

BAB II

LANDASAN TEORI

1.1.KELAPA SAWIT


Tanaman kelapa sawit merupakan salah satu komoditi perkebunan yang memiliki nilai jual yang cukup tinggi dan penyumbang devisa terbesar bagi negara Indonesia dibandingkan dengan komoditi perkebunan lainnya. Setiap tanaman memiliki morfologi yang berbeda-beda cirinya dan fungsinya yang dijual. Tanaman kelapa sawit secara morfologi terdiri atas bagian vegetatif (akar, batang, dan daun) dan bagian generatif (bunga dan buah) (Sunarko, 2007).

Tanaman kelapa sawit berkembang biak dengan biji dan akan berkecambah untuk selanjutnya tumbuh menjadi tanaman. Susunan buah kelapa sawit dari lapisan luar sebagai berikut :

1. Kulit buah yang licin dan keras (*epicarp*).
2. Daging buah (*mesocarp*) terdiri atas susunan serabut (*fibre*) dan mengandung minyak.
3. Kulit biji (cangkang/tempurung), berwarna hitam dan keras (*endocarp*).
4. Daging biji (*mesoperm*), berwarna putih dan mengandung minyak.
5. Lembaga (*embrio*). Lembaga yang keluar dari kulit biji akan berkembang ke dua arah :
 - a. Arah tegak lurus ke atas (*foto trophy*), disebut plumula yang selanjutnya akan menjadi batang dan daun kelapa sawit.
 - b. Arah tegak lurus ke bawah (*geotrophy*), disebut radikula yang selanjutnya akan menjadi akar (Sunarko, 2009).

Volume Ekspor Minyak Kelapa Sawit Indonesia (Mei 2021-Mei 2022)

Gambar 2. 1 Diagram batang ekspor minyak kelapa sawit Indonesia (Liputan 6.com)




Dari data Gabungan Pengusaha Kelapa Sawit Indonesia (GAPKI), volume ekspor minyak kelapa sawit Nasional pada Mei 2022 hanya mencapai 678 ribu ton. Jumlah tersebut menurun sebesar 68% dari volume ekspor April 2022 yang mencapai 2,1 juta ton. Penurunan drastis ini terjadi akibat pelarangan ekspor minyak sawit yang diberlakukan selama periode 28 April-22 Mei 2022. Kebijakan larangan ekspor tersebut tidak hanya berpengaruh terhadap pencapaian ekspor, tetapi juga terhadap produksi. Secara agronomis, produksi TBS tanaman meningkat, tetapi secara industri produksi CPO 18% lebih rendah dari produksi bulan April.

Penelitian ini fokus pada tanaman kelapa sawit sebagai tanaman perkebunan yang saat ini banyak diusahakan oleh petani pekebun dan perusahaan. Tanaman ini menghasilkan buah kelapa sawit yang dikenal sebagai tandan buah segar (TBS). Proses pertumbuhan dan perkembangan tanaman kelapa sawit dimulai dengan berbunga dan membentuk buah sekitar usia 2-3 tahun. Buah akan mencapai kematangan sekitar 5-6 bulan setelah proses penyerbukan (Sukadi, dkk 2014). Dalam penelitian ini, untuk mengetahui tingkat kesuburan tanaman kelapa sawit, peneliti menggunakan data penginderaan jauh dari citra satelit. Metode ini digunakan untuk memperoleh informasi yang akurat mengenai kesuburan tanaman kelapa sawit berdasarkan analisis citra satelit tersebut.

1.2.PENGINDERAAN JAUH

Penginderaan Jauh adalah ilmu dan seni untuk memperoleh informasi tentang suatu objek, daerah, atau fenomena melalui analisis data yang diperoleh dengan suatu alat tanpa kontak langsung dengan objek, daerah, atau fenomena yang dikaji (Purwadhi, 2001). Data Penginderaan Jauh dapat berupa citra, grafik, dan data numerik. Data tersebut dianalisis untuk mendapatkan informasi tentang objek, daerah, atau fenomena yang diindera atau diteliti. Proses penerjemahan data menjadi informasi disebut analisis dan interpretasi data.

Menurut Tindal (2006) komponen sistem penginderaan jauh terdiri atas sumber energi, radiasi (melalui atmosfer), interaksi (tenaga dan objek), sensor perekam, transmisi, resepsi, dan pemrosesan, interpretasi dan analisis (operator), dan aplikasi. Suatu sistem dapat bekerja secara optimal jika masing-masing komponen penyusunnya bekerja sama secara serasi dan seimbang. Komponen sistem penginderaan jauh secara garis besar dapat dibagi menjadi 3 komponen, yakni alami, teknologi, dan manusia. Sistem penginderaan jauh diilustrasikan oleh gambar 2.2 berikut ini.



Gambar 2. 2 komponen-komponen system pengindraan jauh

Keterangan:

A = Sumber tenaga

B = Atmosfer

C = Interaksi tenaga dengan objek

D = Sensor (terpasang pada pesawat terbang atau satelit)

E = Perolehan data (dikirim melalui stasiun-stasiun penerima)

F = Pengguna (mengolah dan menganalisis citra)

G = Informasi (basis data, pemetaan dan rekomendasi kebijakan).

Analisis data Penginderaan Jauh memerlukan data rujukan seperti peta tematik, data statistik, dan data lapangan. Tujuan dari analisis ini adalah untuk memperoleh informasi tentang bentang lahan, jenis penutup lahan, kondisi lokasi, dan kondisi sumber daya daerah yang diindera (Purwadhi, 2001). Salah satu informasi penting yang diperoleh dari analisis penginderaan jauh adalah jenis penutupan lahan, yang merupakan parameter fisik yang sangat berguna untuk berbagai analisis dan evaluasi dalam aplikasi penginderaan jauh.

Proses mendapatkan informasi tentang jenis penutupan lahan ini melibatkan interpretasi citra satelit maupun foto udara. Data citra satelit, khususnya citra dari satelit Landsat, sering digunakan dalam aplikasi penginderaan jauh karena kualitasnya yang baik untuk interpretasi penutupan lahan pada daerah yang luas.

Dengan menggabungkan data rujukan seperti peta tematik, data statistik, dan data lapangan dengan hasil interpretasi citra satelit, analisis Penginderaan Jauh dapat memberikan informasi yang berharga dalam memahami dan memanfaatkan sumber daya daerah serta membantu dalam pengambilan keputusan dalam berbagai bidang. Data penginderaan jauh yang digunakan pada penelitian ini adalah citra satelit landsat 8.

2.3. CITRA SATELIT LANDSAT 8

Satelit Landsat 8 berhasil diluncurkan NASA pada tanggal 11 Februari 2013 lalu bertempat di *vandenberg air force base*, California. periode *checkout* sekitar 100 hari setelah peluncuran memungkinkan pesawat ruang angkasa untuk melakukan manuver orbit, sistem inisialisasi dan kalibrasi kegiatan, dan pindah ke grid WRS-2, 438 mil di atas Bumi, ketika *checkout* selesai USGS mengambil kendali. Landsat 8 akan mengorbit setiap 99 menit dan gambar seluruh bumi setiap 16 hari, mengumpulkan pada akuisisi jadwal yang sama. Karakteristik dari citra Landsat 8 ini adalah menggunakan sensor *operational land manager (OLI)* dengan selang band yang lebih pendek dan tambahan dua band tambahan (9 Band). Citra Landsat 8 disinyalir memiliki akurasi geodetik dan geometrik yang lebih baik. Berikut adalah spesifikasi Landsat 8: (Firmansyah, 2014) Orbit.



Gambar 2. 3 Satelit Landsat 8 (L.M Jaelani, 2013)

Secara umum, karakteristik satelit Landsat 8 adalah sebagai berikut:



Band	Panjang Gelombang (micrometer)	Resolusi (meter)
Band 1 - Coastal aerosol	0.43 – 0.45	30
Band 2 – Blue	0.45 – 0.51	30
Band 3 - Green	0.53 – 0.59	30
Band 4 - Red	0.64 – 0.67	30


Band 5 – Near Infrared (NIR)	0.85 – 0.88	30
Band 6 - SWIR 1	1.57 – 1.65	30
Band 7 - SWIR 2	2.11 – 2.29	30
Band 8 - Panchromatic	0.50 – 0.68	15
Band 9 - Cirrus	1.36 – 1.38	30
Band 10 – Thermal Infrared (TIRRS) 1	10.60 – 11.19	100
Band 11 – Thermal Infrared (TIRS) 2	11.50 – 12.51	100

Tabel 2. 1 Karakteristik Citra Landsat 8 (L.M Jaelani 2013)

kombinasi band pada Landsat 8 adalah sebagai berikut:

	Komposit warna natural menggunakan kombinasi band <i>red</i> (4), <i>green</i> (3), dan <i>blue</i> (2). Ini mereplikasi dekat dengan apa yang biasa dilihat mata manusia. Sementara vegetasi yang sehat berwarna hijau, flora yang tidak sehat berwarna coklat. Perkotaan tampak putih, abu-abu dan air berwarna biru tua atau hitam.
---	---

	Kombinasi pita ini juga disebut komposit <i>Near-Infrared (NIR)</i>. Ini menggunakan <i>near infrared</i> (5), <i>red</i> (4), dan <i>green</i> (3). Karena klorofil memantulkan cahaya <i>near infrared</i>, komposisi band ini berguna untuk menganalisis vegetasi. Secara khusus, area dengan warna merah memiliki kesehatan vegetasi yang lebih baik. Daerah gelap adalah air dan daerah perkotaan berwarna putih.
	Kombinasi band <i>short-wave infrared</i> menggunakan <i>SWIR-2</i> (7), <i>SWIR-1</i> (6), dan <i>red</i> (4). Komposit ini menampilkan vegetasi dalam nuansa hijau. Sementara warna hijau yang lebih gelap menunjukkan vegetasi yang lebih padat, vegetasi yang jarang memiliki warna yang lebih terang. Daerah perkotaan berwarna biru dan tanah memiliki berbagai corak coklat.

	Kombinasi pita ini menggunakan <i>SWIR</i>-1 (6), <i>near infrared</i> (5), dan <i>blue</i> (2). Ini biasanya digunakan untuk pemantauan tanaman karena penggunaan <i>short wave</i> dan <i>near infrared</i>. Vegetasi yang sehat tampak hijau tua. Tapi tanah kosong memiliki rona magenta.
	Kombinasi pita geologi menggunakan <i>SWIR</i>-2 (7), <i>SWIR</i>-1 (6), dan <i>blue</i> (2). Kombinasi pita ini sangat berguna untuk mengidentifikasi informasi geologi, fitur litologi, dan patahan.
	Kombinasi band batimetri (4,3,1) menggunakan band red (4), <i>green</i> (3), dan band coastal. Band coastal berguna dalam studi pesisir, batimetri, dan aerosol karena memantulkan warna biru dan ungu. Kombinasi band ini baik untuk memperkirakan sedimen tarsus pensi di dalam air.

Tabel 2. 2 Kombinasi Band Landsat 8 (Matakuliah Penginderaan jauh)

2.4. Koreksi Radiometrik

Danoedoro (1996) menyatakan bahwa koreksi radiometrik diperlukan untuk meningkatkan kualitas visual citra dan menyesuaikan nilai piksel yang tidak sesuai dengan nilai pantulan atau pancaran yang sebenarnya. Koreksi radiometrik bertujuan untuk mengisi kembali baris yang kosong pada citra serta mengoreksi nilai piksel yang tidak sesuai dengan cara mengambil nilai piksel satu baris di atas dan di bawahnya, lalu dirata-ratakan.

Salah satu bentuk koreksi radiometrik adalah konversi nilai digital number ke reflektansi. Konversi ini digunakan untuk memproses algoritma indeks vegetasi yang memerlukan data nilai reflektansi dari citra yang digunakan. Proses konversi nilai digital number ke reflektansi diperoleh dengan menggunakan persamaan yang telah dijabarkan oleh Kusumaningrum (2014).

$$\rho\lambda = M_p Q_{cal} + A_p \quad \dots (2.1)$$

dimana :

$\rho\lambda$ = TOA planetary reflectance, without correction for solar angle

M_p = Band Specific multiplicative scaling factor from the meta data

A_p = Band Specific additive scaling factor from the meta data

Q_{cal} = Quantize and Calibrate standard product pixel values (DN)

2.5. NDVI (Normalized Difference Vegetation Index)

NDVI (Normalized Difference Vegetation Index) adalah metode penghitungan citra yang digunakan untuk mengukur tingkat kehijauan suatu daerah, dan ini sangat bermanfaat sebagai langkah awal dalam pemetaan vegetasi. NDVI dapat memberikan informasi tentang parameter yang terkait dengan vegetasi, seperti biomassa dedaunan hijau dan luas daerah dedaunan hijau, yang dapat digunakan untuk memetakan wilayah vegetasi.

Perhitungan NDVI didasarkan pada citra yang menggunakan data dari channel 1 dan channel 2. Channel 1 mencakup wilayah spektral yang mengandung klorofil, yang menyebabkan penyerapan radiasi cahaya selama proses fotosintesis. Sementara itu, channel 2 mencakup wilayah spektral yang

menunjukkan struktur sel daun yang disebut *spongy mesophyll*, yang menyebabkan pantulan radiasi cahaya. Dengan menggunakan perbandingan nilai dari channel 1 dan channel 2 dalam citra, NDVI dapat memberikan gambaran tentang tingkat kehidupan vegetasi di wilayah yang diamati. Informasi ini sangat berharga dalam pemetaan dan pemahaman tentang kondisi vegetasi dan lingkungan. (Indrayanti, 2013).

Perbandingan antara kedua channel digunakan sebagai pertimbangan untuk mengurangi variasi yang disebabkan oleh topografi dari permukaan bumi. Meskipun perbandingan ini tidak menghilangkan efek tambahan yang disebabkan oleh attenuasi atmosfer, namun merupakan komponen penting dalam perhitungan NDVI dan korelasi dengan vegetasi. Latar belakang daratan berfungsi sebagai pemantul sinyal yang terpisah dari vegetasi, dan berinteraksi dengan vegetasi melalui hamburan energi radiasi yang kompleks. Formula NDVI yang digunakan adalah (Indrayanti, 2013):

$$NDVI = \frac{NIR - red}{NIR + red}$$

NDVI (*Normalized Difference Vegetation Index*) dihitung dengan membandingkan nilai dari dua band pada citra, yaitu band *Near Infrared* (NIR) dan band merah (*red*). Rentang nilai NDVI berkisaran antara -1.0 hingga +1.0. Nilai NDVI yang lebih besar dari 0.1 biasanya menunjukkan peningkatan tingkat kehijauan dan intensitas dari vegetasi. Nilai NDVI untuk permukaan vegetasi bervariasi mulai dari 0.1 untuk lahan savana (padang rumput) hingga 0.8 untuk daerah hutan hujan tropis. Semakin tinggi nilai NDVI, semakin banyak vegetasi yang ada di suatu wilayah. Perhitungan NDVI dilakukan dengan mengurangkan nilai dari band 2 (*NIR*) dan band 1 (*red*), kemudian hasilnya dijumlahkan. Hasil perhitungan ini menghasilkan nilai NDVI.

Tabel 2.5.1 menunjukkan pembagian kelas nilai indeks vegetasi (NDVI), yang digunakan untuk mengklasifikasikan tingkat kehijauan dan vegetasi pada wilayah yang diamati.

Kelas	Kisaran NDVI
Kesehatan Kurang	-1s.d 0.22
Kesehatan Normal	0.22s.d 0.51
Kesehatan Baik	0.51s.d1

Tabel 2. 3 Pembagian Kelas erdasarkan Nilai NDVI (Rahaldi 2013)

Tingkat kesuburan tanaman mengacu pada table 2.5.1 karna tanaman dinyatakan sehat apabila tanaman tersebut memiliki pertumbuhan baik (daun dan batang segar)

2.6.KLASIFIKASI TERSELIA

Klasifikasi terselia (*supervised classification*) adalah metode klasifikasi nilai piksel yang didasarkan pada daerah yang memiliki jenis obyek dan nilai spektral yang diketahui sebelumnya. Contoh dari daerah-daerah ini disebut sebagai sampel, dan lokasi geografis dari kelompok piksel sampel ini disebut sebagai daerah training (*training area*) (Danoedoro, 1996). Dengan demikian, kita telah mengetahui land cover atau jenis penutupan lahan dari daerah-daerah training yang telah ditentukan sebelumnya. *Training area* ini merupakan contoh sampel dari kelas-kelas yang sudah kita ketahui dengan pasti melalui pengamatan di lapangan.

Klasifikasi terselia sering digunakan untuk meningkatkan hasil klasifikasi citra, karena mengandalkan informasi yang sudah diketahui dan diidentifikasi secara akurat dari daerah training. Dengan menggunakan informasi ini, algoritma klasifikasi dapat mengidentifikasi pola dan hubungan antara nilai spektral piksel dengan jenis penutupan lahan yang sesuai. Hal ini memungkinkan untuk mengklasifikasikan seluruh citra dengan lebih akurat dan efisien (Purwadhi, 2001).

Algoritma klasifikasi terselia yang umum digunakan adalah sebagai berikut:

1. Klasifikasi Berdasarkan Jarak Minimum Rata-Rata Kelas.

Klasifikasi berdasarkan jarak minimum rata-rata kelas adalah metode klasifikasi yang menggunakan pendekatan yang sangat sederhana. Metode ini melibatkan penentuan nilai rata-rata dari setiap kelas, yang

disebut sebagai vektor rata-rata (*meanvector*). Namun, metode ini memiliki keterbatasan karena kurang peka terhadap perbedaan varian dari tanggapan spektral di dalam kelas tersebut (Purwadhi, 2001).

Dengan kata lain, metode klasifikasi ini hanya mempertimbangkan nilai rata-rata dari masing-masing kelas untuk menentukan keanggotaan piksel. Namun, metode ini tidak memperhatikan variasi atau sebaran data dalam kelas tersebut. Akibatnya, jika ada perbedaan yang signifikan dalam varian spektral di dalam kelas, metode ini mungkin menghasilkan hasil klasifikasi yang kurang akurat atau tidak optimal.

Dalam praktiknya, klasifikasi berdasarkan jarak minimum rata-rata kelas sering digunakan sebagai langkah awal atau pendekatan kasar dalam proses klasifikasi citra, tetapi metode yang lebih canggih dan sensitif terhadap variasi data, seperti metode klasifikasi berbasis probabilitas atau berbasis pembelajaran mesin, sering diterapkan untuk meningkatkan akurasi hasil klasifikasi.

2. Klasifikasi Berdasarkan Strategi *Parallelepiped*

Metode klasifikasi *parallelepiped* merupakan strategi yang sensitif terhadap variasi nilai dalam kategori-kategori tertentu. Cara kerja metode ini adalah dengan memperhitungkan rentang nilai digital dari setiap kategori piksel "training" sampel. Dengan mempertimbangkan rentang nilai ini, metode *parallelepiped* mampu mengidentifikasi variasi yang ada dalam masing-masing kategori dan membedakan kelas dengan lebih akurat.

Klasifikasi menggunakan strategi *parallelepiped* memiliki keunggulan karena proses pengklasifikasinya sangat cepat dan efisien. Metode ini dapat diterapkan dalam berbagai sistem analisis citra karena kemampuannya untuk secara otomatis menentukan batas-batas dan batasan kategori dengan cepat.

Dalam keseluruhan, metode klasifikasi *parallelepiped* menjadi pilihan yang baik ketika efisiensi waktu dan ketepatan klasifikasi menjadi perhatian utama dalam analisis citra. Namun, seperti halnya

metode klasifikasi lainnya, penting untuk mempertimbangkan kecocokan metode ini dengan data dan tujuan analisis secara keseluruhan. (Purwadhi, 2001).

3. Klasifikasi Berdasarkan Fungsi Normal “Gauss” Kemiripan Maksimum

Metode klasifikasi ini menggunakan sampel pelatihan yang memiliki distribusi normal, di mana penutup lahan dianggap sebagai vektor rata-rata dan kovarian matriks. Dengan demikian, probabilitas statistiknya mengikuti kurva normal (*gaussian*). Secara umum, metode klasifikasi kemiripan maksimum (*maximum likelihood*) memerlukan perhitungan yang rumit dan memakan waktu untuk mengklasifikasikan setiap piksel citra. Namun, teknik *maximum likelihood* ini menghasilkan klasifikasi yang lebih akurat dibandingkan dengan strategi lainnya.

Metode klasifikasi kemiripan maksimum memperhitungkan kesamaan statistik piksel dengan kelompok pelatihan yang ada, sehingga dapat mengidentifikasi dengan lebih baik kategori yang sesuai untuk setiap piksel. Semakin banyak saluran atau informasi spektral yang dapat digunakan dalam metode klasifikasi kemiripan maksimum, maka hasil klasifikasinya akan semakin baik dan akurat (Purwadhi, 2001).

Meskipun metode ini memerlukan perhitungan yang kompleks, keakuratannya membuatnya menjadi pilihan yang baik ketika klasifikasi dengan tingkat akurasi tinggi sangat diinginkan. Dengan mempertimbangkan fitur distribusi normal dari data pelatihan dan memanfaatkan seluruh informasi spektral yang tersedia, metode klasifikasi kemiripan maksimum dapat memberikan hasil klasifikasi yang lebih mendekati keadaan sebenarnya dalam citra.

4. Klasifikasi Tetangga Terdekat (*Knearest Neighbour*)

Sebagai salah satu variasi dari prinsip kemiripan maksimum (*maximum likelihood*) non-parametrik (Danoedoro, dkk 1996), metode klasifikasi ini menggabungkan nilai pendekatan ambang jarak spektral pada ruang fitur (*feature space*) untuk mencari sampel tetangga yang dijadikan sebagai rujukan. Nilai ambang ini disebut sebagai radius pelacakan (*searching radius*). Selain itu, radius pelacakan juga digunakan untuk menentukan fungsi penghalusan histogramnya (*histogram smoothing*). Dengan pendekatan ini, metode klasifikasi ini mengadopsi strategi kemiripan maksimum namun menggunakan pendekatan yang non-parametrik dalam mencari rujukan sampel. (Danoedoro, dkk 1996).

2.7.KLASIFIKASI TIDAK TERSELIA

Klasifikasi tak terselia (*unsupervised classification*) adalah metode klasifikasi yang tidak menggunakan daerah contoh dengan jenis obyek dan nilai spektral yang diketahui sebelumnya. Metode ini menggunakan algoritma untuk menganalisis sejumlah besar piksel yang tidak diketahui dan membaginya ke dalam sejumlah kelas berdasarkan pengelompokan nilai digital pada citra (Purwadhi, 2001). Proses klasifikasi ini berlangsung secara otomatis oleh komputer tanpa campur tangan dari operator.

Dalam klasifikasi tak terselia, komputer akan mengidentifikasi pola atau kelompok yang memiliki kesamaan nilai spektral dalam citra dan memberikan label atau kelas secara otomatis. Metode ini cocok digunakan ketika tidak ada informasi atau sampel pelatihan yang tersedia, atau ketika jumlah piksel yang harus diklasifikasikan sangat besar sehingga memerlukan pendekatan otomatis untuk mengelompokkannya ke dalam kategori tertentu.

Ada tiga algoritma klasifikasi tak terselia, yaitu jarak minimum ke pusat gugus, penggugusan statistik, dan algoritma campuran (Shrestha 1991).

1. Metode jarak minimum ke pusat gugus (*minimum distance to cluster center*) memulai tahap pertamanya dengan menginput jumlah maksimum kelas atau gugus yang diinginkan. Selanjutnya, komputer secara acak menempatkan vektor rerata sebagai titik-titik pusat gugus yang belum terbentuk. Pada tahap ketiga, berdasarkan distribusi titik-titik pusat ini, seluruh titik piksel dihitung dan diberi label sesuai dengan nama atau urutan gugus yang memiliki jarak minimum dengan titik piksel tersebut.
2. Metode penggugusan statistik (*statistical clustering*) menggunakan parameter statistik berupa nilai variansi untuk menentukan homogenitas kelas atau gugus. Algoritma ini membutuhkan beberapa masukan, yaitu: (a) jumlah maksimum gugus/kelas, (b) nilai ambang variansi, (c) jumlah pergerakan jendela pada setiap perhitungan variansi dan rerata, dan (d) nilai ambang jarak antar gugus.

Hasil dari klasifikasi ini adalah kelompok-kelompok spektral yang dihasilkan berdasarkan analisis nilai variansi dan diatur agar siap untuk diklasifikasikan menggunakan metode klasifikasi terselia (*unsupervised classification*). Metode penggugusan statistik ini bertujuan untuk mengelompokkan piksel-piksel dengan nilai spektral yang serupa dan membentuk kelas-kelas yang homogen, sehingga mempermudah proses klasifikasi selanjutnya.

3. Algoritma Campuran (*hybrid algorithm*)
4. Perhitungan nilai piksel untuk seluruh citra membutuhkan waktu dan biaya yang cukup besar. Oleh karena itu, telah dikembangkan algoritma campuran yang hanya mempertimbangkan daerah sampel yang mewakili secara spektral keseluruhan citra. Hasil dari pengelompokan spektral ini diekstraksi menjadi file terpisah dan digunakan sebagai masukan dalam proses ekstrapolasi pengelompokan untuk seluruh citra. Dengan pendekatan ini, waktu dan sumber daya yang digunakan untuk klasifikasi dapat dikurangi tanpa mengorbankan akurasi hasil klasifikasi secara keseluruhan.

2.8.KLASIFIKASI BERDASARKAN FUNGSI NORMAL “GAUSS” KEMIRIPAN MAKSIMUM


Klasifikasi berdasarkan kemiripan maksimum (*maximum likelihood*) adalah strategi klasifikasi yang menganalisis secara kuantitatif variasi dan korelasi dari pola tanggapan spektral saat mengklasifikasikan piksel yang tidak dikenal. Metode ini menggunakan training sampel yang memiliki distribusi normal, di mana penutup lahan dianggap atau diasumsikan sebagai vektor rata-rata dan matriks kovarian, sehingga probabilitas statistiknya membentuk kurva normal (*gaussian*).

Dalam metode klasifikasi kemiripan maksimum, perhitungan dilakukan dengan membandingkan nilai spektral piksel yang tidak diketahui dengan distribusi normal dari setiap kelas atau jenis penutup lahan. Dengan menghitung probabilitas untuk setiap kelas, piksel akan diklasifikasikan ke dalam kelas dengan probabilitas tertinggi. Pendekatan ini memungkinkan untuk menentukan kelas yang paling sesuai dengan pola spektral dari piksel yang diamati, sehingga menghasilkan klasifikasi yang lebih akurat.

Secara umum, metode klasifikasi kemiripan maksimum (*maximum likelihood*) memerlukan perhitungan yang rumit dan memakan waktu untuk mengklasifikasikan setiap piksel. Meskipun demikian, teknik *maximum likelihood* ini menghasilkan hasil klasifikasi yang lebih akurat dibandingkan dengan strategi klasifikasi lainnya. Kelebihan dari metode kemiripan maksimum adalah ketelitian hasil klasifikasinya, karena metode ini mempertimbangkan variasi dan korelasi pola tanggapan spektral secara kuantitatif. Semakin banyak saluran atau informasi spektral yang dapat digunakan dalam metode klasifikasi kemiripan maksimum, maka hasil klasifikasinya akan semakin baik dan akurat.

Meskipun metode ini memerlukan perhitungan yang rumit, keakuratannya menjadikannya sebagai pilihan yang tepat ketika klasifikasi dengan tingkat akurasi tinggi sangat diinginkan. Dengan memanfaatkan seluruh informasi spektral yang tersedia, metode klasifikasi kemiripan maksimum dapat

memberikan hasil klasifikasi yang lebih mendekati keadaan sebenarnya dalam citra. (Purwadhi, 2001).



Gambar 2. 4 Maximum Likelihood (Murai, 1998)