



# Jurnal Kemaritiman: Indonesian Journal of Maritime



Alamat Jurnal: <https://ejournal.upi.edu/index.php/kemaritiman>

## Model Prediksi Pasang Surut Air Laut Pada Stasiun Pushidrosal Bakauheni Lampung Menggunakan *Support Vector Regression*

Willdan Aprizal Arifin<sup>1\*</sup>, Ishak Ariawan<sup>1</sup>, Ayang Armelita Rosalia<sup>1</sup>, Agung Setyo Sasongko<sup>2</sup>, Muhamad Renaldi Apriansyah<sup>1</sup>

<sup>1</sup>) Program Studi Sistem Informasi Kelautan, Universitas Pendidikan Indonesia, Jl. Dr. Setiabudi No.229, Isola, Kec. Sukasari, Kota Bandung, Jawa Barat 40154

<sup>2</sup>) Program Studi Pendidikan Kelautan dan Perikanan, Universitas Pendidikan Indonesia, Jl. Dr. Setiabudi No.229, Isola, Kec. Sukasari, Kota Bandung, Jawa Barat 40154

Correspondence: E-mail: [willdandarifin@upi.edu](mailto:willdandarifin@upi.edu)

### ABSTRACT

One area that has a tidal observation station in Indonesia is Bakauheni, Lampung. Tides are a phenomenon of the movement of up and down sea levels periodically at a certain time. The tides can affect the activities of the community around the coast, therefore with current technology through the field of Machine Learning, the process of predicting the height of the tides can be a solution for the smooth running of community activities carried out at sea. By utilizing tidal data recorded in real time at the pushidrosal observation station, Bakauheni-Lampung, predictive modeling can be done. The data used is recorded data collected from 2016 to 2019. The data is then divided into training data and test data to be further formed into predictive models. Prediction model formation is carried out using the Support Vector Regression algorithm with the Radial Basis Function (RBF) kernel. Based on the results of parameter tuning performed on the gamma parameter, the best value using the gamma parameter is 1000. The RMSE value generated is 0.4938244 with the correlation value is 0.9202879. Based on these results, the prediction model formed is considered quite good in predicting the tides at the Bakauheni- Lampung pushidrosal station.

© 2023 Kantor Jurnal dan Publikasi UPI

### ARTICLE INFO

#### Article History:

Submitted/Received 02 008 2021

First Revised 09 008 2021

Accepted 03 009 2021

First Available online 25 011 2021

Publication Date 01 012 2021

#### Keyword:

machine learning,

prediction,

svr,

tide

## 1. PENDAHULUAN

Desa Bakauheni merupakan sebuah kawasan yang terletak di wilayah kabupaten Lampung Selatan. Perairan Desa Bakauheni memiliki sumberdaya alam pesisir dan laut yang beraneka ragam, sehingga untuk masa yang akan datang merupakan sumber ekonomi baru bagi pertumbuhan pembangunan di Lampung Selatan (Fitriana & Aini, 2017). Desa Bakauheni merupakan pusat kegiatan perekonomian laut yang dimanfaatkan sebagai lokasi penangkapan ikan (*fishing ground*) masyarakat nelayan tradisional dan sebagai lahan budi daya seperti budi daya rumput laut, budi daya mangrove, dan budi daya udang (Fitriana & Aini, 2017). Perairan Desa Bakauheni memiliki keanekaragaman hayati laut yang tinggi yaitu potensi ekosistem mangrove, terumbu karang dan ikan karang. Hal ini didukung pula dengan kondisi perairan Desa Bakauheni yang dikelilingi oleh banyak pulau-pulau kecil, seperti Pulau Kelapa, Pulau Sindu, Pulau Kandang Lunik, dan Pulau Kandang Balak (Fitriana & Aini, 2017)

Salah satu fenomena yang selalu terjadi di laut adalah pasang surut. Pasang surut merupakan suatu fenomena pergerakan naik turun permukaan air laut secara berkala. Hal tersebut akibat adanya kombinasi gaya gravitasi dan gaya tarik-menarik benda-benda langit terutama matahari, bumi, dan bulan (Nontji, 2007). Pasang surut mempengaruhi aktivitas biologis seperti zonasi tanaman dan kegiatan makan burung, ikan, dan organisme laut yang lain serta proses yang terkait dengan perendaman dan pengeringan permukaan daratan di zona intertidal (Davidson & Arnott, 2010)

Pasang surut air laut mempunyai peranan penting terhadap suatu kegiatan yang dilakukan di laut yaitu kegiatan pelayaran, kegiatan para nelayan, serta bongkar muat kapal. Selain itu, Pasang surut juga mempunyai pengaruh terhadap pembentukan pola sirkulasi air laut ataupun pola pendistribusian material tersuspensi (Kusmanto et al., 2016)

Menurut Nikentari et al. (2018) pasang surut terjadi pada waktu tertentu atau pada waktu yang tidak sama. Sehingga hal tersebut memerlukan suatu prediksi untuk mengetahui tinggi pasang dan surut dari air laut. Dengan mengetahui tinggi pasang surut, maka dapat digunakan sebagai acuan dalam melakukan suatu kegiatan di perairan laut tersebut (Yulius et al., 2017).

Kemajuan teknologi dapat membantu melakukan prediksi tinggi pasang dan surut air laut, yaitu dengan membuat sistem prediksi secara otomatis. Salah satu bidang ilmu yang dapat membantu dalam pembuatan sistem prediksi tersebut adalah *Machine Learning* (ML). ML adalah proses komputer untuk belajar dari data (Dey, 2016). Nikentari et al. (2018) telah sukses menggunakan metode ML yaitu *backpropagation* untuk memprediksi pasang surut air laut. Pada penelitian tersebut pengujian akurasi yang digunakan adalah *Means Square Error* (MSE). MSE yang diperoleh adalah 0.0035861.

Selain *backpropagation*, ML memiliki beberapa metode atau algoritme yang dapat digunakan untuk melakukan prediksi. Salah satu metode tersebut adalah *Support Vector Regresion* (SVR). SVR merupakan bagian dari *support vector machines* (SVM) yang dikembangkan oleh Vapnik dan Chervonenkis (Smola & Scholkopf, 2004) berbasis kecerdasan buatan yang sangat populer dan merupakan metode yang memiliki keunggulan dalam optimasi sistem pengenalan pola dengan kemampuan generalisasi yang baik untuk kasus regresi (Santosa, 2007)

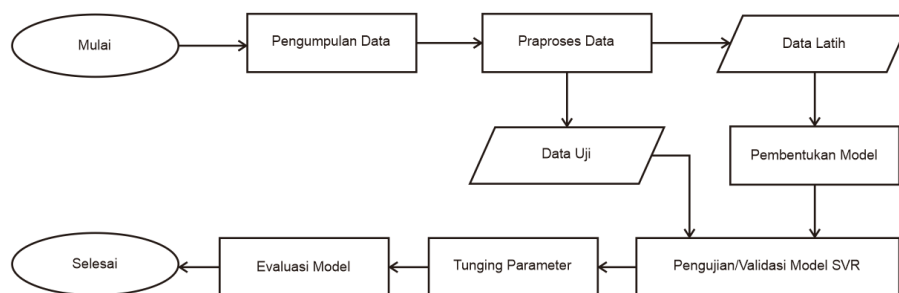
SVR telah banyak digunakan untuk memprediksi suatu objek. Metode ini telah sukses digunakan oleh Gaffar & Sitanggang (2019) untuk memprediksi produktivitas tanaman tebu di setiap pulau jawa berdasarkan faktor iklim. Hasil yang didapatkan menunjukkan bahwa kinerja SVR sangat baik dengan *Root Means Square Error* (RMSE) 0.1203954 dan *correlation*

0.9459743. Selain itu, SVR juga telah sukses digunakan oleh Arifin (2019) untuk memprediksi kualitas lulusan siswa SMP dengan pengaruh sistem zonasi. Hasil yang didapatkan menunjukkan bahwa kinerja SVR cukup baik dengan RMSE 47.90666 dan correlation 0.6719889.

Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model prediksi ketinggian pasang surut air laut di Stasiun Pushidrosal Bakauheni Lampung. Metode yang digunakan dalam penelitian ini yaitu teknik prediksi *Support Vector Regression* (SVR).

## 2. METODE PENELITIAN

Fokus penelitian ini adalah dalam pembuatan model prediksi pasang surut air laut di stasiun pengamatan pushidrosal bakauheni lampung. Terdapat beberapa tahapan yang akan dilakukan dalam penelitian ini, tahapan tersebut tergambar pada Gambar 1.



**Gambar 1 Tahapan Penelitian**

Penjelasan dari setiap tahapan adalah sebagai berikut:

### 2.1 Pengumpulan Data

Penelitian ini menggunakan data pasang surut realtime yang terdapat pada situs Pusat Hidrografi dan Oseanografi Angkatan Laut. Data dikumpulkan menjadi sebuah dataset time series yang terkumpul dari tahun 2016 sampai dengan tahun 2019. Atribut yang didapatkan pada dataset yaitu atribut time yang menunjukkan waktu pengambilan data dan atribut water\_level yang menunjukkan ketinggian air laut pada saat waktu pemantauan.

### 2.2 *Praproses* dan Pembagian Data

Tahap *praproses* data berfokus pada pemrosesan data mentah agar dapat menghasilkan data yang lebih siap untuk diproses dalam pembentukan model prediksi. Hal pertama yang perlu dilakukan adalah memeriksa nilai yang hilang pada dataset. Setelah itu dilakukan pembagian data ke dalam data uji dan data latih menggunakan metode *K-fold cross validation*. Pada *k-fold cross validation*, data akan dibagi secara random ke dalam sejumlah bagian dengan jumlah data yang relatif sama. Proses pelatihan model dilakukan pada bagian k-1 dan sisa bagian lainnya digunakan untuk pengujian. Proses itu terus diulang sebanyak kali sambil mengubah bagian data uji satu persatu sampai pengujian telah dilakukan pada seluruh bagian (Yadav & Shukla, 2016). Penelitian ini menggunakan k sebesar 10 (10-fold).

### 2.3 Pembentukan Model dan Validasi Model

Pembentukan model prediksi pasang surut air laut dilakukan menggunakan algoritme SVR dengan melatih data latih dengan library e1071 di bahasa pemrograman R. Model yang dihasilkan dari data latih kemudian divalidasi dengan data uji. Nilai pada atribut independen pada data uji digunakan sebagai masukan dalam model untuk menghasilkan nilai prediksi. Nilai prediksi tersebut nantinya akan dibandingkan dengan nilai aktual pada peubah dependen data uji. Prediksi akan dilakukan menggunakan bahasa pemrograman R dengan fungsi predict yang terdapat pada library e1071.

### 2.4 Tuning Parameter

Pemodelan prediksi tahap awal dilakukan menggunakan parameter default dari SVR yaitu parameter *Radial Basis Function* (RBF). Kemudian, tuning parameter dilakukan untuk mendapatkan nilai parameter yang paling optimal untuk membentuk model terbaik dalam memprediksi. Fokus pada proses tuning parameter yaitu pada parameter gamma pada algoritme SVR dengan menentukan beberapa nilai untuk parameter tersebut. Kemudian, model kembali diuji untuk dievaluasi setelah mendapatkan parameter yang paling optimal.

### 2.5 Evaluasi Model

Setelah melakukan pengujian, model yang dihasilkan dari beberapa skenario parameter kemudian dievaluasi dengan melihat *root mean squared error* (RMSE) dan nilai koefisien korelasi (R) pada nilai actual dan nilai prediksi. Fungsi rmse pada *library Metrics* yang ada pada R digunakan untuk melakukan perhitungan RMSE dan fungsi cor pada *library EnvStats* di R digunakan untuk melakukan perhitungan nilai korelasi. Nilai RMSE dapat dihitung dengan persamaan 1 (Chai & Draxler, 2014). Nilai koefisien korelasi dari model dapat dihitung dengan persamaan 2 (Mendenhall et al., 2012)

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

dengan:

- $n$  : jumlah data yang diprediksi
- $i$  : urutan data
- $e$  : galat antara nilai aktual dan prediksi

$$R = \frac{S_{xy}}{S_x S_y} \quad (2)$$

dengan:

- $S_{xy}$  : kovarian antara nilai aktual dan prediksi
- $S_x$  : standar deviasi nilai aktual
- $S_y$  : standar deviasi nilai prediksi

### 3. HASIL DAN PEMBAHASAN


#### 3.1 Pengumpulan Data dan Praproses Data

Dataset dikumpulkan berdasarkan data time series pasang surut air laut yang direkam secara realtime dari tanggal 4 Februari 2016 sampai dengan 10 Juni 2019 di stasiun pemantauan PUSHIDROSAL Bakauheni, Lampung. Data yang terkumpul adalah sebanyak 25.246 baris data.

Setelah dataset terkumpul, yang dilakukan selanjutnya adalah membagi data menjadi dua kelompok data, yakni data latih dan data uji. Metode yang digunakan untuk membagi data adalah menggunakan k-fold cross validation dengan iterasi sebanyak 10 fold. Hasil keseluruhan data yang terbagi adalah sebanyak 2.525 untuk data uji dan 22.720 untuk data latih.

#### 3.2 Pembentukan Model dan Validasi Model

Model dibentuk menggunakan algoritme SVR dengan RBF sebagai kernelnya yang terdapat pada library `e1071` di R. RBF dipilih sebagai kernel dikarenakan kernel tersebut dapat menghasilkan nilai prediksi yang akurat daripada hasil prediksi menggunakan kernel yang lain (Bermolen & Rossi, 2008). Awal dari pembentukan model ini adalah melakukan pelatihan pada data latih dengan pengaturan SVR secara default, yaitu dengan nilai gamma 0.125. Setelah melalui proses pelatihan, model tersebut diuji dengan menggunakan data dependen dari data uji yang menghasilkan nilai pasang surut air laut. Nilai pasang surut air laut kemudian dibandingkan dengan nilai aktual data dependen dari data uji. Nilai RMSE yang dihasilkan adalah 1.009267 dan nilai koefisien korelasi yang dihasilkan adalah 0.6927282. Perbandingan nilai aktual dan nilai prediksi awal untuk ketinggian pasang surut air laut dapat dilihat pada grafik yang dihasilkan pada library `ggplot2` pada Gambar 2.



Gambar 2 Grafik perbandingan nilai aktual dan nilai prediksi pasang surut air laut pada stasiun pushidrosal dengan paramter default

Grafik yang ditunjukkan pada Gambar 2 menunjukkan bahwa hasil nilai prediksi banyak memiliki perbedaan dengan nilai aktual. Berdasarkan data yang disajikan, hasil menunjukkan bahwa model terlihat belum mampu untuk memprediksi nilai pasang surut air laut secara akurat, hal tersebut terlihat pada data yang disajikan bahwa tidak semua nilai pada data prediksi dapat mengikuti pola dari data nilai aktual.


### 3.3 Tuning Parameter dan Evaluasi Model

Tuning parameter dilakukan setelah dilakukannya pembentukan model prediksi menggunakan kernel RBF dengan nilai default pada parameter gamma untuk melihat adanya potensi peningkatan akurasi terhadap model dalam memprediksi. Tuning parameter dilakukan pada parameter gamma. Parameter gamma yang diujikan dilakukan pada rentang nilai 0.1 hingga 1000. Setiap model yang terbentuk dari setiap parameter kemudian diuji dan dievaluasi nilai RMSE dan korelasinya. Hasil performa setiap model ditunjukkan pada Tabel 1.

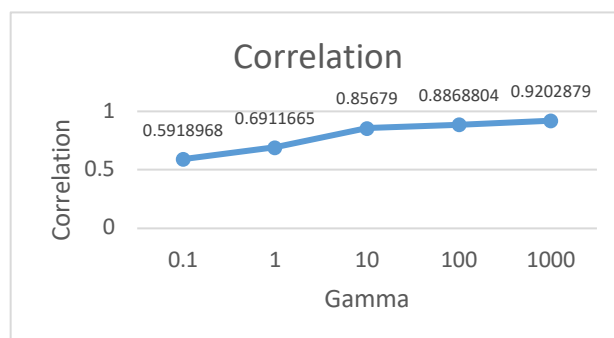
Tabel 1 Evaluasi model dengan beberapa nilai gamma yang berbeda

Percobaan ke-	Gamma	Kernel RBF	
		RMSE	Correlation
1	0.1	1.127705	0.5918968
2	1	1.014931	0.6911665
3	10	0.7004272	0.85679
4	100	0.6210832	0.8868804
5	1000	0.4938244	0.9202879

Hasil tuning parameter dan evaluasi model untuk pasang surut air laut dapat menghasilkan grafik ukuran terbaik model dilihat dari RMSE dan nilai koefisien korelasinya. Grafik evaluasi nilai koefisien korelasi dapat terlihat pada Gambar 4 sedangkan grafik evaluasi nilai RMSE dapat terlihat pada Gambar 3.

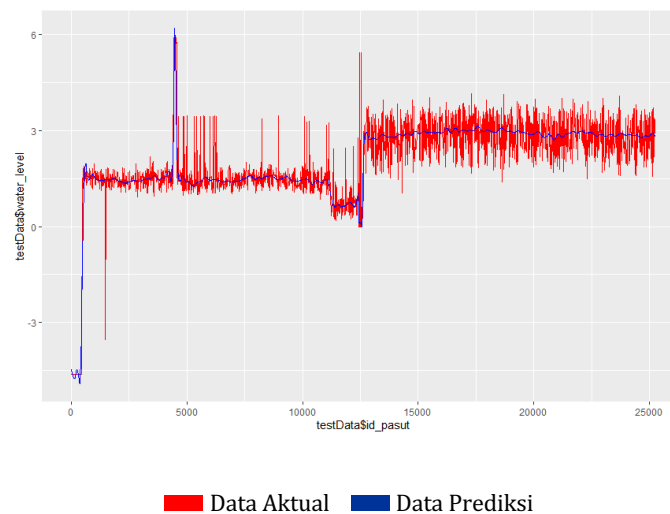


Gambar 3 Grafik nilai RMSE hasil evaluasi model prediksi pasang surut air laut pada stasiun pushidrosal



Gambar 4 Grafik nilai korelasi hasil evaluasi model prediksi pasang surut air laut pada stasiun pushidrosal

Dari beberapa percobaan yang dilakukan, model prediksi pasang surut air laut pada stasiun pushidrosal terbaik dihasilkan dengan menggunakan parameter gamma 1000. Nilai RMSE terbaik yang diperoleh adalah 0.4938244 dan nilai korelasi terbaik yang diperoleh adalah 0.9202879. Berdasarkan nilai RMSE dan korelasi terbaik yang dihasilkan, nilai tersebut menandakan bahwa model prediksi yang dibuat sudah cukup baik dalam memprediksi pasang surut air laut. Terlihat pada grafik pada gambar 5 yang dihasilkan oleh library ggplot2 pada bahasa pemrograman R tentang perbandingan nilai aktual dan nilai prediksi ketinggian pasang surut air laut pada stasiun pushidrosal dengan menggunakan nilai gamma 1000, grafik menunjukkan bahwa nilai prediksi terlihat hampir dapat mengikuti pola dari nilai aktual yang artinya model sudah dianggap cukup baik dalam memprediksi pasang surut air laut pada stasiun pushidrosal.



Gambar 5 Grafik perbandingan nilai aktual dan nilai prediksi pasang surut air laut pada stasiun pushidrosal dengan nilai gamma 100

Dengan demikian model prediksi yang dihasilkan dapat dimanfaatkan untuk melakukan praramalan atau prediksi terhadap ketinggian pasang surut air laut di Stasiun Pushidrosal Bakauheni Lampung di waktu yang akan datang.

#### 4. KESIMPULAN

Model prediksi berhasil dibentuk dengan hasil yang cukup baik. Hasil terbaik yang dihasilkan dari tuning parameter yang dilakukan adalah dengan parameter gamma sebesar 1000 yang menghasilkan RMSE sebesar 0.4938244 dan korelasi sebesar 0.9202879, sehingga model tersebut dianggap cukup baik dalam melakukan prediksi pasang surut air laut pada stasiun pushidrosal Bakauheni Lampung.

#### 5. DAFTAR PUSTAKA

- Arifin, W. A. (2019). *MODEL PREDIKSI KUALITAS LULUSAN SISWA SMP DENGAN PENGARUH SISTEM ZONASI MENGGUNAKAN SUPPORT VECTOR REGRESSION* [Institut Pertanian Bogor]. <https://doi.org/10.1145/2768566.2768568>
- Bermolen, P., & Rossi, D. (2008). Support Vector Regression for Link Load Prediction. *2008 4th International Telecommunication Networking Workshop on QoS in Multiservice IP Networks*, 53(2), 268–273. <https://doi.org/10.1016/j.comnet.2008.09.018>

- Chai, T., & Draxler, R. R. (2014). Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? -Arguments Against Avoiding RMSE in The Literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Davidson, R., & Arnott. (2010). *Introduction to Coastal Processes and Geomorphology*. Cambridge University Press.
- Dey, A. (2016). Machine Learning Algorithms: A Review. *International Journal of Computer Science and Information Technologies*, 7(3), 1174–1179. [www.ijcsit.com](http://www.ijcsit.com)
- Fitriana, I., & Aini, L. N. (2017). *Penataan kawasan pesisir pantai desa bakauheni sebagai kawasan ekowisata. 2014*.
- Gaffar, A. W. M., & Sitanggang, I. S. (2019). Spatial model for predicting sugarcane crop productivity using support vector regression. *IOP Conference Series: Earth and Environmental Science*, 335(1). <https://doi.org/10.1088/1755-1315/335/1/012009>
- Kusmanto, E., Hasanudin, M., & Setyawan, W. B. (2016). Amplifikasi Pasang Surut dan Dampaknya terhadap Perairan Pesisir Probolinggo. *Oseanologi Dan Limnologi Di Indonesia*, 1(3), 69–80.
- Mendenhall, W., Beaver, R. J., & Beaver, B. M. (2012). *Introduction to Probability and Statistics*. Cengage Learning.
- Nikentari, N., Ritha, N., & Haryadi, T. (2018). Prediksi Pasang Surut Air Laut Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Jurnal Sustainable: Jurnal Hasil Penelitian Dan Industri Terapan*, 7(1), 1–6. <https://doi.org/10.31629/sustainable.v7i1.443>
- Nontji, D. A. (2007). *Laut Nusantara*. Djambatan.
- Santosa, B. (2007). *Data Mining : Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Graha Ilmu.
- Smola, A. J., & Scholkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14, 199–222. [http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=1CAD92EF8CCE726A305D8A41F873EEFC?doi=10.1.1.114.4288&rep=rep1&type=pdf%0Ahttp://download.springer.com/static/pdf/493/art%3A10.1023%2FB%3ASTCO.0000035301.49549.88.pdf?auth66=1408162706\\_8a28764ed0fae9](http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=1CAD92EF8CCE726A305D8A41F873EEFC?doi=10.1.1.114.4288&rep=rep1&type=pdf%0Ahttp://download.springer.com/static/pdf/493/art%3A10.1023%2FB%3ASTCO.0000035301.49549.88.pdf?auth66=1408162706_8a28764ed0fae9)
- Yadav, S., & Shukla, S. (2016). Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification. *Proceedings - 6th International Advanced Computing Conference, IACC 2016, Cv*, 78–83. <https://doi.org/10.1109/IACC.2016.25>
- Yulius, Heriati, A., Mustikasari, E., & Zahara, R. I. (2017). KARAKTERISTIK PASANG SURUT DAN GELOMBANG DI PERAIRAN TELUK SALEH, NUSA TENGGARA BARAT. 13(1), 65–73.