

**DETEKSI, KLASIFIKASI DAN MODEL PREDIKSI TUTUPAN  
LAHAN EMBUNG UNTUK PERTANIAN MENGGUNAKAN  
*SUPPORT VECTOR MACHINE DAN MARKOV CELLULAR  
AUTOMATA***

**TESIS**

Untuk memenuhi sebagian persyaratan  
memperoleh gelar Magister Komputer

Disusun oleh:  
Ahmad Syarif Hidayat  
NIM: 186150100111034



PROGRAM STUDI MAGISTER ILMU KOMPUTER  
JURUSAN TEKNIK INFORMATIKA  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS BRAWIJAYA  
MALANG  
2021

## PENGESAHAN

DETEKSI, KLASIFIKASI DAN MODEL PREDIKSI TUTUPAN LAHAN EMBUNG UNTUK  
PERTANIAN MENGGUNAKAN SUPPORT VECTOR MACHINE DAN MARKOV  
CELLULAR AUTOMATA

TESIS

Diajukan untuk memenuhi sebagian persyaratan  
Memperoleh gelar Magister Komputer

Disusun Oleh :  
Ahmad Syarif Hidayat  
NIM: 186150100111034

Thesis ini telah diuji dan dinyatakan lulus pada

23 Juli 2021

Telah diperiksa dan disetujui oleh:

Dosen Pembimbing I

D.Sc. Fatwa Ramdani, S.Si, M.Sc

NIK. 2016118506191001

Dosen Pembimbing II

Dr. Eng. Fitra Abdurrahman Bachtiar, S.T., M.Eng.

NIP. 198406282019031006

Mengetahui

Ketua Jurusan Teknik Informatika



Achmad Basuki, S.T, M.MG, Ph.D

NIP. 197411182003121002

## PENGESAHAN PERNYATAAN ORISINALITAS

Saya menyatakan dengan sebenar-benarnya bahwa sepanjang pengetahuan saya, di dalam naskah Tesis ini tidak terdapat karya ilmiah yang pernah diajukan oleh orang lain untuk memperoleh gelar akademik di suatu perguruan tinggi, dan tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang secara tertulis disitasi dalam naskah ini dan disebutkan dalam daftar pustaka.

Apabila ternyata didalam naskah Tesis ini dapat dibuktikan terdapat unsur-unsur plagiasi, saya bersediaTesis ini digugurkan dan gelar akademik yang telah saya peroleh (Magister) dibatalkan, serta diproses sesuai dengan peraturan perundang-undangan yang berlaku (UU No. 20 Tahun 2003, Pasal 25 ayat 2 dan Pasal 70).

Malang, 23 Juli 2021



Ahmad Syarif Hidayat

NIM: 186150100111034

## KATA PENGANTAR

Tesis dengan judul *Deteksi, Klasifikasi dan Model Prediksi Tutupan Lahan Embung untuk Pertanian menggunakan Support Vector Machine dan Markov Cellular Automata* ini merupakan hasil kuriositas penulis terhadap fenomena keberadaan embung pertanian di Kabupaten Malang yang membutuhkan solusi dengan kajian ilmu geoinformatika terutama pendekatan teknologi *remote sensing* (penginderaan jauh).

Bab satu dari tesis ini menyajikan latar belakang, rumusan masalah, tujuan, manfaat, dan batasan masalah. Bab dua menyajikan landasan kepustakaan berisi uraian dan pembahasan tentang penelitian terkait meliputi deteksi, klasifikasi dan model prediksi. Bab ketiga merupakan metode, teknik, dan langkah-langkah yang digunakan di dalam penelitian yang terkait dengan proses deteksi, klasifikasi dan pembuatan model prediksi pada tutupan lahan embung untuk pertanian. Selanjutnya, bab empat menyajikan bagaimana klasifikasi SVM yang ingin digunakan berdasarkan proses yang terkait, sistematika praproses citra satelit, model Markov-CA yang digunakan serta hasil prediksi. Sementara itu bab lima membahas mengenai hasil pengujian dan analisis metode yang diusulkan. Terakhir, bab enam membahas mengenai kesimpulan yang telah diperoleh dari hasil deteksi dan prediksi perubahan penggunaan lahan embung untuk pertanian di Kabupaten Malang menggunakan klasifikasi SVM dan model Markov-CA.

Penulis mengucapkan rasa syukur yang teramat dalam kepada Allah SWT yang telah memberikan karunia berupa nikmat iman, ilmu, dan kesehatan sehingga penulis dapat menyelesaikan tesis ini. Semoga Allah SWT berkenan menerima karya ilmiah ini sebagai pemberat timbangan kebaikan. Shalawat serta salam selalu terkirimkan kepada Rasulullah Muhammad SAW yang menjadi panutan semua manusia akhir zaman yang telah menjadi pemandu ke jalan cahya.

Ucapan terima kasih dan penghargaan, penulis sampaikan kepada Bapak Fatwa Ramdani dan Bapak Fitra A. Bachtiar selaku pembimbing yang telah memberikan bimbingan dan semangat kepada penulis dalam menyelesaikan penelitian dan tesis, serta Bapak Agung Setia Budi dan Bapak Barlian Henryranu Prasetyo yang telah banyak memberi saran dalam penyempurnaan tesis ini. Di samping itu, penghargaan penulis sampaikan kepada rekan-rekan angkatan 2018 program studi Magister Ilmu Komputer dan Pimpinan serta rekan-rekan di Direktorat Jenderal Tanaman Pangan. Ungkapan terima kasih juga disampaikan kepada istri tercinta dan anak-anak saleh; Kakak dan Adek, serta seluruh keluarga, atas segala doa, pengorbanan, dan kasih sayangnya. Semoga karya ilmiah ini bermanfaat.

Malang, 23 Juli 2021

Ahmad Syarif Hidayat  
ahmadsyarif@student.ub.ac.id

## ABSTRAK

Sektor pertanian merupakan sektor andalan dalam perekonomian Kabupaten Malang. Namun Kabupaten Malang telah mengalami penurunan luas panen padi yang disebabkan oleh kekeringan. Salah satu upaya Pemerintah untuk mengatasi hal tersebut ialah dengan melakukan kegiatan pembangunan embung untuk pertanian. Penggunaan teknologi *remote sensing (penginderaan jauh)* merupakan salah satu alat yang efektif untuk memantau fenomena perubahan yang terjadi secara terus menerus dan dalam area yang luas dalam hal ini embung. Tujuan dari penelitian ini adalah menentukan dan menganalisis penggunaan klasifikasi SVM pada citra satelit dalam hal deteksi embung, serta mengetahui model prediksi perubahan lahan embung untuk pertanian di Kabupaten Malang. Penelitian ini menggunakan *Support Vector Machine (SVM)* untuk mengklasifikasi jenis tutupan lahan dan model *Markov Cellular Automata (Markov-CA)* untuk memprediksi perubahan tutupan lahan embung untuk pertanian berdasarkan peluang perubahan lahan. Model prediksi dibangun dengan kombinasi interval waktu yaitu tahun 2004-2009 dan 2009-2015 yang kemudian diuji untuk memprediksi tutupan lahan tahun 2015 dan 2020. Penelitian ini menggunakan citra satelit PlanetScope, Landsat 7 dan 8. Penelitian ini terdiri dari empat pekerjaan utama yaitu praproses citra satelit, klasifikasi citra satelit, deteksi dan model prediksi perubahan penggunaan lahan. Hasil penelitian menunjukkan penambahan jumlah area contoh pada algoritme SVM berdampak pada waktu komputasi dan akurasi klasifikasi embung, dimana jumlah area contoh yang sedikit waktu komputasi 16 detik dan akurasi 0.5641. Sedangkan jumlah area contoh yang banyak waktu komputasi 307 detik dan akurasi 07093. Model prediksi Markov-CA memiliki akurasi yang baik daripada model aktual pada kasus deteksi perubahan lahan embung untuk pertanian di Kabupaten Malang sebesar 0.3834 dan 0.3769.

Kata kunci: embung, deteksi, penginderaan jauh, *Support Vector Machine*, *Markov, Cellular Automata*

## ABSTRACT

*The agricultural sector is the mainstay sector in the economy of Malang Regency. However, Malang Regency has experienced a decrease in rice harvested area caused by drought. One of the Government's efforts to overcome this is by carrying out the construction of embung for agriculture. The use of remote sensing technology is one of the effective tools to monitor the phenomenon of change that occurs continuously and in a large area in this case the embung. The purpose of this study is to determine and analyze the use of SVM classification in satellite imagery in terms of embung detection, and to find out the prediction model for embung land change for agriculture in Malang Regency. This study uses a Support Vector Machine (SVM) to classify land cover types and a Markov Cellular Automata (Markov-CA) model to predict land cover changes for embung for agriculture based on land change opportunities. The prediction model was built with a combination of time intervals, namely 2004-2009 and 2009-2015 which was then tested to predict land cover in 2015 and 2020. This study used satellite imagery of PlanetScope, Landsat 7, and 8. This study consisted of four main jobs, namely image preprocessing, satellite, satellite image classification, detection, and prediction model of land-use change. The results showed that the increase in the number of sample areas in the SVM algorithm has an impact on the computation time and accuracy of the embung classification, where the number of sample areas is small, the computation time is 16 seconds and the accuracy is 0.5641. While the number of sample areas is large, the computation time is 307 seconds and the accuracy is 0.7093. The Markov-CA prediction model has better accuracy than the actual model in the case of detection of embung land change for agriculture in Malang Regency of 0.3834 and 0.3769.*

**Keywords:** *embung, detection, remote sensing, Support Vector Machine, Markov, Cellular Automata*

## DAFTAR ISI

PENGESAHAN .....	i
PERNYATAAN ORISINALITAS .....	ii
KATA PENGANTAR .....	iii
ABSTRAK .....	iv
ABSTRACT .....	v
DAFTAR ISI .....	vi
DAFTAR TABEL .....	ix
DAFTAR GAMBAR .....	x
BAB 1 PENDAHULUAN .....	1
1.1 Latar Belakang .....	1
1.2 Identifikasi Masalah .....	2
1.3 Rumusan Masalah .....	2
1.4 Tujuan Penelitian .....	2
1.5 Hipotesis .....	2
1.6 Manfaat Penelitian .....	3
1.7 Batasan Masalah .....	3
1.8 Sistematika Pembahasan .....	3
BAB 2 LANDASAN KEPUSTAKAAN .....	5
2.1 Hasil Penelitian yang Relevan .....	5
2.2 Potensi Pertanian Kabupaten Malang .....	6
2.2.1 Sebaran Embung Kabupaten Malang .....	7
2.3 Tutupan Lahan dan Penggunaan Lahan .....	8
2.3.1 Perubahan Penggunaan Lahan .....	9
2.4 Data Geospasial dan Informasi Geospasial .....	9
2.5 Penginderaan Jauh .....	10
2.5.1 Sistem Proyeksi .....	10
2.6 Citra Satelit .....	11
2.6.1 Citra PlanetScope .....	12
2.6.2 Citra Landsat .....	12
2.6.2.1 Citra Landsat 7 .....	12
2.6.2.2 Citra Landsat 8 .....	13

2.7 Machine Learning .....	14
2.7.1 Supervised Learning .....	14
2.7.2 Unsupervised Learnig .....	14
2.8 Support Vector Machine .....	15
2.8.2 Hard – Margin SVM .....	15
2.8.2 Soft – Margin SVM .....	17
2.8.3 Kernel SVM .....	18
2.9 Rantai Markov .....	20
2.9.1 Cellular Automata .....	21
2.10 Koefisien Kontingensi .....	22
2.11 Koefisien Kappa .....	23
2.12 QGIS .....	24
2.13 TerrSet .....	24
BAB 3 METODOLOGI .....	25
3.1 Kerangka Berfikir .....	25
3.2 Metode Penelitian .....	25
3.3 Studi Pustaka .....	27
3.4 Akuisisi Data.....	27
3.5 Praproses Citra Satelit .....	27
3.5.1 Registrasi Citra .....	27
3.5.2 Koreksi Radiometrik .....	27
3.5.3 Penentuan <i>Area of Interest</i> .....	28
3.5.4 Proses Kombinasi Band .....	28
3.5 Klasifikasi Citra Satelit .....	28
3.5.1 Pembuatan Area Contoh .....	28
3.5.2 Klasifikasi SVM .....	29
3.7 Deteksi Perubahan .....	29
3.8 Prediksi Perubahan .....	29
3.9 Kesimpulan dan Saran .....	30
BAB 4 IMPLEMENTASI .....	31
4.1 Hasil Praproses Citra Satelit .....	31
4.1.1 Registrasi Citra .....	31

4.1.2 Koreksi Radiometrik .....	31
4.1.3 Penentuan <i>Area of Interest</i> .....	32
4.1.4 Proses Kombinasi Band .....	33
4.2 Hasil Klasifikasi Citra Satelit .....	34
4.2.1 Pembuatan Area Contoh .....	34
4.2.2 Klasifikasi SVM .....	36
4.3 Hasil Deteksi Perubahan .....	38
4.4 Hasil Prediksi Perubahan .....	40
4.4.1 Hasil Model Prediksi 2015 .....	40
4.4.2 Hasil Model Prediksi 2020 .....	42
BAB 5 ANALIS DAN EVALUASI HASIL .....	44
5.1 Hasil Evaluasi Klasifikasi .....	44
5.1.1 Area Tumpang .....	44
5.1.2 Area Pakis .....	45
5.2 Hasil Evaluasi Model Prediksi .....	46
4.2.2 Model Prediksi 2015 .....	46
4.2.2 Model Prediksi 2020 .....	47
BAB 6 PENUTUP .....	50
6.1 Kesimpulan .....	50
6.2 Saran .....	50
DAFTAR RUJUKAN .....	51

## DAFTAR TABEL

Tabel 2.1 Luas panen tanaman padi (ha) di Kabupaten Malang, 2017 - 2019 .....	7
Tabel 2.2 Jumlah embung (buah) di Kabupaten Malang, 2017 – 2019 .....	8
Tabel 2.3 Spesifikasi satelit PlanetScope .....	12
Tabel 2.4 Spesifikasi satelit Landsat 7 .....	13
Tabel 2.5 Spesifikasi satelit Landsat 8 .....	13
Tabel 2.6 Algoritme dalam <i>machine learning</i> .....	14
Tabel 2.7 Matriks peluang transisi .....	20
Tabel 2.8 Perhitungan koefisien kontingensi .....	22
Tabel 2.9 <i>Confussion matrix</i> .....	23
Tabel 2.10 Interpretasi nilai Kappa .....	23
Tabel 4.1 Penggunaan data citra satelit dalam penelitian .....	31
Tabel 4.2 Pencarian lokasi embung menggunakan Google Maps .....	32
Tabel 4.3 Embung pilihan untuk sampel penelitian .....	32
Tabel 4.4 <i>Area of Interest</i> pada citra satelit PlanetScope .....	33
Tabel 4.5 Pembagian kelas berdasarkan tampilan citra .....	35
Tabel 4.6 Hasil klasifikasi data pada area penelitian .....	37
Tabel 4.7 <i>Area of Interest</i> pada citra satelit Landsat .....	38
Tabel 4.8 Perbandingan luas area kelas ( <i>Overlay</i> ) .....	39
Tabel 4.9 Matrik Peluang Transisi antara 2004 dan 2009.....	40
Tabel 4.10 Perbandingan luasan citra prediksi dan aktual tahun 2015 .....	42
Tabel 4.11 Matrik Peluang Transisi antara 2009 dan 2015 .....	42
Tabel 4.12 Perbandingan luasan citra prediksi dan aktual tahun 2020 .....	43
Tabel 5.1 Perbandingan klasifikasi SVM area tumpang ( <i>pixel base</i> ).....	44
Tabel 5.2 Perbandingan klasifikasi SVM area tumpang ( <i>proposional</i> ) .....	44
Tabel 5.3 Perbandingan klasifikasi SVM area pakis ( <i>pixel base</i> ).....	45
Tabel 5.4 Perbandingan klasifikasi SVM area pakis ( <i>proposional</i> ).....	46
Tabel 5.5 Perbandingan citra prediksi dan aktual 2015 ( <i>pixel base</i> ) .....	46
Tabel 5.6 Perbandingan citra prediksi dan aktual 2015 ( <i>proposional</i> ) .....	47
Tabel 5.7 Perbandingan citra prediksi dan aktual 2020 ( <i>pixel base</i> ) .....	48
Tabel 5.8 Perbandingan citra prediksi dan aktual 2020 ( <i>proposional</i> ) .....	48

## DAFTAR GAMBAR

Gambar 2.1 Peta Kabupaten Malang .....	7
Gambar 2.2 Ilustrasi embung.....	8
Gambar 2.3 Ilustrasi teknik penginderaan jauh.....	10
Gambar 2.4 Sistem koordinat UTM .....	11
Gambar 2.5 Penjabaran citra menjadi <i>digital number</i> .....	11
Gambar 2.6 Tampilan <i>hard margin</i> SVM .....	15
Gambar 2.7 Tampilan <i>Hyperplane terbaik</i> .....	16
Gambar 2.8 Misklasifikasi dalam <i>soft margin</i> SVM .....	17
Gambar 2.9 Penggunaan <i>Kernel SVM</i> .....	20
Gambar 2.10 Susunan <i>cell</i> segiempat 1D (kiri) dan 2D (kanan).....	21
Gambar 2.11 Ukuran filter 5x5, Von Neumann (kiri) dan Moore (kanan).....	22
Gambar 3.1 Kerangka berfikir penelitian.....	25
Gambar 3.2 Bagan alir penelitian.....	26
Gambar 3.3 Penggunaan kelas penutup lahan untuk analisis .....	29
Gambar 4.1 Hasil citra Landsat setelah koreksi radiometrik .....	31
Gambar 4.2 Lokasi embung menggunakan Google Earth Pro .....	33
Gambar 4.3 Tampilan <i>Natural Color</i> (atas) dan <i>Color Infrared</i> (bawah) .....	34
Gambar 4.4 Digitasi pada area Tumpang (atas) dan Pakis (bawah) .....	35
Gambar 4.5 Hasil klasifikasi SVM area Tumpang (atas) dan Pakis (bawah) .....	37
Gambar 4.6 Pembentukan area contoh (atas) dan klasifikasi SVM (bawah) .....	39
Gambar 4.7 Gabungan data (overlay) menggunakan LCM .....	40
Gambar 4.8 Hasil citra prediksi (atas) dan citra aktual tahun 2015 (bawah) .....	41
Gambar 4.9 Hasil citra prediksi (atas) dan citra aktual tahun 2020 (bawah) .....	43

# BAB 1 PENDAHULUAN

## 1.1 Latar Belakang

Potensi alam Indonesia memiliki dampak besar di sektor pertanian. Kesuburan tanah dan dukungan iklim menjadi sebab sebagian besar penduduk di Indonesia adalah sebagai petani. Begitu juga dengan kabupaten Malang di Jawa Timur yang mayoritas masyarakat bekerja di sektor pertanian. Sektor pertanian di kabupaten Malang memiliki potensi cukup besar. Namun, Badan Pusat Statistik (BPS) Kabupaten Malang menemukan bahwa luas panen padi tahun 2019 mengalami penurunan menjadi 62,773 hektar dibandingkan tahun sebelumnya sebesar 68,671 hektar (BPS, 2020).

Salah satu penyebab berkurangnya luas panen padi adalah akibat kekeringan. Untuk mengatasi krisis kekeringan, pemerintah melalui Kementerian Pertanian telah melakukan kegiatan pembuatan waduk atau danau buatan yang dikenal dengan nama embung. Embung merupakan lekungan alami atau buatan pada daerah pegunungan atau dataran tinggi dimana berfungsi menampung air; mata air dan sungai, limpasan atau air hujan (Said & Widayat, 2014). Selain sebagai cadangan air di musim kemarau, embung di musim hujan berfungsi mengatasi genangan air yang tidak terkendali (Setiawan et al., 2016).

Deteksi, klasifikasi dan model prediksi tutupan lahan embung perlu dilakukan sejalan dengan teknologi informasi yang berkembang pesat di Indonesia. Informasi mengenai tutupan lahan embung dapat dijadikan sebagai bahan pertimbangan pemerintah dalam menentukan lokasi, desain, dan pembuatan embung untuk pertanian. Teknologi *remote sensing* (penginderaan jauh) adalah alat untuk mempelajari fenomena perubahan pada suatu wilayah yang terjadi secara terus menerus. Teknologi ini mampu merekam wajah permukaan bumi dari ketinggian ratusan kilometer di luar angkasa (Ramdani, 2017). Teknologi penginderaan jauh berkembang pesat, ditandai dengan munculnya kendaraan satelit sebagai perkembangan fotografi udara. Teknik pengolahan citra satelit mengalami peningkatan signifikan, yang pada awalnya sekedar dapat diinterpretasikan secara visual kemudian berkembang menjadi digital. Teknik pengolahan citra satelit digital bertujuan untuk memperoleh informasi dari citra satelit menjadi informasi yang dapat dipahami oleh pengguna, seperti informasi tutupan lahan. Teknologi penginderaan jauh berperan penting seperti pengurangan waktu survei ke lapangan, ketersediaan peta terbaru, dan klasifikasi citra digital (Ramdani et al., 2015).

Ada banyak jenis algoritme deteksi informasi digital yang dikembangkan selama dekade terakhir. Algoritme *Support Vector Machine* (SVM) termasuk dalam kelompok *supervised classification* (klasifikasi terbimbing) yang banyak digunakan di bidang penginderaan jauh (Kavzoglu & Colkesen, 2009). Berbagai peneliti di bidang ini telah menemukan bahwa akurasi SVM lebih tinggi daripada algoritme lain seperti *Maximum Likelihood* (MLC) (Mondal et al., 2012; Oommen et al.,

2008). Deteksi tutupan lahan dapat dilakukan menggunakan klasifikasi dari data citra satelit beresolusi tinggi suatu wilayah atau area yang akan diteliti.

Sedangkan model prediksi tutupan lahan dilakukan dengan membandingkan hasil klasifikasi perubahan yang terjadi diantara dua atau lebih data citra satelit yang memiliki area sama dan waktu berbeda (Du et al., 2012). Pembuatan model prediksi tutupan lahan di masa depan biasanya menggunakan model rantai Markov, dengan tambahan *Cellular Automata*. Tujuan dari studi ini adalah untuk melakukan deteksi, klasifikasi SVM dan deteksi Markov-CA pada tutupan lahan embung menggunakan data citra satelit *PlanetScope* (PS) dan Landsat pada area pilihan di Kabupaten Malang Provinsi Jawa Timur.

## 1.2 Identifikasi Masalah

- a. Hingga saat ini, penelitian mengenai deteksi embung menggunakan teknologi penginderaan jauh di Indonesia masih sangat kurang, sehingga penelitian ini mencoba mengisi ruang kosong yang terbuka.
- b. Pengaruh klasifikasi tutupan lahan dalam kajian prediksi perubahan lahan embung untuk pertanian di Kabupaten Malang menggunakan model Markov-CA belum banyak diobservasi. Selanjutnya, penelitian ini akan melakukan observasi lebih dalam mengenai hal tersebut.

## 1.3 Rumusan Masalah

Rumusan masalah berusaha memberi jawaban dengan menjelaskan hasil dari penelitian sebagai berikut.

- a. Bagaimana pengaruh akurasi klasifikasi SVM dengan klasifikasi lain jika menggunakan jumlah area contoh yang sedikit dan banyak?
- b. Bagaimana perbandingan model prediksi Markov-CA dan model aktual pada kasus deteksi perubahan lahan embung untuk pertanian di Kabupaten Malang?

## 1.4 Tujuan Penelitian

- a. Menentukan dan menganalisis penggunaan klasifikasi SVM pada citra satelit dalam hal deteksi embung di Kabupaten Malang.
- b. Mengetahui model prediksi perubahan lahan embung untuk pertanian di Kabupaten Malang.

## 1.5 Hipotesis

Hipotesis adalah hasil penelitian yang dibuat kesimpulan sementara. Pembuatan hipotesis sebaiknya sesuai dengan rumusan masalah dan tujuan penelitian, sehingga hasilnya diterima atau ditolak.

- a. Rumusan Masalah 1

$H_0$ : Algoritme SVM memiliki akurasi yang **tidak baik** daripada klasifikasi lain pada kasus klasifikasi embung.

- $H_a$ : Algoritme SVM memiliki akurasi yang baik daripada klasifikasi lain pada kasus klasifikasi embung.
- b. Rumusan Masalah 2
- $H_0$ : Model prediksi Markov-CA memiliki akurasi yang **tidak baik** daripada model aktual pada kasus deteksi perubahan lahan embung untuk pertanian di Kabupaten Malang.
- $H_a$ : Model prediksi Markov-CA memiliki akurasi yang baik daripada model aktual pada kasus deteksi perubahan lahan embung untuk pertanian di Kabupaten Malang.

## 1.6 Manfaat Penelitian

- Memberikan informasi mengenai tutupan lahan embung dan model prediksi perubahan lahan embung untuk pertanian di Kabupaten Malang.
- Rekomendasi bagi pemerintah dalam kebijakan penentuan lokasi embung untuk pertanian di Kabupaten Malang.

## 1.7 Batasan Masalah

- Penggunaan data citra PS tahun 2021 untuk deteksi dan klasifikasi, sedangkan data tahun 2004, 2009, 2015, dan 2020 menggunakan citra Landsat untuk membuat model prediksi penggunaan lahan embung untuk pertanian.
- Wilayah penelitian adalah area pilihan Tumpang dan Pakis di Kabupaten Malang.

## 1.8 Sistematika Pembahasan

Sistematika pembahasan berisi bagian tesis mulai dari bab pendahuluan hingga bab penutup, dengan keterangan tiap-tiap bab.

### BAB I : PENDAHULUAN

Bab satu ini menyajikan latar belakang, identifikasi masalah, rumusan masalah, tujuan penelitian, hipotesis, manfaat penelitian serta batasan masalah.

### BAB II : LANDASAN KEPUSTAKAAN

Bab dua menyajikan definisi tentang klasifikasi dan model prediksi.

### BAB III : METODOLOGI

Bab tiga yaitu metode, teknik, dan langkah-langkah yang digunakan di dalam penelitian terkait proses deteksi, klasifikasi dan model prediksi pada tutupan lahan embung untuk pertanian.

### BAB IV : IMPLEMENTASI

Bab empat membahas mengenai sistematika praproses citra satelit, proses klasifikasi SVM dan model Markov-CA yang digunakan.

## BAB V : ANALISIS DAN EVALUASI HASIL

Bab lima membahas hasil pengujian dan analisis metode yang diusulkan. Pada bab ini akan dilihat bagaimana hasil akurasi pada metode yang digunakan. Tujuan dari pembahasan ini yaitu melihat seberapa baik akurasi metode yang digunakan.

## BAB VI : PENUTUP

Terakhir, bab enam menyajikan kesimpulan yang telah diperoleh dari hasil deteksi dan prediksi perubahan penggunaan lahan embung untuk pertanian di Kabupaten Malang menggunakan klasifikasi SVM dan model Markov-CA.

## BAB 2 LANDASAN KEPUSTAKAAN

### 2.1 Hasil Penelitian yang Relevan

Salah satu perkembangan teknologi dalam deteksi tutupan lahan adalah penginderaan jauh dengan menggunakan sensor multispektral atau hiperspektral. Citra satelit jenis ini membantu memperoleh informasi di daerah yang sulit diakses. Penelitian memanfaatkan citra satelit PS pun banyak digunakan, yaitu untuk mengekstrak kedalaman perairan (Sesama et al., 2021), deteksi vegetasi perkotaan (Gasparovic et al., 2018), memetakan kerusakan akibat penyakit padi (Shi et al., 2018), pemantauan dinamika vegetasi (McCabe et al., 2017) dan deteksi lamun (Traganos et al., 2017). Penelitian identifikasi perubahan tutupan lahan pun dilakukan dengan memanfaatkan citra satelit Landsat di kawasan hutan lindung di Kabupaten Lampung Tengah (Syam et al., 2012). Penelitian ini menggunakan citra satelit PS dengan resolusi spasial 3 m dan Landsat.

SVM adalah salah satu metode *Machine Learning* (ML) berdasarkan teori pembelajaran statistik, dimana termasuk dalam *Supervised Learning* dalam proses klasifikasi dan regresi (Hong et al., 2017). Algoritme berbasis SVM telah digunakan dalam penelitian transportasi, terutama untuk prediksi waktu perjalanan dan deteksi insiden (Chowdhury et al., 2006; Zhou & Zhou, 2010), dan untuk tujuan klasifikasi di banyak domain aplikasi lainnya. SVM menggunakan *hyperplane* secara optimal untuk mengklasifikasikan data dalam ruang berdimensi lebih tinggi (Styawati & Mustofa, 2019). Berbagai metode teknologi penginderaan jauh telah dikembangkan untuk menganalisis tutupan lahan, diantaranya klasifikasi terbimbing berdasarkan pada piksel (Akyürek et al., 2018; Kandziora et al., 2014).

Penelitian terkait situasi terkini perkebunan kelapa sawit di kawasan timur Indonesia dengan membandingkan metode antara SVM, *Random Forest* (RF), *K-Nearest Neighbors* (KNN) dan *Gaussian Mixture Method* (GMM), menghasilkan metode klasifikasi SVM mencapai akurasi tertinggi, 99.7%, dan 99.12%. Sedangkan klasifikasi RF, KNN dan GMM masing-masing menghasilkan 89.06%, 94.63% dan 72.87% (Ramdani, 2019b). Penelitian untuk penilaian dan pengelolaan lingkungan perkotaan di Kota Macheng, Provinsi Hubei, China dengan membandingkan akurasi klasifikasi dari *Desicion Tree* (DT) berbasis piksel dan SVM. Metode klasifikasi SVM berbasis objek dapat mencapai akurasi klasifikasi yang lebih tinggi 92.71% dibanding DT 92.31% (Wu et al., 2017).

Penelitian yang membandingkan teknik klasifikasi SVM dan MLC untuk mengamati perubahan Daerah Aliran Sungai (DAS) Birupa di Odisha, India. Teknik klasifikasi SVM memberi hasil baik 88% dibanding MLC 78% (Mondal et al., 2012). Penelitian lain terkait pengembangan algoritme SVM pada klasifikasi tutupan lahan masih memberikan nilai akurasi tertinggi (Habibi et al., 2016; Huang et al., 2002; Khatami et al., 2016). Penelitian ini melakukan klasifikasi tutupan lahan embung menggunakan metode SVM.

Sedangkan model prediksi tutupan lahan dilakukan dengan membandingkan hasil klasifikasi perubahan yang terjadi diantara dua atau lebih data citra satelit

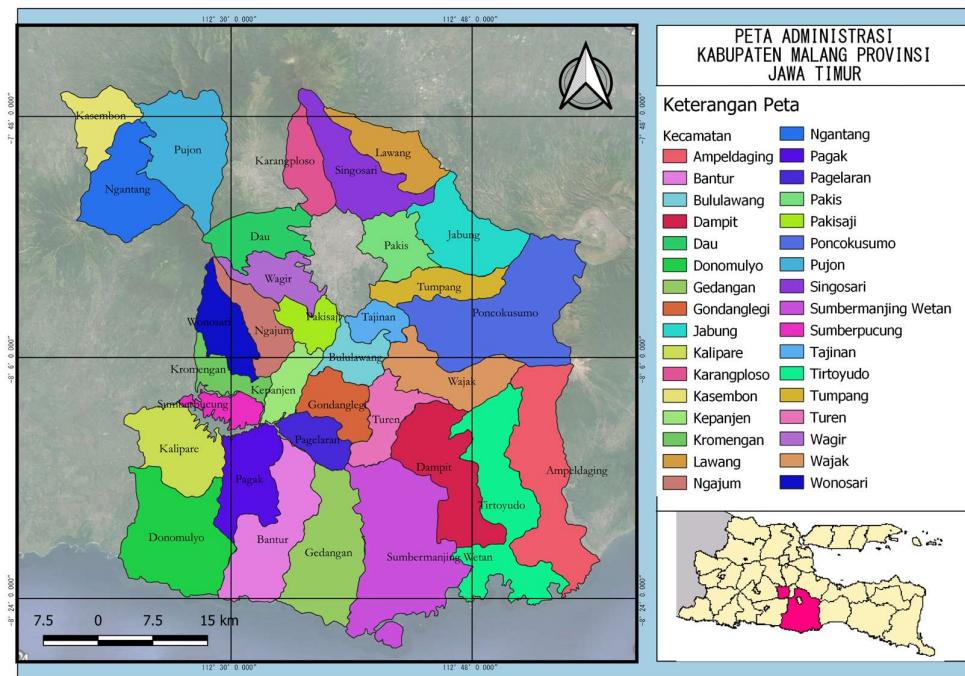
yang memiliki area sama dan waktu berbeda (Du et al., 2012). Pembuatan model prediksi tutupan lahan di masa depan biasanya menggunakan model rantai Markov, dengan tambahan *Cellular Automata*. Penelitian membuat model dan memprediksi dampak perubahan lahan karena adanya restrukturisasi ekonomi di wilayah Su-Xi-Chang, China menggunakan Markov-CA dengan hasil prediksi perubahan lahan sebesar 90% (Yirsaw et al., 2017).

Penelitian lain dengan melakukan analisis perubahan gambut di Kabupaten Rokan Hilir memakai model rantai Markov mendapatkan hasil prediksi perubahan tutupan lahan gambut sebesar 0.92 (Khaira et al., 2016). Terakhir, penelitian memakai model rantai Markov untuk prediksi urban di Jordania memberi hasil baik dengan indeks kesesuaian prediksi dan aktual 0.996, 0.982 dan 0.976 (Al-Bakri et al., 2013). Oleh karena itu, penelitian ini memakai model prediksi menggunakan model rantai Markov, dengan tambahan *Cellular Automata* (Markov-CA).

## 2.2 Potensi Pertanian Kabupaten Malang

Kabupaten Malang merupakan kabupaten terluas kedua wilayahnya setelah kabupaten Banyuwangi sebesar 2977,05 km<sup>2</sup>, dengan jumlah penduduk terbesar di provinsi Jawa Timur. Letaknya dapat dilihat pada Gambar 2.1 dengan koordinat 112°17', 10,90" - 112°57', 00,00" Bujur Timur serta 7°44', 55,11" - 8°26', 35,45" Lintang Selatan. Adapun Kepanjen adalah daerah administrasi kabupaten Malang (BPS, 2020).

Selain kota Batu dan kota Malang sebagai bagian dari Malang Raya, kabupaten Malang pun termasuk didalamnya telah menjadi daerah pilihan destinasi wisata di provinsi Jawa Timur. Kabupaten Malang mempunyai kondisi topografi dataran tinggi dikelilingi beberapa gunung dan dataran rendah atau lembah dengan ketinggian 250 - 500meter di atas permukaan laut (dpl) dengan posisi di bagian tengah wilayah. Dataran tinggi adalah daerah perbukitan kapur di bagian selatan wilayah dengan ketinggian 0 - 650meter dpl. Daerah lereng Tengger Semeru di bagian timur wilayah membujur dari utara ke selatan dengan ketinggian 500 - 3,600meter dpl. Kemudian daerah lereng Kawi dan Arjuno di bagian barat wilayah dengan ketinggian 500 - 3,300meter dpl.



Sumber: Dokumen penulis  
**Gambar 2.1 Peta Kabupaten Malang**

Mayoritas masyarakat kabupaten Malang bekerja di sektor pertanian sebagai petani. Sektor pertanian di kabupaten Malang memiliki potensi cukup besar karena sebagian besar wilayah adalah lahan pertanian. Kabupaten Malang memiliki potensi sawah irigasi dengan luas 45,888 hektare. Jumlah luasan tersebut selama ini telah memberikan kontribusi dalam penyediaan pangan baik nasional maupun daerah sebagai sawah penghasil padi. Adapun luas lahan sawah (ha) di kabupaten Malang disajikan dalam Tabel 2.1.

**Tabel 2.1 Luas panen tanaman padi (ha) di Kabupaten Malang, 2017 - 2019**

Jenis Tanaman Pangan	2017	2018	2019
Tanaman Padi	70,181	70,351	70,312
- Padi sawah	67,181	68,671	62,773
- Padi ladang	3,000	1,680	7,539

Sumber: (BPS, 2020), setelah dimodifikasi

## 2.2.1 Sebaran Embung Kabupaten Malang

Embung merupakan lekungan alami atau buatan pada daerah pegunungan atau dataran tinggi dimana berfungsi menampung air; mata air dan sungai, limpasan atau air hujan (Said & Widayat, 2014). Selain sebagai cadangan air di musim kemarau, embung di musim hujan berfungsi mengatasi genangan air yang

tidak terkendali (Setiawan et al., 2016). Tampilan embung disajikan dalam Gambar 2.2.



Sumber: google.com  
**Gambar 2.2 Ilustrasi embung**

Penggunaan embung diantaranya untuk memenuhi kebutuhan air bersih penduduk, pengairan, peternakan, dan perikanan juga selain sebagai resapan air. Embung untuk memenuhi kebutuhan air bersih penduduk dibuat dalam ukuran terbatas dan mudah diakses di lingkungan setempat, sumber airnya berasal dari air hujan yang relatif lebih bersih. Sedangkan embung untuk pengairan, peternakan dan perikanan membutuhkan lebih banyak air yang terkumpul, dengan berbagai sumber seperti mata air, hujan, maupun limpasan permukaan. Maka dari itu sebenarnya embung dapat dirancang lebih dari satu peruntukan saja. Menurut Kementerian Pertanian, embung untuk pertanian di Kabupaten Malang sudah terdata ada sejak tahun 2013 (Setiawan et al., 2016), namun jumlahnya hingga tahun 2019 mengalami penurunan sesuai Tabel 2.2.

**Tabel 2.2 Jumlah embung (buah) di Kabupaten Malang, 2017 - 2019**

Uraian	2017	2018	2019
Embung	47	47	45
Bendung	320	320	320
Bendungan	4	4	4
Sumber Air	708	737	739

Sumber: (Diskominfo, 2020), setelah dimodifikasi

### **2.3 Tutupan Lahan dan Penggunaan Lahan**

Tutupan lahan adalah tutupan biofisik di permukaan bumi yang bisa diamati dalam melakukan kegiatan produksi perawatan ataupun perubahan pada penutup lahan tersebut (BSN, 2010). Untuk memahami fenomena alam yang terjadi di permukaan bumi, tutupan lahan dapat menyediakan informasi penting untuk keperluan permodelan (Sampurno & Thoriq, 2016). Tutupan lahan didapatkan dari hasil klasifikasi citra satelit dan digunakan sebagai dasar penelitian untuk analisis

dinamika perubahan lahan atau penggunaan lahan di suatu area. Selain itu, hasil klasifikasi citra berupa tutupan lahan (*land cover*) dapat dijadikan dasar pengamatan pertumbuhan pembangunan suatu area (Mukmin et al., 2016).

Penggunaan lahan diartikan sebagai setiap bentuk campur tangan manusia terhadap lahan dalam rangka memenuhi kebutuhan hidupnya baik materil dan spiritual. Penggunaan lahan dikelompokkan menjadi dua bagian, yaitu penggunaan lahan pertanian dan penggunaan lahan bukan pertanian (Rusmawan, 2007). Penggunaan lahan pertanian merupakan penggunaan semua sumber-sumber alam yang bertujuan untuk memperoleh hasil produksi pertanian bagi kehidupan manusia dan dibedakan atas tegalan, sawah, kebun karet, padang rumput, hutan produksi, padang alang-alang dan sebagainya, sedangkan penggunaan lahan non pertanian dibedakan menjadi permukiman, industri, rekreasi, pertambangan dan sebagainya (Arsyad, 2010).

### **2.3.1 Perubahan Penggunaan Lahan**

Perubahan penggunaan lahan atau alih fungsi lahan merupakan proses perubahan dari penggunaan lahan sebelumnya ke penggunaan lain yang dapat bersifat sementara maupun permanen, akibat dari adanya transformasi perubahan dan pertumbuhan struktur sosial ekonomi masyarakat berkembang, baik untuk tujuan industri maupun komersil. Alih fungsi lahan memiliki permasalahan diantaranya masalah pemerataan dan penguasaan sumber daya, serta proses degradasi, kerusakan sumber daya alam dan lingkungan hidup (Rustiadi et al., 2018).

Perubahan penggunaan lahan dikatakan bersifat permanen apabila penggunaan lahan sawah berubah menjadi pemukiman atau industri, sedangkan bersifat sementara apabila hanya beralih menjadi perkebunan (Wijaya & Susetyo, 2017). Data penginderaan jauh sangat berguna dalam pengamatan perubahan penggunaan lahan. Penyebab perubahan penggunaan lahan diantaranya tingginya permintaan atas lahan sebagai akibat dari peningkatan jumlah penduduk, *market failure* dan *goverment failure* (Rustiadi et al., 2018).

## **2.4 Data Geospasial dan Informasi Geospasial**

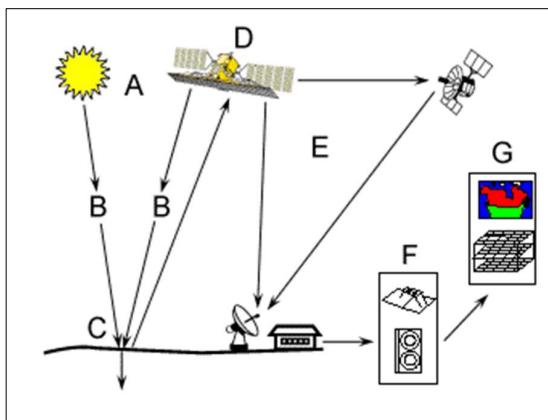
Data merupakan sekumpulan fakta yang sistematis untuk satu atau lebih tujuan tertentu. Sedangkan informasi adalah proses pengolahan data sehingga membentuk arti bagi pengguna dan memiliki nilai tambah bagi pengambil keputusan (Ramdani, 2017). Data geospasial yaitu data yang dikumpulkan serta digunakan untuk pengambilan keputusan dan pemecahan masalah yang berkaitan dengan lokasi tertentu di permukaan bumi.

Informasi geospasial didapat dari data geospasial yang diolah untuk meningkatkan pola pikir spasial, mengetahui dampak dan konsekuensi dari aktifitas manusia dan segala hal yang berhubungan (Ramdani, 2017). Informasi geospasial pada umumnya disajikan dalam bentuk peta cetak, peta interaktif, peta multimedia, peta digital, bola dunia, model tiga dimensi dan daftar koordinat.

Sebuah informasi geospasial hari ini dapat disajikan dalam bentuk digital secara *online* maupun *offline*.

## 2.5 Penginderaan Jauh

Penginderaan jauh merupakan proses mendapatkan informasi suatu objek, fenomena atau daerah dengan menganalisis data menggunakan alat yang tidak kontak langsung dengan fenomena yang sedang diteliti (Lillesand et al., 2015). Sistem penginderaan jauh terdiri dari pengumpulan data dan analisinya. Proses pengumpulan data yaitu, (A) sumber energi, (B) pantulan energi melalui atmosfer, (C) interaksi antara objek dengan energi di permukaan bumi, (D) satelit atau sensor wahana, (E) hasil pembentukan data dalam bentuk numerik atau vektor. Adapun proses analisis data yaitu, (F) pengujian data menggunakan komputer untuk analisis data sensor numerik, dimana hasilnya suatu informasi seperti lokasi, bentangan atau kondisi berbagai sumber daya alam. Kemudian informasi ini tersaji dalam bentuk (G) peta (Gambar 2.4). Hasil informasi seperti peta penggunaan lahan digunakan bagi pengguna untuk pengambilan keputusan.



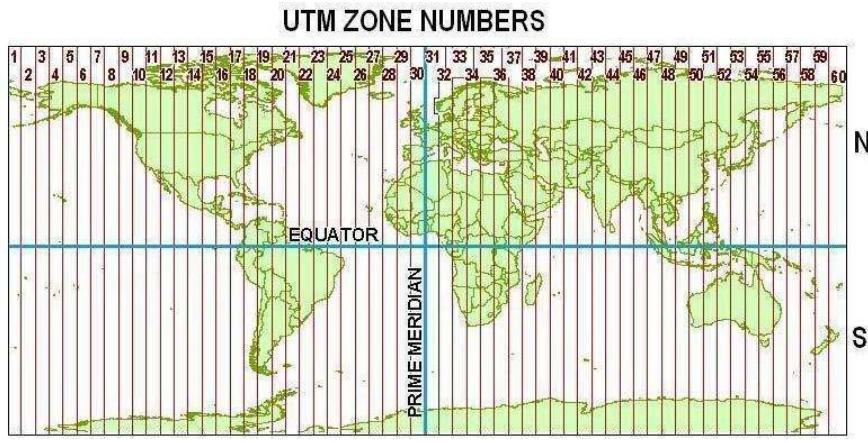
Sumber: (Ali, 2007)  
**Gamber 2.3 Ilustrasi teknik penginderaan jauh**

### 2.5.1 Sistem Proyeksi

Rupa bumi dalam ruang 3D menyerupai ellipsoid dimana untuk menjelaskan dalam bidang datar (2D) perlu dilakukan perubahan menggunakan sistem koordinasi, proyeksi peta serta datum. Sistem koordinat adalah bilangan yang digunakan untuk menunjukkan lokasi suatu titik, garis, ruang atau permukaan. Informasi lokasi ditentukan berdasarkan sistem koordinat yang mencakup proyeksi peta dan datum. Proyeksi peta merupakan hasil pengukuran permukaan bumi yang dilakukan secara matematis dimana hasil disajikan dalam bentuk peta. Sedangkan datum adalah titik referensi pada permukaan bumi beserta model asosiasi matematis terkait perhitungan koordinat dilakukan.

Saat ini Departemen Pertahanan Amerika Serikat mengembangkan datum WGS 1984 menggantikan WGS 72, dimana menyediakan suatu kerangka kerja pengukuran lokasi di seluruh dunia. Di Indonesia, terdapat dua jenis sistem koordinat yang sering digunakan yaitu *Universal Transverse Mercator* (UTM) (X, Y)

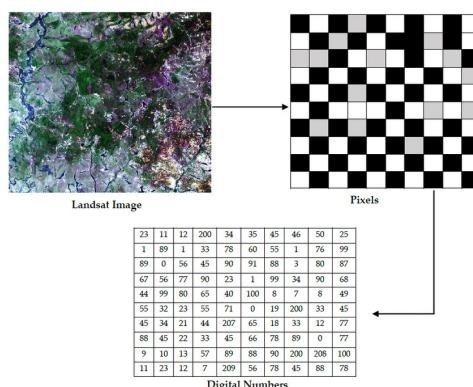
dan sistem geografis (*Latitude, Longitude*). UTM membagi peta dunia menjadi zona 1 hingga 60 (satuan meter), dimana panjang X (meter) dan lebar Y (meter) (Gambar 2.4). Sistem koordinat secara geografis membagi peta bumi dalam 360 bagian dengan bagian lintang dan bujur (satuan derajat). Setiap bagian mempunyai nilai satu derajat, adapun titik nol derajat datum yaitu pada Greenwich (Chang, 2005).



Sumber: (Lenka & R.K., 2020)  
Gambar 2.4 Sistem koordinat UTM

## 2.6 Citra Satelit

Citra adalah perwakilan 2D dari suatu objek di dunia sebenarnya. Citra digital merupakan himpunan (*array*) angka dalam bentuk 2D. Piksel yaitu sel citra digital dimana nilai koordinat diketahui dan nilai intensitas (radiasi elektromagnetik) diwakili oleh suatu angka (*digital number*) yang menunjukkan tingkat kecerahan penyusun citra tersebut. Bagian *array* terdiri dari baris horizontal (*lines*) dan kolom vertikal (*samples*).



Sumber: (Phiri & Morgenroth, 2017)  
Gambar 2.5 Penjabaran citra menjadi *digital number*

Citra digital mempunyai dimensi ketiga yaitu *layer*. *Layer* merupakan bagian pada suatu citra yang sama tetapi memiliki masing-masing informasi yang berbeda. Pada citra satelit, *layer* digambarkan secara multispektral berupa saluran (*band*) yang berbeda (J. G. Liu & Mason, 2009). Resolusi spasial merupakan ukuran

objek terkecil yang terdeteksi oleh suatu sistem pencitraan. Semakin kecil ukuran objek yang di deteksi, maka semakin baik resolusi spasial pada citra tersebut (Danoedoro, 2012).

### 2.6.1 Citra PlanetScope

Planet Labs Inc. atau Planet sudah berdiri sejak 12 Juni 2016 dan telah mengembangkan citra PS di Mountain View, California. Pada tanggal 31 Oktober 2017, Planet telah meluncurkan enam Skysat dan empat Flocks 3 m (termasuk PS) yang bertujuan untuk perekaman resolusi tinggi seluruh bumi per 150 km<sup>2</sup>/hari. Spesifikasi satelit PS pada Tabel 2.3 berikut.

**Tabel 2.3 Spesifikasi satelit PlanetScope**

Saluran ( <i>band</i> )	Panjang Gelombang (μm)	Resolusi Spasial (m)
1	0.455-0.515	3
2	0.500-0.590	3
3	0.590-0.670	3
4	0.780-0.860	3

Sumber: [www.planet.com](http://www.planet.com)

Citra PS tersedia dalam tiga tingkat, yaitu pemandangan dasar (level 1B) adalah produk dengan koreksi radiometrik dan sensor saja, yang dirancang untuk pengguna dengan pengetahuan lanjutan tentang pemrosesan citra. Pemandangan orto (level 3B) adalah produk orthorektifikasi yang diproyeksikan ke proyeksi kartografi. Ubin orto (level 3A) di orthorektifikasi sebagai ubin individual berukuran 25 km × 25 km dan dapat melayani berbagai aplikasi yang memerlukan proyeksi geolokasi dan kartografi yang akurat. Penelitian ini memanfaatkan teknologi penginderaan jauh pada data citra PS level 3B memakai metode klasifikasi SVM untuk mengambil informasi terkait embung di Kabupaten Malang.

### 2.6.2 Citra Landsat

NASA telah mengembangkan citra Landsat pada awal tahun 1970-an di Amerika Serikat. Pada tanggal 22 Juli 1972, NASA telah meluncurkan Landsat 1 sebagai ERTS-1 (*Earth Resources Technology Satellite*) dan hingga saat ini sudah delapan seri satelit (Landsat 8). Setiap warna pada citra satelit Landsat mempunyai nilai refleksi tertentu seperti perairan, batuan atau vegetasi dari permukaan bumi.

#### 2.6.2.1 Citra Landsat 7

Citra Landsat 7 ETM (*Enhanced Thematic Mapper*) adalah salah satu jenis citra multispektral yang sering digunakan untuk proses penginderaan jauh. Resolusi spasial merupakan kemampuan sensor untuk dapat mendekripsi dan membedakan obyek yang ada di permukaan bumi (Lillesand et al., 2015). Spesifikasi satelit Landsat 7 pada Tabel 2.4 berikut.

**Tabel 2.4 Spesifikasi satelit Landsat 7**

Saluran	Panjang Gelombang ( $\mu\text{m}$ )	Resolusi Spasial (m)
1	0.45-0.515	30
2	0.525-0.605	30
3	0.63-0.69	30
4	0.775-0.90	30
5	1.55-1.75	30
6	10.4-12.5	30
7	2.08-2.35	30
8	0.52-0.9	15

Sumber: landsat.gsfc.nasa.gov

#### **2.6.2.2 Citra Landsat 8**

Citra Landsat 8 memiliki karakteristik yang sama dengan Landsat 7, baik berupa resolusi (spektral, temporal, spasial), ketinggian terbang, metode koreksi, maupun karakteristik sensor yang dibawa. Dalam Landsat 8 terdapat penyempurnaan seperti jumlah band, rentang spektrum gelombang elektromagnetik terendah yang ditangkap sensor dan nilai bit atau *DN* dari tiap piksel citra. Landsat 8 mempunyai sensor *Onboard Operational Land Imager* (OLI) pada saluran 1 hingga 9, serta *Thermal Infrared Sensor* (TIRS) pada saluran 10 dan 11 (Tabel 2.5).

**Tabel 2.5 Spesifikasi satelit Landsat 8**

Saluran	Panjang Gelombang ( $\mu\text{m}$ )	Resolusi Spasial (m)
1	0.433–0.453	30
2	0.450–0.515	30
3	0.525–0.600	30
4	0.630–0.680	30
5	0.845–0.885	30
6	1.560–1.660	30
7	2.100–2.300	30
8	0.500–0.680	15
9	1.360–1.390	30
10	10.6-11.2	100
11	11.5-12.5	100

Sumber: landsat.gsfc.nasa.gov

Penelitian ini memanfaatkan teknologi penginderaan jauh pada data citra Landsat memakai metode model Markov-CA untuk mengambil informasi terkait perubahan penggunaan lahan embung untuk pertanian di Kabupaten Malang.

## **2.7 Machine Learning**

*Machine Learning* merupakan metode yang diterapkan pada mesin untuk mendapatkan pengetahuan dengan cara melihat kesesuaian permasalahan sebelumnya untuk mendapat solusi. Penggunaan kecerdasan buatan (*Artificial Intelligence*) pada *machine learning* berguna pada pembuatan suatu desain *Intelligent Decision Support System* (DSS) (Turban et al., 2004). *Machine learning* terbagi menjadi dua pendekatan *Unsupervised Learning* dan *Supervised Learning*. Berikut algoritme *machine learning* yang digunakan pada pendekatan *Unsupervised Learning* dan *Supervised Learning* (Tabel 2.6).

**Tabel 2.6 Algoritme dalam machine learning**

<b><i>Unsupervised Learning</i></b>	<b><i>Supervised Learning</i></b>
<i>K – Means</i>	<i>Decision tree</i>
<i>Hierarchical Clustering</i>	<i>Nearest – Neighbor Classifier</i>
<i>DBSCAN</i>	<i>Naive Bayes Classifier</i>
<i>Fuzzy C – Means</i>	<i>Support Vector Machine</i>
<i>Self – Organizing Maps</i>	<i>Fuzzy K – Nearest Neighbor</i>

Sumber: datascience.or.id

### **2.7.1 Supervised Learning**

*Supervised learning* (pembelajaran terbimbing) adalah proses dari serangkaian pengamatan data dimana hasil yang diinginkan telah diketahui sebelumnya. *Supervisor* dalam *supervised learning* merupakan variabel target dimana kolom dalam data perwakilan nilai digunakan untuk memprediksi dengan kolom lain. Algoritme *supervised learning* atau *predictive modelling* (pemodelan prediktif) merupakan proses klasifikasi pada variabel target bersifat kategori atau regresi untuk variabel target yang kontinu (Abbott, 2014).

*Supervised learning* memakai *training dataset* atau data latih dalam pengembangan model prediksi untuk *dataset* baru dengan cara melakukan *input data* serta *output*. Untuk memperoleh hasil yang baik dan prediksi yang besar pada *dataset* batu, maka model yang memakai *supervised learning* sangat tergantung dengan variansi dan ukuran data latih (Khanna & Awad, 2015).

### **2.7.2 Unsupervised Learning**

*Unsupervised Learning* (pembelajaran tidak terbimbing) atau *descriptive modelling* (pemodelan deskriptif) adalah proses yang tidak mempunyai suatu variabel target tetapi melakukan analisis data input kemudian disatukan dan diberi label berdasarkan unsur kedekatan. Sebagai contoh, fungsi model *unsupervised learning* dalam analisis pelanggan disebut suatu segmentasi dalam grup.

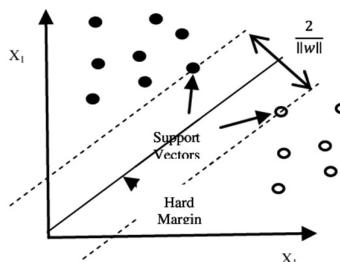
## 2.8 Support Vector Machine

Permasalahan yang ditimbulkan dalam pemodelan data empiris biasanya data yang didapat tidak seragam dan berdimensi tinggi dimana berakibat kesulitan dalam generalisasi dan *overfit data* ketika analisis menggunakan analisis *neural network* secara tradisional (Gunn, 1998). *Neural network* melakukan identifikasi pola yang sulit secara otomatis sehingga dapat menghasilkan proses pengambilan keputusan yang sesuai. Salah satu metode *neural network* yang dikembangkan untuk permasalahan klasifikasi secara baik dalam generalisasi data yaitu menggunakan teknik *Support Vector Machine* (SVM) (Vapnik et al., 1997).

SVM adalah teknik pembelajaran terbimbing dengan menggunakan ruang dalam fungsi linear pada suatu ruang fitur berdimensi tinggi dimana dilatih menggunakan algoritme teori optimasi dengan *learning bias* (Santosa, 2007). Prinsip dasar SVM yaitu memilih *hyperplane* terbaik berupa *line* untuk memisahkan dua kelas atau dimensi pada ruang input. SVM adalah algoritme *machine learning* yang menggunakan *training dataset* dalam pelatihan dengan proses generalisasi dan prediksi pada data yang baru.

### 2.8.1 Hard Margin SVM

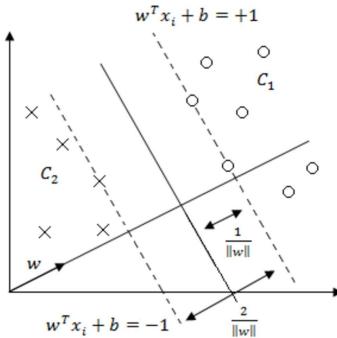
Ketika data yang digunakan sudah terpisah secara linear dengan *hyperlane* hasil klasifier, terlihat kelas lingkaran abu-abu dan hitam terpisah secara total. Berikut gambar 2.6 ketika data termasuk kedalam *hard margin SVM* (Khanna & Awad, 2015).



Sumber: (Bagchi, 2013)

Gambar 2.6 Tampilan *hard margin* SVM

*Hyperplane* terbaik dihasilkan dengan menghitung margin *hyperplane* dan titik maksimalnya. Margin adalah jarak antara *hyperplane* dengan data terdekat dari setiap kelas. Subset training dataset yang mendekati *hyperplane* disebut *support vector*. Pada Gambar 2.7 menunjukkan *hyperplane* terbaik. (Öz & Kaya, 2013).



Sumber: (Öz & Kaya, 2013)

**Gambar 2.7 Tampilan *hyperplane* terbaik**

Diumpamakan *data learning* dengan *data points*  $x_i$  ( $i = 1, 2, \dots, m$ ) mempunyai dua kelas  $y_i = \pm 1$ ; kelas positif (+1) serta kelas negatif (-1), maka persamaan *decision function* sebagai berikut.

$$f(x) = \text{sign}(w \cdot x + b) \quad (2.1)$$

Dimana (.) adalah skalar dimana  $w \cdot x \equiv w^T x$ . Dari persamaan diatas, data dapat diklasifikasi dengan benar apabila  $y_i(w \cdot x_i + b) \geq 0 \forall i$ . Oleh karena itu,  $(w \cdot x_i + b)$  idealnya mendapat nilai positif saat  $y_i = +1$ , serta nilai negatif  $y_i = -1$ . Untuk menghindari *decision function* bersifat ambigu ketika menjabarkan konsep margin atau jarak, sebaiknya skala pada  $(w, b)$  ditetapkan  $w \cdot x + b = 1$  untuk titik terdekat dari satu sisi serta  $w \cdot x + b = -1$  untuk sisi lainnya. Dinamakan *hyperplane* kanonik apabila melewati batas tersebut ( $w \cdot x + b = 1$  dan  $w \cdot x + b = -1$ ) serta area antar *hyperplane* dinamakan *margin band* (Campbell & Ying, 2011).

Margin maksimum didapatkan dengan melakukan nilai jarak secara maksimal antara *hyperplane* dengan titik terdekat  $\frac{1}{\|w\|}$ . Penamaan *Quadratic Programming (QP) Problem* untuk mendapat titik minimal terlihat dari persamaan berikut.

$$\min \tau(w) = \frac{1}{2} \|w\|^2 \quad (2.2)$$

Kemudian persamaan subjek *constrain* (kendala) sebagai berikut.

$$y_i(w \cdot x_i + b) \geq 0 \forall i \quad (2.3)$$

Persamaan tersebut adalah masalah optimisasi kendala, dimana fungsi objek di persamaan (2.2) secara minimal terhadap kendala di persamaan (2.3). Permasalahan tersebut dapat dikurangi menggunakan fungsi *Lagrange* dimana jumlahan fungsi objektif serta  $m$  kendala dikali pengganda *Lagrange* dalam persamaan berikut.

$$L(w, b) = \frac{1}{2} (w \cdot w) - \sum_{i=1}^m \alpha_i (y_i(w \cdot x_i + b) - 1) \quad (2.4)$$

Nilai  $\alpha_i$  adalah *Lagrange Multipliers*, serta nilai  $\alpha_i \geq 0$ . Saat terjadi minimum, dilakukan proses penurunan  $b$  serta  $w$  menjadi nol dalam persamaan berikut.

$$\frac{\partial L}{\partial b} = - \sum_{i=1}^m \alpha_i y_i = 0 \quad (2.5)$$

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^m \alpha_i y_i x_i = 0 \quad (2.6)$$

Pergantian nilai  $w$  pada persamaan (2.6) menjadi  $L(w, b)$  menghasilkan rumus ganda atau *wolfe dual* pada persamaan berikut.

$$W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (2.7)$$

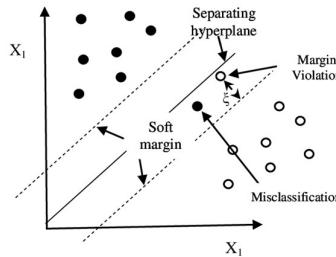
Dimana nilai  $\alpha_i$  terhadap kendala dalam persamaan sebagai berikut.

$$\alpha_i \geq 0 \quad \sum_{i=1}^m \alpha_i y_i = 0 \quad (2.8)$$

Sumber: Persamaan (2.1)-(2.8) (Campbell & Ying, 2011)

### 2.8.2 Soft Margin SVM

Apabila data yang dipakai tidak dapat dipisah, maka *slack variables*  $x_i$  dimasukkan dalam fungsi obyektif SVM untuk menghindari kesalahan ketika proses misklasifikasi. SVM melakukan *soft margin classifier* dimana akan mengklasifikasikan semua data dengan sempurna, disisi lain model juga membuat misklasifikasi pada titik di sekitar batas pemisah. Gambar 2.8 menjelaskan data dalam *soft margin SVM* (Khanna & Awad, 2015).



Sumber: (Bagchi, 2013)

**Gambar 2.8 Misklasifikasi dalam soft margin SVM**

Persamaan *soft margin* memiliki kesamaan dengan *hard margin* pada persamaan (2.3) dengan sedikit modifikasi *slack* variabel seperti berikut.

$$y_i(w \cdot x_i + b) \geq 1 - \varepsilon_i \quad (2.9)$$

Selain itu dilakukan juga proses minimalisasi jumlah error  $\sum_{i=1}^m \varepsilon_i$  dalam persamaan berikut.

$$\min \left[ \frac{1}{2} w \cdot w + C \sum_{i=1}^m \varepsilon_i \right] - \sum_{i=1}^m \alpha_i [y_i(w \cdot x_i + b) - 1 + \varepsilon_i] - \sum_{i=1}^m r_i \varepsilon_i \quad (2.10)$$

Maka persamaan (2.2) berubah menjadi persamaan berikut.

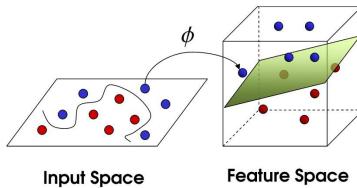
$$\min \tau(w) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^m \varepsilon_i \quad (2.11)$$

Sumber: Persamaan (2.9)-(2.11) (Campbell & Ying, 2011)

Parameter  $c$  dipakai dalam menjaga *trade off* antara kesalahan klasifikasi  $\varepsilon$  dengan margin.

### 2.8.3 Kernel SVM

Penggunaan *kernel* SVM sebagai proses transformasi data ke ruang dimensi tinggi atau ruang kernel, agar data terpisah secara linier. Hal ini terjadi apabila data tidak dapat dipisah secara linier dalam ruang input, dimana *soft margin* SVM gagal mendapat *hyperplane* yang kuat untuk mengurangi misklasifikasi (Khanna & Awad, 2015).



Sumber: (N.J & Palanivel, 2015)

**Gambar 2.9 Penggunaan Kernel SVM**

*Kernel* menghitung kesamaan atau ketidaksamaan pada objek data dari data diskrit dan kontinu menggunakan grafik dan urutan data. SVM adalah metode jangkauan kelas luas yang berbasis *kernel* dalam melakukan analisis data (Campbell & Ying, 2011). Berikut penjelasan penggunaan fungsi *kernel* dalam melakukan pemisahan data. Diketahui data mempunyai *input space* yaitu  $x = \{x_1, x_2\}$  serta  $z = \{z_1, z_2\}$  dalam persamaan berikut.

$$\begin{aligned} K(x, z) &= (x^T z)^2 \\ K(x, z) &= (x_1 z_1 + x_2 z_2)^2 \\ K(x, z) &= (x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 x_2 z_1 z_2)^2 \\ K(x, z) &= (x_1^2 \sqrt{2x_1 x_2 z_1 z_2})^T (z_1^2 \sqrt{2z_1 z_2 z_1 z_2}) \\ K(x, z) &= \phi(x)^T \phi(z) \end{aligned} \quad (2.12)$$

Dimana  $K$  adalah pemetaan ke ruang dimensi tinggi dan  $\phi$  adalah identitas ada tidaknya pemetaan, maka persamaannya sebagai berikut.

$$\phi(x) = \{x_1^2, \sqrt{2x_1 x_2 z_1 z_2}\} \quad (2.13)$$

Kernel  $K(x, z)$  menggunakan *input space* dan memberi kesamaan dalam *feature space* dalam persamaan berikut.

$$\phi: X \rightarrow F$$

$$K: X \times X \rightarrow R, K(x, z) = \phi(x) \cdot \phi(z)$$

Setelah mendapatkan fungsi *kernel*, dilanjutkan perhitungan prediksi dari data dalam *feature space* pada persamaan berikut.

$$\begin{aligned} f(\phi(x)) &= \text{sign}(w \cdot \phi(x) + b) \\ f(\phi(x)) &= \text{sign}(\sum_{i=1}^m \alpha_i y_i K(x, z) + b) \end{aligned} \quad (2.14)$$

Sumber: Persamaan (2.12)-(2.14) (Campbell & Ying, 2011)

Dimana  $b$  adalah nilai bias,  $m$  adalah jumlah *support vector*, dan  $K(x, z)$  adalah fungsi *kernel*. Nilai  $K$  dalam fungsi *kernel* sudah sesuai dengan kondisi *Mercer* berikut.

- Termasuk dalam *Hilbert Space* dimana nilai *feature space* adalah vektor dengan *dot product*.
- Bernilai benar jika  $K$  adalah fungsi definit positif.

$$\int dx \int dz f(x)K(x, z)f(z) > 0 (\forall f \in L_2) \quad (2.15)$$

- Nilai  $K_1$  dan  $K_2$  adalah fungsi *kernel*, oleh karena itu:

$$K(x, z) = K_1(x, z) + K_2(x, z) \quad (2.16)$$

$$K(x, z) = \alpha K_1(x, z): \text{Skalar Product} \quad (2.17)$$

$$K(x, z) = K_1(x, z)K_2(x, z): \text{Direct product} \quad (2.18)$$

Sumber: Persamaan (2.15)-(2.18) (Johnson et al., 2020)

Beberapa fungsi *kernel* yang umum digunakan sebagai berikut.

a. *Linear Kernel*

*Linear kernel* dipakai ketika data sudah terpisah secara linear. Penggunaan *linear kernel* dilakukan apabila banyak fitur karena pemetaan ke ruang dimensi tinggi tidak meningkatkan kinerja, sebagai contoh dalam proses klasifikasi teks dimana jumlah dokumen (*instances*) dan kata atau fitur sama besar (Kim et al., 2015). Persamaan fungsi linear *kernel* sebagai berikut.

$$K(x, z) = x^T z \quad (2.19)$$

b. *Polynomial Kernel* (derajat  $d$ )

*Polynomial kernel* adalah fungsi *kernel* yang dipakai ketika data belum terpisah secara linear. *Polynomial kernel* dilakukan apabila terdapat masalah padasemua *training dataset* dilakukan proses normalisasi. Persamaan fungsi polinomial *kernel* sebagai berikut.

$$K(x, z) = (x^T z)^d \text{ atau } (1 + x^T z)^d \quad (2.20)$$

c. *Radial Basis Function (RBF) Kernel*

*RBF kernel* merupakan fungsi *kernel* yang biasa digunakan dalam analisis ketika data tidak terpisah secara linear. *RBF kernel* memiliki dua parameter yaitu *Gamma* dan *Cost*. Parameter *Cost* atau biasa disebut sebagai *C* merupakan parameter yang bekerja sebagai pengoptimalan SVM untuk menghindari misklasifikasi di setiap sampel dalam *training dataset*. Parameter *Gamma* menentukan seberapa jauh pengaruh dari satu sampel *training dataset* dengan nilai rendah berarti "jauh", dan nilai tinggi berarti "dekat". Dengan *gamma* yang rendah, titik yang berada jauh dari garis pemisah yang masuk akal dipertimbangkan dalam perhitungan untuk garis pemisah. Ketika *gamma* tinggi berarti titik-titik berada di sekitar garis yang masuk akal akan

dipertimbangkan dalam perhitungan. Berikut merupakan persamaan dari RBF kernel.

$$K(x, z) = \exp[-\gamma \|x - z\|^2] \quad (2.21)$$

Sumber: Persamaan (2.19)-(2.21) (Pramudita & Musdholifah, 2020)

## 2.9 Rantai Markov

Rantai Markov (*Markov chain*) merupakan teknik perhitungan yang digunakan dalam memperkirakan perubahan yang mungkin terjadi di masa depan. Perubahan tersebut dalam bentuk nilai variabel keadaan dinamis pada tiap-tiap waktu tertentu (Cesare et al., 1992). Sedangkan model Rantai Markov (*Markov chain model*) adalah penggambaran model waktu  $t$ , dimana waktu kejadian yaitu  $K_t$  serta waktu kejadian sebelumnya yaitu  $K_{t(j)}, \dots, K_{t(j-n)}$ , maka peluang waktu kejadian akan datang  $K_{t(j)}$  bergantung pada waktu kejadian yaitu  $K_{t(j-1)}$  dan bukan pada waktu kejadian sebelumnya yaitu  $K_{t(j-2)}, K_{t(j-3)}, \dots, K_{t(j-n)}$ .

Suatu informasi probabilitas yang dihasilkan melalui analisis Markov dengan teknik deskriptif dapat digunakan dalam pembuatan keputusan. Hasil keluaran pada rantai Markov adalah matriks peluang transisi, yaitu peluang transformasi dari satu keadaan ke keadaan lain dengan periode atau waktu berikutnya. Matriks peluang transisi pada Gambar 2.7.

**Tabel 2.7 Matriks peluang transisi**

Dari Keadaan ke-:	Pindah ke keadaan ke-:					
	1	2	...	j	...	N
1	$P_{11}$	$P_{12}$	...	$P_{1j}$	...	$P_{1n}$
2	$P_{21}$	$P_{22}$	...	$P_{2j}$	...	$P_{2n}$
...	...	...	...	...	...	...
i	$P_{i1}$	$P_{i2}$	...	$P_{ij}$	...	$P_{in}$
...	$P_{n1}$	$P_{n2}$	...	$P_{nj}$	...	...

Sumber: (Andry, 2015) setelah dimodifikasi

dimana  $n$  adalah nilai keadaan, serta  $P_{ij}$  adalah peluang transisi dari keadaan ke- $i$  pindah ke keadaan ke- $j$ . Jika pada keadaan  $i$ , maka baris  $i$  berisi nilai pada  $P_{i1}, P_{i2}, P_{in}$  adalah peluang pindah ke keadaan berikutnya. Oleh karena itu, nilai tersebut adalah bilangan positif dan tunggal seperti pada persamaan berikut.

$$P\{X_{n+1} = j | X_n = i\} \quad (2.22)$$

Sedangkan persamaan rantai Markov orde  $m$  (*m order Markov chain*) sebagai berikut.

$$P\{X_{n+1} = j | X_{(n+1)-m} = i_1, X_{(n+1)-m+1} = i_2, \dots, X_n = i_n\} \quad (2.23)$$

$$P = \begin{bmatrix} P_{11} & P_{12} \dots & P_{1n} \\ P_{21} & P_{22} \dots & P_{2n} \\ \dots & \dots & \dots \\ P_{n1} & P_{n2} \dots & P_{nn} \end{bmatrix}$$

Sumber: Persamaan (2.22)-(2.23) (Andry, 2015)

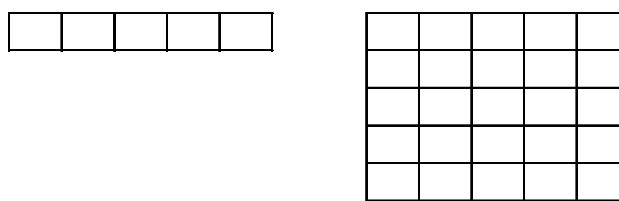
### 2.9.1 Cellular Automata

*Cellular Automata* (CA) merupakan sistem diskrit pembagian ruang dalam bentuk spasial sel yang teratur dan menpunyai waktu proses yang berbeda. Pada tiap sel di sistem ini terdapat satu kondisi, dimana selalu diperbaharui mengikuti waktu yang diberikan, aturan lokal, keadaannya sendiri, serta keadaan tetangganya pada saat sebelumnya (Wolfram, 1984). CA terdiri dari 5 unsur (Gong et al., 2009), yaitu:

1. *Cell* (sel) adalah unit dasar spasial pada ruang. Dalam penelitian, sel digunakan dalam pemodelan alih fungsi lahan.
2. *State* (keadaan) merupakan suatu atribut dari sistem. Satu keadaan diambil oleh setiap sel dari sekumpulan keadaan di waktu tertentu. Dalam penelitian, keadaan mewakili kelas penggunaan lahan.
3. *Neighborhood* (Ketetanggaan) adalah interaksi yang terjadi pada sekumpulan sel. Dua tipe dasar lingkungan dalam ruang 2D yaitu lingkungan Von Neumann (dua belas sel) dan Moore (dua puluh empat sel).
4. *Transition rules* (aturan transisi) merupakan suatu aturan tentang bagaimana perubahan pada sel ketika merespon keadaan saat ini dan tetangganya.
5. *Time-step* (waktu) dapat didefinisikan sebagai periode iterasi.

Konsep sederhana CA dalam bidang komputer dikembangkan oleh Von Neumann sejak tahun 1940 (Y. Liu & He, 2009). CA berguna dalam pemodelan proses spasial secara *temporal* (Barredo et al., 2003). Konsep CA dimana keadaan setiap sel bergantung dengan keadaan sel awal dengan berpedoman pada aturan transisi (White et al., 1997). Sekumpulan sel (*grid*) tersebut membentuk segiempat maupun susunan lain seperti sarang lebah segienam.

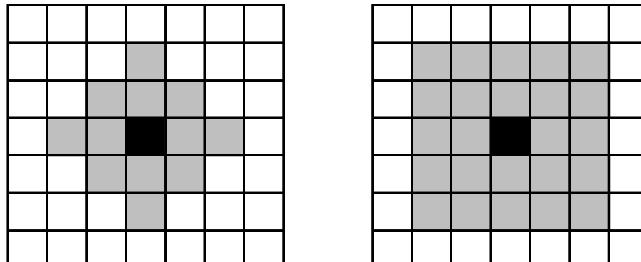
Setiap data dari *grid* diatur sehingga hanya boleh berada di salah satu keadaan. Struktur tersebut diberi pilihan dalam bentuk piksel (*lattice*). Bentuk *lattice* ada yang 1 D dan 2 D seperti pada Gambar 2.10.



Sumber: (Buhari, 2016)

Gambar 2.10 Susunan *cell* segiempat 1D (kiri) dan 2D (kanan)

Konsep ketetanggaan banyak digunakan pada kasus penggunaan lahan, dimana perubahan piksel dipengaruhi piksel tetangganya. Maka dari itu perlu diketahui jumlah piksel yang terpilih sebagai tetangga. Penggunaan ketetanggaan dengan filter atau jendela dapat dilihat pada Gambar 2.11.



Sumber: (Eastman, 1999)

**Gambar 2.11 Ukuran filter 5x5, Von Neumann (kiri) dan Moore (kanan)**

## 2.10 Koefisien Kontingensi

Penggunaan koefisien kontingensi ( $C$ ) dalam perhitungan hubungan antar variabel dimana data berbentuk nominal. Teknik ini bertujuan untuk menguji hipotesis komparatif  $k$  sampel independen dengan nilai Chi Kuadrat. Adapun persamaan yang dimaksud sebagai berikut.

$$C = \sqrt{\frac{\chi^2}{N + \chi^2}} \quad (2.24)$$

Dimana  $\chi^2$  adalah Chi Kuadrat dan  $N$  adalah banyak baris dalam tabel. Untuk mendapatkan nilai Chi Kuadrat menggunakan persamaan berikut.

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^k \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \quad (2.25)$$

Sumber: Persamaan (2.24)-(2.25) (Sugiyono, 2017)

Dimana  $O$  adalah *observation* dan  $E$  adalah *expectation*. Kemudian data hasil penelitian dimasukkan ke dalam tabel berikut.

**Tabel 2.8 Perhitungan koefisien kontingensi**

Variabel B	Variabel A				Jumlah
B1	( $A_1B_1$ )	( $A_2B_2$ )	.....	( $A_kB_k$ )	
B2	( $A_2B_2$ )	( $A_3B_3$ )	.....	( $A_kB_k$ )	
-	-	-	.....	.....	
-	-	-	.....	.....	
Br	( $A_1B_r$ )	( $A_2B_r$ )	.....	( $A_kB_k$ )	
<b>Jumlah</b>					

Sumber: (Sugiyono, 2017)

Nilai  $H_a$  akan diterima atau dapat diberlakukan pada populasi (signifikan) apabila nilai Chi Kuadrat hitung lebih besar dari nilai Chi Kuadrat tabel atau sebaliknya.

## 2.11 Koefisien Kappa

Evaluasi model merupakan tahapan yang dilakukan untuk menentukan kinerja suatu model. Penggunaan tabel *confusion matrix* dengan isian kelas aktual dan kelas prediksi pada Tabel berikut.

**Tabel 2.9 Confussion matrix**

Kelas Aktual	Kelas Prediksi				
	A	B	...	H	$\Sigma$
A	$X_{AA}$	$X_{AB}$	...	$X_{AH}$	$X_{A+}$
B	$X_{BA}$	$X_{BB}$	...	$X_{BH}$	$X_{B+}$
...	...	...	...	...	...
H	$X_{HA}$	$X_{HB}$	...	$X_{AA}$	$X_{H+}$
$\Sigma$	$X_{+A}$	$X_{+B}$	...	$X_{+H}$	$X$

Sumber : (G. Foody, 2017), setelah dimodifikasi

Evaluasi hasil dapat dihitung berdasarkan *confussion matrix* salah satunya menggunakan koefisien Kappa. Koefisien Kappa pada dasarnya adalah ukuran seberapa baik kinerja model klasifikasi atau prediksi dibandingkan dengan seberapa baik itu bekerja secara aktual. Nilai kappa tinggi pada suatu model menunjukkan adanya perbedaan besar antara tingkat kesalahan nol dan akurasi (Pontius Jr & Millones, 2011). Tingkat kesalahan nol adalah peluang salah jika model klasifikasi selalu memprediksi kelas mayoritas. Nilai maksimal koefisien Kappa adalah 1 yang artinya model akan semakin baik jika nilai koefisien Kappa mendekati 1. Berikut adalah rumus dari koefisien Kappa:

$$\text{Koefisien Kappa} = \frac{(n \sum_{i=1}^p n_{ii}) - \sum_{i=1}^p n_{i+} n_{+i}}{n^2 - \sum_{i=1}^p n_{i+} n_{+i}} \quad (2.26)$$

Sumber: (Pontius Jr & Millones, 2011)

Dimana  $n_{ii}$  adalah nilai diagonal dari tabulasi silang kolom dan baris.  $n_{+i}$  adalah jumlah sampel dalam kolom ke- $i$ ,  $n_i$  adalah jumlah sampel dalam baris ke- $i$  serta  $n$  adalah total banyaknya sampel. Nilai koefisien Kappa dapat dikategorikan tingkat kesepakatan seperti Tabel berikut.

**Tabel 2.10 Interpretasi nilai Kappa**

Nilai Kappa (%)	Tingkat Kesepakatan
< 20	Buruk ( <i>Poor</i> )
21-40	Cukup ( <i>Fair</i> )
41-60	Sedang ( <i>Moderate</i> )

61-80	Baik ( <i>Good</i> )
81-100	Baik Sekali ( <i>Very good</i> )

Sumber: (Altman, 1990)

## 2.12 QGIS

Quantum GIS atau lebih dikenal dengan nama QGIS merupakan salah perangkat lunak pengolah data spasial bersifat *open-source* yang sudah dikembangkan sejak tahun 2002. QGIS dapat diunduh secara gratis di laman [www.qgis.org](http://www.qgis.org). Segala macam informasi terkait seperti jenis produk QGIS, studi kasus, dan dokumentasi penggunaannya dapat ditemukan pada laman tersebut. QGIS mempunyai kemampuan mengolah data vektor dan raster, analisis GIS (*buffer, intersection, query*), digitasi dan *editing*.

## 2.13 TerrSet

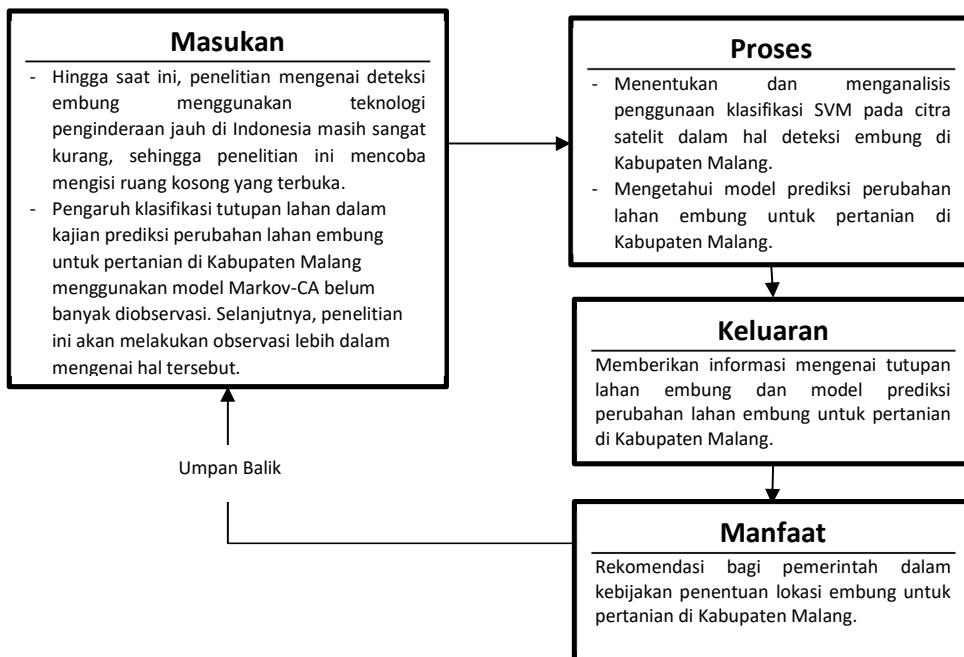
TerrSet adalah perangkat lunak kaya fitur terintegrasi yang digunakan untuk memodelkan sistem bumi yang dikembangkan oleh Clark Labs di Clark University, Amerika Serikat. Salah satu kemampuan TerrSet adalah menampilkan penggunaan lahan. QGIS dapat diunduh di laman [www.clarklabs.org](http://www.clarklabs.org). Dalam penelitian ini fungsi TerrSet yang dipakai yaitu *Land Change Modeler* (LCM) dan *IDRISI Image Processing System*.

LCM untuk menganalisis perubahan tutupan lahan, secara empiris memodelkan hubungannya dengan variabel penjelas, dan memproyeksikan perubahan di masa depan. Sedangkan *IDRISI Image Processing System* untuk peningkatan, transformasi, restorasi dan klasifikasi citra penginderaan jauh. IDRISI memiliki rangkaian prosedur klasifikasi terluas di industri termasuk prosedur klasifikasi keras dan lunak berdasarkan *machine learning* (seperti neural networks) dan karakterisasi statistik.

## BAB 3 METODOLOGI

### 3.1 Kerangka Berfikir

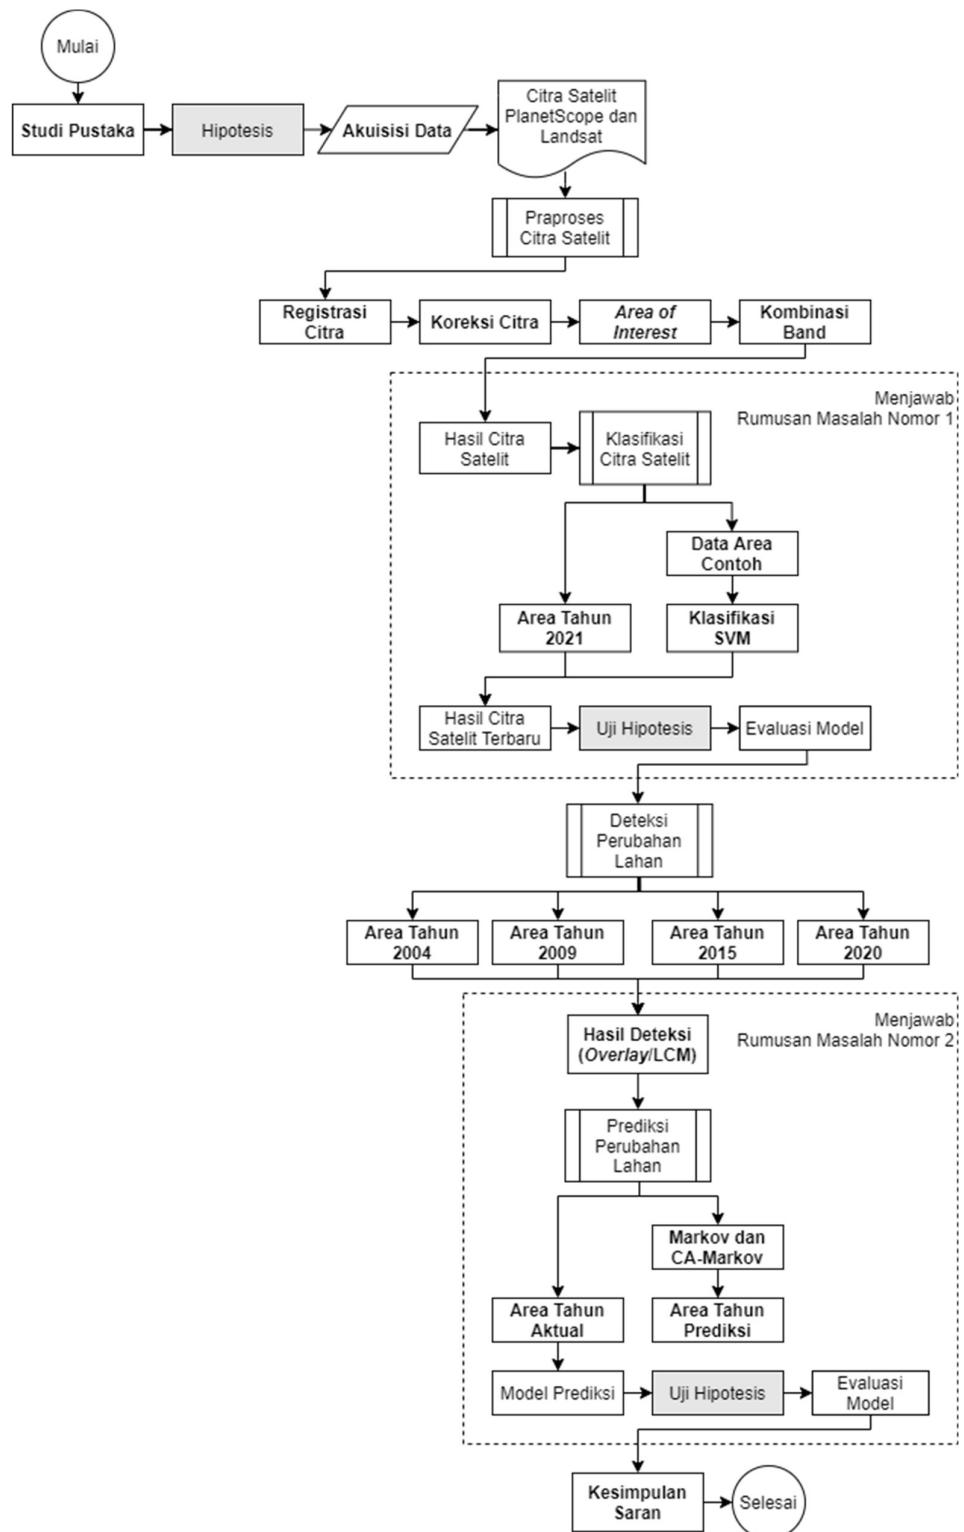
Kerangka berpikir pada penelitian merupakan langkah-langkah yang digunakan untuk menjawab tujuan dari penelitian. Mencakup pada masalah utama penelitian, bagaimana proses menjawab permasalahan penelitian, hasil apa yang diharapkan dan dihasilkan, serta umpan balik seperti apa yang dihasilkan untuk menjawab masalah penelitian.



Sumber: Dokumen penulis  
Gambar 3.1 Kerangka berfikir penelitian

### 3.2 Metode Penelitian

Metodologi penelitian merupakan teknik yang dilakukan oleh peneliti untuk mengumpulkan data atau informasi dalam melakukan penelitian yang disesuaikan dengan subjek atau objek yang diteliti. Penelitian ini terdiri atas tujuh tahapan yaitu studi pustaka, akuisisi data, praproses citra satelit dan klasifikasi citra satelit. Selanjutnya, deteksi perubahan penggunaan lahan, uji hipotesis serta model prediksi embung untuk pertanian (Gambar 3.2).



Sumber: Dokumen penulis  
**Gambar 3.2** Bagan alir penelitian

### **3.3 Studi Pustaka**

Studi pustaka merupakan proses berdasarkan referensi yang bertujuan menjawab tujuan penelitian atau dasar dalam menggunakan rumusan tertentu untuk analisis dan desain suatu model. Pustaka yang digunakan mencakup penginderaan jauh, citra satelit, klasifikasi SVM, model Markov-CA, dan hasil penelitian yang relevan.

### **3.4 Akuisisi Data**

Data penelitian dikatakan baik apabila alat akuisisi telah lulus reabilitas dan uji validasi, prosesnya dengan pengawasan ketat, dan metode analisis data yang tepat (Ramdani, 2019a). Penelitian ini menggunakan metode *experiments* (uji coba) dengan hasil sebuah model, yang kemudian diimplementasikan serta dilakukan analisis. Data atau informasi yang digunakan dalam penelitian ini diambil dari laman [www.planet.com](http://www.planet.com) dan [earthexplorer.usgs.gov](http://earthexplorer.usgs.gov).

Penggunaan perangkat keras (*hardware*) serta perangkat lunak (*software*) dalam penelitian sebagai berikut.

1. Perangkat keras: komputer pribadi yang spesifikasi menggunakan Intel Processor Core i5-7200U, Harddisk 1 TB (*Terabyte*) dan RAM 8 GB.
2. Perangkat lunak:
  - a. Microsoft Windows 10 Pro 64-bit
  - b. QGIS 3.10.8-A Coruña untuk praproses data
  - c. TerrSet 2020 *Geospatial Monitoring and Modeling Software* untuk proses klasifikasi, analisis data dan prediksi model
  - d. Google Earth Pro atau Google Maps

### **3.5 Praproses Citra Satelit**

#### **3.5.1 Registrasi Citra**

Registrasi citra sebagai suatu proses pencarian transformasi yang paling cocok, menurut beberapa ukuran kesamaan dari dua atau lebih gambar yang berbeda dalam aspek tertentu tetapi pada dasarnya merupakan objek yang sama (Serief et al., 2009). Data citra satelit PS yang diambil mencakup area Tumpang dan sekitarnya. Sedangkan citra satelit Landsat memilih nomor jalur (*path*) dan baris (*row*) yaitu 118/66, serta persentase tutupan awan (*Cloud Cover*) kurang dari 15%. Semua data citra satelit memakai sistem referensi geospasial yaitu WGS84.

#### **3.5.2 Koreksi Radiometrik**

Koreksi radiometrik merupakan koreksi pada citra dengan memperbaiki nilai piksel yang mempunyai sumber kesalahan pada gangguan atmosfer. Koreksi radiometrik ini menggunakan metode pergeseran histogram, sebagai metode yang paling umum digunakan. Penilaian metode ini adalah nilai piksel terkecil tiap

saluran bernilai 0. Namun bila nilai piksel terkecil lebih dari nol ( $>0$ ), maka dianggap *offset* (bias). Nilai bias menunjukkan adanya pengaruh atmosfer sehingga harus diperbaiki. Koreksi radiometrik menghilangkan bias tersebut dengan mengurangi keseluruhan nilai spektral pada saluran asli dengan nilai biasnya sendiri-sendiri (Danoedoro, 2012). Data citra satelit yang dilakukan koreksi hanya citra Landsat dengan QGIS menggunakan *Plugin ‘Semi-Automatic Classification’*.

### **3.5.3 Penentuan *Area of Interest***

Penentuan *Area of Interest* (AOI) dilakukan dengan proses pemotongan (*cropping*) sesuai dengan area penelitian yang diinginkan mengacu pada peta sebenarnya yaitu kabupaten Malang, provinsi Jawa Timur. Pada penelitian ini difokuskan pada area yang terdapat embung untuk pertanian.

### **3.5.4 Proses Kombinasi Band**

Citra komposit merupakan proses kombinasi band yang memiliki resolusi spasial sama dan resolusi spektral berbeda. Resolusi spasial adalah ukuran objek terkecil di permukaan bumi yang dapat dikenali. Resolusi spektral adalah batasan domain, spektral atau lebar band (radiasi elektromagnetik) yang direkam oleh sistem sensor satelit. Citra komposit bertujuan mendapatkan tampilan visual yang optimal yang bisa digunakan dalam identifikasi penggunaan lahan. Kombinasi band *Natural Color* menampilkan citra yang sama dengan penglihatan manusia (warna alami), sedangkan kombinasi band *Color Infrared/Vegetation* menampilkan daerah berwarna merah sebagai vegetasi. Kombinasi ini biasa digunakan dalam monitoring drainase dan pola tanah, tahapan dalam pertumbuhan tanaman, serta studi vegetasi lainnya. Maka penelitian ini memilih menggunakan kombinasi band *Color Infrared/Vegetation* daripada *Natural Color*.

## **3.6 Klasifikasi Citra Satelit**

### **3.6.1 Pembuatan Area Contoh**

Proses identifikasi area contoh atau data uji yang diambil dari setiap tutupan lahan dan selanjutnya dibangun deskripsi numerik dengan penamaan piksel (*labelling*) (Lillesand et al., 2015). Beberapa yang perlu diperhatikan dalam pembuatan area contoh (Ramdani, 2018) yaitu:

- a. Data uji atau area contoh harus berupa data numerik, bukan deskriptif.
- b. Minimal *labelling* yang diuji berjumlah 5 kelas, supaya hasil grafik terlihat jelas.
- c. Titik uji validasi minimal berjumlah 10-30 titik uji, dengan titik sebaran merata dilakukan pada area penelitian.

Penentuan label kelas bertujuan untuk memperoleh informasi mengenai kelas-kelas yang akan digunakan dalam klasifikasi. Sehingga dapat dilakukan *sampling* untuk data yang mewakili masing-masing kelas sehingga tidak menggunakan keseluruhan piksel citra di area penelitian. Pembagian kelas dalam

penelitian ini mengacu pada kelas penutup lahan yang telah ditentukan oleh pemerintah (BSN, 2010), seperti pada gambar 3.3.

Perkebunan	Hutan Tanaman
Sawah	Awan
Pemukiman	Badan Air
Pertanian Lahan Kering	

Sumber: Dokumen penulis

**Gambar 3.3 Penggunaan kelas penutup lahan untuk analisis**

### 3.6.2 Klasifikasi SVM

Klasifikasi SVM menetapkan sebagian data uji atau area contoh yang kemudian dikelaskan berdasarkan statistik area penelitian. Terdapat tiga tahapan yaitu pembuatan area contoh, klasifikasi dan tampilan (*output*). SVM hanya mendukung dua kelas masalah (G. M. Foody & Mathur, 2004). Untuk menangani data *multiclass*, ada dua pendekatan umum: teknik *One-Against-One* (1A1) dan *One-Against-All* (1AA). Penelitian ini menerapkan teknik 1AA. Pendekatan 1AA mewakili pendekatan SVM *multiclass* paling awal dan paling umum dan melibatkan pembagian *dataset* kelas N menjadi dua kasus kelas N (Melgani & Bruzzone, 2004).

Prinsip SVM yaitu melakukan proses pengklasifikasi linier dan non-linier (menggunakan konsep kernel pada ruang berdimensi tinggi). Penelitian ini memakai metode kernel RBF yang melibatkan pengaturan dua parameter, lebar kernel  $\gamma$ , dan Parameter C menukar kesalahan klasifikasi yang salah. Selain itu menggunakan *grid-search* pada range parameter yang ditentukan untuk mengembalikan nilai terbaik yang digunakan untuk parameter  $\gamma$  dan C. Adaupun rentang parameter adalah  $10^{-6}$ - $10^{-1}$  dan  $10^{-1}$ - $10^1$  untuk parameter C.

## 3.7 Deteksi Perubahan

Proses deteksi dilakukan dengan membandingkan hasil citra-citra yang telah diklasifikasikan untuk mengetahui perubahan yang terjadi. Proses deteksi perubahan penggunaan lahan memakai perbandingan berbasis piksel (Mustapha et al., 2010). Dalam hal ini data citra dari tahun 2004 hingga 2020 yang telah diklasifikasikan berdasarkan kelas dibandingkan. Hasilnya adalah seberapa luas kelas tersebut mengalami perubahan dalam jangka waktu tertentu.

## 3.8 Prediksi Perubahan

Tahapan ini untuk memprediksi perubahan lahan dalam beberapa tahun ke depan. Penelitian ini menggunakan model rantai Markov dengan CA berfilter matriks 5x5. Dilakukan proses prediksi perubahan lahan tahun 2015 dengan dasar data tahun 2004 dan 2009, serta prediksi tahun 2020 dengan dasar data tahun 2009 dan 2015.

Prediksi perubahan dalam penelitian ini menggunakan gabungan probabilitas transisi rantai Markov dengan CA (Markov-CA). Model ini terdiri empat komponen yang saling berinteraksi dalam dimensi waktu dengan persamaan berikut.

$$(U, S, N, T) \quad (3.1)$$

dimana,  $U$  (*universe*) adalah dimensi ruang sel (*cell space*),  $S$  (*states*) adalah keadaan yang mungkin dicapai oleh sel. Sedangkan  $N$  (*neighborhood*) adalah jumlah sel tetangga yang dipertimbangkan dalam penentuan nilai dari sel. Terakhir,  $T$  (*transition*) adalah aturan dalam penentuan nilai dari sel.

Perubahan sel ( $S$ ) dalam keadaan awal ( $S_t$ ) dengan waktu  $t$  berubah menjadi ( $S_{t+1}$ ) dengan waktu  $t + 1$  adalah fungsi dari kondisi sekitarnya ( $N$ ) dan prinsip transisi tertentu ( $T$ ). Fungsi perubahan tersebut dapat dituliskan dengan persamaan berikut.

$$S_{t+1} = f(S_t, N, T) \quad (3.2)$$

*Ketetanggaan (Neighborhood)* adalah komponen utama dalam Markov-CA ini. Nilai sel akan berubah pada waktu tertentu pengaruh dari sejumlah sel tetangganya (*neighborhood cells*). Jumlah sel tetangga yang digunakan dalam Markov-CA biasanya dua belas (*Von Neumann neighborhood*) atau dua puluh empat (*Moore neighborhood*) seperti ditunjuk pada Gambar 2.11. Probabilitas perubahan nilai sel  $C$  dari keadaan  $S_i$  dengan waktu  $t$  menjadi  $S_i$  dengan waktu  $t + 1$  berdasarkan model CA dihitung dengan persamaan berikut.

$$Prob_c(S_t \rightarrow S_{t+1}) = P_{ij}(N(C)) \quad (3.3)$$

Sumber: Persamaan (3.1)-(3.3) (Susilo, 2016)

dimana  $N(C)$  menunjukkan jumlah sel tetangga dari sel  $C$ .

### 3.9 Kesimpulan dan Saran

Proses analisis dan hasil kesimpulan didapat dengan interaksi antara data geospasial dengan data geospasial lainnya. Kesimpulan yang berdasarkan pada akurasi dari model yang digunakan dan data atribut yang digunakan dalam hal ini penggunaan klasifikasi SVM pada citra satelit PS dan model prediksi Markov-CA pada citra satelit Landsat.

Sedangkan saran untuk dipertimbangkan terkait sumber dan usia data geospasial yang digunakan, luasan area pada lokasi studi, resolusi spasial, atau proses pengolahan data geospasial.

## BAB 4 IMPLEMENTASI

### 4.1 Hasil Praproses Citra Satelit

#### 4.1.1 Registrasi Citra

Pemilihan Citra PS digunakan untuk menentukan dan menganalisis penggunaan tutupan lahan embung di Kabupaten Malang, sedangkan citra Landsat terkait membangun model prediksi perubahan tutupan lahan embung untuk pertanian di masa depan. Penggunaan *Landsat Collection 2 Level-1* sebagai data dimana terdiri dari DN berskala terkuantisasi dan terkalibrasi yang mewakili data citra multispektral (Tabel 4.1).

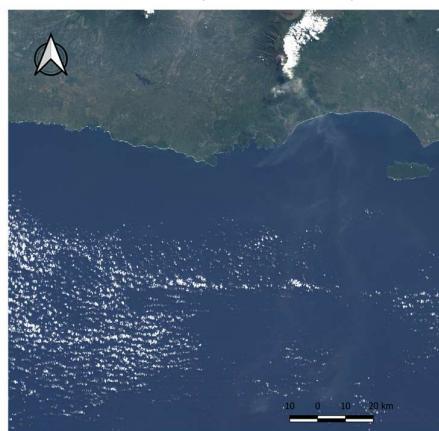
**Tabel 4.1 Penggunaan data citra satelit dalam penelitian**

Satelit	Tanggal Akuisisi	Level
PlanetScope	23 April 2021	3B
Landsat 7	25 Juni 2004	Landsat Collection 2 Level-1
Landsat 7	23 Juni 2009	Landsat Collection 2 Level-1
Landsat 8	16 Juni 2015	Landsat Collection 2 Level-1
Landsat 8	13 Juni 2020	Landsat Collection 2 Level-1

Sumber: Dokumen penulis

#### 4.1.2 Koreksi Radiometrik

Sebelum dilakukan koreksi radiometrik, semua citra Landsat 7 terlebih dahulu dilakukan proses '*Fill nodata*' di aplikasi QGIS. Citra satelit tersebut terdapat bagian berwarna hitam (*stripping*) efek dari *Scan Line Corrector* (SLC) yang mengalami kerusakan tanggal 31 Mei 2003. Proses koreksi radiometrik dilakukan pada semua citra satelit Landsat dengan tambahan proses '*pansharpening*' menggunakan *Plugin 'Semi-Automatic Classification'*. Berikut salah satu hasil citra setelah dilakukan koreksi radiometrik (Gambar 4.1).



Sumber: Dokumen penulis

**Gambar 4.1 Hasil citra Landsat setelah koreksi radiometrik**

#### **4.1.3 Penentuan *Area of Interest***

Terkait lokasi embung di Kabupaten Malang, penulis mengalami misinformasi yang diberikan oleh pemerintah dalam hal jumlah dan lokasi. Oleh karena itu penulis mencari lokasi embung menggunakan Google Maps dengan hasil rincian Tabel 4.2 sebagai berikut.

**Tabel 4.2 Pencarian lokasi embung menggunakan Google Maps**

Kecamatan	Nama
Tajinan	Embong Pandanmulyo, Embong Purboyo
Pocokusumo	Embong Jambesari
Tumpang	Embong Malangsuko, Embong Wringinsongo
Pakis	Embong Sumber Umbulan, Embong Cempaka
Singosari	Embong Wisata Lowokjati
Ngajum	Embong Babadan
Sumberpucung	Rawa Klampok
Dampit	Waduk Kaliungkal Sukodono
Kromengan	Waduk Laor

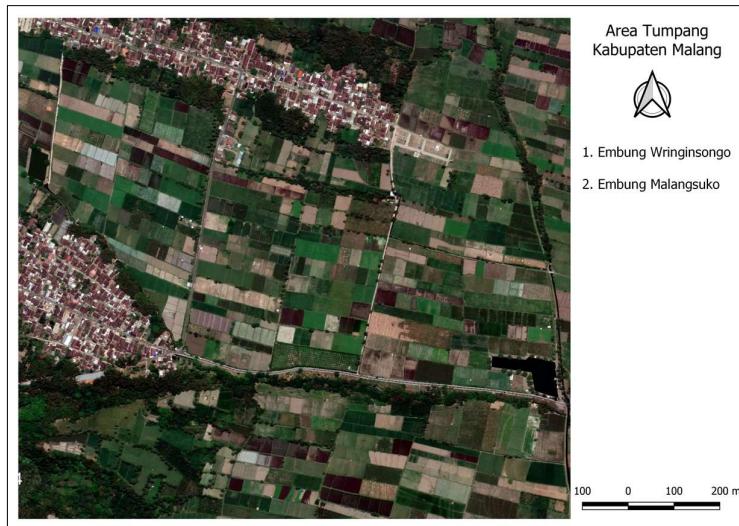
Sumber: Dokumen penulis

Dari hasil pencarian di atas, penulis memilih empat embung yang terletak di Kecamatan Tumpang dan Pakis untuk menjadi sampel penelitian (Tabel 4.3) karena memiliki lokasi embung yang berdekatan dalam satu kecamatan. Salah satu tampilan lokasi penelitian dalam Gambar 4.2.

**Tabel 4.3 Embung pilihan untuk sampel penelitian**

Nama	Desa	Kecamatan	Latitude	Longitude
Embong Wringinsongo	Wringinsongo	Tumpang	-7.9945	112.7454
Embong Malangsuko	Malangsuko	Tumpang	-7.9981	112.7552
Embong Sumber Umbulan	Banjarejo	Pakis	-7.9896	112.7163
Embong Cempaka	Sukoanyar	Pakis	-7.9786	112.7392

Sumber: Dokumen penulis



Sumber: Dokumen penulis

**Gambar 4.2 Lokasi embung menggunakan Google Earth Pro**

Penggunaan TerrSet 2020 pun dilakukan dengan proses '*image windowing*' pada kedua area tersebut pada data citra satelit PlanetScope untuk mendapatkan *area of interest*. Adapun rincian Tabel 4.4 sebagai berikut.

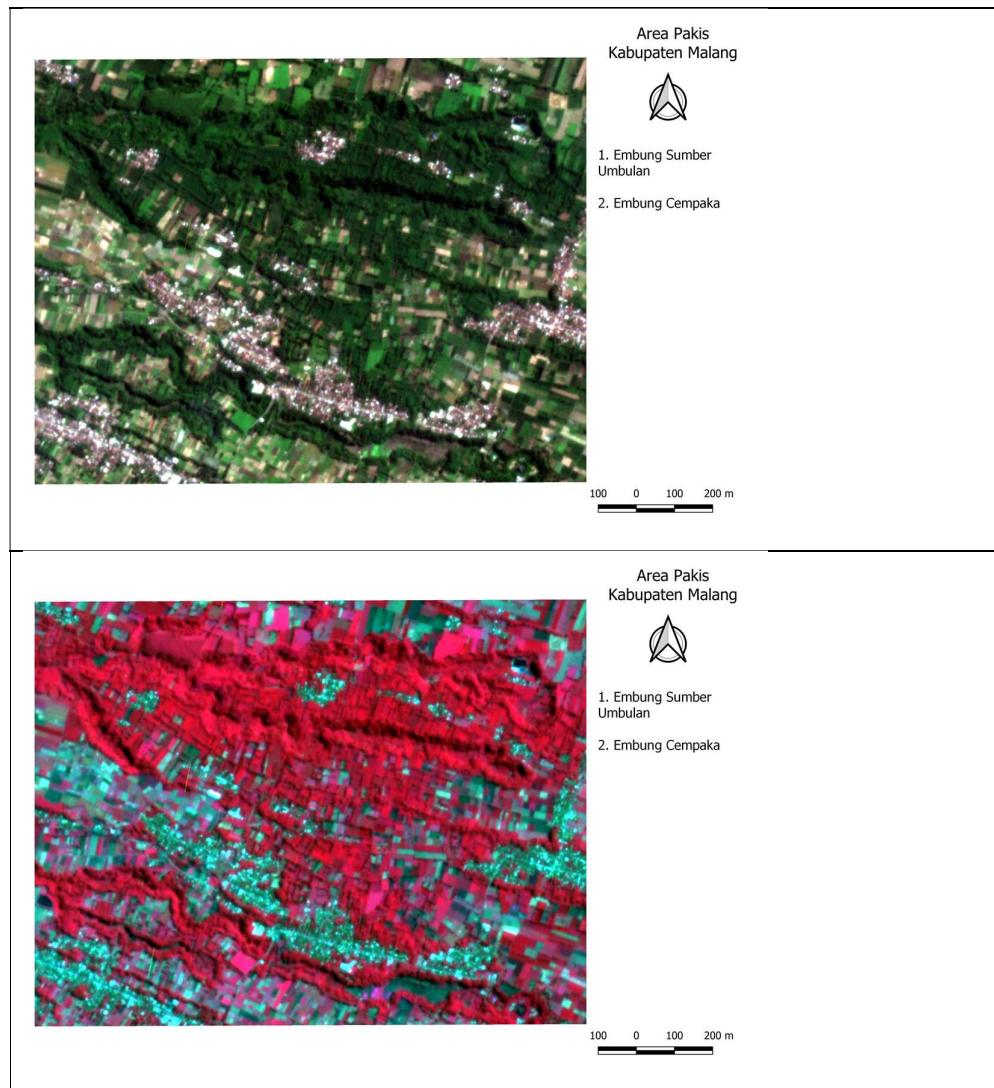
**Tabel 4.4 Area of Interest pada citra satelit PlanetScope**

Area	Skala	Kolom atas-kiri	Baris atas-kiri	Kolom bawah-kanan	Baris bawah-kanan
Tumpang	1 : 12,899	7,262	2,571	7,800	2,952
Pakis	1 : 25,193	6,250	2,051	7,299	2,794

Sumber: Dokumen penulis

#### 4.1.4 Proses Kombinasi Band

Untuk citra satelit PS dilakukan gabungan band 1,2,3 untuk *Natural Color* dan band 2,3,4 untuk *Color Infrared/Vegetation* menggunakan '*image compositing utility*' di TerrSet dan hasil tampilan Gambar 4.3 sebagai berikut.



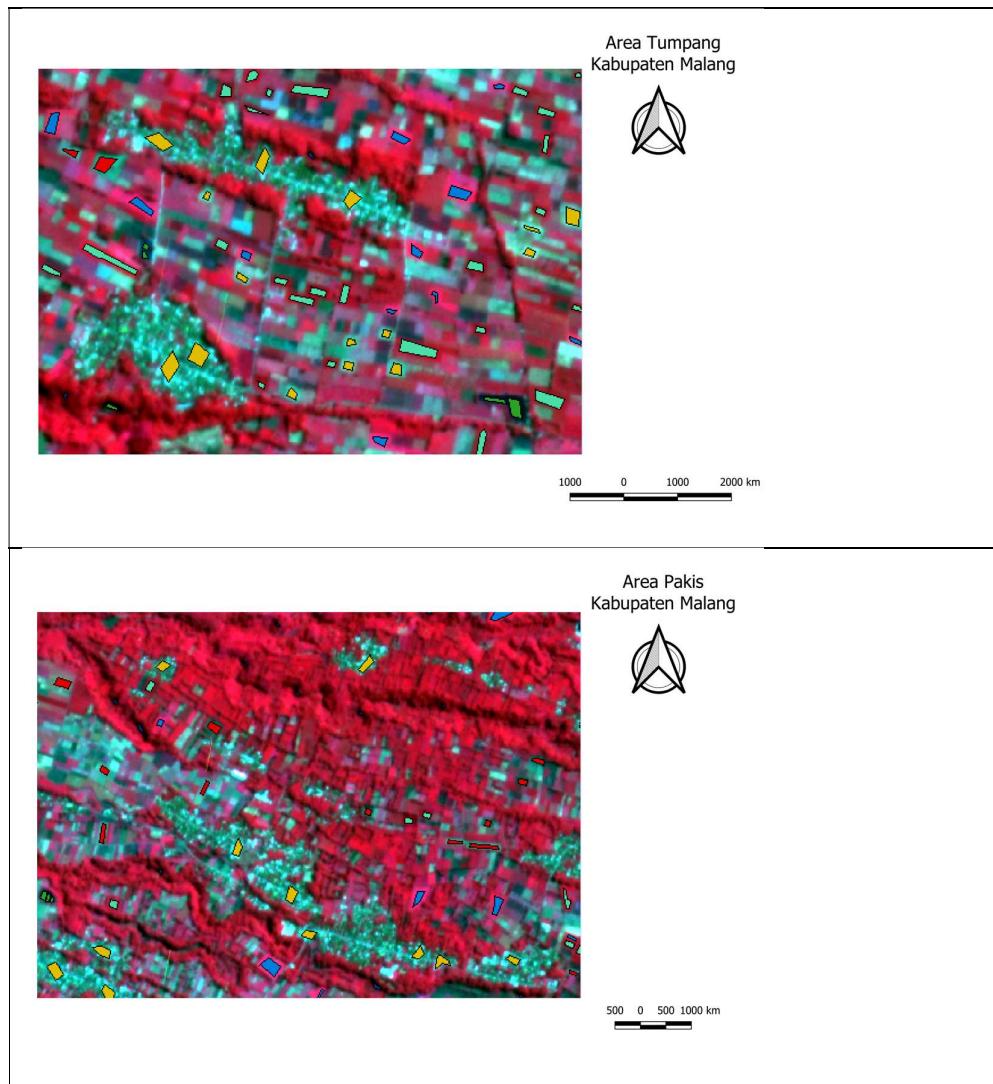
Sumber: Dokumen penulis

**Gambar 4.3 Tampilan *Natural Color* (atas) dan *Color Infrared* (bawah)**

## 4.2 Hasil Klasifikasi Citra Satelit

### 4.2.1 Pembuatan Area Contoh

Pada proses ini dilakukan digitasi manual pada 2 area penelitian, menggunakan kombinasi band *Color Infrared/Vegetation* sebagai dasar citra, tipe *layer* poligon, penentuan titik uji sebanyak 10-30, dan 6 kelas untuk analisis. Proses yang dilakukan pada TerrSet menggunakan *digitize* dan *signature extraction* (Gambar 4.4).



Sumber: Dokumen penulis

**Gambar 4.4 Digitasi pada area Tumpang (atas) dan Pakis (bawah)**

Pemilihan kelas berdasarkan perbandingan warna antara citra kombinasi band *Color Infrared/Vegetation* dengan *Natural Color*, dengan detail Tabel 4.5 sebagai berikut.

**Tabel 4.5 Pembagian kelas berdasarkan tampilan citra**

Kelas Klasifikasi	Warna Klasifikasi	Band Natural Color	Band Color Infrared
Perkebunan			
Sawah			

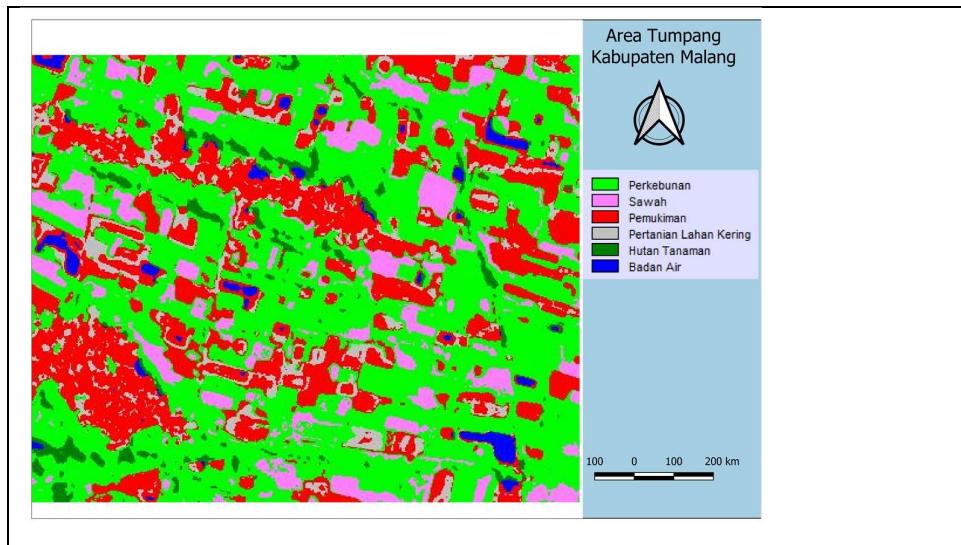
Pemukiman			
Pertanian Lahan Kering			
Hutan Tanaman			
Badan Air			

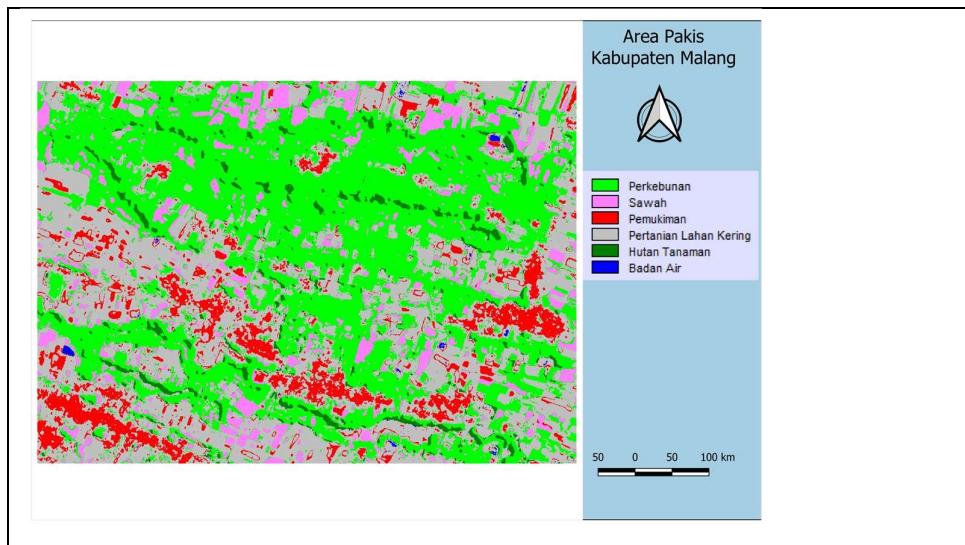
Sumber: Dokumen penulis

Dalam klasifikasi ini tidak terlihat kelas awan, karena satelit PS mempunyai resolusi spasial 3 m yang menampilkan citra lebih detail, sehingga kelas badan air dalam hal ini embung dapat diidentifikasi. Sedangkan klasifikasi selanjutnya dengan satelit Landsat resolusi spasial 30 m, kelas awan dapat terlihat. Namun kemungkinan untuk mencari kelas badan air dalam hal ini embung sangat sulit ditemukan.

#### 4.2.2 Klasifikasi SVM

Proses *Support Vector Machine classification* pada TerrSet dilakukan dengan *training parameter mode* yaitu *grid-search*, nilai *penalty C* = 100, nilai *Gamma* = 0.33, nilai *Epsilon* = 0.01, dan tipe kernel RBF. Berikut peta hasil klasifikasi citra satelit menggunakan SVM (Gambar 4.5).





Sumber: Dokumen penulis

**Gambar 4.5 Hasil klasifikasi SVM area Tumpang (atas) dan Pakis (bawah)**

Penentuan parameter model berdasarkan data latih dengan data uji, sehingga dapat diperoleh nilai estimasi kemampuan generalisasi model sebagai berikut (Tabel 4.6).

**Tabel 4.6 Hasil klasifikasi data pada area penelitian**

Kelas	Area Tumpang				Area Pakis			
	Data Latih	Data Uji	Rasio	Akurasi	Data Latih	Data Uji	Rasio	Akurasi
Perkebunan	18	3,577	0.0050	1.0000	114	4,095	0.0278	0.9900
Sawah	13	1,262	0.0103	1.0000	114	4,886	0.0233	0.9914
Pemukiman	235	2,192	0.1072	0.9644	1449	4,991	0.2903	0.9158
Lahan Kering	220	313	0.7029	0.7093	1450	4,559	0.3181	0.8329
Hutan Tanaman	10	96	0.1042	1.0000	9	926	0.0097	1.0000
Badan Air	9	464	0.0194	1.0000	16	322	0.0497	1.0000
Jumlah	505	7,904			3,152	19,779		

Sumber: Dokumen penulis

Dari hasil tabel diatas, nilai akurasi setiap kelas mendekati nilai 1 (artinya mesin dapat mengenali baik) kecuali kelas pertanian lahan kering dimana bernilai paling kecil 0.7093 dan 0.8329. Hal ini bisa disebabkan karena citra kelas pertanian lahan kering memiliki banyak warna. Selain itu proses pelatihan (*training time*) antara area Tumpang dan Pakis berbeda yaitu 16 detik dan 307 detik. Hal ini disebabkan jumlah data uji yang diproses pada area Pakis lebih banyak daripada area Tumpang.

### 4.3 Hasil Deteksi Perubahan

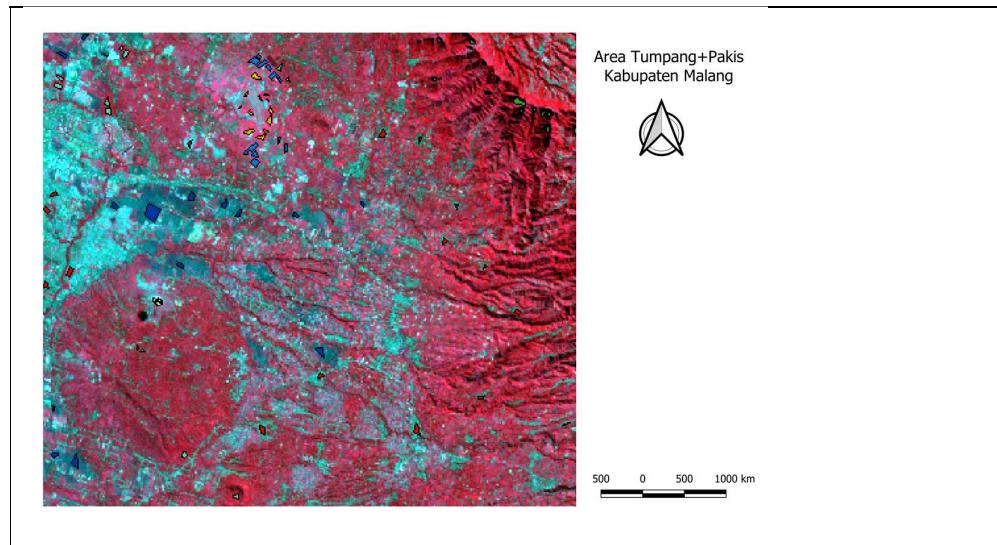
Proses menggunakan citra satelit Landsat dengan menggabungkan area Tumpang dan Pakis menjadi satu area penelitian. Hal ini berlaku untuk semua citra satelit Landsat yang dijadikan penelitian yaitu tahun 2004, 2009, 2015 dan 2020 (Tabel 4.7).

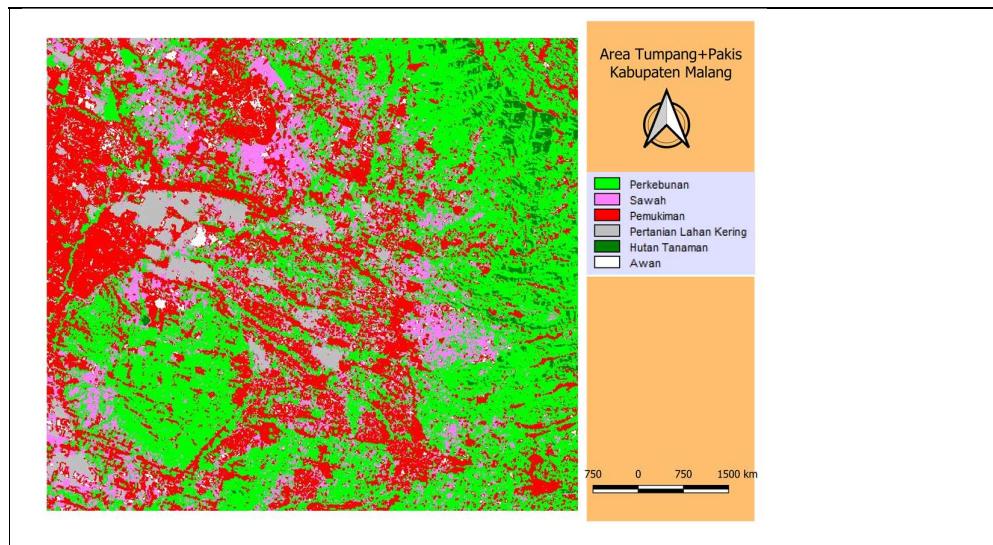
**Tabel 4.7 Area of Interest pada citra satelit Landsat**

Area	Skala	Kolom atas-kiri	Baris atas-kiri	Kolom bawah-kanan	Baris bawah-kanan
Tumpang dan Pakis	1:189,503	3,453	679	4,113	1,266

Sumber: Dokumen penulis

Dilakukan proses yang sama dalam menggabungkan kombinasi band *Color Infrared/Vegetation* di Landsat 7 (band 2,3,4) dan Landsat 8 (3,4,5). Kemudian dilanjutkan proses pembentukan area contoh dan klasifikasi menggunakan SVM dengan hasil salah satu citra satelit Landsat sebagai berikut (Gambar 4.6).





Sumber: Dokumen penulis

**Gambar 4.6 Pembentukan area contoh (atas) dan klasifikasi SVM (bawah)**

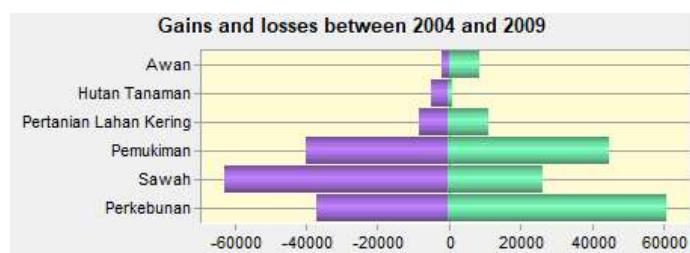
Semua proses di atas diterapkan pada semua citra yaitu citra tahun 2004, 2009, 2015 dan 2020. Selanjutnya dilakukan proses *overlay* data dengan perbandingan luas area kelas sebagai berikut (Gambar 4.8).

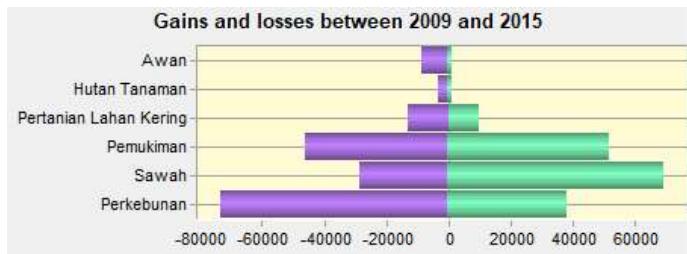
**Tabel 4.8 Perbandingan luas area kelas (*Overlay*)**

Kategori	Citra 2004 (m <sup>2</sup> )	Citra 2009 (m <sup>2</sup> )	Citra 2015 (m <sup>2</sup> )	Citra 2020 (m <sup>2</sup> )
Perkebunan	126,795,600	148,698,000	117,082,800	152,220,600
Sawah	81,750,600	49,309,200	86,283,900	92,457,000
Pemukiman	111,805,200	116,738,100	122,283,000	81,558,000
Lahan Kering	15,539,400	18,360,000	15,453,900	7,180,200
Hutan Tanaman	11,605,500	8,577,900	6,975,900	10,218,600
Awan	2,304,900	8,118,000	1,721,700	6,166,800

Sumber: Dokumen penulis

Selain itu juga perbandingan dapat menggunakan '*Land Change Modeler (LCM)*' pada TerrSet sebagai berikut (Gambar 4.7).





Sumber: Dokumen penulis

**Gambar 4.7 Gabungan data (*overlay*) menggunakan LCM**

Dari dua cara perbandingan di atas, dapat diberikan hasil sebagai berikut.

- Terjadi fluktuasi jumlah luasan antara kelas perkebunan dan sawah.
- Terjadi peningkatan luasan kelas pemukiman dari tahun 2004 hingga 2015.
- Terjadi penurunan luasan kelas hutan tanaman dari tahun 2004 hingga 2015.

Menurut penulis, poin (a) bisa disebabkan letak area Tumpang dan Pakis dekat gunung Bromo dan Semeru sehingga terjadi pergantian pertanaman komoditas pertanian menjadi perkebunan seperti kakao, kelapa, teh, kelapa sawit, lada, dan kopi oleh petani setempat atau sebaliknya (BPS, 2020).

#### 4.4 Hasil Prediksi Perubahan

Proses menggabungkan *Markovian transition estimator* dan *Cellular Automata/ Markov Change Prediction* pada Terrset dilakukan prediksi perubahan lahan periode 2004-2009 untuk memprediksi perubahan lahan tahun 2015, dan periode 2009-2015 untuk memprediksi perubahan lahan tahun 2020.

##### 4.4.1 Hasil Model Prediksi 2015

Perbandingan lahan periode 2004 dan 2009 mempunyai jarak 5 tahun dan 6 tahun dengan model prediksi 2015. Dengan menggunakan pilihan *background cell* dengan *assign 0.0* (1) dan nilai proposisional 0.0 maka dihasilkan nilai matrik peluang transisi dalam Tabel 4.9.

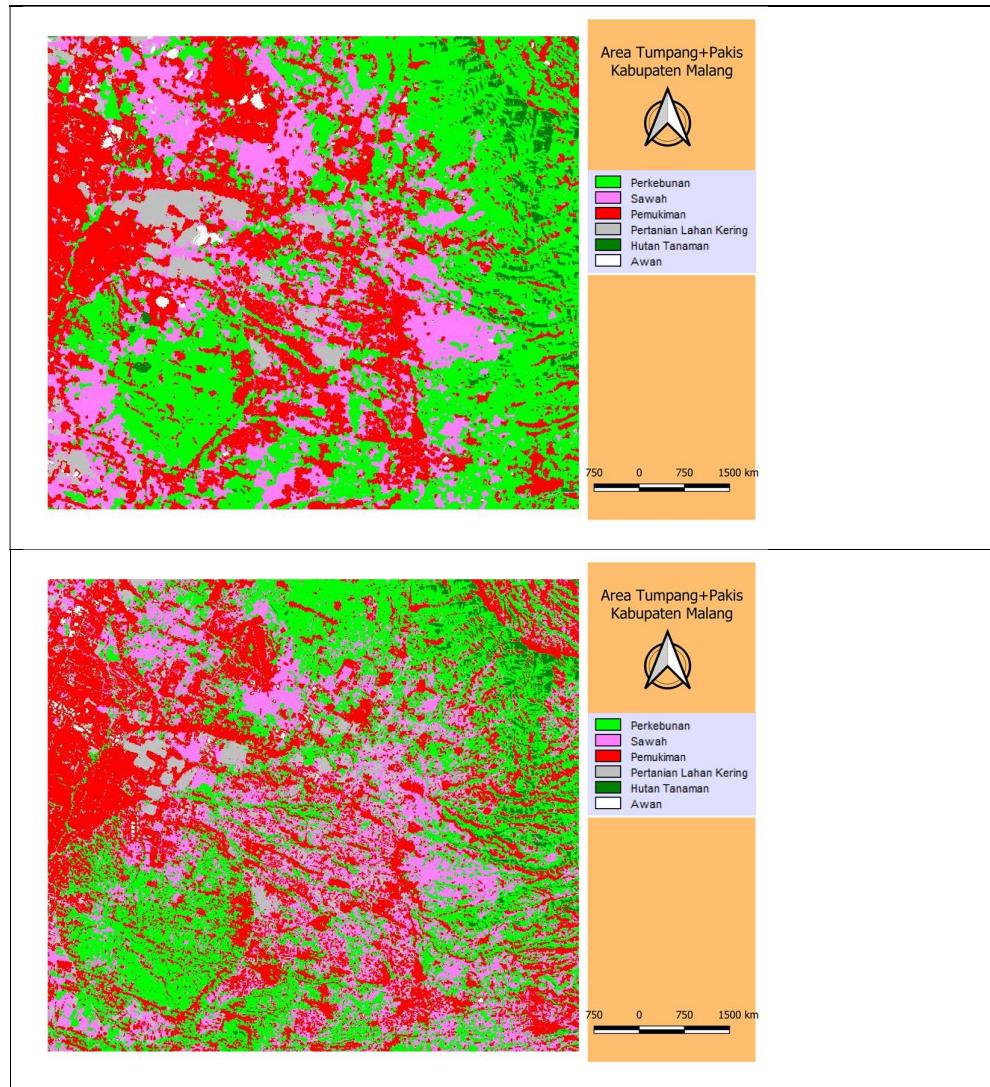
**Tabel 4.9 Matrik Peluang Transisi antara 2004 dan 2009**

	Perkebunan	Sawah	Pemukiman	Lahan Kering	Hutan Tanaman	Awan
Perkebunan	0.7058	0.0958	0.1643	0.0172	0.0079	0.0090
Sawah	0.4056	0.2690	0.2460	0.0532	0.0034	0.0227
Pemukiman	0.1788	0.0976	0.6428	0.0398	0.0009	0.0401
Lahan Kering	0.1537	0.1365	0.2131	0.4640	0.0021	0.0306
Hutan Tanaman	0.3844	0.0108	0.0122	0.0138	0.5783	0.0005
Awan	0.1548	0.1457	0.4063	0.0792	0.0214	0.1927

Sumber: Dokumen penulis

Dari tabel di atas dapat dijelaskan terkait kelas perkebunan dari keadaan periode 2004 pindah ke keadaan periode 2009 dengan nilai peluang 0.7058, menunjukkan terjadi peningkatan (mendekati 1). Kelas pemukiman dan hutan tanaman pun mengalami peningkatan dengan nilai peluang 0.6428 dan 0.5783. Berbeda dengan kelas sawah, pertanian lahan kering dan awan yang mengalami penurunan dengan nilai peluang 0.2690, 0.4640 dan 0.1927.

Dari hasil keluaran nilai probabilitas bersyarat maka dapat dilanjutkan untuk membuat model prediksi periode 2015 dengan menggunakan iterasi sebanyak 10 dan tipe CA menggunakan standard *5x5 contiguity filter* (Gambar 4.9).



Sumber: Dokumen penulis

**Gambar 4.9 Hasil citra prediksi (atas) dan citra aktual tahun 2015 (bawah)**

Hasil perbandingan luasan antara citra prediksi dengan citra aktual tahun 2015 menunjukkan hasil yang berbeda (Tabel 4.10).

**Tabel 4.10 Perbandingan luasan citra prediksi dan aktual tahun 2015**

Kategori	Citra Prediksi 2015 (m <sup>2</sup> )	Citra Aktual 2015 (m <sup>2</sup> )
Perkebunan	131,313,600 (37.54%)	117,082,800 (33.47%)
Sawah	75,108,600 (21.47%)	86,283,900 (24.67%)
Pemukiman	113,974,200 (32.58%)	122,283,000 (34.96%)
Pertanian Lahan Kering	16,263,000 (4.65%)	15,453,900 (4.42%)
Hutan Tanaman	9,630,900 (2.75%)	6,975,900 (1.99%)
Awan	3,510,900 (1.00%)	1,721,700 (0.49%)

Sumber: Dokumen penulis

Citra prediksi menunjukkan bahwa area perkebunan pada tahun 2015 akan mencapai 37.54%, berbeda dengan citra aktual dimana areal pemukiman yang mencapai 34.96%.

#### **4.4.2 Hasil Model Prediksi 2020**

Perbandingan lahan periode 2009 dan 2015 mempunyai jarak 6 tahun dan 5 tahun dengan model prediksi 2020. Dengan menggunakan pilihan *background cell* dengan *assign 0.0* (1) dan nilai proposional 0.0 maka dihasilkan nilai matrik peluang transisi dalam Tabel 4.11.

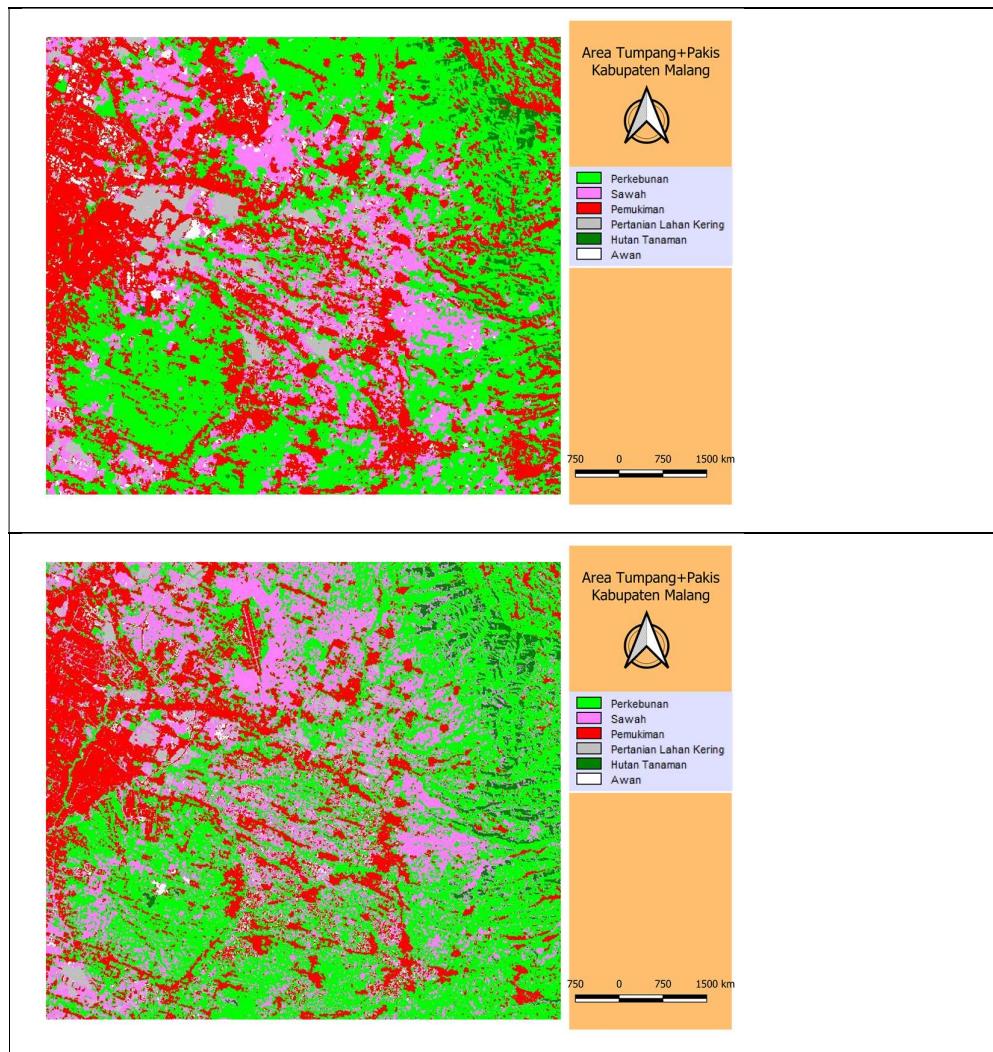
**Tabel 4.11 Matrik Peluang Transisi antara 2009 dan 2015**

	Perkebunan	Sawah	Pemukiman	Lahan Kering	Hutan Tanaman	Awan
Perkebunan	0.5898	0.1119	0.0345	0.2067	0.0303	0.0106
Sawah	0.4490	0.1528	0.0320	0.2762	0.0582	0.0065
Pemukiman	0.4386	0.1020	0.1605	0.2296	0.0268	0.0045
Lahan Kering	0.2531	0.1186	0.0440	0.4830	0.0586	0.0032
Hutan Tanaman	0.2599	0.1420	0.0281	0.2717	0.2607	0.0044
Awan	0.4939	0.0433	0.0112	0.0590	0.0207	0.3679

Sumber: Dokumen penulis

Dari tabel di atas dapat dijelaskan terkait kelas perkebunan dari keadaan periode 2009 pindah ke keadaan periode 2015 dengan nilai peluang 0.5898, menunjukkan terjadi peningkatan (mendekati 1). Sedangkan kelas lain seperti sawah, pemukiman, pertanian lahan kering, hutan tanaman dan awan mengalami penurunan dengan nilai peluang 0.1528, 0.1605, 0.4830, 0.2607 dan 0.3679.

Dari hasil keluaran nilai probabilitas bersyarat maka dapat dilanjutkan untuk membuat model prediksi periode 2020 dengan menggunakan iterasi sebanyak 10 dan tipe CA menggunakan standard 5x5 *contiguity filter* (Gambar 4.10).



Sumber: Dokumen penulis

**Gambar 4.10 Hasil citra prediksi (atas) dan citra aktual tahun 2020 (bawah)**

Hasil perbandingan luasan antara citra prediksi dan aktual tahun 2020 menunjukkan tren area sama yaitu perkebunan, seperti pada Tabel 4.12 berikut.

**Tabel 4.12 Perbandingan luasan citra prediksi dan aktual tahun 2020**

Kategori	Citra Prediksi 2020 (m <sup>2</sup> )	Citra Aktual 2020 (m <sup>2</sup> )
Perkebunan	143,199,000 (40.94%)	152,220,600 (43.52%)
Sawah	57,670,200	92,457,000
Pemukiman	115,080,300	81,558,000
Pertanian Lahan Kering	18,247,500	7,180,200
Hutan Tanaman	7,470,000	10,218,600
Awan	8,134,200	6,166,800

Sumber: Dokumen penulis

## BAB 5 ANALISIS DAN EVALUASI HASIL

### 5.1 Hasil Evaluasi Klasifikasi

Untuk mengetahui hasil evaluasi klasifikasi, perlu dilakukan juga uji hipotesis terhadap penggunaan klasifikasi SVM pada area Tumpang dan Pakis.

#### 5.1.1 Area Tumpang

Penggunaan *cross-tabulation* pada TerrSet dengan membandingkan citra hasil klasifikasi SVM dan klasifikasi lain dengan pendekatan piksel, selanjutnya dalam Tabel sebagai berikut.

**Tabel 5.1 Perbandingan klasifikasi SVM area tumpang (*pixel base*)**

	Perkebunan		Sawah		Pemukiman		Lahan Kering		Hutan Tanaman		Badan Air		Total
	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	
Perkebunan	73,785	40,748.26	19	7,919.85	464	19,679.97	403	5,006.25	2,788	2,810.51	8	1,302.17	77,467
Sawah	23,954	24,054.35	20,167	4,675.21	1,566	11,617.40	43	2,955.27	0	1,659.09	0	768.69	45,730
Pemukiman	10,247	30,892.98	640	6,004.37	38,200	14,920.22	6,810	3,795.45	416	2,130.77	2,418	987.23	58,731
Lahan Kering	314	9,233.02	224	1,794.53	11,321	4,459.22	5,694	1,134.35	0	636.83	0	295.05	17,553
Hutan Tanaman	4	2,282.35	0	443.60	0	1,102.29	0	280.41	4,243	157.42	92	72.94	4,339
Badan Air	0	1,093.05	0	212.45	756	527.90	356	134.29	23	75.39	943	34.93	2,078
Total	108,304		21,050		52,307		13,306		7,470		3,461		205,898

Sumber: Dokumen penulis

Berdasarkan tabel di atas, hasil perhitungan nilai Chi Kuadrat hitung = 360,401. Kemudian dilanjutkan koefisien kontingensi  $C$ , dengan rumus sebagai berikut.

$$C = \sqrt{\frac{\chi^2}{N+\chi^2}}$$

$$C = \sqrt{\frac{360,401.3750}{205,898+360,401.3750}} = 0.7978$$

Jadi besarnya koefisien kontingensi klasifikasi SVM = 0.7978. Pengujian signifikansi koefisien  $C$  dilakukan dengan membandingkan nilai Chi Kuadrat hitung dengan Chi Kuadrat tabel (pada taraf kesalahan dan  $dk$  tertentu). Nilai  $dk$  =  $(k - 1)(r - 1)$ , dimana  $k$  adalah jumlah baris (6) dan  $r$  adalah jumlah kolom (6), sehingga  $dk$  =  $(6 - 1)(6 - 1) = 25$ . Berdasarkan nilai  $dk$  adalah 25 dan taraf kesalahan 0.05, didapatkan nilai Chi Kuadrat tabel senilai 37,652. Maka didapatkan nilai Chi Kuadrat hitung lebih besar dari tabel ( $360,401 > 37,652$ ).

Sedangkan untuk menguji akurasi pada setiap kelas, dapat menggunakan koefisien Kappa dengan Tabel proposisional atau *confussion matrix* berikut.

**Tabel 5.2 Perbandingan klasifikasi SVM area tumpang (*proposisional*)**

	Perkebunan	Sawah	Pemukiman	Lahan Kering	Hutan Tanaman	Badan Air	Total
Perkebunan	0.3584	0.0001	0.0023	0.0020	0.0135	0.0000	0.3762
Sawah	0.1163	0.0979	0.0076	0.0002	0.0000	0.0000	0.2221
Pemukiman	0.0498	0.0031	0.1855	0.0331	0.0020	0.0117	0.2852

Lahan Kering	0.0015	0.0011	0.0550	0.0277	0.0000	0.0000	0.0853
Hutan Tanaman	0.0000	0.0000	0.0000	0.0000	0.0206	0.0004	0.0211
Badan Air	0.0000	0.0000	0.0037	0.0017	0.0001	0.0046	0.0101
Total	0.5260	0.1022	0.2540	0.0646	0.0363	0.0168	1.0000

Sumber: Dokumen penulis

Dari tabel di atas dapat dijelaskan terkait nilai akurasi pada semua kelas yang bernilai kurang baik, dimana nilai paling tinggi adalah kelas perkebunan senilai 0.3584, dilanjut kelas pemukiman 0.1855, dan kelas sawah, pertanian lahan kering, hutan tanaman, dan badan air dimana bernilai 0.0979, 0.0277, 0.0206, dan 0.0046. Adapun nilai koefisien Kappa = 0.5641, masuk di kategori 41-60 (Sedang). Hal ini bisa disebabkan jumlah data uji yang tidak proposional atau sebarannya tidak merata di area penelitian.

### 5.1.2 Area Pakis

Proses yang sama dilakukan terhadap area Pakis yaitu membandingkan citra hasil klasifikasi SVM dan klasifikasi lain dengan pendekatan piksel, selanjutnya dalam Tabel sebagai berikut.

**Tabel 5.3 Perbandingan klasifikasi SVM area pakis (*pixel base*)**

	Perkebunan		Sawah		Pemukiman		Lahan Kering		Hutan Tanaman		Badan Air		Total
	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	
Perkebunan	310,515	152,227.82	10,554	31,436.62	51	30,087.50	21,406	122,505.18	6,343	11,992.48	0	619.41	348,869
Sawah	17,975	47,155.11	54,796	9,738.02	53	9,320.10	35,244	37,948.03	0	3,714.87	0	191.87	108,068
Pemukiman	0	20,105.54	0	4,152.00	40,346	3,973.82	5,725	16,179.92	6	1,583.91	0	81.81	46,077
Lahan Kering	12,353	115,834.33	5,044	23,920.98	26,872	22,894.40	211,612	93,217.55	9,075	9,125.41	508	471.32	265,464
Hutan Tanaman	31	4,996.17	0	1,031.76	0	987.48	0	4,020.66	11,417	393.60	2	20.33	11,450
Badan Air	0	555.03	0	114.62	51	109.70	331	446.66	13	43.73	877	2.26	1,272
Total	340,874		70,394		67,373		274,318		26,854		1,387		781,200

Sumber: Dokumen penulis

Berdasarkan tabel di atas, hasil perhitungan nilai Chi Kuadrat hitung = 1,818,288. Kemudian dilanjutkan koefisien kontingensi  $C$ , dengan rumus sebagai berikut.

$$C = \sqrt{\frac{1,818,287.5000}{781,200+1,818,287.5000}} = 0.8363$$

Jadi besarnya koefisien kontingensi klasifikasi SVM = 0.8363. Pengujian signifikansi koefisien  $C$  dilakukan dengan membandingkan nilai Chi Kuadrat hitung dengan Chi Kuadrat tabel (pada taraf kesalahan dan  $dk$  tertentu). Nilai  $dk$  =  $(k - 1)(r - 1)$ , dimana  $k$  adalah jumlah baris (6) dan  $r$  adalah jumlah kolom (6), sehingga  $dk$  =  $(6 - 1)(6 - 1) = 25$ . Berdasarkan nilai  $dk$  adalah 25 dan taraf kesalahan 0.05, didapatkan nilai Chi Kuadrat tabel senilai 37,652. Dari perhitungan ternyata Chi Kuadrat hitung lebih besar dari tabel ( $1,818,288 > 37,652$ ).

Sedangkan untuk menguji akurasi pada setiap kelas, dapat menggunakan koefisien Kappa dengan tabel proposisional atau *confussion matrix* berikut.

**Tabel 5.4 Perbandingan klasifikasi SVM area pakis (*proposional*)**

	Perkebunan	Sawah	Pemukiman	Lahan Kering	Hutan Tanaman	Badan Air	Total
Perkebunan	0.3975	0.0135	0.0001	0.0274	0.0081	0.0000	0.4466
Sawah	0.0230	0.0701	0.0001	0.0451	0.0000	0.0000	0.1383
Pemukiman	0.0000	0.0000	0.0516	0.0073	0.0000	0.0000	0.0590
Lahan Kering	0.0158	0.0065	0.0344	0.2709	0.0116	0.0007	0.3398
Hutan Tanaman	0.0000	0.0000	0.0000	0.0000	0.0146	0.0000	0.0147
Badan Air	0.0000	0.0000	0.0001	0.0004	0.0000	0.0011	0.0016
Total	0.4363	0.0901	0.0862	0.3511	0.0344	0.0018	1.0000

Sumber: Dokumen penulis

Dari tabel di atas dapat dijelaskan terkait nilai akurasi pada semua kelas yang bernilai kurang baik, dimana nilai paling tinggi adalah kelas perkebunan senilai 0.3975, dilanjut kelas pertanian lahan kering 0.2709, dan kelas sawah, pemukiman, hutan tanaman, dan badan air dimana bernilai 0.0701, 0.0516, 0.0146, dan 0.0011. Adapun nilai koefisien Kappa = 0.7093, dimana masuk di kategori 61-80 (Baik).

Dengan demikian dapat disimpulkan dari kedua uji hipotesis terkait evaluasi klasifikasi, bahwa  $H_0$  ditolak dan  $H_a$  diterima yaitu ‘Algoritme SVM memiliki akurasi yang baik daripada klasifikasi lain pada kasus klasifikasi embung.’.

## 5.2 Hasil Evaluasi Model Prediksi

Sama seperti proses evaluasi klasifikasi sebelumnya, evaluasi model prediksi pun dilakukan uji hipotesis antara model prediksi dan model aktual.

### 5.2.1 Model Prediksi 2015

Penggunaan *cross-tabulation* pada TerrSet dengan membandingkan citra prediksi dan aktual 2015 dengan pendekatan piksel, selanjutnya dalam Tabel sebagai berikut.

**Tabel 5.5 Perbandingan citra prediksi dan aktual 2015 (*pixel base*)**

	Perkebunan		Sawah		Pemukiman		Lahan Kering		Hutan Tanaman		Awan		Total
	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	
Perkebunan	83,626	48,835.88	28,567	27,933.09	11,341	42,387.31	2,323	6,048.25	3,920	3,581.76	315	1,305.71	130,092
Sawah	26,582	35,989.49	37,732	20,585.23	25,189	31,237.23	4,930	4,457.25	121	2,639.57	1,317	962.24	95,871
Pemukiman	32,164	51,004.91	12,699	29,173.73	85,001	44,269.93	3,821	6,316.89	131	3,740.84	2,054	1,363.71	135,870
Lahan Kering	2,349	6,445.91	4,083	3,686.92	3,771	5,594.75	6,811	798.32	56	472.76	101	172.34	17,171
Hutan Tanaman	1,116	2,909.69	114	1,664.28	7	2,525.48	41	360.36	6,473	213.40	0	77.80	7,751
Badan Air	67	718.13	259	410.76	1,329	623.30	144	88.94	0	52.67	114	19.20	1,913
Total	145,904	83,454		126,638		18,070		10,701		3,901		388,668	

Sumber: Dokumen penulis

Berdasarkan tabel di atas, hasil perhitungan nilai Chi Kuadrat hitung = 369,623. Kemudian dilanjutkan koefisien kontingensi  $C$ , dengan rumus sebagai berikut.

$$C = \sqrt{\frac{369,623.4063}{388,668+3 ,623.4063}} = 0.6981$$

Jadi besarnya koefisien antara citra prediksi dan citra aktual = 0.6981. Pengujian signifikansi koefisien  $C$  dilakukan dengan membandingkan nilai Chi Kuadrat hitung dengan Chi Kuadrat tabel (pada taraf kesalahan dan  $dk$  tertentu). Nilai  $dk = (k - 1)(r - 1)$ , dimana  $k$  adalah jumlah baris (6) dan  $r$  adalah jumlah kolom (6), sehingga  $dk = (6 - 1)(6 - 1) = 25$ . Berdasarkan nilai  $dk$  adalah 25 dan taraf kesalahan 0.05, didapatkan nilai Chi Kuadrat tabel senilai 37,652. Dari perhitungan ternyata Chi Kuadrat hitung lebih besar dari tabel ( $369,623 > 37,652$ ).

Sedangkan untuk menguji model pada setiap kelas, dapat menggunakan koefisien Kappa dengan tabel proposisional atau *confussion matrix* berikut.

**Tabel 5.6 Perbandingan citra prediksi dan aktual 2015 (proposisional)**

	Perkebunan	Sawah	Pemukiman	Lahan Kering	Hutan Tanaman	Awan	Total
Perkebunan	0.2152	0.0735	0.0292	0.0060	0.0101	0.0008	0.3347
Sawah	0.0684	0.0971	0.0648	0.0127	0.0003	0.0034	0.2467
Pemukiman	0.0828	0.0327	0.2187	0.0098	0.0003	0.0053	0.3496
Lahan Kering	0.0060	0.0105	0.0097	0.0175	0.0001	0.0003	0.0442
Hutan Tanaman	0.0029	0.0003	0.0000	0.0001	0.0167	0.0000	0.0199
Awan	0.0002	0.0007	0.0034	0.0004	0.0000	0.0003	0.0049
Total	0.3754	0.2147	0.3258	0.0465	0.0275	0.0100	1.0000

Sumber: Dokumen penulis

Dari tabel di atas dapat dijelaskan terkait nilai akurasi pada semua kelas yang bernilai kurang baik, dimana nilai paling tinggi adalah kelas pemukiman senilai 0.2187, dilanjut kelas perkebunan 0.2152, dan kelas sawah, pertanian lahan kering, hutan tanaman, dan awan dimana bernilai 0.971, 0.0175, 0.0167 dan 0.0003. Maka nilai koefisien Kappa yang didapat 0.3834, dimana masuk di kategori 21-40 (Cukup). Hal ini bisa disebabkan jumlah pembentukan area contoh atau data uji yang tidak proposisional dan sebarannya tidak merata di area penelitian.

### 5.2.2 Model Prediksi 2020

Penggunaan *cross-tabulation* pada TerrSet dengan membandingkan citra prediksi dan aktual 2020 dengan pendekatan piksel, selanjutnya dalam Tabel sebagai berikut.

**Tabel 5.7 Perbandingan citra prediksi dan aktual 2020 (*pixel base*)**

	Perkebunan		Sawah		Pemukiman		Lahan Kering		Hutan Tanaman		Awan		Total
	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	fo	fh	
Perkebunan	101,687	69,238.81	21,679	27,884.39	40,166	55,643.01	3,512	8,822.93	291	3,611.85	1,799	3,933.01	169,134
Sawah	46,829	42,054.84	32,978	16,936.65	11,431	33,796.91	8,849	5,358.95	607	2,193.80	2,036	2,388.86	102,730
Pemukiman	4,361	37,097.34	6,598	14,940.13	72,616	29,812.87	2,438	4,727.22	9	1,935.19	4,598	2,107.26	90,620
Lahan Kering	1,532	3,265.97	1,185	1,315.30	905	2,624.66	4,180	416.18	13	170.37	163	185.52	7,978
Hutan Tanaman	3,895	4,648.02	6	1,871.89	16	3,735.33	54	592.29	7,380	242.47	3	264.02	11,354
Badan Air	806	2,805.02	1,632	1,129.66	2,733	2,254.22	1,242	357.44	0	146.32	439	159.34	6,852
Total	159,110		64,078		127,867		20,275		8,300		9,038		388,668

Sumber: Dokumen penulis

Berdasarkan tabel di atas, hasil perhitungan nilai Chi Kuadrat hitung = 420,646. Kemudian dilanjutkan koefisien kontingensi  $C$ , dengan rumus sebagai berikut.

$$C = \sqrt{\frac{420,646.3750}{388,668+420,646.3750}} = 0.7209$$

Jadi besarnya koefisien antara citra prediksi dan citra aktual = 0.7209. Pengujian signifikansi koefisien  $C$  dilakukan dengan membandingkan nilai Chi Kuadrat hitung dengan Chi Kuadrat tabel (pada taraf kesalahan dan  $dk$  tertentu). Nilai  $dk = (k - 1)(r - 1)$ , dimana  $k$  adalah jumlah baris (6) dan  $r$  adalah jumlah kolom (6), sehingga  $dk = (6 - 1)(6 - 1) = 25$ . Berdasarkan nilai  $dk$  adalah 25 dan taraf kesalahan 0.05, didapatkan nilai Chi Kuadrat tabel senilai 37,652. Dari perhitungan ternyata Chi Kuadrat hitung lebih besar dari tabel ( $420,646 > 37,652$ ).

Sedangkan untuk menguji model pada setiap kelas, dapat menggunakan koefisien Kappa dengan Tabel proposional atau *confussion matrix* berikut.

**Tabel 5.8 Perbandingan citra prediksi dan aktual 2020 (*proposional*)**

	Perkebunan	Sawah	Pemukiman	Lahan Kering	Hutan Tanaman	Awan	Total
Perkebunan	0.2616	0.0558	0.1033	0.009	0.0007	0.0046	0.4352
Sawah	0.1205	0.0848	0.0294	0.0228	0.0016	0.0052	0.2643
Pemukiman	0.0112	0.017	0.1868	0.0063	0	0.0118	0.2332
Lahan Kering	0.0039	0.003	0.0023	0.0108	0	0.0004	0.0205
Hutan Tanaman	0.01	0	0	0.0001	0.019	0	0.0292
Awan	0.0021	0.0042	0.007	0.0032	0	0.0011	0.0176
Total	0.4094	0.1649	0.329	0.0522	0.0214	0.0233	1.0000

Sumber: Dokumen penulis

Dari tabel di atas dapat dijelaskan terkait nilai akurasi pada semua kelas yang bernilai kurang baik, dimana nilai paling tinggi adalah kelas perkebunan senilai 0.2616, dilanjut kelas pemukiman 0.1868, dan kelas sawah, pertanian lahan kering, hutan tanaman, dan awan bernilai 0.848, 0.0108, 0.0019 dan 0.0011. Maka nilai koefisien Kappa yang didapat 0.3769, dimana masuk di kategori 21-40 (Cukup). Hal ini bisa disebabkan jumlah data uji yang tidak proposisional dan sebarannya tidak merata di area penelitian.

Dengan demikian dapat disimpulkan dari kedua uji hipotesis terkait evaluasi model prediksi, bahwa  $H_0$  ditolak dan  $H_a$  diterima yaitu ‘model prediksi Markov-CA memiliki akurasi yang baik daripada aktual model pada kasus deteksi perubahan lahan embung untuk pertanian di Kabupaten Malang.’

## **BAB 6 PENUTUP**

### **6.1 Kesimpulan**

Hasil penelitian berhasil mengklasifikasikan tutupan lahan badan air dalam hal ini embung di Kabupaten Malang menggunakan metode SVM dengan nilai koefisien Kappa area Tumpang 0.5641 (sedang) dan area Pakis 0.7093 (baik). Perihal tidak mendapat nilai sangat baik bisa disebabkan dalam pembentukan area contoh atau data uji, jumlahnya tidak proposisional dan sebarannya tidak merata di area penelitian. Akan tetapi penggunaan klasifikasi SVM dengan memanfaatkan citra satelit PlanetScope secara umum memberikan solusi yang akurat dan efisien.

Model prediksi perubahan embung untuk pertanian dengan model Markov-CA menunjukkan bahwasanya citra satelit multi temporal menghasilkan nilai prediksi cukup dengan indeks nilai koefisien Kappa model prediksi 2015 dan 2020 sebesar 0.3834 dan 0.3769. Dari hasil penelitian menunjukkan bahwa antara tahun 2004 hingga 2015 area pemukiman semakin bertambah, sedangkan area hutan tanaman semakin berkurang. Prediksi dengan menggunakan model Markov-CA menunjukkan bahwa area perkebunan pada tahun 2020 akan mencapai 40.94%, sehingga perlu dilakukan pembagunan embung. Model prediksi perubahan tutupan lahan dapat memberikan acuan bagi Pemerintah untuk kebijakan dalam penentuan lokasi embung untuk pertanian di masa depan.

### **6.2 Saran**

Penelitian lanjutan diharapkan menggunakan citra resolusi tinggi lain seperti citra ALOS PRISM dan FUSI agar dapat mengidentifikasi tutupan lahan secara detail. Penelitian menggunakan jumlah pembuatan area contoh atau data uji yang proposisional dan sebarannya merata di area penelitian untuk menganalisis penggunaan tutupan lahan.

## DAFTAR RUJUKAN

- Abbott, D. (2014). *Applied Predictive Analytics: Principles and Techniques for the Professional Data Analyst* (1st ed.). USA: Wiley.
- Akyürek, D., Koç, Akbaba, E. M., & Sunar, F. (2018). Land use/land cover change detection using multi-temporal satellite dataset: A case study in Istanbul new airport. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3W4). <https://doi.org/10.5194/isprs-archives-XLII-3-W4-17-2018>
- Al-Bakri, J. T., Duqqah, M., & Brewer, T. (2013). Application of Remote Sensing and GIS for Modeling and Assessment of Land Use/Cover Change in Amman/Jordan. *Journal of Geographic Information System*, 05(05), 509–519. <https://doi.org/10.4236/jgis.2013.55048>
- Ali, M. (2007). *The Exploitation of Remote Sensing Products to Improve Water Quality Monitoring in the Nile Delta* [Thesis, Vrije universiteit Brussel]. <https://link.springer.com/article/10.1007/s11356-020-11765-1>
- Altman, D. G. (1990). *Practical Statistics for Medical Research* (1st ed.). New York: Chapman and Hall/CRC.
- Andry, J. F. (2015). *Implementasi Penerapan Markov Chain Pada Database Marketing Studi Kasus Pelanggan E-Commerce*. 5(1), 94–108. <https://journal.ubm.ac.id/index.php/teknologi-informasi/article/view/350>
- Arsyad, S. (2010). *Konservasi Tanah & Air*. Bogor: IPB Press.
- Bagchi, T. (2013). Refining AI Methods for Medical Diagnostics Management. *NMIMS Management Review*, XXIII, 67–90. [https://www.researchgate.net/publication/263582095\\_Refining\\_AI\\_Methods\\_for\\_Medical\\_Diagnostics\\_Management](https://www.researchgate.net/publication/263582095_Refining_AI_Methods_for_Medical_Diagnostics_Management)
- Barredo, J. I., Kasanko, M., McCormick, N., & Lavalle, C. (2003). Modelling dynamic spatial processes: simulation of urban future scenarios through cellular automata. *Landscape and Urban Planning*, 64(3), 145–160. [https://doi.org/https://doi.org/10.1016/S0169-2046\(02\)00218-9](https://doi.org/https://doi.org/10.1016/S0169-2046(02)00218-9)
- BPS. (2020). *Kabupaten Malang Dalam Angka*. Malang: BPS Kabupaten Malang.
- BSN. (2010). *Klasifikasi Penutup Lahan*. Jakarta: Badan Standardisasi Nasional.
- Buhari, B. (2016). *Analisis Geospasial Menggunakan Metode Cellular Automata Untuk Prediksi Perubahan Garis Pantai* [Skripsi, Universitas Hasanuddin]. <https://doi.org/10.13140/RG.2.2.26919.75683>
- Campbell, C., & Ying, Y. (2011). Learning with Support Vector Machines. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 5(1), 1–95. <https://doi.org/10.2200/S00324ED1V01Y201102AIM010>
- Cesare, M. A., Carlos, S., Carl, T., & H., V. E. (1992). Modeling Bridge Deterioration

- with Markov Chains. *Journal of Transportation Engineering*, 118(6), 820–833. [https://doi.org/10.1061/\(ASCE\)0733-947X\(1992\)118:6\(820\)](https://doi.org/10.1061/(ASCE)0733-947X(1992)118:6(820))
- Chang, K. (2005). *Introduction to Geographic Information Systems* (3rd ed.). UK: McGraw-Hill Higher Education.
- Chowdhury, M., Sadek, A., Ma, Y., Kanhere, N., & Bhavsar, P. (2006). Applications of Artificial Intelligence Paradigms to Decision Support in Real-Time Traffic Management. *Transportation Research Record*, 1968(1), 92–98. <https://doi.org/10.1177/0361198106196800111>
- Danoedoro, P. (2012). *Pengantar Penginderaan Jauh Digital*. Yogyakarta: Penerbit ANDI.
- Diskominfo. (2020). *Kabupaten Malang Satu Data*. Malang: Dinas Komunikasi dan Informatika Kabupaten Malang.
- Du, P., Liu, S., Gamba, P., Tan, K., & Xia, J. (2012). Fusion of Difference Images for Change Detection Over Urban Areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(4), 1076–1086. <https://doi.org/10.1109/JSTARS.2012.2200879>
- Eastman, R. (1999). *IDRISI32 2.0: Guide to GIS and Image Processing Volume 2*. USA: Clark Labs.
- Foody, G. (2017). Impacts of sample design for validation data on the accuracy of feedforward neural network classification. *Applied Sciences*, 7(9). <https://doi.org/https://doi.org/10.3390/app7090888>
- Foody, G. M., & Mathur, A. (2004). Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93(1), 107–117. <https://doi.org/https://doi.org/10.1016/j.rse.2004.06.017>
- Gasparovic, M., Dobrinic, D., & Medak, D. (2018). Urban Vegetation Detection Based On The Land Cover Classification Of PlanetScope, RapidEye And WorldView-2 Satellite Imagery. *18th International Multidisciplinary Scientific GeoConference SGEM 2018*, 18(2.3), 249–256. <https://doi.org/10.5593/sgem2018/2.3/S10.032>
- Gong, J., Liu, Y., Xia, B., & Zhao, G. (2009). Urban ecological security assessment and forecasting, based on a cellular automata model: A case study of Guangzhou, China. *Ecological Modelling*, 220(24), 3612–3620. <https://doi.org/https://doi.org/10.1016/j.ecolmodel.2009.10.018>
- Gunn, S. R. (1998). *Support Vector Machines for Classification and Regression*. Technical Report, University of Southampton. <http://ce.sharif.ir/courses/85-86/2/ce725/resources/root/LECTURES/SVM.pdf>
- Habibi, M., Sahebi, M., Maghsoudi, Y., & Ghayourmanesh, S. (2016). Classification of Polarimetric SAR Data Based on Object-Based Multiple Classifiers for Urban Land-Cover. *Journal of the Indian Society of Remote Sensing*, 44.

- <https://doi.org/10.1007/s12524-016-0558-5>
- Hong, H., Liu, J., Zhu, A.-X., Shahabi, H., Pham, B. T., Chen, W., Pradhan, B., & Bui, D. T. (2017). A novel hybrid integration model using support vector machines and random subspace for weather-triggered landslide susceptibility assessment in the Wuning area (China). *Environmental Earth Sciences*, 76(19), 652. <https://doi.org/10.1007/s12665-017-6981-2>
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725–749. <https://doi.org/10.1080/01431160110040323>
- Johnson, J. E., Laparra, V., Pérez-Suay, A., Mahecha, M. D., & Camps-Valls, G. (2020). Kernel methods and their derivatives: Concept and perspectives for the earth system sciences. *PLOS ONE*, 15(10), e0235885. <https://doi.org/10.1371/journal.pone.0235885>
- Kandziora, M., Dörnhöfer, K., Oppelt, N., & Müller, F. (2014). Detecting land use and land cover changes in Northern German agricultural landscapes to assess ecosystem service dynamics. *Landscape Online*, 35(1). <https://doi.org/10.3097/LO.201435>
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352–359. <https://doi.org/https://doi.org/10.1016/j.jag.2009.06.002>
- Khaira, U., Sitanggang, I. S., & Syaufina, L. (2016). Detection and prediction of peatland cover changes using support vector machine and Markov Chain Model. *Telkomnika (Telecommunication Computing Electronics and Control)*, 14(1), 294–301. <https://doi.org/10.12928/TELKOMNIKA.v14i1.2400>
- Khanna, R., & Awad, M. (2015). Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers. In *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*. <https://doi.org/10.1007/978-1-4614-990-9>
- Khatami, R., Mountrakis, G., & Stehman, S. V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177. <https://doi.org/10.1016/j.rse.2016.02.028>
- Kim, S., Liu, H., Yeganova, L., & Wilbur, W. J. (2015). Extracting drug–drug interactions from literature using a rich feature-based linear kernel approach. *Journal of Biomedical Informatics*, 55, 23–30. <https://doi.org/https://doi.org/10.1016/j.jbi.2015.03.002>
- Lenka, B., & R.K., D. (2020). An Introduction to Digital Soil Mapping. In *Book: Advances in Agriculture Sciences* (Vol. 25, pp. 1–17). India: AkiNik Publications. <https://doi.org/10.22271/ed.book.773>
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *Remote sensing and image*

- interpretation*. New York : Wiley.
- Liu, J. G., & Mason, P. (2009). *Essential Image Processing and GIS for Remote Sensing*. UK: Wiley-Blackwell. <https://doi.org/10.1002/9781118687963.ch1>
- Liu, Y., & He, J. (2009). Developing a web-based cellular automata model for urban growth simulation. In Yaolin Liu & X. Tang (Eds.), *International Symposium on Spatial Analysis, Spatial-Temporal Data Modeling, and Data Mining* (Vol. 7492, pp. 1569–1576). SPIE. <https://doi.org/10.1117/12.838657>
- McCabe, M. F., Aragon, B., Houborg, R., & Mascaro, J. (2017). CubeSats in Hydrology: Ultrahigh-Resolution Insights Into Vegetation Dynamics and Terrestrial Evaporation. *Water Resources Research*, 53(12), 10017–10024. <https://doi.org/https://doi.org/10.1002/2017WR022240>
- Melgani, F., & Bruzzone, L. (2004). Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. *Geoscience and Remote Sensing, IEEE Transactions On*, 42, 1778–1790. <https://doi.org/10.1109/TGRS.2004.831865>
- Mondal, A., Kundu, S., Chandniha, S. K., Shukla, R., & Mishra, P. K. (2012). Comparison of Support Vector Machine and Maximum Likelihood Classification Technique using Satellite Imagery. *International Journal of Remote Sensing and GIS*, 1(2), 116–123. [https://www.researchgate.net/publication/280316746\\_Comparison\\_of\\_support\\_vector\\_machine\\_and\\_maximum\\_likelihood\\_classification\\_technique\\_using\\_satellite\\_imagery](https://www.researchgate.net/publication/280316746_Comparison_of_support_vector_machine_and_maximum_likelihood_classification_technique_using_satellite_imagery)
- Mukmin, S. Al, Wijaya, A., & Sukmono, A. (2016). Analisis Pengaruh Perubahan Tutupan Lahan Terhadap Distribusi Suhu Permukaan dan Keterkaitannya Dengan Fenomena Urban Heat Island. *Jurnal Geodesi Undip*, 5(1), 224–233. <https://ejournal3.undip.ac.id/index.php/geodesi/article/view/10594>
- Mustapha, M., Lim, H. S., & Mat Jafri, M. Z. (2010). Comparison of Neural Network and Maximum Likelihood Approaches in Image Classification. *Journal of Applied Sciences*, 10. <https://doi.org/10.3923/jas.2010.2847.2854>
- N.J, N., & Palanivel, s. (2015). Music emotion recognition: The combined evidence of MFCC and residual phase. *Egyptian Informatics Journal*, 17. <https://doi.org/10.1016/j.eij.2015.05.004>
- Oommen, T., Misra, D., Twarakavi, N. K. C., Prakash, A., Sahoo, B., & Bandopadhyay, S. (2008). An Objective Analysis of Support Vector Machine Based Classification for Remote Sensing. *Mathematical Geosciences*, 40(4), 409–424. <https://doi.org/10.1007/s11004-008-9156-6>
- Öz, E., & Kaya, H. (2013). Support vector machines for quality control of DNA sequencing. *Journal of Inequalities and Applications*, 2013(1), 85. <https://doi.org/10.1186/1029-242X-2013-85>
- Phiri, D., & Morgenroth, J. (2017). remote sensing Review Developments in Landsat Land Cover Classification Methods: A Review. *Remote Sensing*, 9.

- <https://doi.org/10.3390/rs9090967>
- Pontius Jr, R. G., & Millones, M. (2011). Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407–4429. <https://doi.org/10.1080/01431161.2011.552923>
- Pramudita, D. A., & Musdholifah, A. (2020). GSA to Obtain SVM Kernel Parameter for Thyroid Nodule Classification. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 14(1), 11. <https://doi.org/10.22146/ijccs.41215>
- Ramdani, F. (2017). *Pengantar Ilmu Geoinformatika*. Malang: UB Press.
- Ramdani, F. (2018). *Ilmu Geoinformatika: Observasi Hingga Validasi*. Malang: UB Press.
- Ramdani, F. (2019a). *Kuriositas: Metode Ilmiah Penelitian Teknologi Informasi*. Malang: UB Press.
- Ramdani, F. (2019b). Recent expansion of oil palm plantation in the most eastern part of Indonesia: feature extraction with polarimetric SAR. *International Journal of Remote Sensing*, 40(19), 7371–7388. <https://doi.org/10.1080/01431161.2018.1508924>
- Ramdani, F., Putra, A. P., & Utomo, B. N. (2015). Historical Urban Land Use Transformation in Virtual Geo-Library. In *ISPRS International Journal of Geo-Information* (Vol. 4, Issue 3). <https://doi.org/10.3390/ijgi4031500>
- Rusmawan. (2007). Perubahan Penggunaan Lahan Pertanian ke Non-Pertanian dalam Perspektif Sosial Budaya. *Jurnal Geomedia*, 5(1), 111–118. <https://doi.org/https://doi.org/10.21831/gm.v5i1.14207>
- Rustiadi, E., Saefulhakim, S., & Panuju, D. (2018). *Perencanaan dan Pengembangan Wilayah* (Cetakan ke). Bogor: Crestpent Press.
- Said, N. I., & Widayat, W. (2014). *Pengisian Air Tanah Buatan, Pemanenan Air Hujan dan Teknologi Pengelolaan Air Hujan*. Jakarta: BPPT Press.
- Sampurno, R., & Thoriq, A. (2016). Klasifikasi Tutupan Lahan Menggunakan Citra Landsat 8 Operational Land Imager (OLI) Di Kabupaten Sumedang. *Jurnal Teknotan*, 10, 61–70. <https://doi.org/10.24198/jt.vol10n2.9>
- Santosa, B. (2007). *Data Mining : Teknik Pemanfaatan Data Untuk Keperluan Bisnis Teori & Aplikasi* (Ed. 1 Cet.). Jakarta: Graha Ilmu.
- Serief, C., Barkat, M., Bentoutou, Y., & Benslama, M. (2009). Robust feature points extraction for image registration based on the nonsubsampled contourlet transform. *AEU - International Journal of Electronics and Communications*, 63(2), 148–152. <https://doi.org/https://doi.org/10.1016/j.aeue.2007.11.005>
- Sesama, A., Setiawan, K., & Julzarika, A. (2021). Bathymetric Extraction Using PlanetScope Imagery (Case Study: Kemujan Island, Central Java). *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, 17, 209. <https://doi.org/10.30536/j.ijreses.2020.v17.a3445>

- Setiawan, B. I., Wirasembada, Y. C., Kuswanda, W. P., Jannati, S. L., & Andayani, A. (2016). *Penentuan Lokasi, Rancangan dan Pembuatan Embung untuk Pertanian: Upaya Menghadirkan Solusi Permanen Mengatasi Kritis Kekeringan*. Bogor: BBSDLP.
- Shi, Y., Huang, W., Ye, H., Ruan, C., Xing, N., Geng, Y., Dong, Y., & Peng, D. (2018). Partial Least Square Discriminant Analysis Based on Normalized Two-Stage Vegetation Indices for Mapping Damage from Rice Diseases Using PlanetScope Datasets. *Sensors*, 18, 1901. <https://doi.org/10.3390/s18061901>
- Styawati, S., & Mustofa, K. (2019). A Support Vector Machine-Firefly Algorithm for Movie Opinion Data Classification. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 13(3). <https://doi.org/10.22146/ijccs.41302>
- Sugiyono. (2017). *Metode Penelitian Bisnis* (Edisi Ke-3). Bandung: ALFABETA.
- Susilo, B. (2016). Pemodelan Spasial Probalistik Integrasi Markov Chain dan Cellular Automata Untuk Kajian Perubahan Penggunaan Lahan Skala Regional di Provinsi Daerah Istimewa Yogyakarta. *Jurnal Geografi GEA*, 11(2). <https://doi.org/10.17509/gea.v11i2.1638>
- Syam, T., Darmawan, A., Banuwa, I. S., & Ningsih, K. (2012). Pemanfaatan Citra Satelit Dalam Mengidentifikasi Perubahan Penutupan Lahan : Studi Kasus Hutan Lindung Register 22 Way Waya Lampung Tengah ( Utilization of Satellite Imagery in Identifying of Land Cover Changes : *Jurnal Globe*, 14(2), 146–156.
- Traganos, D., Cerra, D., & Reinartz, P. (2017). CubeSat-Derived Detection Of Seagrasses Using Planet Imagery Following Unmixing-Based Denoising: Is Small The Next Big? *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-1/W1, 283–287. <https://doi.org/10.5194/isprs-archives-XLII-1-W1-283-2017>
- Turban, E., Aronson, J. E., & Liang, T.-P. (2004). *Decision Support Systems and Intelligent Systems* (7th Edition). United States: Prentice-Hall, Inc.
- Vapnik, V., Golowich, S., & Smola, A. (1997). Support Vector Method for Function Approximation, Regression Estimation and Signal Processing. In M. C. Mozer, M. Jordan, & T. Petsche (Eds.), *Advances in Neural Information Processing Systems* (Vol. 9, pp. 281–287). MIT Press. <https://proceedings.neurips.cc/paper/1996/file/4f284803bd0966cc24fa8683a34afc6e-Paper.pdf>
- White, R., Engelen, G., & Uljee, I. (1997). The Use of Constrained Cellular Automata for High-Resolution Modelling of Urban Land-Use Dynamics. *Environment and Planning B: Planning and Design*, 24(3), 323–343. <https://doi.org/10.1068/b240323>
- Wijaya, A., & Susetyo, C. (2017). Analisis Perubahan Penggunaan Lahan di Kota Pekalongan Tahun 2003, 2009, dan 2016. *Jurnal Teknik ITS*, 6(2), 417–420. <https://doi.org/10.12962/j23373539.v6i2.24454>

- Wolfram, S. (1984). Cellular automata as models of complexity. *Nature*, 311(5985), 419–424. <https://doi.org/10.1038/311419a0>
- Wu, Q., Zhong, R., Zhao, W., Fu, H., & Song, K. (2017). A comparison of pixel-based decision tree and object-based support vector machine methods for land-cover classification based on aerial images and airborne lidar data. *International Journal of Remote Sensing*, 38(23). <https://doi.org/10.1080/01431161.2017.1371864>
- Yirsaw, E., Wu, W., Shi, X., Temesgen, H., & Bekele, B. (2017). Land Use/Land Cover change modeling and the prediction of subsequent changes in ecosystem service values in a coastal area of China, the Su-Xi-Chang region. *Sustainability (Switzerland)*, 9(7), 1–17. <https://doi.org/10.3390/su9071204>
- Zhou, Z., & Zhou, L. (2010). An Automatic Incident of Freeway Detection Algorithm Based on Support Vector Machine. *2010 International Symposium on Intelligence Information Processing and Trusted Computing*. <https://doi.org/10.1109/IPTC.2010.97>