

IMPLEMENTASI METODE SUPPORT VECTOR MACHINE DALAM KLASIFIKASI KUALITAS PRODUK FURNITURE PADA PT. HERDEX SEJAHTERA

Hendra

Fakultas Ilmu Komputer
Universitas Dian Nuswantoro
Semarang, Indonesia
hendra@mhs.dinus.ac.id

Rahmawan, Elkaf P M.Kom

Fakultas Ilmu Komputer
Universitas Dian Nuswantoro
Semarang, Indonesia

Abstract— The company has a goal of producing a product for consumers either in the form of goods or services. In order that consumers are satisfied in using the product, companies need to have a good quality product. Quality control of a product has to really look for in an industry, so that the consumer is satisfied in using a product or service from the company. the company should be able to do efficiency in order to keep its price or even cheaper and certainly has a good quality, so company doesn't lose consumers. One of the things that needs to be done is efficiency problem in classification of product quality. To select and classify the quality of a product needed a better method than conventional methods. One method of classification which is quite famous for the most powerful and accurate is a method of Support Vector Machine (SVM). This research proposes the use of method of SVM to the classification of quality furniture products at PT Herdex Sejahtera. SVM is used for the classification of products into three classes. From the results of the experiment method of SVM can do the classification accuracy classification results with 84 percent.

Keyword : *Support Vector Machine, Data Mining, Furniture, Quality Control*

PENDAHULUAN

Suatu perusahaan tentunya memiliki tujuan jangka panjang yaitu untuk selalu berkembang ke arah yang lebih baik. Perusahaan didirikan memiliki tujuan menghasilkan suatu produk untuk konsumen baik berupa barang atau jasa. Tentunya agar konsumen puas dalam menggunakan produk, perusahaan harus mempunyai produk yang berkualitas. Kualitas merupakan salah satu kebijakan penting dalam meningkatkan daya saing produk yang harus memberi kepuasan kepada konsumen. Kualitas produk adalah produk yang sesuai dengan yang disyaratkan atau distandarkan [1]. Untuk menangani masalah pengendalian kualitas produk suatu

perusahaan biasanya memiliki standar operasional prosedur (SOP).

Pengendalian kualitas suatu produk harus dapat mengarahkan kepada beberapa tujuan secara terpadu dan merupakan suatu hal yang perlu benar benar diperhatikan dalam dunia usaha, sehingga para konsumen puas dalam menggunakan produk atau jasa dari perusahaan. Harga produk atau jasa perusahaan tersebut harus dapat ditekan serendah rendahnya serta proses produksi harus dapat selesai sesuai dengan waktu yang telah direncanakan sebelumnya didalam perusahaan yang bersangkutan. Pengendalian kualitas merupakan suatu kegiatan yang sering dilakukan disetiap perusahaan. Apabila pengendalian kualitas dilakukan dengan baik, bagi perusahaan akan menimbulkan tambahan biaya yaitu biaya pengawasan kualitas, dan tingkat kerusakan produk yang dihasilkan sangat rendah atau produk rusak yang terjadi sedikit.

PT Herdex Sejahtera adalah perusahaan yang bergerak dalam industri furniture dengan merk label HERMAN DEXTER, merupakan perusahaan yang bergerak dalam bidang pembuatan furniture untuk kebutuhan Hospital, Cafe and Restaurant, Clinic, Hotel, Apartement, Living room, Bed room. untuk meningkatkan keuntungan perusahaan tentunya PT. Herdex Sejahtera harus menjaga dan meningkatkan kualitas produknya. Untuk menjaga kualitas produk perlu adanya kontrol yang efektif dan efisien. selama ini kontrol yang dilakukan adalah kontrol

manusia yang tidak sepenuhnya dapat diandalkan dan tidak menjamin kualitas dari kontrol.

Pada saat ini perusahaan harus bisa melakukan efisiensi agar harga produknya tetap atau bahkan lebih murah dan tentunya memiliki kualitas yang baik, dengan demikian perusahaan tidak kehilangan konsumen. salah satu hal yang perlu dilakukan yaitu melakukan efisiensi dalam masalah pengelompokan atau klasifikasi kualitas produk. Untuk memilih dan mengelompokan kualitas suatu produk diperlukan suatu metode baku dan lebih baik dari metode konvensional. Salah satu metode klasifikasi yang cukup terkenal paling kuat dan akurat adalah metode Support Vector Machine (SVM). Pada penelitian yang dilakukan oleh jinho kim metode SVM dibandingkan dengan metode K-Nearest Neighbor untuk melakukan klasifikasi objek seperti pesawat, motor, mobil dan wajah manusia dengan data gambar. Hasil dari penelitian tersebut menunjukkan metode SVM mempunyai performa yang melebihi metode K-Nearest Neighbor [1]. Seperti yang dilakukan penelitian sebelumnya dengan judul klasifikasi parket kayu jati menggunakan metode Support Vector Machine (SVM). Permasalahan yang dihadapi adalah kegiatan usaha ekspor produk flooring parket dari bahan kayu jati mengalami penurunan drastis, oleh karena itu perlu adanya peningkatan dari mutu produksi parket kayu jati dan mengendalikan kualitas produksi. Tujuan dari penggunaan metode support vector machine pada penelitian tersebut yaitu mengklasifikasikan parket kedalam beberapa jenis parket yang berbeda-beda tetapi mempunyai sifat yang serupa ke dalam kelompok kelompok berdasarkan pemakaiannya. [3].

Penelitian ini mengusulkan penggunaan metode klasifikasi support vector machine dalam melakukan klasifikasi kualitas produk. Dalam kasus ini peneliti menggunakan data produk furniture dari PT Herdex Sejahtera.

Tujuan dari laporan tugas akhir yang dibuat oleh penulis adalah sebagai berikut :

1. Mengimplementasikan metode support vector machine untuk membantu PT. Herdex Sejahtera dalam mengklasifikasikan kualitas produk furniture.

2. Menemukan model klasifikasi yang mempunyai akurasi tinggi atau error yang kecil dalam melakukan klasifikasi kualitas produk.

3. Menerapkan metode support vector machine sebagai alternatif solusi penentuan kualitas produk furniture pada PT herdex Sejahtera secara manual.

SUPPORT VECTOR MACHING

Support Vector Machine (SVM) pertama kali diperkenalkan oleh Vapnik pada tahun 1992 sebagai rangkaian harmonis konsep-konsep unggulan dalam bidang pattern recognition (pengenalan pola). Sebagai salah satu metode pengenalan pola, usia SVM terbilang masih relatif muda. Walaupun demikian, evaluasi kemampuannya dalam berbagai aplikasi menempatkannya sebagai sebuah karya terbaik dalam pengenalan pola. SVM adalah metode learning machine yang bekerja atas prinsip Structural Risk Minimization (SRM) dengan tujuan menemukan hyperplane terbaik yang memisahkan dua buah class pada input space.

Konsep dasar SVM sebenarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya, seperti margin hyperplane, kernel diperkenalkan oleh Aronszajn tahun 1950 dan demikian juga dengan konsep-konsep pendukung yang lain. Akan tetapi hingga tahun 1992, belum pernah ada upaya merangkaikan komponen-komponen tersebut.

Berbeda dengan strategi neural network yang berusaha mencari hyperplane pemisah antar kelas, SVM berusaha menemukan hyperplane yang terbaik pada input space. Prinsip dasar SVM adalah linear classifier, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear, dengan memasukkan konsep kernel trick pada ruang kerja berdimensi tinggi. Perkembangan ini memberikan rangsangan minat penelitian di bidang pengenalan pola untuk investigasi potensi kemampuan SVM secara teoritis maupun dari segi aplikasi. Dewasa ini SVM telah berhasil diaplikasikan dalam aplikasi di dunia nyata dan secara umum memberikan solusi yang lebih baik dibandingkan dengan metode konvensional seperti misalnya artificial neural network.

Berbeda dengan strategi neural network yang berusaha mencari hyperplane pemisah antar kelas,

SVM berusaha menemukan hyperplane yang terbaik pada input space. Prinsip dasar SVM adalah linear classifier, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear, dengan memasukkan konsep kernel trick pada ruang kerja berdimensi tinggi. Perkembangan ini memberikan rangsangan minat penelitian di bidang pengenalan pola untuk investigasi potensi kemampuan SVM secara teoritis maupun dari segi aplikasi. Dewasa ini SVM telah berhasil diaplikasikan dalam aplikasi di dunia nyata dan secara umum memberikan solusi yang lebih baik dibandingkan dengan metode konvensional seperti misalnya artificial neural network.

Karakteristik SVM yaitu:

- Secara prinsip SVM adalah linear classifier
- Pattern recognition dilakukan dengan mentransformasikan data pada input space ke ruang yang berdimensi lebih tinggi, dan optimisasi dilakukan pada ruang vector yang baru tersebut. Hal ini membedakan SVM dari solusi pattern recognition pada umumnya, yang melakukan optimisasi parameter pada ruang hasil transformasi yang berdimensi lebih rendah daripada dimensi input space.
- Menerapkan strategi Structural Risk Minimization (SRM)
- Prinsip kerja SVM pada dasarnya hanya mampu menangani klasifikasi dua class.

Kelebihan SVM

1. Generalisasi

Generalisasi didefinisikan sebagai kemampuan suatu metode untuk mengklasifikasikan suatu pattern, yang tidak termasuk data yang dipakai dalam fase pembelajaran metode tersebut.

Generalization error dipengaruhi oleh dua faktor: error terhadap training set dan dimensi VC (Vapnik–Chervonenkis dimension). Jadi, SVM dapat meminimalkan error pada training-set, juga meminimalkan dimensi VC.

2. Curse of dimensionality

Curse of dimensionality didefinisikan sebagai masalah yang dihadapi suatu metode pattern recognition dalam mengestimasi parameter

(misalnya jumlah hidden neuron pada neural network, stopping criteria dalam proses pembelajaran, dsb) dikarenakan jumlah sampel data yang relatif sedikit dibandingkan dimensional ruang vektor data tersebut. Semakin tinggi dimensi dari ruang vector informasi yang diolah, membawa konsekuensi dibutuhkan jumlah data dalam proses pembelajaran.

3. Feasibility

SVM dapat diimplementasikan relatif mudah, karena proses penentuan support vector dapat dirumuskan dalam QP problem (Quadratic programming). Dengan demikian, jika kita memiliki library untuk menyelesaikan QP problem, dengan sendirinya SVM dapat diimplementasikan dengan mudah.

Kekurangan SVM

1. Sulit dipakai dalam problem berskala besar. Skala besar dalam hal ini dimaksudkan dengan jumlah sample yang diolah.
2. SVM secara teoritik dikembangkan untuk problem klasifikasi dengan dua class atau lebih. Namun demikian, masing-masing strategi ini memiliki kelemahan, sehingga dapat dikatakan penelitian dan pengembangan SVM pada multiclass problem masih merupakan tema penelitian yang masih terbuka.

Formulasi Matematis SVM

Secara matematika, formulasi SVM untuk kasus klasifikasi linier di dalam primal space adalah

$$\min \frac{1}{2} \|\omega\|^2$$

Subject to

$$y_i (w x_i + b) \geq 1, i=1, \dots, l, \quad (1)$$

dimana x_i adalah data input, y_i adalah keluaran dari data x_i , w , b adalah parameter-parameter yang kita cari nilainya. Dalam formulasi di atas, kita ingin meminimalkan fungsi tujuan (obyektif function) $\frac{1}{2} \|w\|^2$ atau memaksimalkan kuantitas $\|w\|^2$ atau w^2 dengan memperhatikan pembatas $y_i(w x_i + b) \geq 1$. Bila output data $y_i = +1$, maka

pembatas menjadi $(w x_i + b) \geq 1$. Sebaliknya bila $y_i = -1$, pembatas menjadi $(w x_i + b) \leq -1$. Di dalam kasus yang tidak feasible (infeasible) dimana beberapa data mungkin tidak bisa dikelompokkan secara benar, formulasi matematikanya menjadi berikut.

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^{\ell} t_i$$

Subject to

$$y_i(\omega x_i + b) + t_i \geq 1$$

$$t_i \geq 0, i = 1, \dots, \ell, \quad (2)$$

dimana t_i adalah variabel slack. Dengan formulasi ini kita ingin memaksimalkan margin antara dua kelas dengan meminimalkan $\|\omega\|^2$ [4]. Dalam formulasi ini kita berusaha meminimalkan kesalahan klasifikasi (misclassification error) yang dinyatakan dengan adanya variabel slack t_i , sementara dalam waktu yang sama kita memaksimalkan margin, $\|\omega\|^2$. Penggunaan variabel slack t_i adalah untuk mengatasi kasus ketidaklayakan (infeasibility) dari pembatas (constraints) $y_i(w x_i + b) \geq 1$ dengan cara memberi penalti untuk data yang tidak memenuhi pembatas tersebut. Untuk meminimalkan nilai t_i ini, kita berikan penalti dengan menerapkan konstanta ongkos C . Vektor w tegak lurus terhadap fungsi pemisah: $w x + b = 0$. Konstanta b menentukan lokasi fungsi pemisah relatif terhadap titik asal (origin).

Problem (3) adalah program nonlinear. Ini bisa dilihat dari fungsi tujuan (objective function) yang berbentuk kuadrat. Untuk menyelesaikannya, secara komputasi agak sulit dan perlu waktu lebih panjang. Untuk membuat masalah ini lebih mudah dan efisien untuk diselesaikan, masalah ini bisa kita transformasikan ke dalam dual space. Untuk itu, pertama diubah problem (3) menjadi fungsi Lagrangian :

$$J(\omega, b, \alpha) = \frac{1}{2} \omega^T \omega - \sum_{i=1}^{\ell} \alpha_i [y_i(\omega^T x_i + b) - 1] \quad (3)$$

dimana variabel non-negatif α_i , dinamakan Lagrange multiplier. Solusi dari problem optimisasi dengan pembatas seperti di atas ditentukan dengan mencari saddle point dari fungsi Lagrangian $J(w, b, \alpha)$. Fungsi ini harus diminimalkan terhadap variabel w dan b dan harus dimaksimalkan terhadap variabel α . Kemudian kita cari turunan pertama dari fungsi $J(w, b, \alpha)$ terhadap variabel w dan b dan kita samakan dengan 0. Dengan melakukan proses ini, akan didapatkan dua kondisi optimalitas berikut:

1. Kondisi 1

$$\frac{\partial J(w, b, \alpha)}{\partial w} = 0$$

2. Kondisi 2

$$\frac{\partial J(w, b, \alpha)}{\partial b} = 0$$

Penerapan kondisi optimalitas 1 pada fungsi Lagrangian (4) akan menghasilkan

$$\omega = \sum_{i=1}^{\ell} \alpha_i y_i x_i \quad (4)$$

Penerapan kondisi optimalitas 2 pada fungsi Lagrangian (5) akan menghasilkan

$$\sum_{i=1}^{\ell} \alpha_i y_i = 0 \quad (5)$$

Menurut duality theorem [1]:

Jika problem primal mempunyai solusi optimal, maka problem dual juga akan mempunyai solusi optimal yang nilainya sama

Bila w_0 adalah solusi optimal untuk problem primal dan α_0 untuk problem dual, maka perlu dan cukup bahwa w_0 solusi layak untuk problem primal dan Untuk mendapatkan problem dual dari problem kita, kita jabarkan persamaan (4) sebagai berikut:

$$J(\omega, b, \alpha) = \frac{1}{2} \omega^T \omega - \sum_{i=1}^{\ell} \alpha_i y_i \omega^T x_i - b \sum_{i=1}^{\ell} \alpha_i y_i + \sum_{i=1}^{\ell} \alpha_i \quad (6)$$

Menurut kondisi optimalitas ke dua dalam (6), term ketiga sisi sebelah kanan dalam persamaan di atas sama dengan 0. Dengan memakai nilai-nilai w di (5), kita dapatkan.

$$\omega^T \omega = \sum_{i=1}^{\ell} \alpha_i y_i \omega^T x_i = \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (7)$$

maka persamaan 7 menjadi

$$Q(\alpha) = \sum_{i=1}^{\ell} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{\ell} y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (8)$$

Selanjutnya didapatkan formulasi dual dari problem (3):

$$\begin{aligned} \max \quad & \sum_{i=1}^{\ell} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{\ell} y_i y_j \alpha_i \alpha_j x_i^T x_j \\ \text{Subject to} \quad & \\ & \sum_{i=1}^{\ell} \alpha_i y_i = 0 \\ & 0 \leq \alpha_i, i = 1, \dots, \ell, \end{aligned} \quad (9)$$

Dengan dot product $x_i x_j$ sering diganti dengan simbol K . K adalah matrik kernel yang dijelaskan dalam bagian 3. Formulasi (9) adalah quadratic programming (QP) dengan pembatas (constraint) linier. Melatih SVM ekuivalen dengan menyelesaikan problem *convex optimization*. Karena itu solusi dari SVM adalah unik (dengan asumsi bahwa k adalah positive definite) dan global optimal. Hal ini berbeda dengan solusi neural networks [5] yang ekuivalen dengan problem *nonconvex optimization* dengan akibat solusi yang ditemukan adalah *local optima*. Ambil $f(x) = \sum_{i=1}^{\ell} y_i \alpha_i k(x_i, x) + b$. Fungsi pemisah optimal

adalah $g(x) = \text{sign}(\sum_{i=1}^{\ell} y_i \alpha_i k(x_i, x)) + b$, dimana $\alpha_i, i = 1, \dots, \ell$ adalah solusi optimal dari problem (10) dan b dipilih sehingga $y_i f(x_i) = 1$ untuk sembarang i dengan $C > \alpha_i > 0$ [6]. Data x_i dimana $\alpha_i > 0$ dinamakan *support vector* dan menyatakan data training yang diperlukan untuk mewakili fungsi keputusan yang optimal. Dalam gambar 1, sebagai contoh, 3 titik berwarna putih menyatakan *support vector*. Untuk mengatasi masalah ketidaklinieran (nonlinearity) yang sering terjadi dalam kasus nyata, kita bisa menerapkan metoda kernel. Metoda kernel [7] memberikan pendekatan alternatif dengan cara melakukan mapping data x dari input space ke *feature space* F melalui suatu fungsi φ sehingga $\varphi : x \rightarrow \varphi(x)$ Karena itu suatu titik x dalam input space menjadi $\varphi(x)$ dalam feature space..

METODE PENELITIAN

Prosedur implementasi metode Support Vector Machine yang digunakan dalam penelitian ini yaitu :

1. Preprosesing data yang dapat digunakan dalam metode Support Vector machine karena metode SVM membutuhkan data yang bersifat bilangan real. Dalam penelitian ini transformasi data atau preprosesing yang digunakan bersifat pengkategorian misalnya parameter C1 = {Tidak Goyang, Goyang}, kemudian dikategorikan kedalam nilai C1 = {1,0}.

2. Setelah data diubah dalam nilai numerik selanjutnya dilakukan normalisasi pada data training dan data testing.

3. Proses pelatihan menggunakan SVM multiclass one agains all dengan beberapa parameter seperti kernel yang digunakan yaitu Kernel Radial Basic Function (RBF). fungsi kernel yang digunakan adalah fungsi kernel RBF karena memiliki performansi yang sama dengan kernel linier pada parameter tertentu, memiliki perilaku seperti fungsi kenel sigmoid dengan parameter tentu dan rentang nilainya kecil [0,1].

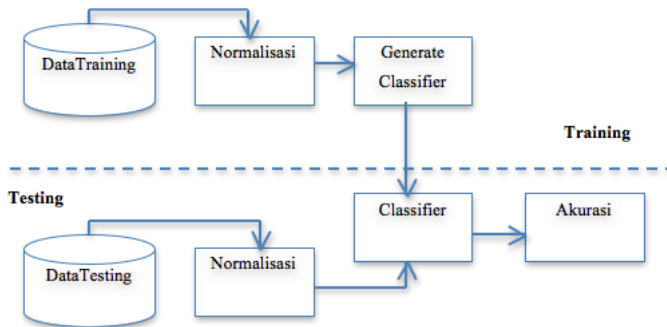
4. Lakukan proses training untuk mencari nilai terbaik dari parameter kernel C dan γ . C adalah parameter yang menentukan besar penalti akibat kesalahan dalam klasifikasi data dan nilainya

ditentukan oleh pengguna. Sedangkan γ merupakan konstanta dari kernel RBF.

5. Menggunakan model yang telah dihasilkan dari proses training untuk data testing.

6. Pengujian dengan data testing (uji) untuk mengetahui akurasi dari model klasifikasi. Hasil dari akurasi dapat dilihat dari prosentase kebenaran hasil klasifikasi terhadap data asli dan membuat tabel kebenaran (confusion matrix).

Skenario dari Klasifikasi dengan Support Vector Machine direpresentasikan pada gambar 1.



Gambar 1 : Tahap Implementasi klasifikasi SVM

HASIL DAN PEMBAHASAN

Hasil penelitian direpresentasikan dalam tahap-tahap sebagai berikut

1. Pengolahan data

- Data survey

Data survey diperoleh dari hasil survey atau pengecekan produk setelah diproduksi. Pada penelitian ini data survey yang didapat merupakan data produksi bulan Juni – Oktober tahun 2013 dengan 3 jenis produk yaitu Adonis Round Table, Ariston Square Table dan Acuba Round, Table. Pada tabel 1 ditampilkan sampel data survey produksi bulan juni 2013.

Tabel 1: Data Survey Produksi Furniture

Date	Code	Description	Parameter					Bayaknya Cacat
			C1	C2	C3	C4	C5	
6/2/13	ADR 048	Adonis Round Table	tidak goyang	bersih	rata	rapat	baik	0
6/3/13	ADR 049	Adonis Round Table	goyang	cacat	rata	rapat	rusak	3
6/3/13	ADR 050	Adonis Round Table	tidak goyang	cacat	rata	rapat	baik	1
6/6/13	ADR 051	Adonis Round Table	tidak goyang	bersih	rata	mengelupas	baik	1
6/6/13	ADR 052	Adonis Round Table	tidak goyang	bersih	bergelombang	mengelupas	rusak	3
6/6/13	ADR 053	Adonis Round Table	tidak goyang	bersih	rata	rapat	baik	0
6/7/13	ADR 054	Adonis Round Table	goyang	cacat	rata	mengelupas	baik	3
6/7/13	ADR 055	Adonis Round Table	goyang	bersih	rata	rapat	baik	1
6/7/13	ADR 056	Adonis Round Table	tidak goyang	bersih	bergelombang	rapat	baik	1
6/7/13	ADR 057	Adonis Round Table	tidak goyang	bersih	rata	rapat	baik	0
6/7/13	ADR 058	Adonis Round Table	tidak goyang	cacat	bergelombang	rapat	baik	2

Keterangan

Parameter	Deskripsi
C1	Hasil pemasangan kaki meja, terdapat dua kategori hasil pemasangan yaitu goyang dan tidak goyang. Hasil pemasangan yang menyebabkan meja goyang yaitu salah satu kaki meja mempunyai jarak dengan permukaan alas lebih dari 3 milimeter
C2	Kebersihan permukaan meja. Terdapat dua kategori dari kebersihan permukaan meja yaitu bersih dan cacat. Permukaan meja bersih apabila pada saat pengecekan permukaan tidak terdapat dent (lubang kecil, pecahan).
C3	Rata permukaan meja, permukaan dikategorikan rata apabila kemiringan permukaan antara 0 - 5 derajat.
C4	Lapisan laminating . Lapisan laminating terdapat dua kategori rapat dan mengelupas. Pengecekan lapisan laminating dilakukan dengan cara manual
C5	Hasil dari pengemasan. Kategori dari pengemasan yaitu baik dan rusak. Pengecekan hasil pengemasan dilakukan dengan cara manual

Dari survey yang dihasilkan terdapat hasil penilaian untuk setiap parameter. Untuk penilaian akhir dari nilai parameter akan dikelompokkan menjadi tiga kelas sesuai dengan standar operasional produksi yang dimiliki oleh PT. Herdex Sejahtera. Standar kelas dijelaskan pada tabel.

Tabel 2: Deskripsi Kelas

Kategori	Deskripsi
Kelas 1	Sesuai standar pabrik dan siap untuk dikirim
Kelas 2	Kerusakan masih dapat ditoleransi untuk diperbaiki
Kelas 3	Tidak layak untuk diperbaiki

- Pembentukan Dataset

Setelah diperoleh data survey, parameter-parameter data dan standar kualitas sebagai kelas. Maka data diolah menjadi dataset penelitian. Dataset terdiri dari data training (pelatihan) dan data testing (uji). Pada laporan ini sampel dataset yang ditampilkan sebanyak 150 data dengan jenis produk Adonis Round Table. Sampel dataset Adonis Round Table ditampilkan pada tabel 3

Tabel 3: Dataset Penelitian

Parameter					Kelas
C1	C2	C3	C4	C5	
tidak goyang	bersih	rata	rapat	baik	kelas 1
goyang	cacat	rata	rapat	rusak	kelas 3
tidak goyang	cacat	rata	rapat	baik	kelas 2
tidak goyang	bersih	rata	mengelupas	baik	kelas 2
tidak goyang	bersih	bergelombang	mengelupas	rusak	kelas 3
tidak goyang	bersih	rata	rapat	baik	kelas 1
goyang	cacat	rata	mengelupas	baik	kelas 3
goyang	bersih	rata	rapat	baik	kelas 2
tidak goyang	bersih	bergelombang	rapat	baik	kelas 2
tidak goyang	bersih	rata	rapat	baik	kelas 1

- Transformasi Dataset

Data ditransformasi menjadi nilai decimal agar dapat diolah dengan metode support vector machine. Transformasi data dapat dilihat pada table 4

Tabel 4: Transformasi Dataset

Parameter					
C1	C2	C3	C4	C5	
1	1	1	1	1	kelas 1
0	0	1	1	0	kelas 3
1	0	1	1	1	kelas 2
1	1	1	0	1	kelas 2
1	1	0	0	0	kelas 3
1	1	1	1	1	kelas 1
0	0	1	0	1	kelas 3
0	1	1	1	1	kelas 2
1	1	0	1	1	kelas 2
1	1	1	1	1	kelas 1
1	0	0	1	1	kelas 2
0	0	1	1	1	kelas 2
0	1	1	1	0	kelas 2

- Normalisasi Data

Data training dan testing yang ada harus dinormalisasi sehingga dalam proses training support vector machine akan menghasilkan data training yang stabil dan sesuai.

Tabel 5: Normalisasi Data

Parameter				
C1	C2	C3	C4	C5
0.715344	-1.30987	-1.38861	-1.18739	0.848122
0.715344	0.758345	0.715344	0.836569	0.848122
0.715344	-1.30987	-1.38861	-1.18739	0.848122
-1.38861	-1.30987	0.715344	-1.18739	0.848122
-1.38861	0.758345	-1.38861	0.836569	0.848122
0.715344	-1.30987	0.715344	0.836569	-1.17122
0.715344	0.758345	-1.38861	-1.18739	-1.17122
0.715344	-1.30987	-1.38861	0.836569	-1.17122
0.715344	-1.30987	-1.38861	0.836569	0.848122
0.715344	0.758345	-1.38861	0.836569	0.848122

2. Pelatihan Support Vector Machine

Pada tahap ini data training digunakan untuk proses pelatihan. Proses training menggunakan multiclass SVM dengan metode one-against-all. dibangun k buah model SVM biner (k adalah jumlah kelas). Setiap model klasifikasi ke-i dilatih dengan menggunakan keseluruhan data, untuk mencari solusi permasalahan. Implementasi proses pelatihan pada program bisa dilihat pada gambar 2.

Gambar 2: Pelatihan SVM


```

optimization finished, #iter = 16
nu = 0.101727
obj = -4.067651, rho = 1.329181
nSV = 10, nBSV = 4
Total nSV = 10
*
optimization finished, #iter = 16
nu = 0.101703
obj = -4.067652, rho = -1.329063
nSV = 10, nBSV = 3
Total nSV = 10
*
optimization finished, #iter = 16
nu = 0.101703
obj = -4.067652, rho = -1.329063
nSV = 10, nBSV = 3
Total nSV = 10
*
optimization finished, #iter = 16
nu = 0.101703
obj = -4.067652, rho = -1.329063
nSV = 10, nBSV = 3

```

Parameters	[0;2;3;0.2000;0]	0	3
nr_class	2	2	2
totalSV	10	10	10
rho	1.3292	1.3292	1.3292
Label	[1;0]	0	1
ProbA	-3.1377	-3.1377	-3.1377
ProbB	0.1697	0.1697	0.1697
nSV	[5;5]	5	5
sv_coef	[0.0691;1;1;1;-0.761...	-0.8726	1
SVs	<10x5 double>		

Keterangan model :

- Parameters : array yang berisi parameter kernel yaitu nilai C (koefisien kernel), jumlah kelas dan epsilon.
- Nr_class : jumlah kelas yang ada pada tiap model
- totalSV : total dari support vector
- rho : bias
- nSV : banyaknya dari support vector
- SVs : bobot dari support vector

Keterangan model :

- nu : nilai yang ekuivalen dengan C
- obj : nilai optimal objektif dari dual SVM
- nSV : banyaknya dari support vector
- rho : bias
- totalSV : total dari support vector

Setelah dilakukan penelitian maka diperoleh model atau mesin klasifikasi yang akan digunakan sebagai standar mesin klasifikasi dan digunakan untuk menguji klasifikasi dengan data testing. Terdapat 3 model yang dihasilkan dari proses training data. Model-model hasil training berisi parameter-parameter yang optimal dari hasil training. Model ditunjukkan pada gambar 3.

Gambar 3: Model SVM

3. Pengujian Model

Setelah dilakukan training dan menghasilkan model klasifikasi, tahap selanjutnya yang dilakukan adalah menguji model klasifikasi dengan data testing. Hasil dari pengujian bisa dilihat pada table 6.

Tabel 6: Hasil Pengujian Model

Parameter					Kelas
C1	C2	C3	C4	C5	
0.715344	0.758345	-1.38861	-1.18739	-1.17122	3
0.715344	-1.30987	0.715344	-1.18739	-1.17122	3
0.715344	0.758345	0.715344	0.836569	0.848122	1
0.715344	0.758345	0.715344	0.836569	-1.17122	2
0.715344	0.758345	0.715344	0.836569	0.848122	1
-1.38861	-1.30987	0.715344	0.836569	-1.17122	3
0.715344	0.758345	-1.38861	0.836569	0.848122	2
0.715344	0.758345	0.715344	0.836569	0.848122	1
0.715344	0.758345	0.715344	-1.18739	-1.17122	2
0.715344	-1.30987	-1.38861	0.836569	0.848122	2
0.715344	0.758345	0.715344	-1.18739	-1.17122	2
-1.38861	0.758345	0.715344	0.836569	0.848122	2
0.715344	0.758345	0.715344	-1.18739	-1.17122	2
0.715344	0.758345	-1.38861	-1.18739	0.848122	2

Dari hasil eksperimen dan perhitungan menunjukkan hasil akurasi sebesar 90 persen. Hasil pengujian klasifikasi bisa dilihat pada tabel 7. terdapat 3 kelas yang telah diklasifikasi, akurasi untuk kelas 1

sebesar 100 persen, akurasi untuk kelas 2 sebesar 92 persen dan akurasi kelas 3 sebesar 94 persen. Nilai dari table kebenaran atau *confusion matrix* ditunjukkan pada tabel 7.

Tabel 7: Confusion Matrix Pengujian Model

		prediksi		
		kelas 1	kelas 2	kelas 3
asli	kelas 1	8	0	0
	kelas 2	0	19	4
	kelas 3	0	0	19

Keterangan confusion matrix :

- Kelas 1 : produk yang berhasil diprediksi sebagai kelas 1 yaitu 8 data sedangkan jumlah asli 8 data
- Kelas 2 : produk yang berhasil diprediksi sebagai kelas 2 yaitu 19 data sedangkan jumlah asli 23 data
- Kelas 3 : produk yang berhasil diprediksi sebagai kelas 3 yaitu 19 data sedangkan jumlah asli yaitu 19 data

4. Pengujian Data

Setelah dihasilkan model dari klasifikasi dilakukan pengujian dari data selain dataset. Pengujian menggunakan data produksi meja dengan produk yang berbeda yaitu produksi ariston square table sebanyak 200 data.

Tabel 8: Hasil Pengujian Data

0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
-2.17239	0.434059	0.425964	0.558717	0.635277	2
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	0.558717	0.635277	1
-2.17239	-2.29237	0.425964	-1.78091	0.635277	3
0.458033	0.434059	0.425964	0.558717	0.635277	1
0.458033	0.434059	0.425964	-1.78091	0.635277	2

Dari hasil pengujian dengan data uji menunjukkan hasil akurasi sebesar 84 persen. Hasil klasifikasi

bisa dilihat pada tabel 9 yang menunjukkan nilai dari table kebenaran atau *confusion matrix* dari klasifikasi.

Tabel 9: Confusion Matrix Pengujian Data

		prediksi		
		kelas 1	kelas 2	kelas 3
asli	kelas 1	96	0	0
	kelas 2	0	46	31
	kelas 3	0	0	28

Keterangan confusion matrix :

- Kelas 1 : produk yang berhasil diprediksi sebagai kelas 1 yaitu 96 data sedangkan jumlah asli 96 data
- Kelas 2 : produk yang berhasil diprediksi sebagai kelas 2 yaitu 46 data sedangkan jumlah asli 77 data
- Kelas 3 : produk yang berhasil diprediksi sebagai kelas 3 yaitu 28 data sedangkan jumlah asli yaitu 28 data.

KESIMPULAN DAN SARAN

Dari hasil penelitian dan implementasi klasifikasi data kualitas produksi dengan metode Support Vector Machine, pada akhir laporan penulis dapat memberikan kesimpulan sebagai berikut :

1. Metode Support Vector Machine dapat diimplementasikan dalam klasifikasi kualitas hasil produksi furniture pada PT. Herdex Sejahtera.
2. Implementasi metode Support Vector Machine dalam klasifikasi menghasilkan model klasifikasi yang baik, terbukti dengan capaian nilai akurasi dari model sebesar 92 persen dan akurasi dengan data uji sebesar 84 % persen

Berdasarkan kesimpulan dan analisis laporan , saran dari peneliti untuk penelitian lebih lanjut yaitu :

1. Penelitian lebih lanjut dapat menerapkan dan melakukan optimasi terhadap metode Support Vector Machine. Dapat ditambahkan ekstraksi fitur untuk meningkatkan performa dari metode SVM.
2. Dikembangkan penelitian yang lebih mendalam dan variasi algoritma SVM digabungkan dengan algoritma lain agar hasil

dan kecepatan training yang dihasilkan lebih optimal.

REFERENSI

- [1] JINHO KIM, "Comparing Image Classification Methods: K-Nearest-Neighbor and Support-Vector-Machines ," *Applied Mathematics in Electrical and Computer Engineering*.
- [2] Philip B Crosby, *Quality is Free : The Art Of Making Quality Certain*. New York: New American Library, 1979.
- [3] Xindong Wu and Viping Kumar, *The Top Ten Algorithms In Data Mining.:* Taylor & Francis Group, LLC, 2009.
- [4] Rina Yuliani Siagian, "KLASIFIKASI PARKET KAYU JATI MENGGUNAKAN METODE SUPPORT VECTOR MACHINES (SVM)," 2013.
- [5] Esyudha Endha, "Klasifikasi Keluhan Pelanggan Berdasarkan Tweet dengan Menggunakan Metode Support Vector Machine (SVM)," in *Sekolah Teknik Elektro dan Informatika*, Bandung.
- [6] Simon Haykin, *Neural Network: A Comprehensive Foundation*. New Jersey: Prentice.
- [8] Scholkopf B and J, Smola A, *Learning with Kernels*. Massachusetts: The MIT Press, 2000.
- [7] Cristianini N and Shawe-Taylor J, *An Introduction to Support Vector Machines.:* Cambridge University Press, 2000.
- [9] D. J., & Sharda, R. Power, "Model-driven decision support systems: Concepts and research directions," *APA*, vol. 43(3), pp. 1044-1061, 2007.
- [10] Marihot Tua Efendi Hariandja, *Manajemen Sumber Daya Manusia*. Jakarta: PT Grasindo, 2007.
- [11] "Standar Kualitas Produksi Furniture PT.Herdex Sejahtera," *Produksi*,.