luas Panen dan Produksi Padi di Indonesia 2023" (Angka Sementara). *Berita Resmi BPS* No. 68/10/

Th XXVI, 16 Oktober 2023. Jakarta: BPS

Manaswi, N. K. 2018. RNN and LSTM: In Deep Learning with Application Using Python. Berkeley, CA: A Press.

Warsono, Y. Antonio, D. Kurniasari, M. Azram and M. Usman. 2018. "Analysis of Dynamic Structure, Granger Causality and Forecasting with Vector Autoregression (VAR) Models on Credit Risk Data". Sci. Int. (Lahore), 30(1): 7-16.

Wei, W. S. 2018. Multivariate Time Series Analysis and Applications. New York: John Wiley & Sons.

Zhang, G. P. 2003. "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model", Neurocomputing 50: 159-175.