

Implementasi *Support Vector Machine* dalam Memprediksi Harga Rumah pada Perumahan di Kota Bandar Lampung

¹Favorisen Rosyking Lumbanraja, ²Reza Aji Saputra, ³Kurnia Muludi, ⁴Astria Hijriani dan ⁵Akmal Junaidi.

^{1,2,3,4,5}Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, Jl. Prof. Dr. Ir. Sumantri Brojonegoro, RW.No: 1, Gedong Meneng, Kec. Rajabasa, Kota Bandar Lampung, Lampung, Indonesia
e-mail: ¹favorisen.lumbanraja@fmipa.unila.ac.id, ²rezaajis27@gmail.com, ³kmuludi@yahoo.com,
⁴astria.hijriani@gmail.com, ⁵Akmal.junaidi@fmipa.unila.ac.id.

Abstract- *Machine Learning has been widely used in terms of predictions for analyzing datasets. One method of Machine Learning is Support Vector Machine (SVM). The house has an important role in the survival of human beings. With the times, many developers are competing to build housing. The purpose of this study is to predicted the housing cost using Support Vector Machine. The data in this research used the data of house in Bandar lampung, the price, the location and the building specification. The amount of data used 51 datas and 33 variables with regression and classification, also used 3 kernels and it's model, 12 times first trial and next 6 experiments done with fitur selection. The trial result was kernel regression polynomial model reached the highest R^2 that was 95,99% linear kernel and gaussian kernel reached R^2 90,99% and 81,43% each. While in accuration classification model trial is obtained in 8 class of gaussian kernel as big as 91,18%, and linear kernel and polinimonal kernel get an accuracy of 90,20% and 89,90%.*

Keywords: *Classification; Machine Learning; Regression; Support Vector Machine.*

1. PENDAHULUAN

Rumah adalah salah satu komponen kehidupan yang penting karena dapat memberikan perlindungan, keamanan dan kehangatan, serta sebagai tempat untuk beristirahat [1]. Rumah dapat didefinisikan sebagai sebuah bangunan atau tempat untuk berlindung dari cuaca dan binatang buas, tempat untuk berkumpul, tempat untuk melepas lelah dan penat setelah beraktivitas di luar, dan sebagai tempat berlangsungnya aktivitas keluarga. Rumah dijadikan sebagai simbol pencapaian, penerimaan sosial, dan indikator pertumbuhan jumlah penduduk di perkotaan [2].

Seiring dengan meningkatnya pertumbuhan jumlah penduduk, permintaan konsumen terhadap perumahan pun semakin bertambah [3]. Fakta tersebut dimanfaatkan oleh para pelaku bisnis yang bergerak dalam bidang pengembangan perumahan. Banyak perusahaan pengembang perumahan yang bersaing dalam memberikan fasilitas dan pelayanan menarik kepada konsumen. Hal tersebut dapat dilihat dari banyaknya perumahan dengan berbagai tipe dan fasilitas yang dibangun di sejumlah wilayah di Indonesia, salah satunya di Kota Bandar Lampung.

Forecasting (peramalan) merupakan cara untuk meramalkan kejadian masa depan berdasarkan data masa lalu yang diukur secara *periodic* dan akan membentuk suatu rangkai waktu data atau yang biasa disebut dengan *Time Series*. Rangkai waktu merupakan suatu pengamatan terhadap variabel tunggal yang diukur secara teratur selama periode waktu tertentu. Alasan mengapa melakukan analisis rangkai waktu adalah untuk meramalkan atau memprediksi nilai masa depan. *Forecasting* berdasarkan jangka waktunya dapat dibagi menjadi tiga, yaitu : jangka pendek (*short term*) merupakan jangka pendek meliputi kurun waktu mulai dari satu hari sampai satu musim atau dapat sampai satu tahun, jangka menengah (*medium term*) jangka menengah meliputi kurun waktu dari satu musim sampai dua tahun dan jangka panjang (*long term*) jangka panjang meliputi peramalan untuk kurun waktu minimal lima tahun [4].

Dengan mengetahui model rangkai waktu masa lalu dapat meramalkan nilai masa depan, apakah akan naik atau turun [5]. Pemilihan perumahan yang tepat untuk masa yang akan datang sangat penting, karena berkaitan dengan perlindungan, keamanan dan kenyamanan pemilik perumahan tersebut. Jika pemilihan perumahan tersebut tidak di pertimbangkan secara matang maka keamanan dan kenyamanan perumahan di masa depan tidak bisa terjamin.

Salah satu metode yang dapat digunakan dalam proses prediksi adalah *Support Vector Machine*. Metode ini merupakan teknik berbasis *Machine Learning* yang masih jarang digunakan untuk melakukan proses prediksi, baik digunakan dalam kasus klasifikasi maupun regresi, dan sangat populer belakangan ini. *Support Vector Machine* merupakan satu dari sekian banyak metode yang dapat digunakan untuk menyelesaikan berbagai macam permasalahan diantaranya ialah masalah prediksi. Dalam menyelesaikan sebuah permasalahan, *Support Vector Machine* mampu menangani permasalahan *linear* dan *non-linear* dengan adanya fungsi kernel yang membuat metode ini dapat digunakan untuk peramalan *time series* [6].

Penelitian sebelumnya pernah dilakukan oleh Aprilarita tahun 2018 dalam penelitiannya yang berjudul “Sistem Pendukung Keputusan Pemilihan Rumah Di Wilayah Bandar Lampung Dengan Metode *Simple Additive Weighting* (SAW) Berbasis Android” dalam penelitiannya penulis mengembangkan sebuah aplikasi *mobile* berbasis android yang berguna untuk melakukan proses pemilihan rumah secara tepat dengan menggunakan metode SAW. Penulis menggunakan lima belas kriteria atau variabel untuk penelitiannya yaitu : nama rumah, harga, luas bangunan, luas tanah, kamar tidur, kamar mandi, lantai, spesifikasi bangunan, jarak, air, listrik, latitude, longitude, lokasi, *contact person* [7].

Pada penelitian kali ini menggunakan metode *Support Vector Machine* dengan dua model yaitu model regresi dan klasifikasi pada sistem prediksinya untuk memprediksi harga perumahan di Kota Bandar Lampung.

2. METODOLOGI PENELITIAN

2.1. *Machine Learning*

Machine Learning adalah metode yang digunakan untuk membuat program yang bisa belajar dari data. Berbeda dengan program komputer biasa yang statis, program *Machine Learning* adalah program yang dirancang untuk mampu belajar sendiri [8].

A. *Supervised Learning*

Supervised learning merupakan suatu teknik pembelajaran dengan membuat suatu fungsi tertentu dari data latihan. Data latihan terdiri dari pasangan nilai input, dan output. Tugas utama dari *Supervised Learning* adalah memprediksi nilai fungsi untuk semua nilai input yang telah melalui proses pelatihan.

Contoh algoritma *Supervised Learning* :

1. *Logistic Regression*
2. *K-nearest Neighbors*
3. *Naive Bayes*
4. *Decision Tree*
5. *Support Vector Machine*

B. *Unsupervised Learning*

Data tidak diberikan label, tapi secara otomatis dibagi berdasarkan kemiripan dan struktur lain dari data tersebut. Misalnya, ketika kita mengorganisasikan foto. Kita harus melakukan *tagging* secara manual.

Contoh – contoh algoritma *Unsupervised Learning* :

1. *K-Means*
2. *Clustering*
3. *DBSCAN*
4. *Fuzzy C-Means*
5. *Self-Organizing Map*

2.2. *Support Vector Machine*

SVM (*Support Vector Machine*) memiliki kemampuan untuk mengatasi masalah yang bersifat *linear* dan *nonlinear*. Pendekatan kernel yang dikembangkan pada SVM juga dapat digunakan untuk mengatasi jumlah kelas yang beragam dan banyak, SVM untuk prediksi disebut dengan SVM *regression* terdiri dari fungsi *linear* dan *nonlinear*. Metode SVM *regression* disebut sebagai suatu teknik *non parametric* karena bergantung pada fungsi kernel [8].

Konsep SVM dapat dijabarkan sebagai suatu cara atau metode untuk mencari *hyperplane* terbaik yang berfungsi sebagai pemisah antara dua buah *class* pada *input space*. Konsep tersebut memiliki prinsip *Structural Risk Minimization* atau yang biasa disebut dengan SRM, dengan tujuan menemukan *hyperplane* terbaik yang dapat memisahkan data ke dalam dua buah kelas [9].

2.3. *K-fold Cross Validation*

K-fold Cross Validation merupakan suatu metode yang biasa digunakan untuk melakukan evaluasi kinerja *classifier*, metode ini dapat digunakan apabila memiliki jumlah data yang sedikit. *k-fold cross validation* juga biasanya digunakan untuk mengetahui rata-rata keberhasilan dari suatu sistem dengan cara melakukan subuah pengulangan dengan cara mengacak atribut masukan sehingga sistem tersebut teruji untuk beberapa atribut input yang acak yang baru [10].

3. METODELOGI

3.1. Data

Data yang di gunakan pada penelitian ini adalah data perumahan di kota Bandar Lampung data yang digunakan tahun 2017 dan 2018, data tersebut di peroleh dari penelitian sebelumnya yaitu penelitian yang dilakukan oleh Aprilarita (2017) yang berjudul “Sistem Pendukung Keputusan Pemilihan rumah Di Wilayah Bandar Lampung Dengan Metode SAW Berbasis Android” serta data yang di peroleh dari agen property perumahan Bandar Lampung [7].

3.2. Fitur Dalam Data

1. Nama Perumahan adalah nama yang diberikan oleh pemilik developer perumahannya sehingga tiap nama perumahan berbeda-beda dan memiliki artinya masing-masing.
2. Harga Perumahan adalah harga yang telah di tetapkan oleh developer perumahan tersebut dan harga perumahan dilihat dari beberapa segi contohnya dilihat dari : luas bangunan, luas tanah, kamar tidur, kamar mandi, spesifikasi bangunan menggunakan satuan (Rp/100 juta).
3. Jarak lokasi antara perumahan dan universitas atau pusat perbelanjaan yang terdekat dari perumahan menggunakan satuan (KM²).
4. Air tiap perumahan memiliki pengaliran air yang berbeda beda contoh PAM, WTP, dan Sumur Bor.

5. Listrik adalah sumber penting untuk penerangan di perumahan, tiap perumahan memiliki arus listrik yang berbeda beda sesuai dengan ukuran perumahannya semakin besar perumahannya semakin membutuhkan arus listrik yang besar menggunakan satuan (Watt).
6. *Latitude* dan *longitude* adalah suatu sistem koordinat geografis yang digunakan untuk menentukan lokasi suatu tempat di permukaan bumi, data ini diperoleh dari google maps.
7. Lokasi adalah merupakan alamat dari perumahan tersebut.

3.3. Alat

Dalam penelitian ini peneliti menggunakan Software dan Hardware sebagai berikut :

1. Software

Sistem operasi Windows 10 Profesional, R studio versi 3.5.1, *Package* caret versi 6.0-81, *Package* kernlab versi 0.9-27 dan R versi 3.5.1.

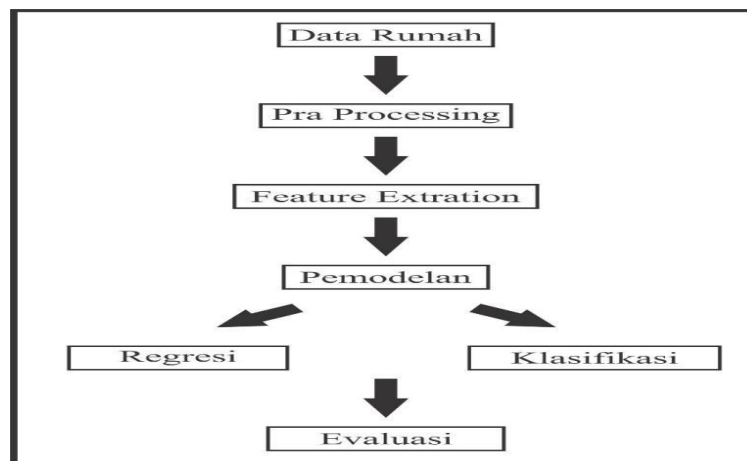
2. Hardware

Prosesor AMD® Bristol Ridge A12-9700P (2.7 GHz), 4 Threads, 4 Cores, 2 MB Smart Cache, AMD Radeon™ R8 M435DX, DDR4, RAM 8 GB, HDD 1 TB.

3.4. Tahap Penelitian

Penelitian ini menggunakan metode SVM (*Support Vector Machine*), untuk pemodelan nya dilakukan menggunakan 2 model yaitu : regresi, dan klasifikasi, dan selanjutnya menggunakan 3 kernel yaitu : Linear, Gaussian, dan Polynomial.

Pada Gambar 1 menampilkan bagaimana cara untuk melakukan prediksi dengan menggunakan metode SVM.



Gambar 1. Proses penelitian prediksi dengan model SVM.

Berikut adalah penjelasan pada tahap proses penelitian dengan model SVM :

3.4.1. Data Rumah

Pada tahap ini dilakukan proses pengumpulan data yang akan digunakan dalam pembuatan sistem prediksi harga perumahan. Data yang digunakan adalah data penelitian sebelumnya yang dilakukan oleh Aprilarita yang berjudul “Sistem Pendukung Keputusan Pemilihan Rumah Di Wilayah Bandar Lampung Dengan Metode

Simple Additive Weighting (SAW) Berbasis Android” serta data dari agen properti perumahan Bandar Lampung.

3.4.2. *Pra Processing*

Pada tahap ini mulai dilakukan merubah variable kategorik menjadi numerik. Hal yang terlebih dahulu dilakukan yaitu dengan menentukan variable kategorik yang akan di rubah menjadi numerik. Pada tahap ini juga dilakukan penghapusan data yang tidak terpakai untuk proses prediksi. Variabel yang tidak terpakai yaitu *latitude*, *langitude*, dan tahun.

3.4.3. *Feature Extraction*

Pada tahap ini atribut kategorik yang sudah dirubah menjadi numerik pada tahap proses *pra processing* akan dirubah menjadi data yang berformat *Comma Separated Values (CSV)*.

Kategorik : air, lokasi, plafond, pondasi, dinding, kerangka atap, lantai.

Numerik : harga, luas bangunan, luas tanah, kamar tidur, kamar mandi, lantai tingkat, jarak, listrik, latitude, longitude.

3.4.4. *Pemodelan*

Pada tahap ini menggunakan metode Support vector Machine dan menggunakan 3 kernel :

1. Kernel *Linear*

Kernel *Linear* merupakan fungsi kernel paling sederhana [11]. Kernel ini sering digunakan pada data set yang sebaran datanya dapat diklasifikasikan dengan cara linear. Fungsi kernel SVM Linear dapat dilihat pada persamaan 1.

$$K(x_i, x_j) = x_i \cdot x_j \quad (1)$$

Dengan x_i dan x_j merupakan vektor dari data set.

2. Kernel *Gaussian*

Kernel SVM Gaussian merupakan kernel pada SVM yang digunakan untuk menyelesaikan masalah yang tidak bisa diselesaikan dengan cara Linear [11]. Fungsi kernel SVM Gaussian dapat dilihat pada persamaan 2.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2)$$

Dengan x_i dan x_j merupakan vektor dari data set, γ adalah parameter untuk mengontrol kecepatan proses learning dan \exp merupakan basis dari logaritma alami.

3. Kernel *Polinomial*

Persamaan Polynomial merupakan sebuah persamaan yang terdiri dari variabel dan koefisien yang memiliki suku banyak[11]. Kernel SVM Polynomial sering digunakan dalam masalah dimana semua training data-nya dinormalisasi. Fungsi kernel SVM Polynomial dapat dilihat pada persamaan 3.

$$K(x_i, x_j) = (x_i \cdot x_j + r)^d \quad (3)$$

Dengan x_i dan x_j merupakan vektor dari data set, r adalah parameter untuk mengontrol kecepatan proses learning dan d merupakan pangkat polynomial yang digunakan.

3.4.5. Evaluasi

Tahap ini dilakukan evaluasi menggunakan metode *K-Fold Cross Validation* yaitu menggunakan *10 Fold Cross Validation* dengan parameter :

1. Regresi

a. *Sum Of Squares Error* (SSE)

Sum Of Squares Error (SSE) adalah mengukur kesalahan penggunaan estimasi persamaan regresi untuk menghitung nilai variabel terikat dari sampel. Fungsi dari SSE dapat dilihat pada persamaan 4.

$$SSE = \sum (Y_i - \hat{Y}_i)^2 \quad (4)$$

Dengan Y_i merupakan data aktual dan \hat{Y}_i merupakan data hasil prediksi.

b. Total *Sum Of Squares* (TSS)

Total *Sum Of Squares* (TSS) adalah menggunakan nilai rata-rata (mean) hasil penjualan kuartalan dari sampel. Fungsi dari TSS dapat dilihat pada persamaan 5.

$$SST = \sum (Y_i - \bar{Y})^2 \quad (5)$$

Dengan Y_i merupakan data aktual dan \bar{Y} merupakan data testing.

c. *R-Squared* (R^2)

R-Squared (R^2) adalah fungsi untuk mengukur tingkat keberhasilan model regresi yang kita gunakan dalam memprediksi nilai. R^2 dengan nilai mendekati 1 berarti data yang cukup bermacam-macam sudah di tangani dengan baik oleh model regresi dan jika 0 maka sebaliknya. Fungsi dari *R-Squared* dapat dilihat pada persamaan 6.

$$R^2 = 1 - SSE/SST \quad (6)$$

2. Klasifikasi

Evaluasi Matriks atau *Confusion Matrix* merupakan metode untuk penilaian dengan menggunakan matriks digunakan untuk model klasifikasi [12]. Dengan penjelasan *confusion matrix* pada Tabel 1.

Tabel 1. Klasifikasi pada *confusion matrix*

		Aktual kelas	
		Positif	Negatif
Prediksi kelas	Positif	<i>True Positive</i> (TP)	<i>False Positive</i> (FP)
	Negatif	<i>False Negative</i> (FN)	<i>True Negative</i> (TN)

Keterangan :

True Positive : Jika hasil prediksi negatif dan data sebenarnya negatif.

False Positive : Jika hasil prediksi positif sedangkan nilai sebenarnya negatif.

True Negative : Jika hasil prediksi negatif sedangkan nilai sebenarnya positif.

False Negative : Jika hasil prediksi positif dan nilai sebenarnya positif.

Berikut ini merupakan macam-macam dari evaluasi matrik:

a. *Recall*

Recall adalah proporsi jumlah dokumen yang dapat berhasil di temukan kembali oleh sebuah pencarian dalam sistem temu kembali. Sedangkan nilai dari *recall* atau *sensitivity* merupakan proporsi jumlah kasus positif yang sebenarnya yang diprediksi positif secara benar. Untuk menghitung nilai *recall* digunakan rumus sebagai berikut :

$$Recall = \frac{TP}{TP+FN} \times 100 \% \quad (7)$$

b. *Precision*

Precision merupakan jumlah kelompok dokumen yang relevan dari total jumlah dokumen yang ditemukan oleh system. Nilai *precision* atau dikenal juga dengan nama *confidence* merupakan proporsi jumlah kasus yang diprediksi positif yang juga positif benar pada data yang sebenarnya. *Precision* dapat diartikan sebagai kepersisan atau kecocokan (antara permintaan informasi dengan jawaban terhadap permintaan itu). Seberapa persis atau cocok data tersebut untuk keperluan prediksi, bergantung pada seberapa relevan data tersebut. Untuk menghitung nilai *Precision* digunakan rumus sebagai berikut :

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (8)$$

c. *Accuracy*

Accuracy merupakan persentase jumlah record data yang diklasifikasikan secara benar oleh sebuah algoritma dapat membuat klasifikasi setelah dilakukan pengujian pada hasil klasifikasi tersebut. Untuk menghitung nilai *Accuracy* digunakan rumus sebagai berikut :

$$Accuracy = \frac{TP+TN}{TP+FN+TN+FP} \times 100\% \quad (9)$$

d. *Specificity*

Specificity adalah Tingkat negatif yang sebenarnya adalah proporsi individu dengan kondisi negatif yang diketahui untuk mana tes hasilnya negatif. Angka ini sering disebut kekhususan. Untuk menghitung nilai *Specificity* digunakan rumus sebagai berikut :

$$Specificity = \frac{TN}{TN+FP} \times 100\% \quad (10)$$

e. *F1-Score*

F1-Score adalah ukuran akurasi tes. Jumlah hasil positif yang benar dibagi dengan jumlah semua hasil positif yang dikembalikan oleh pengklasifikasi, dan r adalah jumlah hasil positif yang benar dibagi dengan jumlah semua sampel yang relevan (semua sampel yang seharusnya diidentifikasi sebagai positif). *F1-Score* adalah rata - rata dari *Precision* dan *Recall*, di mana *F1-Score* mencapai nilai terbaiknya pada 1 dan terburuk pada 0. Untuk menghitung nilai *F1-Score* digunakan rumus sebagai berikut :

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (11)$$

4. PEMBAHASAN

Penelitian ini menggunakan 2 model yaitu model regresi dan klasifikasi. Percobaan ini menggunakan 3 kernel Linear, Gaussian dan Polynomial. Pada model regresi dilakukan 9 kali percobaan dengan kernel Linear 3 kali

percobaan, Gaussian 3 kali percobaan, dan Polynomial 3 kali percobaan. Dengan percobaan penghapusan variabel sebanyak 2 kali, penghapusan variabel latitude, dan longitude, serta penghapusan variabel tahun. Pada model klasifikasi dibagi menjadi 3 percobaan yaitu dengan data 2 kelas, 4 kelas, dan 8 kelas pada tiap kernelnya.

Pada percobaan pertama menggunakan data asli dengan kernel linear, polynomial, dan Gaussian data yang digunakan sebanyak 51 dengan 33 variabel yaitu : nama rumah, harga, luas bangunan, luas tanah, kamar tidur, kamar mandi, lantai tingkat, jarak, air1, air2, air3, listrik, latitude, longitude, lokasi 1-6, plafond 1-3, pondasi 1-4, dinding, kerangka atap, lantai 1-2, dan tahun. Dengan data tersebut didapatkan R² sebesar 86,60% untuk kernel Linear, 95,99% untuk kernel Polynomial dan 61,42% untuk kernel Gaussian.

Pada percobaan kedua tanpa menggunakan variabel latitude dan longitude dengan kernel linear, Gaussian, dan Polynomial data yang digunakan sebanyak 51 dengan 31 variabel yaitu : nama rumah, harga, luas bangunan, luas tanah, kamar tidur, kamar mandi, lantai tingkat, jarak, air1, air2, air3, listrik, lokasi 1-6, plafond 1-3, pondasi 1-4, dinding, kerangka atap, lantai 1-2, dan tahun. Dengan data tersebut didapatkan R² sebesar 90,99% untuk kernel Linear, 81,43% untuk kernel Gaussian, dan 92,56% untuk kernel Polynomial.

Pada percobaan ketiga tanpa menggunakan variabel tahun dengan kernel linear, polynomial dan Gaussian data yang digunakan sebanyak 51 dengan 32 variabel yaitu : nama rumah, harga, luas bangunan, luas tanah, kamar tidur, kamar mandi, lantai tingkat, jarak, air1, air2, air3, listrik, latitude, longitude, lokasi 1-6, plafond 1-3, pondasi 1-4, dinding, kerangka atap, dan lantai 1-2. Dengan data tersebut didapatkan R² sebesar 88,58% untuk kernel Linear, 92,52% untuk kernel polynomial dan 70,97% untuk kernel Gaussian.

Pada percobaan klasifikasi menggunakan data 2 kelas, 4 kelas, dan 8 kelas dengan kernel linear, Gaussian, dan Polynomial data yang digunakan sebanyak 51 dengan 34 variabel yaitu : nama rumah, harga, class, luas bangunan, luas tanah, kamar tidur, kamar mandi, lantai tingkat, jarak, air1, air2, air3, listrik, latitude, longitude, lokasi 1-6, plafond 1-3, pondasi 1-4, dinding, kerangka atap, lantai 1-2, dan tahun. Dengan data tersebut didapatkan akurasi sebesar 80% 2 kelas, 85,30% 4 kelas, dan 90,20% 8 kelas untuk kernel Linear, 80,50% 2 kelas, 80,64% 4 kelas, 91,18% 8 kelas untuk kernel Gaussian, dan 75,33% 2 kelas, 75,46% 4 kelas, 89,90% 8 kelas untuk kernel Polynomial.

5. KESIMPULAN

Percobaan model regresi tanpa melakukan penghapusan variabel didapatkan tingkat R² sebesar 86,60% untuk kernel Linear, 95,99% untuk kernel polynomial, dan 61,42% untuk kernel Gaussian. Untuk percobaan tanpa variabel latitude dan longitude. R² sebesar 90,99% untuk kernel Linear, 81,43% untuk kernel Gaussian dan 92,56% untuk kernel Polynomial. Untuk Percobaan tanpa variabel tahun R² sebesar 88,58% untuk kernel Linear, 92,52%, dan 70,97% untuk kernel Gaussian. Percobaan model klasifikasi menggunakan data 2 kelas, 4 kelas, dan 8 kelas didapatkan akurasi sebesar 80% 2 kelas, 85,3% 4 kelas, dan 90,2% 8 kelas untuk kernel Linear, 80,5% 2 kelas, 80,64% 4 kelas, 91,18% 8 kelas untuk kernel Gaussian, dan 75,33% 2 kelas, 75,46% 4 kelas, 89,9% 8 kelas untuk kernel Polynomial.

DAFTAR PUSTAKA

- [1] I. Henilane, "Housing Concept and Analysis of Housing Classification." *Baltic Journal of Real Estate Economics and Construction Management*, Riga Technical University, 13(2) : 415-425. 2016.
- [2] A. A. Bujang, H. A. Zarin, & N. Jumadi, "The Relationship Between Demographic Factors and Housing Affordability." *Malaysian Journal of Real Estate*, Universiti Teknologi Malaysia, 9, hal 2491-2521, 2010.
- [3] C. H. Mulder, "Key Note Presentation The Relationship Between Population and Housing." Department of Geography, Planning and International Development Studies, University of Amsterdam, Vol. 3 (2), Hal. 101-114. 2006.

- [4] E. Setyawan, R. Subantoro, & R. Prabowo, "Analisis peramalan." *Jurnal Ilmu-Ilmu Pertanian*, Universitas Wahid Hasyim Semarang, Vol. 1, No. 1 ISSN : 2301-928X. 2016.
- [5] B. Putro, M. T. Furqon, & S. H. Wijoyo, "Prediksi Jumlah Kebutuhan Pemakaian Air Menggunakan Metode Exponential Smoothing." *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, Universitas Brawijaya, Vol 8, No 1, hal-11-19. 2018.
- [6] R. H. Kusumodestoni, "Komparasi Model Support Vector Machines (Svm) dan Neural Network Untuk Mengetahui Tingkat Akurasi Prediksi Tertinggi Harga Saham." *Jurnal Informatika Upgris*, Universitas Islam Nahdlatul Ulama Jepara, 2 (4), hal 22-34. 2017.
- [7] Q. Aprilarita, "Sistem Pendukung Keputusan Pemilihan Rumah Di Wilayah Bandar Lampung Dengan Metode Simple Additive Weighting (SAW) Berbasis Android" Universitas Lampung. 2018.
- [8] V. N. Vapnik, "A Training Algorithm for Optimal Margin Classifiers." *Neural Computation*, 20, 273-297. 1992.
- [9] Honakan, Adiwijaya, & S. A. Faraby, "Analisis Dan Implementasi Support Vector Machine Dengan String Kernel Dalam Melakukan Klasifikasi Berita Berbahasa Indonesia Analysis and Implementation Support Vector Machine With String Kernel for Classification Indonesian news," *E-Proceeding of Engineering*, Universitas Telkom, Vol 8, No 8, Hal 26-35. 2018.
- [10] P. Pitria, "Pengguna Twitter Pada Akun Resmi Samsung Indonesia Dengan Menggunakan Naive Bayes," *Jurnal Informatika*, Bandung, Hal 53-64, 2014.
- [11] H. Bhavsar, & M. H. Panchal, "A Review on Support Vector Machine for Data Classification," *International Journal of Advanced Research in Computer Engineering & Technology*, India, 3 (19), 879-886. 2012.
- [12] M. F. Fibrianda, & A. Bhawiyuga, "Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naive Bayes Dan Support Vector Machine (SVM)," *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(9), 3112-3123. 2018.