

Model Spasial untuk Prediksi Konsentrasi Polutan Kabut Asap Kebakaran Lahan Gambut Menggunakan *Support Vector Regression*

Spatial Model for Predicting Haze Concentration of Peatland Fires Using Support Vector Regression

MUHAMMAD ASYHAR AGMALARO^{1*}, IMAS SUKAESIH SITANGGANG¹, LAILAN SAHRINA HASIBUAN¹, MUHAMMAD MURTADHA RAMADHAN¹

Abstrak

Kabut asap dari kebakaran lahan gambut mengandung berbagai macam polutan seperti CO dan CO₂. Polutan tersebut dapat berimplikasi buruk pada kesehatan masyarakat sekitar peristiwa itu terjadi yang berupa Infeksi Saluran Pernafasan Atas (ISPA). Penelitian ini bertujuan untuk membuat model spasial untuk prediksi konsentrasi polutan kabut asap yang berupa CO dan CO₂ dari kebakaran lahan gambut di Sumatra tahun 2015. Model spasial dibentuk menggunakan algoritme *support vector regression* (SVR) dengan kernel *radial basis function* (RBF) untuk melihat konsentrasi polutan dari beberapa titik tetangga. *Parameter tuning* dilakukan untuk mendapatkan nilai *gamma* yang paling optimal untuk kernel RBF. Hasil penelitian menunjukkan bahwa model spasial untuk prediksi konsentrasi CO yang terbaik didapatkan pada parameter *gamma* dengan nilai 20 yang menghasilkan *root mean squared error* (RMSE) dan nilai koefisien korelasi sebesar $1,174242 \times 10^{-8}$ dan 0,5879287. Model spasial prediksi konsentrasi CO₂ terbaik dibentuk pada *gamma* dengan nilai 10 yang menghasilkan RMSE dan nilai koefisien korelasi sebesar $9,843717 \times 10^{-8}$ dan 0,6058418. Hasil prediksi dari model yang dibentuk telah dapat mengikuti pola nilai aktual konsentrasi polutan.

Kata Kunci: CO, CO₂, kabut asap, model spasial, *Support Vector Regression*.

Abstract

Haze of peatland fires contains several kinds of pollutant such as CO and CO₂. Those pollutants can give negative implication to society around the occasion which is ISPA. This research aims to make spatial model to predict the of pollutants concentration in form of CO and CO₂ emitted from peatland fires in Sumatra 2015. Spatial model is formed using support vector regression (SVR) with radial basis function (RBF) kernel by considering pollutant concentration of several neighboring points. Parameter tuning is conducted to the most optimum gamma of RBF kernel. The result for the research shows that the best spatial model for predicting CO concentration is obtained while gamma of 20 resulting root mean squared error (RMSE) and coefficient of correlation value of $1,174242 \times 10^{-8}$ and 0,5879287. Meanwhile, the best model for predicting CO₂ concentration is while gamma of 10 resulting RMSE and coefficient of correlation of $9,843717 \times 10^{-8}$ and 0,6058418. The prediction result of the models formed has been able to follow the pattern of actual pollutant concentration value.

Keywords: CO, CO₂, haze, spatial model, Support Vector Regression

PENDAHULUAN

Kebakaran hutan merupakan salah satu isu krusial yang menjadi perhatian pemerintah Indonesia dewasa ini. Hal tersebut dominannya terjadi di daerah Sumatera, Kalimantan, dan Riau dan terkonsentrasi pada konsesi pertanian dan lahan gambut menurut analisis Global Forest Watch Fires (WRI 2017). Di tahun 2015, 2,6 juta hektar lahan terbakar pada interval bulan Juni hingga Oktober yang merupakan musim kemarau di Indonesia (WRI 2017). Menurut NASA yang dilansir dalam DW (2015), tahun 2015 menjadi rekor terparah dalam sejarah kebakaran hutan dan kabut asap di Indonesia. Peristiwa kebakaran hutan di Indonesia bahkan telah disebut

¹Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor, 16680

*Penulis Korespondensi Surel: agmalaro@apps.ipb.ac.id

sebagai tindakan kriminal lingkungan hidup terbesar pada abad ke-21 karena aktivitas manusia menjadi penyebab utama terjadinya peristiwa ini (WorldBank 2015).

Banyak dampak merugikan yang ditimbulkan oleh peristiwa kebakaran hutan khususnya terhadap kehidupan masyarakat seperti gangguan pernapasan. Hal ini terjadi karena terbakarnya lahan gambut yang kaya akan karbon akan menyebarkan kabut asap beracun kepada lingkungan sekitar. Menurut WRI Indonesia (2015), kabut beracun yang dihasilkan mencapai tiga kali lipat emisi gas rumah kaca tahunan Indonesia dan kabut tersebut terpapar pada jutaan orang di Asia Tenggara. Polutan kebakaran hutan menyebabkan pencemaran udara yang berakibat pada Infeksi Saluran Pernafasan Akut (ISPA). 425.377 orang terserang ISPA akibat kebakaran hutan yang terjadi di tujuh provinsi menurut data Kementerian Kesehatan Republik Indonesia (Abri dan Tarigan 2015).

Berbagai usaha antisipasi pun dapat dilakukan untuk meminimalisir dampak kerugian kabut asap yang dihasilkan oleh kebakaran hutan. Salah satu langkah yang dapat dilakukan adalah dengan menganalisis nilai konsentrasi polutan dari kabut asap kebakaran hutan yang terjadi. Analisis pada komponen tersebut akan memberikan informasi mengenai bagaimana tingkat pencemaran udara dari polutan kabut asap yang dihasilkan kebakaran hutan. Informasi-informasi tersebut pun dapat menjadi pemberitahuan kepada masyarakat akan terjadinya pencemaran udara yang dapat berakibat fatal.

Konsentrasi polutan yang disebabkan kabut asap pada lahan gambut di titik lokasi dan waktu tertentu dapat diperoleh dan diprediksi dengan membuat pemodelan secara spasial dari kumpulan data nilai konsentrasi polutan, dan melihat komponen spasialnya yaitu posisi ketetanggaan konsentrasi polutan berdasarkan koordinat *longitude* dan *latitude* dari lahan gambut. Model prediksi tersebut dapat dibangun dengan pendekatan *machine learning* yaitu dengan algoritme *elman recurrent neural network* (ERNN), *support vector regression* (SVR), dan beberapa pendekatan lainnya.

Penelitian terkait model spasial yang digunakan untuk memprediksi nilai tertentu sudah dilakukan oleh Robby (2017). Penelitian tersebut mengembangkan model prediksi terhadap jumlah kemunculan titik panas pada lahan gambut di Kabupaten Siak menggunakan algoritme *elman recurrent neural network* (ERNN) untuk model spasial titik panas dengan melihat matriks ketetanggaan. Hasil penelitian tersebut memberikan nilai evaluasi prediksi dengan basis *normalized mean square error* (NMSE) sebesar 0.999657 dengan input data ketetanggaan berasal dari jumlah kemunculan titik panas dari Kabupaten Bengkalis, Kabupaten Rokan Hilir dan Kota Dumai. Model tersebut secara umum cukup baik untuk memprediksi jumlah kemunculan titik panas.

Penelitian lain yaitu oleh Apriliantono (2017), juga melakukan pengembangan model untuk kasus *trajectory pattern mining* yang dapat menjelaskan pola pergerakan kabut asap beserta konsentrasi polutannya dari sisi spasial dan temporal. Penelitian tersebut membangkitkan *trajectory* dan konsentrasi polutan kabut asap menggunakan model *hybrid single particle langrangian* (HYSPLIT), kemudian dianalisis dengan pendekatan *spatio-temporal clustering*. Hasil analisis menggunakan algoritme K-Means menunjukkan bahwa daerah Kubu, kabupaten Rokan Hilir, Riau, memiliki rata-rata tingkat CO dan CO₂ terbesar dengan Indeks Standar Pencemaran Udara (ISPU) sebesar 142.86 dan telah masuk pada kategori 'tidak sehat'. Hasil analisis juga menunjukkan tingkat konsentrasi polutan dengan rata-rata ketinggian terendah yaitu pada 16.574 m AGL yang berada di 4 wilayah Indonesia dan 8 daerah di Malaysia.

Penelitian-penelitian sebelumnya dominan berfokus pada prediksi jumlah titik panas atau klusterisasi konsentrasi polutan dengan pendekatan spasial maupun temporal. Pada penelitian Robby (2017), pembangunan model spasial untuk prediksi jumlah titik panas di Kabupaten Siak sudah berhasil dilakukan. Beberapa penelitian terkait *trajectory pattern mining* untuk konsentrasi polutan juga telah dilakukan yang salah satunya dilakukan oleh Apriliantono (2017). Penelitian ini berhasil melakukan pembangkitan data *trajectory* dan konsentrasi polutan kabut asap Sumatra tahun 2015 dengan model HYSPLIT dan hanya sebatas menganalisis hasil kluster pembangkitan data menggunakan pendekatan *k-means clustering*, belum sampai pada tahap memprediksi

konsentrasi polutan disekitar lokasi terdampak kabut asap di lahan gambut. Oleh karena itu, penelitian ini akan befokus pada pembuatan model spasial untuk memprediksi konsentrasi polutan dari lahan gambut menggunakan algoritme *support vector regression* (SVR).

METODE

Data Penelitian

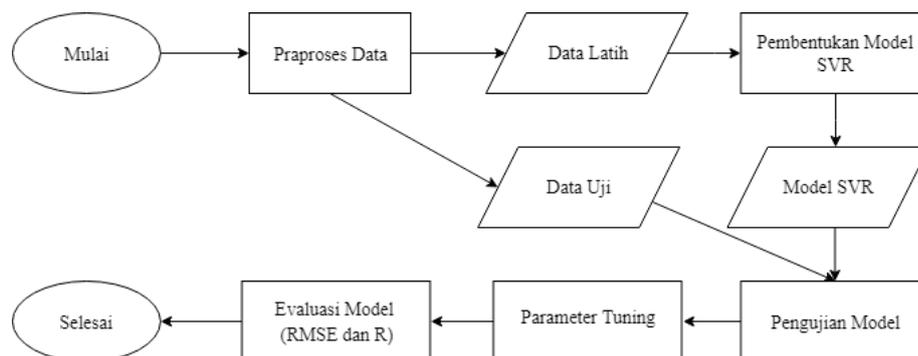
Data yang digunakan pada penelitian ini adalah data hasil penelitian Tyas (2018) yang berupa data nilai konsentrasi polutan CO dan CO₂ dari kabut asap kebakaran lahan gambut Sumatra pada tanggal 22 sampai 25 September 2015 hasil pembangkitan dengan HYSPLIT. Data tersebut berjumlah 25 789 *record* dengan beberapa atribut seperti yang tertera pada Tabel 1. Untuk pembuatan model spasial prediksi konsentrasi polutan, aspek utama yang akan diamati yaitu koordinat lokasi tersebarnya kabut asap berupa *longitude* dan *latitude* untuk melihat ketetangaan dari satu titik yang diprediksi.

Tabel 1 Atribut-atribut pada *dataset* yang digunakan untuk penelitian

Nama Atribut	Jenis Data	Keterangan
YEAR	Numerik	Tahun terjadinya kebaran lahan gambut
MONTH	Numerik	Bulan terjadinya kebakaran lahan gambut
DAY	Numerik	Tanggal terjadinya kebakaran lahan gambut
HOUR	Numerik	Jam terjadinya kebakaran lahan gambut yang dinyatakan per 3 jam
LAT	Numerik	Nilai koordinat lintang tersebarnya polutan kabut asap kebakaran lahan gambut
LON	Numerik	Nilai koordinat bujur tersebarnya polutan kabut asap kebakaran lahan gambut
CO2	Numerik	Nilai konsentrasi CO ₂ kabut asap kebakaran lahan gambut dalam satuan kg/m ³
CO	Numerik	Nilai konsentrasi CO kabut asap kebakaran lahan gambut dalam satuan kg/m ³

Tahapan Penelitian

Penelitian ini berfokus pada pembuatan model spasial konsentrasi polutan kabut asap kebakaran lahan gambut Sumatra pada tanggal 22 sampai 25 September 2015. Penelitian dimulai dari melakukan praproses data dengan membentuk struktur data baru berdasarkan aspek spasial dari data. Langkah selanjutnya yaitu membentuk model spasial prediksi menggunakan algoritme SVR dengan parameter terbaik. Model spasial prediksi dengan beberapa nilai parameter diuji dan hasilnya dievaluasi. Tahapan-tahapan yang dilakukan pada penelitian ini dapat dilihat pada Gambar 1.



Gambar 1 Tahapan penelitian

Praproses Data dan Pembagian Data

Pada tahap praproses data, fokus utama yang dilakukan adalah memproses data mentah untuk menghasilkan data yang siap untuk membentuk model prediksi. Hal pertama yang dilakukan adalah memeriksa apakah ada nilai yang hilang pada *dataset*. Tahap selanjutnya adalah melakukan seleksi atribut data yang representatif yang akan menjadi bahan pembelajaran model dan mereduksi data yang tidak diperlukan. Tahap ini menghasilkan data konsentrasi polutan kabut asap kebakaran lahan gambut berupa nilai CO, CO₂, dan atribut yang merepresentasikan aspek spasial konsentrasi polutan untuk membentuk model spasial prediksi

Data konsentrasi polutan kabut asap yang telah diseleksi kemudian dinormalisasi untuk menghilangkan dependensi data pada satuan pengukuran dan mengatasi ketimpangan data sehingga setiap atribut pada data mempunyai bobot yang sama (Han *et al.* 2011). Data yang dinormalisasi pada kasus ini yaitu nilai CO dan CO₂. Metode normalisasi yang digunakan yaitu normalisasi min-max pada rentang 0 sampai 1 dengan persamaan 1 (Han *et al.* 2011):

$$v'_i = \frac{v_i - \min_A}{\max_A - \min_A} \quad (1)$$

dengan:

v'_i = data hasil normalisasi

v_i = data yang akan dinormalisasi

\min_A = data minimum pada rentang A

\max_A = data maksimum pada rentang A

Setelah normalisasi data, analisis dilakukan dengan menentukan titik-titik tetangga terdekat dari satu titik pada radius tertentu yang menjadi target prediksi dalam kedudukan temporal yang sama. Apabila terdapat titik yang tidak mempunyai jumlah tetangga pada batas minimum yang ditentukan, titik tersebut dieliminasi dan tidak dimasukkan dalam pengolahan data. Di samping itu, data yang telah memenuhi batas minimum jumlah tetangga dan masih terdapat slot tetangga yang kosong, metode interpolasi digunakan untuk menentukan titik tetangga tersebut beserta konsentrasi polutannya. Metode interpolasi yang digunakan pada penelitian ini yaitu metode *inverse distance weighting* persamaan 2 (Achilleos 2011):

$$C_p = \frac{\sum_{i=1}^N \left(\frac{C_i}{d_i^2} \right)}{\sum_{i=1}^N \left(\frac{1}{d_i^2} \right)} \quad (2)$$

dengan:

C_p = konsentrasi polutan hasil interpolasi

C_i = konsentrasi polutan tetangga untuk interpolasi

d_i = jarak *euclidean* antara titik tetangga dengan titik sasaran interpolasi

Setelah praproses dilakukan, data dibagi menjadi dua bagian yaitu data latih dan data uji. Pembagian data dilakukan dengan persentase 80% dan 20% untuk data latih dan data uji. Pembagian data tersebut dilakukan dengan pemilihan data secara acak dari seluruh data dalam *dataset*.

Pembuatan Model Spasial Prediksi dan Pengujian Model

Pembentukan model spasial prediksi konsentrasi polutan dilakukan dengan memproses data latih yang telah dibentuk dengan algoritme SVR. SVR merupakan metode turunan dari *support vector machine* (SVM) yang biasa digunakan untuk melakukan klasifikasi dengan pemisahan data menggunakan *hyperplane*. SVR pada kasus regresi dengan mempertimbangkan melakukan pencarian *hyperplane* paling optimal ϵ -insensitive *loss function* (Cheng *et al.* 2007). Galat diabaikan selama nilai galat berada di bawah nilai ϵ . SVR melakukan pemetaan non-linier pada data masukan ke dalam ruang fitur berdimensi tinggi dan kemudian membentuk masalah linier pada ruang fitur tersebut. (Ko dan Lee 2012). SVR merupakan teknik yang cocok untuk menyelesaikan permasalahan regresi non-linier (Zeng dan Qiao 2012).

Penelitian ini menggunakan *radial basis function* (RBF) sebagai kernel pada SVR. SVR dengan kernel RBF melakukan proses komputasi lebih efisien daripada metode SVM karena pelatihan model yang dilakukan hanya memerlukan solusi dari himpunan persamaan linier (Ramedani *et al.* 2014). Hasil studi Ramdani (2014) juga menyimpulkan bahwa RBF merupakan kernel yang mendukung dan cocok untuk membatasi proses pelatihan secara komputasional dan meningkatkan nilai efisiensi generalisasi dari SVM.

Parameter Tuning

Parameter tuning dilakukan untuk mencari nilai parameter paling optimal dalam membentuk model prediksi terbaik. Proses *parameter tuning* berfokus pada pemilihan nilai

paramater γ dari fungsi kernel RBF dengan sebelumnya menentukan rentang nilai dari parameter tersebut. Setiap nilai γ yang ditetapkan pada tahap pelatihan model, akan dihitung dan dibandingkan nilai akurasi modelnya menggunakan *k-fold cross validation*. Setelah mendapatkan parameter yang paling optimal, yaitu dengan akurasi model terbaik, model kembali diuji untuk dievaluasi menggunakan data uji.

Evaluasi Model

Hasil pengujian model dengan beberapa skenario parameter dievaluasi dengan melihat *root mean squared error* (RMSE) dan nilai koefisien korelasi (R) pada nilai prediksi dan nilai aktual. Perhitungan RMSE dilakukan dengan fungsi *rmse* pada *package* Metrics dan perhitungan nilai korelasi dilakukan dengan fungsi *cor* pada *package* EnvStats di R. Nilai RMSE dapat dihitung dengan persamaan 3 (Chai dan Draxler 2014). Nilai koefisien korelasi dari model dapat dihitung dengan persamaan 4 (Mendenhall *et al.* 2009):

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad (3)$$

dengan:

n = jumlah data yang diprediksi

i = urutan data

e = galat antara nilai aktual dan prediksi

$$R = \frac{S_{xy}}{S_x S_y} \quad (4)$$

dengan:

S_{xy} = kovarian antara nilai aktual dan prediksi

S_x = standar deviasi nilai aktual

S_y = standar deviasi nilai prediksi

HASIL DAN PEMBAHASAN

Praproses dan Pembagian Data

Praproses data diawali dengan melakukan pemeriksaan nilai yang hilang (*N/A value*) pada *dataset*. Nilai *N/A* dapat diartikan bahwa terdapat data yang tidak tercatat oleh system yang melakukan pencatatan terhadap obyek observasi. Keluaran fungsi yang berupa nilai boolean TRUE atau FALSE. Hasil keluaran berupa TRUE dijumlah dan hasilnya tidak ditemukan nilai yang hilang pada *dataset* yang diolah. Hasil dengan nilai 0 pada atribut data polutan mempunyai interpretasi bahwa konsentrasi polutan telah tercatat dan memiliki nilai 0. Setelah memeriksa nilai yang hilang, proses reduksi dan normalisasi data dilakukan. Dari delapan atribut yang terdapat dalam *dataset*, atribut YEAR dan MONTH dianggap dapat dihilangkan karena setiap kejadian kebakaran lahan gambut yang dianalisis terjadi pada bulan dan tahun yang sama sehingga data pada atribut tersebut tidak digunakan dalam proses pembentukan model. Kemudian, nilai CO dan CO₂ dalam *data set* dinormalisasi pada rentang data masing-masing.

Data yang telah direduksi dan dinormalisasi diproses untuk membentuk struktur data baru dengan menentukan delapan titik tetangga dari tiap titik yang ada pada *dataset*. Penentuan titik tetangga dilakukan dengan melihat nilai LON dan LAT pada setiap data pada radius 50 kilometer atau 0.45045 *degree* (Sirimongkonlertkul *et al.* 2013). Fungsi *nn2* pada *package* RANN di R digunakan untuk proses tersebut dan menghasilkan keluaran berupa ID titik tetangga dan jarak titik tetangga dari titik pusat.

Setiap titik kemudian diperiksa apakah sudah mempunyai setidaknya 70% dari jumlah titik tetangga yang ditentukan atau sebanyak 5 titik. Hasil analisis menunjukkan terdapat 56 titik yang

tidak memenuhi batas jumlah titik tetangga tersebut. Titik yang tidak memenuhi jumlah tetangga tidak dimasukkan ke dalam *dataset* baru untuk pemodelan.

Kemudian, metode interpolasi *inverse distance weighting* digunakan untuk mengisi nilai konsentrasi tetangga titik yang belum mempunyai 8 titik tetangga walaupun sudah memenuhi batas jumlah tetangga yang ditentukan. Pencarian nilai minimum dan maksimum dari posisi *longitude* dan *latitude* dari setiap baris data yang diinterpolasi untuk menentukan jangkauan data. Jangkauan data *longitude* dan *latitude* digunakan untuk pembangkitan titik baru pada posisi acak yang berada pada jangkauan data sehingga titik yang dibangkitkan berada pada lingkup baris data tersebut seperti pada Gambar 2.



Gambar 2 Interpolasi titik pada titik dengan slot tetangga yang belum lengkap

Dari hasil analisis yang dilakukan, terdapat 68 data yang telah memenuhi batas ketetangaan dan harus diinterpolasi yang dapat dilihat pada Tabel 2. Interpolasi mempertimbangkan nilai tetangga lainnya dan tidak menggunakan nilai titik utama. Interpolasi pada titik ke-8 dan ke-9 memungkinkan untuk menggunakan titik tetangga yang sudah ada atau titik hasil interpolasi titik sebelumnya.

Tabel 2 Sebaran jumlah titik yang harus diinterpolasi *inverse distance weighting*

Jumlah titik ketetangaan yang kosong	Jumlah data
3 titik	11
2 titik	17
1 titik	40

Dataset baru dengan nilai konsentrasi CO dan CO₂ setiap titik beserta tetangganya dibagi menjadi dua bagian yaitu data latih dan data uji. Dengan skenario pembagian 80% data latih dan 20% data uji, didapatkan 20 744 untuk data latih dan 4 989 untuk data uji.

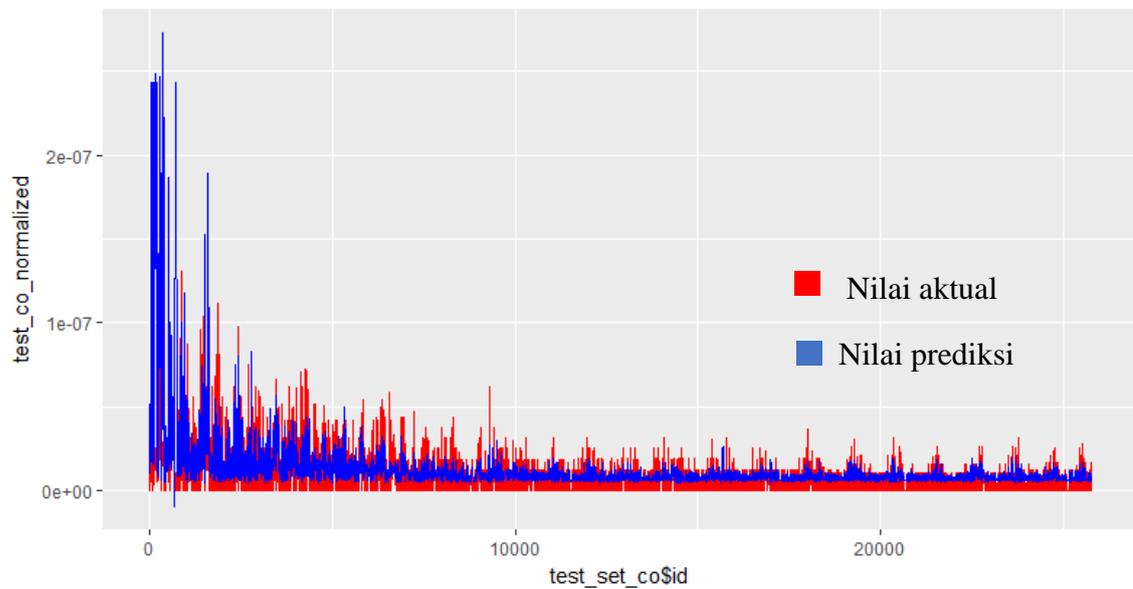
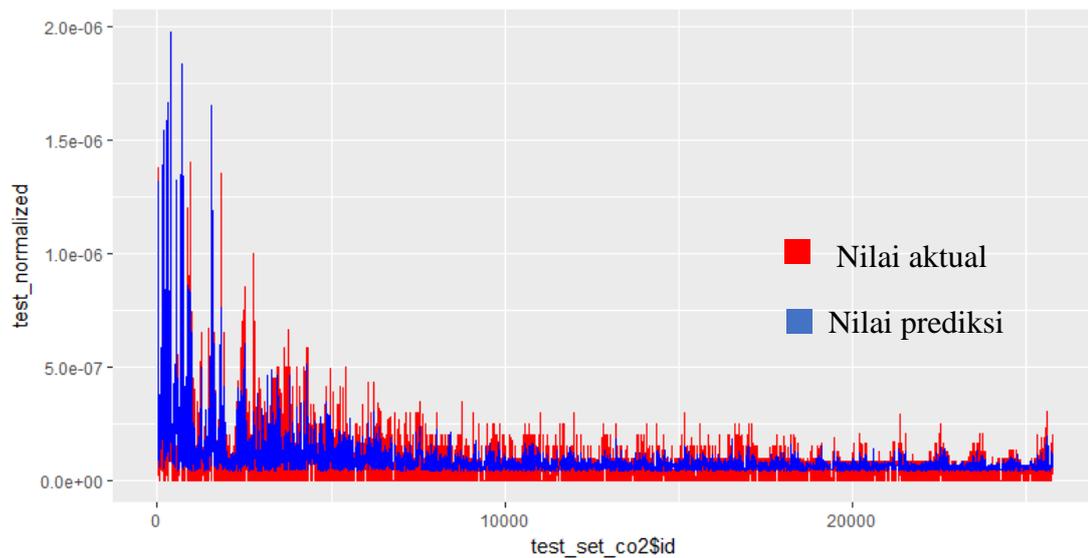
Pembentukan Model Spasial Prediksi dan Pengujian Model

Model spasial prediksi dibentuk dengan melatih data latih CO dan CO₂ secara terpisah. Pembentukan model dilakukan dengan algoritme SVR dengan kernel RBF pada *package* *e1071* di R. Pelatihan awal dilakukan dengan pengaturan parameter dari SVR secara *default* yaitu *gamma* dengan nilai 0.125.

Model tersebut diuji menggunakan data independen dari data uji yang menghasilkan nilai konsentrasi CO dan CO₂ prediksi. Nilai konsentrasi CO dan CO₂ dibandingkan dengan nilai aktual data independen dari data latih dan RMSE yang dihasilkan yaitu $1,402122 \times 10^{-8}$ untuk CO dan $1,202121 \times 10^{-7}$ untuk CO₂. Nilai koefisien korelasi model prediksi CO yaitu 0,4712828 untuk model prediksi CO₂ yaitu 0,5647305. Perbandingan nilai aktual dan nilai prediksi awal untuk konsentrasi CO dan CO₂ juga dapat dilihat dari grafik yang dihasilkan dengan *package* *ggplot2* pada Gambar 3 dan Gambar 4.

Parameter Tuning dan Evaluasi Model

Setelah pembuatan model spasial prediksi dengan parameter *gamma* dengan nilai *default*, *parameter tuning* dilakukan dengan melihat adanya potensi peningkatan performa model. *Parameter tuning* dilakukan pada 1 parameter yaitu *gamma* pada rentang nilai 0.125 hingga 100. Model yang telah terbentuk dari beberapa nilai parameter kemudian diuji dan dievaluasi nilai RMSE dan korelasinya. Hasil performa setiap model ditunjukkan pada Tabel 3 dan Tabel 4.

Gambar 3 Grafik perbandingan nilai aktual dan nilai prediksi konsentrasi CO dengan nilai γ 0.125Gambar 4 Grafik perbandingan nilai aktual dan nilai prediksi konsentrasi CO₂ dengan nilai γ 0.125

Tabel 3 Evaluasi Model Spasial Prediksi Konsentrasi CO

Parameter	RMSE	R(Korelasi)
RBF ($\gamma = 0.125$)	$1,402122 \times 10^{-8}$	0,4712828
RBF ($\gamma = 0.25$)	$1,398119 \times 10^{-8}$	0,4758549
RBF ($\gamma = 0.5$)	$1,382254 \times 10^{-8}$	0,4852648
RBF ($\gamma = 1$)	$1,338964 \times 10^{-8}$	0,5039793
RBF ($\gamma = 2$)	$1,272662 \times 10^{-8}$	0,5319344
RBF ($\gamma = 5$)	$1,207692 \times 10^{-8}$	0,5664784
RBF ($\gamma = 10$)	$1,187537 \times 10^{-8}$	0,5827698
RBF ($\gamma = 20$)	$1,174242 \times 10^{-8}$	0,5879287
RBF ($\gamma = 50$)	$1,180169 \times 10^{-8}$	0,5651515
RBF ($\gamma = 100$)	$1,21935 \times 10^{-8}$	0,5318691

Tabel 4 Evaluasi Model Spasial Prediksi Konsentrasi CO₂

Parameter	RMSE	R
RBF ($\gamma = 0.125$)	$1,202121 \times 10^{-7}$	0,5647305
RBF ($\gamma = 0.25$)	$1,145406 \times 10^{-7}$	0,5857659
RBF ($\gamma = 0.5$)	$1,103414 \times 10^{-7}$	0,597961
RBF ($\gamma = 1$)	$1,052059 \times 10^{-7}$	0,6130552
RBF ($\gamma = 2$)	$1,013476 \times 10^{-7}$	0,6220526
RBF ($\gamma = 5$)	$9,946507 \times 10^{-8}$	0,616345
RBF ($\gamma = 10$)	$9,843717 \times 10^{-8}$	0,6058418
RBF ($\gamma = 20$)	$9,951708 \times 10^{-8}$	0,5795776
RBF ($\gamma = 50$)	$1,028983 \times 10^{-7}$	0,5357178
RBF ($\gamma = 100$)	$1,07367 \times 10^{-7}$	0,4989881

SIMPULAN

Model spasial berbasis nilai ketetangaan cukup representatif untuk memprediksi konsentrasi polutan CO atau CO₂ di suatu lokasi tertentu. Hasil model spasial prediksi CO terbaik didapatkan dengan menggunakan kernel *radial basis function* ketika parameter γ 20 yang menghasilkan RMSE sebesar $1,174242 \times 10^{-8}$ dan nilai koefisien korelasi sebesar 0,5879287. Sementara itu, hasil model spasial prediksi CO₂ terbaik didapatkan dengan menggunakan kernel *radial basis function* ketika parameter γ 10 yang menghasilkan RMSE sebesar $9,843717 \times 10^{-8}$ dan nilai koefisien korelasi sebesar 0,6058418. Pola nilai konsentrasi polutan hasil prediksi yang dibentuk telah cukup dapat mengikuti pola nilai aktualnya.

DAFTAR PUSTAKA

- [WorldBank]. World Bank Group – International Development, Poverty, and Sustainability. 2015. Krisis Kebakaran dan Asap Indonesia. [internet]. [diunduh 2017 Des 26]. Tersedia pada: <http://www.worldbank.org/in/news/feature/2015/12/01/indonesias-fire-and-haze-crisis>.
- [WRI]. World Resources Institute. 2017. Riwayat Kebakaran di Indonesia untuk Mencegah Kebakaran di Masa Depan. [internet]. [diunduh pada 2017 Des 26]. Tersedia pada: <http://www.wri-indonesia.org/id/blog/riwayat-kebakaran-di-indonesia-untuk-mencegah-kebakaran-di-masa-depan>.
- [DW]. Deutsche Welle. 2015. NASA: Kabut Asap Indonesia Terparah Dalam Sejarah. [internet]. [diunduh 2017 Des 26]. Tersedia pada: <http://www.dw.com/id/nasa-kabut-asap-indonesia-terparah-dalam-sejarah/a-18756969>
- Abri H, Tarigan M. 2015. Dampak Kabut Asap, ISPA Jangkiti 425 Ribu Jiwa di 7 Provinsi. [internet]. [diunduh 2017 Des 26]. Tersedia pada: <https://nasional.tempo.co/read/710325/dampak-kabut-asap-ispa-jangkiti-425-ribu-jiwa-di-7-provinsi>
- Achilleos, G. A. 2011. The Inverse Distance Weighted interpolation method and error propagation mechanism—creating a DEM from an analogue topographical map. *Journal of Spatial Science*, 56(2):283-304.
- Apriliantono. 2017. Pola *Trajectory* dan Konsentrasi Polutan Kabut Asap Kebakaran Gambut Sumatra Menggunakan Pendekatan *Trajectory Pattern Mining* [tesis]. Bogor (ID): Institut Pertanian Bogor.
- Cheng T, Wang, J, Li X, 2007. The support vector machine for nonlinear spatio-temporal regression. *Proc Geocomputation*.
- Han J, Kamber M, Pei J. 2011. *Data Mining Concept and Techniques*. Maltham (US): Elsevier.

- Robby IS. 2017. Model *Spatio-Temporal* untuk Prediksi Kemunculan Titik Panas pada Lahan Gambut di Kabupaten Siak Menggunakan SARIMA dan *Elman Recurrent Neural Network* [tesis]. Bogor (ID): Institut Pertanian Bogor.
- Ko CN, Lee CM. 2013. Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended Kalman filter. *Energy*. 49:413-422.
- Ramedani Z, Omid M, Keyhani A, Shamshirband S, Khoshnevisan B. 2014. Potential of radial basis function based support vector regression for global solar radiation prediction. *Renewable and Sustainable Energy Reviews*. 39:1005-1011.
- Sirimongkolertkul, N., Upayokhin, P., & Phonekeo, V. (2013). Multi-Temporal Analysis of Haze Problem in Northern Thailand: A Case Study in Chiang Rai Province. *Kasetsart Journal (Natural Science)*, 47, 768-780.
- Tyas DNS. 2018. Modul Visualisasi Kabut Asap dalam Aplikasi *Haze Trajectory Pattern Mining* [skripsi]. Bogor (ID): Institut Pertanian Bogor.
- Zeng J, Qiao W. 2013. Short-term solar power prediction using a support vector machine. *Renewable Energy*. 52:118-127.