

BAB II LANDASAN TEORI

2.1 Tinjauan Pustaka

Sebagai upaya penguatan topik penelitian, penulis melakukan analisis dari hasil riset penelitian sebelumnya yang berkaitan dengan topik penelitian. Berikut beberapa hasil dari penelitian sebelumnya :

- a. Rahmat Robi Waliyansyah dan Citra Fitriyah (2019) dengan judul penelitian “Perbandingan Akurasi Klasifikasi Citra Kayu Jati Menggunakan Metode Naive Bayes dan k-Nearest Neighbor (k-NN)”. Pada penelitian ini menggunakan 3 jenis kayu jati, yaitu semarangan, blora, dan sulawesi. Penelitian ini melakukan perbandingan metode *Naive Bayes* dan k-NN pada proses klasifikasi. Parameter akurasi yang digunakan adalah AUC, CA, *F1 score*, *Precision* dan *Recall*. Berdasarkan hasil evaluasi yang telah dilakukan nilai akurasi CA, *F1 score*, *Precision* dan *Recall* pada Metode k-NN lebih baik dibandingkan *Naive Bayes* pada citra kayu jati (semarangan, blora dan sulawesi). Klasifikasi citra kayu jati yang berasal dari sulawesi dengan Metode *Naive Bayes* paling baik dengan persentase tingkat akurasi sebesar 82,7%. Nilai *Area Under Curve* (AUC) pada Metode *Naive Bayes* lebih baik dari pada k-NN. Hal ini dikarenakan akurasi Metode k-NN dipengaruhi oleh banyaknya data latih yang digunakan. Sedangkan Metode *Naive bayes* dapat menghasilkan akurasi yang baik walaupun memiliki data latih yang sedikit. (Robi et al., n.d., 2019)
- b. Deni Wahyu Wibowo, Danang Erwanto dan Diah Arie Widhining Kusumastutie (2021) dengan judul penelitian "Klasifikasi Jenis Kayu Menggunakan Ekstrasi Fitur *Gray Level Co-Occurance Matrix* dan *MultiLayer Perceptron*". Penelitian ini memiliki tahapan *Pre-processing* yaitu untuk mengubah citra berwarna menjadi citra ke abuan (*Grayscale*) dilanjutkan dengan tahapan *image enhancement* untuk memperjelas tepi pada obyek. Penelitian ini melakukan klasifikasi jenis

kayu jati, sengon, mahoni dan mindi. Dan memiliki jumlah sebanyak 400 data dengan masing-masing 100 data dari setiap jenis kayu yang diteliti dengan proporsi citra sebesar 320×240 pixel. Untuk jumlah data testing sebanyak 80 data dengan masing-masing jenis kayu menggunakan 20 data perjenis kayu untuk keperluan akurasi. Proses ekstraksi fitur menggunakan metode GLCM pada masing-masing citra kayu jati, sengon, mahoni dan mindi dengan penajaman citra pada nilai radius 10 dan amount 2 dapat menghasilkan nilai parameter GLCM berupa correlation, contrast, energy dan homogeneity yang bervariasi. Penerapan metode MLP untuk klasifikasi citra kayu jati, sengon, mahoni dan mindi menghasilkan akurasi sistem pada data train sebesar 96%. Pada saat pengujian data validasi, tingkat akurasi menurun sebesar 7,25%. (Wibowo et al., 2021)

- c. Jaenal Arifin (2022) dengan judul “klasifikasi citra tekstur kayu menggunakan *gray level co-occurrence matrix* dan *local binary pattern*”. Penelitian ini memiliki tahapan *Pre-processing* yaitu untuk mengubah citra berwarna menjadi citra keabuan (*Grayscale*) dilanjutkan ekstraksi fitur *Gray Level Co-Occurance Matrix* (GLCM) dan *Local Binary Pattern* (LBP). Terdapat beberapa hasil akurasi dengan parameter yang berbeda-beda yang dapat mempengaruhi hasil akurasi yang diperoleh. Pengujian dengan membedakan jumlah nilai k menghasilkan nilai keakurasian yang berbeda, dengan melakukan pengujian sebanyak 20 kali menggunakan citra data latih dan citra non latih, menghasilkan keakurasian antara 73% sampai 86% dan yang memiliki nilai keakurasian tertinggi adalah k sebanyak 3 dengan hasil 86%. Pengujian menggunakan inputan data citra latih dan data citra diluar data latih menghasilkan tingkat keakurasian yang berbeda. Pada pengujian menggunakan citra data latih sebagai citra inputan, hasil klasifikasi mencapai keakurasian 100%. Dan pada pengujian menggunakan data citra non latih sebagai citra inputan keberhasilannya keakurasiannya mencapai rata-rata 78%. (Arifin, 2022)

- d. Latifudin, Ratih Kumalasari dan Lilia Sinta (2022) dengan judul “klasifikasi kualitas kayu glugu menggunakan metode (*Support Vektor Machine*) SVM”. Penelitian ini memiliki tahapan *Pre-processing* yaitu untuk mengubah citra berwarna menjadi citra ke abuan (*Grayscale*) dilanjutkan ekstraksi fitur *Gray Level Co-Occurance Matrix* (GLCM). Pada penelitian ini ada 110 dataset dari keseluruhan data yang digunakan untuk pelatihan sebanyak 70% dan untuk pengujian sebanyak 30% dimensi 256 x 256 piksel dan menggunakan data pelatihan sebanyak data 80 dan data pengujian sebanyak 30 data. Hasil dari penelitian ini menunjukkan bahwa klasifikasi kualitas kayu kepala menggunakan metode atau algoritma Support Vektor Machine (SVM) berdasarkan tekstur pada citra kayu kelapa memperoleh nilai akurasi sebesar 60 % dengan jumlah 110 dataset yang dibagi menjadi 80 data untuk data training dan 30 data testing. (Latifudin et al., n.d., 2022)
- e. Benedictus Mario, Hanny Hikmayanti, dan Santi Arum (2023) dengan judul ” Penerapan Algoritma *K-Nearest Neighbor* Dengan Pengolahan Citra Digital Untuk Mengidentifikasi Jenis Kayu” pada penelitian ini menggunakan ekstraksi fitur *Gray Level Co-Occurance Matrix* (GLCM) dan dilanjutkan dengan klasifikasi menggunakan *K-Nearest Neighbor* (K-NN). Pada penelitian ini terdapat 3 jenis citra kayu, yaitu kayu Jati, kayu Mahoni, dan kayu Karet. Untuk dataset yang diolah terdapat 300 data dan terdiri dari 100 data dari masing-masing jenis kayu dan berdiamensi 4000x 4000 piksel. Dari dataset tersebut dibagi menjadi Data *Training* dan Data Uji dengan pembagian 90 citra menjadi Data *Training* dan 10 citra menjadi Data Uji. Pembagian Data *Training* terdiri dari 30 citra kayu Jati, 30 citra kayu Mahoni, dan 30 citra kayu Karet. Sedangkan pembagian Data Uji adalah 3 citra kayu Jati, 3 citra kayu Karet dan 4 citra kayu Mahoni. Pada penelitian ini menghasilkan akurasi tertingginya adalah 91.6% dan nilai akurasi terendahnya adalah 61.1%. Sehingga rata rata nilai akurasi dari penghitungan ini adalah 75.54%. (Benedictus Mario et al., 2023)

- f. Neneng, Novia Utami, dan Erliyan Redi (2020) dengan judul ”Klasifikasi Jenis Kayu Menggunakan *Support Vector Machine* Berdasarkan Ciri Tekstur *Local Binary Pattern*” pada penelitian ini menggunakan metode ekstraksi ciri tekstur *Local Binary Pattern* dan diklasifikasikan dengan *Support Vector Machine*. Ciri tekstur LBP yang digunakan dalam penelitian ini adalah *mean*, *standar deviasi*, *skewness*, *energi*, dan *entropi*. Jumlah citra yang digunakan dalam penelitian ini untuk masing-masing kayu bayur, cempaka, damar, meranti, dan merbau adalah 150 citra. Dengan demikian, jumlah citra untuk seluruh kayu yang digunakan adalah 750 citra untuk ukuran asli citra kayu ini adalah 4000 x 6016 piksel. Selanjutnya ukuran citra asli ini dikonversi menjadi 2400 x 1700 piksel. Kemudian untuk data latih masing-masing citra kayu berjumlah 130 citra dengan total data latih adalah 650 citra. Sedangkan data uji untuk masing- masing citra kayu adalah 30 citra dengan total data uji sebanyak 150 citra. Berdasarkan pengujian data menggunakan jarak ketetanggaan $R=1$ adalah sebesar 91,3% terletak pada parameter sigma 0,3 dan untuk Nilai *error* terkecil sebesar 8,7% yang berada pada parameter sigma 0,3. (Utami Putri & Redi Susanto, 2020)
- g. Ignatius Ngesti, Robertus Krismanto, dan Antonius Sugianto (2022) dengan judul “Penentuan Kualitas Kayu Jati Secara Visual Menggunakan Metode *Learning Vector Quantization*” pada penelitian ini terbagi menjadi 3 jenis pola pada kayu jati yaitu pola serat tinggi = grade A; pola serat sedang = grade B dan pola serat rendah = grade C. Selanjutnya pola dari kayu jati melakukan proses *cropping* gambar sehingga menjadi ukuran 256 x 256 piksel. Dalam penelitian ini akan digunakan 160 gambar pola yang terdiri dari 100 gambar pola untuk pelatihan dan 30 gambar pola untuk pengujian. Kemudian pada penelitian melakukan proses *re-processing* dan memiliki tahapan yaitu *spatial filtering*, *color conversion*, *noise removal* dan *morfologi*. Selanjutnya dilakukan pengklasifikasian menggunakan *Learning Vector Quantization*. Dari hasil penelitian yang dilakukan guna menentukan

kualitas kayu jati secara visual dengan menggunakan neural network dengan pembelajaran *Learning Vector Quantization* (LVQ) dibandingkan dengan penentuan kerapatan kayu jati yang dilakukan oleh para expert menghasilkan bahwa: tingkat akurasinya sebesar 68,71%. (Ngesti Yuwono et al., 2022)

- h. Nurhalimah, Gede Pasek, Fitri Bimantoro (2020) dengan judul ”Klasifikasi Kain Songket Lombok Berdasarkan Fitur GLCM Dan Moment Invariant Dengan Teknik Pengklasifikasian *Linear Discriminant Analysis* (LDA)” penelitian ini mengkaji metode identifikasi kain Songket Lombok menggunakan algoritma *Linear Discriminant Analysis* dengan ekstraksi fitur berbasis GLCM dan Moment Invariant. Metode *Gray Level Co- Occurrence Matrix* (GLCM) untuk ekstraksi fitur tekstur dan metode Moment Invariant untuk ekstraksi fitur bentuk. Pada penelitian ini citra Songket Lombok sebanyak 1000 citra dari 10 motif yaitu Anggrek, Cangkir, Kabut, Keke, Keke Ngangak, Klukus Ulah, Kupu-kupu, Lembang, Nanas, Subahnale Rante dengan ukuran maksimal 300x300 piksel. Jumlah citra setiap motif yaitu 100 citra. Citra songket Lombok ini kemudian dibagi menjadi citra latih dan citra uji dengan pembagian 700 citra latih dan 300 citra uji. Kemudian masuk pada tahap proses *resizing* dilakukan agar waktu komputasi yang dibutuhkan sistem tidak besar. Selain itu, 4 ukuran berbeda dari citra tersebut yaitu 64x64 piksel, 128x128 piksel, 256x256 piksel dan 300x300 piksel. Untuk penelitian ini dibagi menjadi 3 tahap, yaitu proses fitur Moment Invariant, GLCM, dan Moment Invariant dan GLCM. Pada fitur Moment Invariant peningkatan akurasi dari citra 64x64 piksel ke citra 128x128 piksel yakni sebesar 5%. Sedangkan peningkatan akurasi dari citra 128x128 piksel ke citra 256x256 piksel sebesar 9.67% saja. Dan untuk akurasi dari citra 256x256 piksel ke citra 300x300 piksel peningkatannya hanya sebesar 4.33%. Pada fitur GLCM peningkatan akurasi dari citra 64x64 piksel ke citra 128x128 piksel tidak signifikan yakni sebesar 6.66% saja.

Sedangkan peningkatan akurasi dari citra 128x128 piksel ke citra 256x256 piksel cukup signifikan yakni sebesar 22.67%. Sedangkan pada saat citra diubah menjadi 300x300 piksel terjadi penurunan akurasi sebesar 1%. Untuk fitur Moment Invariant dan GLCM peningkatan akurasi dari citra 64x64 piksel ke citra 128x128 piksel sebesar 8%. Sedangkan peningkatan akurasi dari citra 128x128 piksel ke citra 256x256 cukup signifikan yakni sebesar 20%. Dan untuk akurasi dari citra 256x256 piksel ke citra 300x300 piksel peningkatannya sebesar 6% saja. (Gede Pasek Suta Wijaya & Bimantoro, n.d. 2020)

- i. Arma Adzhana, Rinci Kembang, dan Hendro Nugroho (2020) dengan judul "Penerapan *Naive Bayes Gaussian* Pada Klasifikasi Jenis Jamur Berdasarkan Ciri Statistik Orde Pertama". Dalam penelitian ini, dilakukan klasifikasi jenis jamur menggunakan metode Naive Bayes Gaussian berdasarkan ciri statistik orde pertama. Tahapan yang dilakukan meliputi pengolahan citra, ekstraksi fitur, dan klasifikasi. Pengolahan citra dilakukan dengan mengubah citra RGB menjadi grayscale dan membuat histogram grayscale. Ekstraksi fitur dilakukan dengan menghitung nilai mean, variance, skewness, kurtosis, dan entropy dari histogram grayscale. Hasil fitur kemudian digunakan untuk klasifikasi menggunakan metode Naive Bayes Gaussian. Pengujian dilakukan menggunakan 60 citra jamur dengan metode cross-validation $k=4$, menghasilkan akurasi sebesar 98.75%. (Mahran et al., n.d. 2020)
- j. Yudha Arya, Soffiana Agustin, Umi Chotijah, dan Farhanna Mar'i (2022) dengan judul "Perbandingan Metode GLCM Dan LBP Dalam Klasifikasi Jenis Kayu". Penelitian ini menerapkan teknologi pengolahan citra digital dengan menggunakan metode ekstraksi fitur *Gray Level Co-Occurrence Matrix (GLCM)* dan *Local Binary Pattern (LBP)* untuk menghasilkan parameter nilai ekstraksi fitur pada tekstur kayu. Hasil dari parameter GLCM dan LBP kemudian digunakan sebagai data untuk klasifikasi jenis kayu menggunakan metode multilayer perceptron (MLP). Dalam penelitian ini, digunakan tiga jenis

kayu sebagai data latihan dan data uji, yaitu kayu agathis, keruing, dan meranti. Total data yang digunakan dalam penelitian ini sebanyak 150 citra, dengan masing-masing jenis kayu terdiri dari 50 citra. Data tersebut dibagi menjadi data pelatihan dan data pengujian untuk menguji keefektifan model. Hasil penelitian ini menunjukkan bahwa metode GLCM mencapai tingkat akurasi sebesar 90%, sementara metode LBP mencapai tingkat akurasi sebesar 70%. Metode GLCM terbukti lebih efektif dalam menangkap tekstur yang khas dari masing-masing jenis kayu dibandingkan dengan metode LBP. Selain itu, kombinasi dari kedua metode ekstraksi fitur ini menunjukkan potensi yang besar untuk meningkatkan akurasi klasifikasi lebih lanjut. (Arya Prasaja et al., 2022)

Berdasarkan hasil analisis penelitian terdahulu, maka penelitian Klasifikasi Jenis Kayu Menggunakan *Support Vektor Machine* (SVM) dapat menggunakan ekstraksi ciri *Local Binary Pattern*.

2.2 Landasan Teori

2.2.1 Citra Digital

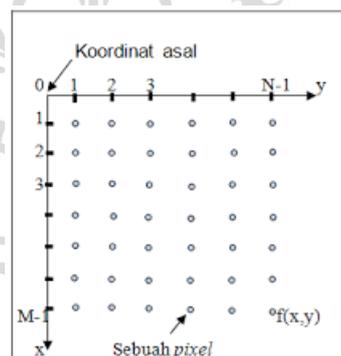
Citra merupakan suatu representasi atau gambaran, kemiripan, atau imitasi dari suatu objek. Citra dibagi menjadi 2 bagian yaitu citra bersifat analog dan citra yang bersifat digital. Citra analog adalah citra yang bersifat kontinu seperti gambar pada monitor, televisi, foto sinar x, hasil CT scan dan lainnya. Sedangkan pada citra digital adalah citra yang dapat diolah oleh komputer. Sebuah citra digital dapat diwakili oleh sebuah matriks yang terdiri dari baris x baris y kolom, dimana perpotongan antara kolom dan baris disebut piksel.

2.2.2 Pengolahan Citra Digital

Pengolahan citra digital adalah sebuah disiplin ilmu yang mempelajari hal-hal yang berkaitan dengan:

1. Preprocessing: Perbaiki kualitas gambar (peningkatan kontras, transformasi warna, restorasi citra), transformasi gambar (rotasi, translasi, skala, transformasi geometrik).
2. Ekstraksi Fitur (segmentasi): Melakukan proses penarikan informasi atau deskripsi objek atau pengenalan objek yang terkandung pada citra, melakukan kompresi atau reduksi data untuk tujuan penyimpanan data, transmisi data dan waktu proses data.
3. Klasifikasi Proses pengenalan informasi yang lebih spesifik pada obyek tertentu dari hasil ekstraksi.

Pengolahan citra digital digunakan untuk melakukan rekayasa dengan menggunakan komputer terhadap gambar 2 dimensi. Dalam konteks yang lebih luas, pengolahan citra digital mengacu pada pengolahan setiap data dari gambar 2 dimensi. Teknik yang dilakukan dalam pengolahan citra digital adalah melakukan manipulasi nilai pada masing-masing piksel. Citra digital merupakan sebuah larik (array) yang berisi nilai-nilai real maupun kompleks yang direpresentasikan dengan deretan bit tertentu. Gambaran mengenai koordinat citra digital ditunjukkan oleh Gambar 2.1.



Gambar 2.1 Koordinat Citra Digital

Citra digital juga memiliki kanal warna dasar yang terdiri dari merah, hijau dan biru sehingga dikelan dengan citra RGB. Bentuk persamaan matrik dari citra digital ditulis seperti persamaan 1 sebagai berikut:

$$f(x,y) = \begin{pmatrix} f(0,0) & \dots & f(0,N-1) \\ \vdots & \ddots & \vdots \\ f(M-1,0) & \dots & f(M-1,N-1) \end{pmatrix} \quad (2.1)$$

Keterangan :

- x = sumbu x
- y = sumbu y
- f = titik koordinat
- M = nilai x
- N = nilai y

2.3 Konversi Citra RGB ke Grayscale

LBP mengekstraksi fitur dari citra grayscale saja, sehingga diperlukan konversi dari citra RGB ke grayscale dengan menambah nilai kanal warna (r.g.b) pada masing masing piksel suatu citra menjadi nilai citra grayscale dengan nilai s. Proses konversi cira RGB menjadi grayscale adalah mengambil nilai rata-rata r, g dan b sehingga persamaanya dapat dituliskan seperti pada persamaan 2.2.

$$s = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (2.2)$$

2.4 Penajaman Citra

Salah satu jenis pengolahan citra adalah kualitas citra. Perbaikan kualitas citra (image enhancement) adalah operasi yang bertujuan untuk memperbaiki kualitas citra dengan cara memanipulasi parameter-parameter citra. Dengan operasi ini ciri-ciri khusus yang terdapat pada citra lebih ditonjolkan. Yang termasuk dalam klasifikasi ini antara lain:

- a. Perbaikan kontras gelap/terang (contrast enhancement)
- b. Perbaikan tepian objek (edge enhancement)
- c. Penajaman (Sharpening)
- d. Pemberian warna semu (Pseudocoloring)
- e. Penyaringan derau (noise filtering)

Penajaman citra atau biasa disebut dengan transformasi ini digunakan dalam meningkatkan kontras warna dan cahaya pada suatu citra. Proses ini dilakukan untuk mempermudah dalam proses interpretasi dan analisis citra. Penajaman kontras dalam citra merupakan cara untuk memperbaiki tampilan dengan memaksimumkan kontras antara pencahayaan dan penggelapan atau menaikkan dan merendahkan harga suatu data citra.

Proses penajaman citra dilakukan untuk mempermudah pengguna dalam menginterpretasikan objek yang ada pada tampilan citra. Dengan proses Algoritma dapat mempermudah pengguna melakukan berbagai macam proses penajaman citra. Jenis-jenis operasi penajaman citra meliputi:

1. Penggabungan Data (*Data fusion*), menggabungkan citra dari sumber yang berbeda pada area yang sama untuk membantu di dalam interpretasi.
2. *Colodraping*, menempelkan satu jenis data citra di atas data yang lainya untuk membuat suatu kombinasi tampilan sehingga memudahkan untuk menganalisa dua atau lebih variabel. Contoh citra vegetasi dari satelit di colordraping di atas citra foto udara pada area yang sama.
3. Penajaman kontras, memperbaiki tampilan citra dengan memaksimumkan kontras antara pencahayaan dan penggelapan atau menaikkan dan merendahkan harga data suatu citra.
4. Filtering, memperbaiki tampilan citra dengan mentransformasikan nilai-nilai digital citra, seperti mempertajam batas area yang mempunyai nilai digital yang sama (*enhance edge*), menghaluskan citra dari *noise* (*smooth noise*).
5. Klasifikasi, menampilkan citra menjadi kelas-kelas tertentu secara statistik berdasarkan nilai digitalnya.
6. Penajaman tepi (*sharpening edge*). Bertujuan memperjelas tepi pada objek di dalam citra. Penajaman citra merupakan kebalikan dari operasi pelembutan karena operasi ini menghilangkan bagian citra yang lembut.

Operasi penajaman dilakukan dengan melewati citra pada penapis lolos tinggi (*high pass filter*). Penapis lolos tinggi akan meloloskan (memperkuat) komponen yang berfrekuensi tinggi (tepi/pinggir objek) dan akan menurunkan komponen berfrekuensi rendah. Akibatnya pinggiran akan terlihat lebih tajam dibandingkan sekitarnya.

Dengan melakukan penajaman citra menggunakan metode *high-pass filter* didapatkan citra yang memberikan kesan dari pola tekstur kayu lebih tegas dan selanjutnya dilakukan ekstraksi fitur menggunakan LBP. Proses penajaman citra pada penelitian ini lebih difokuskan pada tekstur kayu agar lebih baik dalam proses klasifikasi.

2.5 Local Binary Pattern (LBP)

Local Binary Pattern diperkenalkan pertama kali pada tahun 1992 oleh Timo Ojala dan David Harwood di Universitas Maryland. LBP didefinisikan sebagai perbandingan nilai biner piksel pada pusat gambar dengan 8 nilai piksel disekelilingnya (M. P. Inen, 2011). Local Binary Pattern merupakan deskriptor untuk mengklarifikasi gambar berdasarkan tekstur gambar. Jadi, sebuah gambar yang berukuran 3x3, dimana nilai biner pada pusat gambarnya dibandingkan dengan nilai sekelilingnya. Jika intensitas piksel tengah lebih besar dari pada biner pusat maka nilai yang ditetapkan 1, Jika lebih kecil maka 0. Dengan 8 piksel disekelilingnya berarti bahwa ada 256 kemungkinan kombinasi kode Local Binary Pattern.

Membangun *Local Binary Pattern* yaitu perbandingan nilai biner piksel pada pusat gambar dengan 8 nilai piksel disekelilingnya. Selanjutnya menghitung nilai Local Binary Pattern untuk piksel yang ditengah mulai dari piksel disekelilingnya dengan cara clockwise (searah jarum jam) atau counter-clockwise (berbalik arah jarum jam) dengan syarat harus konsisten. Misal 3 x 3 berarti ada 8 tes biner. Kemudian hasil uji biner disimpan dalam array 8 bit yang diubah menjadi desimal.

$$LBP_{P,R} = \sum_{p=0}^{p-1} s(g_p - g_c) 2^p \quad (2.3)$$

Keterangan :

- R = radius
 P = sampling poin
 g_p = piksel ketetanggaan
 g_c = piksel pusat
 s = fungsi s

Tahap pertama perhitungan *Local Binary Pattern* (LBP) dengan melakukan perbandingan nilai tetangga piksel terdekat pada nilai tengah piksel atau nilai titik pusat kernel pada citra hasil pra-pemrosesan dengan nilai *grayscale*.

$$s(x) = \begin{cases} 0, & \text{jika } x < 0 \\ 1, & \text{jika } x \geq 0 \end{cases} \quad (2.4)$$

Pada proses perbandingan nilai *grayscale*, apabila nilai tetangga piksel lebih besar atau sama dengan nilai pusat piksel, maka hasil perbandingan akan diberikan nilai 1 pada nilai tetangga piksel dan sebaliknya apabila nilai tetangga piksel lebih kecil dari nilai pusat piksel maka hasil perbandingan akan diberikan nilai 0 pada nilai tetangga piksel. Proses ini dilakukan secara berurutan dimulai dari pojok kiri atas pada (perbandingan nilai pusat 8 dan nilai tetangga 10) dan seterusnya mengikuti perputaran arah jarum jam (dilihat pada panah merah) atau sebaliknya berlawanan dengan arah jarum jam.

2.6 Momen *Invariant*

Momen invariant orde pertama adalah dasar dalam analisis citra dan pengenalan pola, memberikan informasi penting seperti lokasi pusat massa (*centroid*) dari obyek dalam citra. Meskipun belum invariant terhadap semua transformasi geometris, momen-momen ini membentuk landasan bagi perhitungan momen invariant yang lebih kompleks dan berguna dalam berbagai aplikasi pengolahan citra.

Secara khusus, momen orde pertama mencakup perhitungan posisi relatif objek dalam gambar, yang kemudian digunakan untuk normalisasi citra, memungkinkan algoritma pengenalan pola untuk bekerja lebih efektif

meskipun ada variasi translasi. Momen-momen ini kemudian berfungsi sebagai dasar untuk menghitung momen ordo lebih tinggi yang invarian terhadap rotasi, skala, dan translasi, yang sangat berguna dalam visi komputer dan aplikasi pengenalan pola. Ada 4 perhitungan momen invarian dalam ordo pertama yaitu *Mean*, *Strandard Deviation*, *Skewness*, dan *Kurtosis*. Berikut adalah penjelasan dan perhitungannya :

a. Mean

Mean atau rata-rata adalah nilai yang mewakili himpunan atau sekelompok data. Mean didapat dengan menjumlahkan seluruh data individu dalam kelompok, kemudian dibagi dengan jumlah individu yang ada dalam kelompok. Rumus untuk menghitung mean sebagai berikut.

$$E_i = \sum_j^N = 1 \frac{1}{N} P_{i j} \quad (2.5)$$

Keterangan :

E_i = skor rata – rata

N = total piksel yang dimiliki oleh citra

j = kelas dari data (kelas jenis kayu)

$P_{i j}$ = kemungkinan muncul nilai i dan j

b. Standard Deviation

Standar deviasi adalah suatu pengukuran penyebaran dari suatu set data dari rata-ratanya. Standar deviasi dihitung sebagai akar kuadrat dari varians dengan menentukan variasi antara setiap titik data relatif terhadap rata-rata. Jika titik data lebih jauh dari rata-rata, menunjukkan ada penyimpangan yang lebih tinggi dalam kumpulan data. Standar deviasi dihitung berdasarkan rata-rata. Jarak setiap titik data dari rata-rata dikuadrat, kemudian dijumlah dan dirata-ratakan untuk mendapatkan nilai variansnya. Dengan kata lain, Varians diturunkan dengan mengambil rata-rata titik data, mengurangi rata-rata dari setiap titik data satu per satu, dan mengkuadratkan masing-masing hasil ini dan kemudian mengambil titik lain dari kuadrat ini. Singkatnya, varians adalah rata-rata perbedaan kuadrat dari mean dan standar deviasi adalah akar kuadrat dari varians. dari Rumus standar deviasi dapat dilihat pada persamaan (6) berikut:

$$\sigma_i = \sqrt{\left(\frac{1}{N} \sum_j (P_{ij} - E_i)^2\right)} \quad (2.6)$$

Keterangan :

σ_i = skor *standard deviation*

N = total dari seluruh piksel yang dimiliki oleh citra

j = kelas dari data (kelas jenis kayu)

i = total data yang ada dikelas

P_{ij} = total data *ke- i* dan skor piksel *ke- j*

E_i = skor rata – rata

c. *Skewness*

Skewness adalah derajat asimetri atau jarak dari simetri suatu distribusi. *Skewness* didefinisikan sebagai kemiringan sebaran data. Rata-rata, median, dan modus suatu distribusi asimetris besarnya tidak sama, sehingga distribusinya akan terkonsentrasi pada satu sisi dan kurvanya akan melengkung. Ukuran kemiringan suatu kurva adalah derajat atau ukuran asimetri sebaran data. Jika nilainya antara -2 dan 2, nilai *skewness* (ukuran kemiringan) menampilkan data normal. Jika mean yang dihitung > modus/median, maka kurvanya positif. Jika *mean* aritmatika < modus/median, kurvanya negatif. Jika ekor di sebelah kanan suatu distribusi lebih panjang daripada ekor di sebelah kiri, maka distribusi tersebut dikatakan miring ke kanan, atau mempunyai kemiringan positif. Sebaliknya, jika ekor kiri suatu distribusi lebih panjang dari ekor kanannya, maka distribusi tersebut dikatakan miring ke kiri atau mempunyai kemiringan negatif. Rumus untuk menghitung *skewness* sebagai berikut.

$$\sigma_i = \frac{1}{N} \sum_{i=1}^N \left(\frac{P_{ij} - E_i}{N}\right)^3 \quad (2.7)$$

Keterangan :

σ_i = skor *Skewness*

N = total dari seluruh piksel yang dimiliki oleh citra

j = kelas dari data (kelas jenis kayu)

i = total data yang ada dikelas

P_{ij} = total data *ke- i* dan skor piksel *ke- j*

E_i = skor rata – rata

d. *Kurtosis*

Kurtosis adalah sebuah konsep dalam statistika yang mengukur tingkat "kepuncakan" atau "kemiringan" dari sebuah distribusi data. Secara spesifik, *kurtosis* menggambarkan seberapa tajam atau datar puncak distribusi data tersebut dibandingkan dengan distribusi normal. Distribusi data dengan *kurtosis* yang tinggi memiliki puncak yang lebih tinggi dan lebih tajam, sementara distribusi dengan *kurtosis* rendah memiliki puncak yang lebih datar. *Kurtosis* merupakan salah satu dari empat momen statistik, bersama dengan mean, variance, dan skewness, yang digunakan untuk menggambarkan sifat-sifat distribusi data. Konsep *kurtosis* digunakan dalam berbagai bidang, termasuk statistika, keuangan, ilmu sosial, dan analisis citra.

$$\sigma_i = \frac{1}{N} \sum_{i=1}^N \left(\frac{P_{ij} - E_i}{\sigma} \right)^4 \quad (2.8)$$

σ_i = skor *kurtosis*

N = total dari seluruh piksel yang dimiliki oleh citra

j = kelas dari data (kelas jenis kayu)

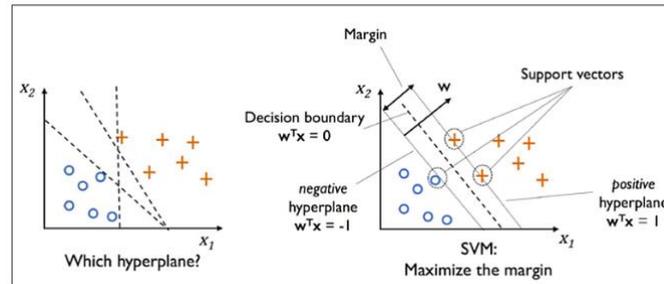
i = total data yang ada dikelas

P_{ij} = total data ke- i dan skor piksel ke- j

E_i = skor rata – rata

2.7 *Support Vector Machine (SVM)*

Metode SVM (*Support Vector Machine*) merupakan salah satu metode dalam machine learning yang digunakan untuk klasifikasi dan regresi. SVM bekerja dengan cara mencari hyperplane terbaik yang memisahkan dua kelas data dalam ruang fitur (feature space). Hyperplane ini dipilih sedemikian rupa sehingga jarak (margin) antara hyperplane dan instance terdekat dari masing-masing kelas (yang disebut support vectors) maksimal.



Gambar 2.2 Contoh Gambar *Hyperlane*

Hyperplane yang ditemukan SVM diilustrasikan seperti Gambar 2.2 posisinya berada ditengah-tengah antara dua kelas, artinya jarak antara hyperplane dengan objek-objek data berbeda dengan kelas yang berdekatan (terluar) yang diberi tanda bulat kosong dan positif. Dalam SVM objek data terluar yang paling dekat dengan hyperplane disebut support vector. Objek yang disebut support vector paling sulit diklasifikasikan dikarenakan posisi yang hampir tumpang tindih (overlap) dengan kelas lain. Mengingat sifatnya yang kritis, hanya support vector inilah yang diperhitungkan untuk menemukan hyperplane yang paling optimal oleh SVM.

Rumus umum untuk hyperplane dalam SVM untuk klasifikasi biner adalah:

$$f(x) = \text{sign}(w \cdot x + b) \quad (2.9)$$

keterangan :

$f(x)$ = fungsi keputusan yang memberikan label kelas untuk instance x .

w = vektor bobot.

x = vektor fitur dari instance.

b = bias.

Tujuan dari SVM adalah untuk menemukan w dan b yang memaksimalkan margin, dengan memecahkan masalah optimasi sebagai berikut:

$$\text{minimize } \left(\frac{1}{2} \|w\|^2\right) \quad (2.10)$$

Dengan kendala:

$$y_i (w \cdot x_i + b) \geq 1 \quad (2.11)$$

Dimana y_i adalah label kelas dari instance x_i .

Saat terjadi ketidaklinieran pada data, SVM juga dapat menggunakan fungsi kernel (seperti kernel linear, polynomial, atau radial basis function) untuk memetakan data ke dalam ruang dimensi yang lebih tinggi sehingga data menjadi linier terpisah. Dalam kasus ini, rumus SVM menjadi sedikit berubah dengan penambahan fungsi kernel. SVM merupakan salah satu metode yang kuat dan umum digunakan dalam klasifikasi, terutama ketika data memiliki dimensi tinggi dan jumlah fitur yang besar.

2.8 Softmax

Data keluaran yang dihasilkan dari algoritma SVM berupa nilai prediksi dan nilai data *softmax* hasil klasifikasi yang menampilkan hasil dari nilai tertinggi yang didapat dari nilai prediksi. Nilai yang memiliki angka tertinggi dari hasil kemungkinan merupakan hasil dari pengklasifikasian tersebut. Data *softmax* dari pengolahan SVM menghasilkan nilai pada setiap jenis kayu kemudian dari hasil output tersebut dicari nilai tertinggi daripada hasil output yang lainnya. Dari data softmax tersebut menghasilkan satu jenis klasifikasi yang ditampilkan dari tiga jenis kayu yang diteliti, keluaran akhir pada penelitian ini adalah keterangan jenis kayu.

2.9 Confusion Matrix

Pengujian penelitian ini menggunakan confusion matrix. Menurut Han & Kember (2012), pengujian ini digunakan untuk mengukur kemampuan atau sebagai tingkat pengakuan algoritma dalam klasifikasi data. Dengan demikian parameter benar dan salah dalam pengklasifikasian data uji pada kelas yang berbeda merupakan proses confusion matrix.

Tabel 2.1 *Confusion Matrix*

<i>Three-Class Prediction</i>		<i>Prediction Class</i>		
		1	2	3
<i>Actual</i>	1			

Class	2			
	3			

Jika dalam actual class data termasuk kedalam predicted class dan pada saat dilakukan proses prediksi menghasilkan kelas yang sama dengan actual class maka disebut true positive atau true negative. Sedangkan prediksi yang salah dalam klasifikasi yang menghasilkan prediksi kelas lain disebut false positive dan prediksi yang salah dalam klasifikasi yang menghasilkan prediksi kelas lain disebut false negative. Dalam menentukan nilai akurasi tersebut, dapat dihitung menggunakan rumus:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.12)$$

$$Precision = \frac{TP}{TP + FP} \quad (2.13)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.14)$$

$$Specifity = \frac{TN}{TN + FP} \quad (2.15)$$

Keterangan :

TP : Jumlah data *true positive*

TN : Jumlah data *true negative*

FP : Jumlah data *false positive*

FN : Jumlah data *true negative*