

**PEMANFAATAN METODA *MACHINE LEARNING* UNTUK MENINGKATKAN AKURASI
PENENTUAN POTENSI LAHAN TAMBAK GARAM
DI KECAMATAN KAPETAKAN DAN SURANENGGALA KABUPATEN CIREBON**

***UTILIZATION OF MACHINE LEARNING METHODS TO IMPROVE THE ACCURACY
OF DETERMINING POTENTIAL LAND FOR SALT PONDS
IN KAPETAKAN AND SURANENGGALA SUB-DISTRICTS, CIREBON REGENCY***

Yusa Inderapermana, Dangi, Fitri Nurliasari, Eva Rahmifa, Dwi Kusumayanti, Nur Fauziyah Rahmawati, & Umayah

Bappelitbangda Kabupaten Cirebon
Jl. Sunan Kalijaga No.11, Sumber, Indonesia, Telp/Fax : 0231-321991

e-mail : yusa95@yahoo.com

Diterima tanggal: 14 Maret 2023 ; diterima setelah perbaikan: 26 September 2023 ; Disetujui tanggal: 28 Desember 2023

ABSTRAK

Kabupaten Cirebon berada di sepanjang pantai utara laut Jawa dan memiliki potensi pengembangan usaha tambak garam dengan garis pantai sepanjang +77,97 km. Kesiapan lahan garam cukup luas yaitu sebesar 1.557,75 Ha. Potensi ini sesuai dengan program Kementerian Kelautan dan Perikanan (KKP) yaitu Sentra Ekonomi Garam Rakyat (SEGAR). Penelitian ini bertujuan untuk mengidentifikasi potensi lahan garam di Kecamatan Kapetakan sebagai kecamatan yang diprioritaskan sebagai lokasi pengembangan SEGAR dan Kecamatan Suranenggala sebagai Kecamatan yang bersebelahan. Metode penelitian yang digunakan adalah *Algoritma Machine Learning Random Forest* dengan menggunakan aplikasi *Google Earth Engine* dan Citra Satelit Sentinel 2A. Hasil penelitian ini menunjukkan bahwa potensi lahan garam di Kecamatan Kapetakan diperkirakan sebesar 2.002,44 ha atau 30% dari luas total kecamatan dan potensi lahan garam di Kecamatan Suranenggala diperkirakan sebesar 417,02 ha atau 16% dari luas total kecamatan. Hal lain yang mendukung potensi pengembangan garam di Kecamatan Kapetakan adalah adanya sejumlah gudang garam yang dikelola swasta dan masyarakat, kecocokan kesesuaian tata ruang dengan RTRW Kabupaten Cirebon, rata-rata petak lahan kepemilikan petambak garam lebih besar dari 5 ha sehingga memudahkan proses konsolidasi lahan dan aspek sosial masyarakat yang mendukung program pemerintah daerah, seperti masyarakat yang partisipatif, dan komunikatif.

Kata kunci: Kabupaten Cirebon, tambak garam, Sentinel 2A, *Google Earth Engine*, *Machine Learning*, *Random Forest*.

ABSTRACT

Cirebon Regency is located along the north coast of the Java Sea and has the potential to develop a salt pond business with a coastline of +77,97 km. The readiness of salt land is quite wide, amounting to 1,557.75 ha. This potential is under the program of the Ministry of Marine Affairs and Fisheries (KKP), namely the People's Salt Economic Center (SEGAR). This study aims to identify the potential of salt land in Kapetakan District as a district prioritized as a SEGAR development location and Suranenggala District as an adjoining district. The research method used is the Machine Learning Random Forest Algorithm using Google Earth Engine and Sentinel 2A Imagery. The results of this study show that the potential for salt land in Kapetakan District is estimated at 2,002.44 ha or 30% of the total area of the sub-district and the potential for salt land in Suranenggala District is estimated at 417.02 ha or 16% of the total area of the sub-district. Another thing that supports the potential for salt development in Kapetakan District is the existence of some salt warehouses managed by the private sector and the community, the compatibility of spatial planning with the Cirebon Regency, the average plot of land owned by salt farmers is greater than 5 ha to facilitate the process of land consolidation and social aspects of the community that supports local government programs, such as participatory communities, and communicative.

Keywords: Cirebon Regency, salt ponds, Sentinel 2A, *Google Earth Engine*, *Machine Learning*, *Random Forest*.

PENDAHULUAN

Kabupaten Cirebon adalah bagian dari provinsi Jawa barat yang berada di sepanjang pantai Utara Laut Jawa dan memiliki potensi pengembangan usaha tambak garam dengan garis pantai sepanjang +77,97 km, curah hujan kecil rata-rata 1.808,45 mm/thn, suhu rata-rata sebesar 27,96°– 30,55°C, berada di ketinggian ±0–130 mdpl dan kemiringan lereng antara 0-1%, memiliki jenis tanah alluvial kelabu tua yang cocok sebagai petakan pembuatan garam dan kadar salinitas yang tinggi mencapai 25–28%.

Salah satu potensi Kabupaten Cirebon yang besar adalah adanya kesiapan lahan garam yang cukup luas dengan luas potensi lahan sebesar 3.140 Ha dan luas lahan produksi yaitu sebesar 1.557,75 Ha. Alokasi lahan garam berdasarkan Peraturan Daerah Kabupaten Cirebon Nomor 7 Tahun 2018 tentang Rencana Tata Ruang Wilayah (RTRW) Kabupaten Cirebon Tahun 2018-2038 dan perubahan alokasi lahan garam berdasarkan draft revisi Perda Nomor 7 Tahun 2018 disajikan dalam Tabel 1.

Berdasarkan Tabel 1 dan data eksisting di lapangan, maka kesesuaian lahan garam dengan arahan Rencana Tata Ruang juga hampir sesuai 99,15%. Kondisi ini sesuai dengan syarat pelaksanaan program yang tengah dilaksanakan oleh Kementerian Kelautan dan Perikanan (KKP) yaitu Pengembangan Sentra Ekonomi Garam Rakyat (SEGAR).

Selain potensi lahan, jumlah petambak garam Kabupaten Cirebon juga cukup banyak yaitu sebesar 924 Jiwa. Peluang pasar lokal Kabupaten Cirebon

untuk komoditas garam juga cukup menjanjikan dengan rincian dalam Tabel 2.

Karakteristik usaha tambak garam di Kabupaten Cirebon dikerjakan oleh petani garam yang berpengalaman lebih dari 10 tahun dengan luas garapan lahan +0,5–5 ha, mayoritas status lahan sewaan, produksi garam yang dihasilkan + 35–65 ton (Bappelitbangda & ITB, 2021), dengan kualitas garam masih bervariasi dimana sebagian besar belum memenuhi standar garam industri. Kabupaten Cirebon sebagai salah satu sentra garam nasional belum mampu memenuhi kebutuhan garam baik di tingkat lokal maupun tingkat nasional. Hal tersebut disebabkan kebutuhan garam baik di tingkat lokal maupun nasional sebesar kurang lebih 80% merupakan kebutuhan garam untuk industri, sehingga untuk memenuhi kebutuhan tersebut Indonesia selalu melakukan impor garam setiap tahunnya. Data lahan tambak garam dari Dinas Ketahanan Pangan dan Perikanan (DKPP) Kabupaten Cirebon tahun 2018 sebesar 2.202,1 ha dan tahun 2021 menjadi 614,8 ha menunjukkan kecenderungan penurunan lahan tambak garam.

Rendahnya produksi garam nasional dibandingkan kebutuhan garam secara nasional bisa menjadi peluang bagi petambak garam lokal khususnya di Kabupaten Cirebon. Salah satu upaya untuk mewujudkan hal tersebut adalah dengan mengidentifikasi potensi lahan produksi garam di Kabupaten Cirebon secara berkelanjutan agar diperoleh data potensi lahan produksi garam yang lengkap dan terbaru. Selain itu, dengan teridentifikasinya potensi lahan garam ini,

Tabel 1. Alokasi Luas Lahan Garam dan Rencana Perubahan

Table 1. Salt Land Allocation Area and Change Plan

No	Kecamatan	Alokasi Lahan Garam (Ha)	
		Perda Nomor 7 Tahun 2018	Rencana Perubahan
1	Kapetakan	830,23	961,11
2	Suranenggala	76,55	101,59
3	Gunungjati	94,95	-
4	Mundu	-	46,81
5	Pangenan	248,07	847,08
6	Astanajapura	-	-
7	Gebang	254,04	0,28
8	Losari	120,61	0,01
Total		1.624	1.956,87

Sumber: Dinas Pekerjaan Umum dan Tata Ruang Kabupaten Cirebon, Tahun 2022

Tabel 2. Kebutuhan Garam Kabupaten Cirebon Tahun 2022

Table 2. Cirebon Regency Salt Needs in 2022

No	Jenis Garam	Jumlah IKM	Kebutuhan Garam Per Bulan (Ton)
1	Garam Konsumsi	19	7.410
2	Garam untuk Industri Aneka Pangan	5.000	500
3	Garam untuk Industri Pakan Ternak	3	750
4	Garam untuk Industri Pengasinan Ikan	40	240
5	Garam untuk Industri Tekstil	5	35
6	Garam untuk Kosmetik	1	0.2
Total		5.068	8.935,2

Sumber: Dinas Perindustrian dan Perdagangan Kabupaten Cirebon, Tahun 2022

pemerintah daerah dapat menyusun kebijakan dan strategi pengembangan lahan garam yang lebih baik, karena saat ini data potensi lahan produksi garam yang tersedia saat ini tidak lengkap dan tidak mutakhir, bahkan pada tahun 2019 tidak ada data potensi lahannya. Tersedianya data potensi lahan produksi garam yang lengkap dan terbaru diharapkan dapat digunakan untuk mengoptimalkan potensi lahan garam yang dimiliki Kabupaten Cirebon. Tujuan dari penelitian ini adalah mengidentifikasi potensi lahan garam di Kabupaten Cirebon di Kecamatan Kapetakan dan Kecamatan Suranenggala sebagai lokasi pengembangan Sentra Ekonomi Garam Rakyat (SEGAR) sehingga dapat disusun perencanaan pembangunan daerah dibidang kelautan dan perikanan yang lebih baik.

Sentra Ekonomi Garam (SEGAR)

Sentra Ekonomi Garam (SEGAR) merupakan Implementasi teknis Peraturan Presiden No. 16 tahun 2017 tentang Kebijakan Kelautan Indonesia. Salah satu pilar kebijakan kelautan Indonesia adalah ekonomi dan infrastruktur kelautan dan peningkatan kesejahteraan, yang dilakukan melalui “pembangunan kawasan ekonomi kelautan secara terpadu, dengan prinsip-prinsip ekonomi biru di wilayah pesisir, pulau-pulau kecil, pulau-pulau terluar, dan perairan laut Indonesia secara realistis” (gambar 1).

Berdasarkan Peraturan Presiden Republik Indonesia Nomor 126 Tahun 2022 tentang Percepatan Pembangunan Pergaraman Nasional Sentra Ekonomi Garam Rakyat yang selanjutnya disebut SEGAR adalah kawasan Usaha Pergaraman yang dilakukan secara terintegrasi. Adapun SEGAR ditetapkan pada provinsi yang memiliki potensi pengembangan Usaha Pergaraman dengan kriteria:

- a. Tersedia lahan untuk produksi Garam;
- b. Tersedia prasarana dan sarana Usaha Pergaraman;
- c. Terdapat pangsa pasar Garam; dan

d. Terdapat dukungan dari Pemerintah pusat, Pemerintah Daerah, dan/atau pemangku kepentingan.

Provinsi Jawa Barat adalah salah satu Provinsi yang tercantum dalam rencana aksi Percepatan Pembangunan Pergaraman Nasional, dengan target yaitu:

- a. Tersedianya lokasi, desain, dan kontruksi untuk pembangunan dan atau rehabilitasi saluran irigasi dan kolam penampung air di lokasi SEGAR.
- b. Terlaksananya operasi dan pemeliharaan pembangunan dan atau rehabilitasi saluran irigasi dan kolam penampung air di lokasi SEGAR.
- c. Tersedianya masterplan untuk pembangunan dan atau preservasi jalan akses menuju atau dari kawasan produksi garam di lokasi SEGAR.
- d. Tersedianya lahan untuk pembangunan dan atau preservasi jalan akses menuju atau dari kawasan produksi garam di lokasi SEGAR.
- e. Tersedianya desain pembangunan dan atau preservasi jalan akses menuju atau dari kawasan produksi garam di lokasi SEGAR.
- f. Terlaksananya pembangunan dan atau preservasi jalan akses menuju atau dari kawasan produksi garam di lokasi SEGAR.

Adapun dalam rencana aksi SEGAR ini pada proses produksi diperlukan integrasi lahan untuk tambak Garam seluas 200 hektar per tahun di lokasi SEGAR.

Potensi Garam di Kabupaten Cirebon

Data jumlah petambak garam dari Dinas Ketahanan Pangan dan Perikanan Kabupaten Cirebon tidak lengkap, yaitu data jumlah petambak garam di Kecamatan Astanajapura, Kecamatan Gunungjati, Kecamatan Lemahabang, dan Kecamatan Babakan.

Secara keseluruhan jumlah petambak garam yang ada di Kabupaten Cirebon pada tahun 2019 mengalami kenaikan dari tahun 2018 hingga mencapai angka 3.142 orang. Kemudian menurun di tahun 2020 dan



Tabel 1. Ilustrasi Konsep SEGAR.
Figure 1. SEGAR Concept Illustration.

Tabel 3. Petambak Garam Kabupaten Cirebon Tahun 2018-2021 (Orang)

Table 3. Salt Farmers of Cirebon Regency for 2018-2021 (People)

No	Kecamatan	2018	2019	2020	2021
1	Kapetakan	386	386	386	92
2	Suranenggala	14	284	14	31
3	Mundu	118	118	118	138
4	Astanajapura	61	*)	*)	61
5	Pangenan	1.900	1.900	1.900	645
6	Losari	194	194	194	161
7	Gebang	210	210	210	80
8	Gunungjati	4	50	4	*)
9	Lemahabang	*)	*)	*)	1
10	Babakan	*)	*)	*)	7
Total Petambak		2.887	3.142	2.826	1.216

Sumber: Dinas Perindustrian dan Perdagangan Kabupaten Cirebon, Tahun 2022

2021, menjadi sejumlah 1.216 orang. Jumlah petambak garam terbanyak pada tahun 2021 terdapat di Kecamatan Pangenan sebanyak 645 orang (Tabel 3).

Adapun luas lahan produksi garam di Kabupaten Cirebon pada tahun 2018 terdapat 2.202,1 Ha. Selanjutnya meningkat di tahun 2019 hingga 2.839,3 Ha. Pada tahun 2020, luas lahan produksi garam menurun menjadi 1.557,75 Ha dan kembali menurun di tahun 2021 hingga hanya seluas 614,8 Ha. Kecamatan Pangenan menjadi kecamatan dengan lahan produksi garam terluas di tahun 2021, yaitu 218,62 Ha (Tabel 4). Lahan yang berpotensi sebagai lahan produksi garam di Kabupaten Cirebon secara keseluruhan di tahun 2018 dan tahun 2020 adalah sama, yakni seluas 2.616 Ha. Adapun data potensi lahan produksi garam di tahun

Tabel 4. Luas Lahan Tambak Garam Kabupaten Cirebon Tahun 2018-2021 (Ha)

Table 4. The Salt Ponds Land Area in Cirebon Regency for 2018-2021 (Ha)

No	Kecamatan	2018	2019	2020	2021
1	Kapetakan	288	288	288	128
2	Suranenggala	16	626	120	21,34
3	Mundu	41,3	41,3	41,3	70,44
4	Astanajapura	*)	*)	62	14,35
5	Pangenan	1550	1550	800	218,62
6	Losari	170	188	109,65	84,3
7	Gebang	136	136	136	70,4
8	Gunungjati	0,8	10	0,8	0,8
9	Lemahabang	*)	*)	*)	0,2
10	Babakan	*)	*)	*)	6,35
Total Luas Lahan		2.202,1	2.839,3	1.557,75	614,8

*) Tidak ada data

Sumber: Dinas Ketahanan Pangan dan Perikanan Kabupaten Cirebon, Tahun 2022

2019 tidak tersedia. Pada tahun 2021, potensi luas lahan produksi garam meningkat menjadi 3.140 Ha. Potensi lahan produksi garam di Kecamatan Kapetakan, Kecamatan Mundu, Kecamatan Losari, dan Kecamatan Gebang dari tahun 2018 sampai dengan tahun 2021 adalah tetap. Potensi luas lahan produksi garam di Kecamatan Suranenggala mengalami penurunan dari tahun 2020 ke tahun 2021, sementara di Kecamatan Pangenan mengalami peningkatan dari tahun 2020 ke tahun 2021. Kecamatan Pangenan menjadi kecamatan dengan potensi lahan produksi garam terluas di tahun 2021 seluas 1.628 Ha (tabel 5).

Produksi garam Kabupaten Cirebon dari tahun 2018 hingga tahun 2021 cenderung menurun. Dari total 424.616 ton di tahun 2018 hingga 142 ton di tahun 2021. Data produksi garam di tahun 2021 tidak lengkap, yaitu tidak adanya data produksi garam di Kecamatan Suranenggala, Mundu, Gebang, dan Lemahabang. Berdasarkan data yang masuk di tahun 2021, produksi garam tertinggi adalah di Kecamatan Astanajapura sebanyak 65 ton (tabel 6).

Sentra Garam di Kecamatan Kapetakan dan Suranenggala

Desa Bungko dan Bungko Lor (gambar 2) adalah beberapa desa di Kecamatan Kapetakan yang ditetapkan Pemerintah Kabupaten Cirebon sebagai lokasi pengembangan Sentra Ekonomi Garam Rakyat (SEGAR), dengan beberapa pertimbangan sebagai berikut:

1. Adanya lahan garam sehamparan yang luasnya lebih dari 200 ha, dan diperkirakan potensi luasnya bisa lebih dari 400 ha.

Tabel 5. Potensi Lahan Produksi Garam Kabupaten Cirebon Tahun 2018-2021 (Ha)

Table 5. The Salt Potential Production Land in Cirebon Regency for 2018-2021 (Ha)

No	Kecamatan	2018	2019	2020	2021
1	Kapetakan	400	*)	400	400
2	Suranenggala	284	*)	284	250
3	Mundu	62	*)	62	62
4	Astanajapura	*)	*)	*)	80
5	Pangenan	1.200	*)	1.200	1.628
6	Losari	250	*)	250	250
7	Gebang	420	*)	420	420
8	Gunungjati	*)	*)	*)	50
9	Lemahabang	*)	*)	*)	*)
Total Luas Lahan		2.616	*)	2.616	3.090

*) Tidak ada data

Sumber: Dinas Ketahanan Pangan dan Perikanan Kabupaten Cirebon, Tahun 2022

Tabel 6. Produksi Garam Kabupaten Cirebon Tahun 2018-2021 (Ton)

Table 6. The Cirebon Regency Salt Production for 2018-2021 (Ton)

No	Kecamatan	2018	2019	2020	2021
1	Kapetakan	1.726	9.916	65	8
2	Suranenggala	626	1.664	206	*)
3	Mundu	4.817	2.298	166	*)
4	Astanajapura	*)	3.122	752	65
5	Pangenan	332.940	92.282	155	60
6	Losari	30.523	11.020	313	3
7	Gebang	53.856	16.185	910	*)
8	Gunungjati	128	207	104	6
9	Lemahabang	*)	*)	*)	*)
Total Produksi		424.616	136.694	2.670	142

*) Tidak ada data

Sumber: Dinas Ketahanan Pangan dan Perikanan Kabupaten Cirebon, Tahun 2022

2. Terdapat sejumlah gudang garam yang dikelola swasta dan masyarakat.
3. Kecocokan kesesuaian tata ruang dengan RTRW Kabupaten Cirebon.
4. Rata-rata petak kepemilikan lahan para petambak garam lebih besar dari 5 ha sehingga memudahkan proses konsolidasi lahan.
5. Aspek sosial masyarakat yang mendukung program pemerintah daerah, seperti masyarakat yang partisipatif, dan komunikatif.

Kecamatan lain yang juga memiliki potensi pengembangan garam adalah Kecamatan Suranenggala yaitu di Desa Sura Lor dan Muara, yang bersebelahan dengan Kecamatan Kapetakan sebagaimana dijelaskan dalam tabel 7.

Laju Akresi dan Abrasi Garis Pantai di Kabupaten Cirebon

Kabupaten Cirebon secara umum rawan terhadap erosi dan akresi. Erosi terjadi di sekitar kecamatan Kapetakan wilayah barat, Cirebon utara, Pangenan wilayah timur, dan Losari wilayah timur (terbesar) sedangkan akresi terjadi di kecamatan Kapetakan wilayah timur, Kejaksan, Lemahwungkuk, Mundu, Astanajapura, dan Pangenan (terbesar) (Harahap *et al.*, 2019). Wilayah pesisir barat cenderung lebih stabil dibandingkan wilayah timur (Heriati & Husrin, 2017). Pesisir Kabupaten Cirebon didominasi oleh pantai berlumpur. Adanya pengaruh dari beberapa sungai, seperti Sungai Condong, Kalijaga, Kanci, Ciberes, Karanganyar, Cimanis, dan Losari, menyebabkan terjadinya akresi. Di samping itu, terjadi alih fungsi lahan mangrove menjadi tambak di Pangenan dan Losari. Penutupan

Tabel 7. Luas Lahan Produksi dan Potensi Garam Kabupaten Cirebon Tahun 2021

Table 7. Production Land Area and Salt Potential of Cirebon Regency in 2021

No	Kecamatan	Desa	Luas Lahan Produksi (ha)	Potensi Lahan Produksi (ha)
1	Kapetakan	Bungko	288	400
2	Suranenggala	Bungko Lor	120	250
3	Mundu	Sura Lor	41,3	62
4	Astanajapura	Muara	62	60
5	Pangenan	Citemu	800	1628
6	Losari	Waruduwur	109,6	250
7	Gebang	Kanci	136	420
8	Gunungjati	Kanci Kulon	0,8	50
Total			1.558	3.120

Sumber: Dinas Ketahanan Pangan dan Perikanan Kabupaten Cirebon, Tahun 2022

sungai di pantai Losari mengakibatkan terjadinya abrasi hingga 120,7 m (Kenedi, 2017).

Dari hasil kajian Bappelitbangda Kab. Cirebon dan Institut Teknologi Bandung (ITB) pada periode 1996-2021, wilayah barat Kabupaten Cirebon sampai dengan Kecamatan Pangenan lebih didominasi oleh akresi. Sementara pada wilayah timur, yaitu Kecamatan Pangenan sampai dengan Kecamatan Losari, juga didominasi oleh akresi dengan terdapat beberapa area yang mengalami erosi cukup besar, khususnya Kecamatan Losari dan Pangenan. Terdapat beberapa perubahan garis pantai yang terjadi cukup signifikan di wilayah Kabupaten Cirebon (Gambar 3). Pada area Kecamatan Suranenggala yang dekat dengan Kecamatan Gunungjati, terjadi akresi mencapai sekitar



Gambar 2. Foto Hampan Lahan Garam di Desa Bungko Lor, Kabupaten Cirebon.
 Figure 2. Photo of Salt Land Overlay in Bungko Lor Village, Cirebon Regency.

20 m/tahun. Pada area Kecamatan Astanajapura sebagian wilayahnya mengalami akresi sampai dengan 20 m/tahun dan terus membesar ke arah Kecamatan Pangenan. Di area Kecamatan Pangenan sendiri, terjadi akresi 53 yang besar mencapai 60 m/tahun, kemudian ke arah timur, nilai perubahan garis pantainya semakin mengecil, bahkan mengalami erosi dengan nilai mencapai minus 30 m/tahun. Nilai tersebut kemudian kembali bertambah ke arah timur dan kembali terjadi akresi dan mencapai nilai 20 m/tahun. Di Kecamatan Gebang terjadi akresi dengan nilai berkisar antara 0-10 m/tahun dan terdapat akresi pada sebagian kecil area yang mencapai 20 m/tahun. Sementara itu,

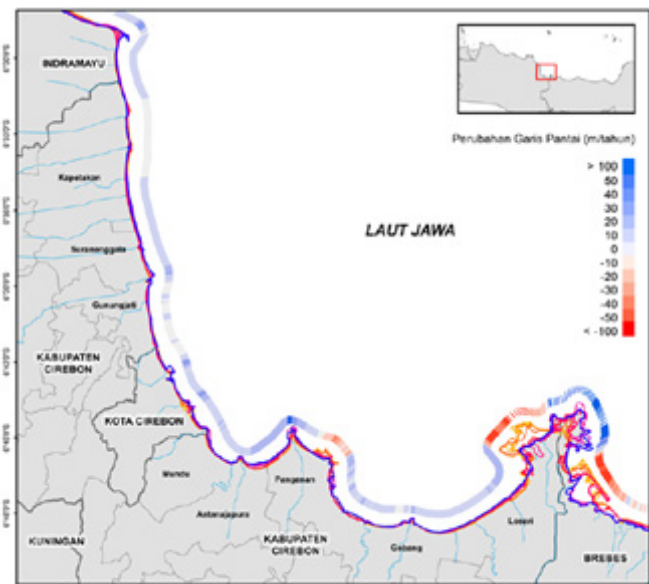
Salah satu pertimbangan pengembangan SEGAR di Wilayah Pesisir Barat Kabupaten Cirebon adalah laju akresi dan abrasi pantainya yang relatif kecil dibandingkan Wilayah Pesisir Timur Kabupaten Cirebon. Dengan laju akresi sekitar 10-20 m/tahun di wilayah pantai Barat Kabupaten Cirebon tentunya akan menambah lahan potensial untuk tambak garam di Kabupaten Cirebon.

Kecamatan Losari terjadi erosi yang cukup besar dan mencapai minus 85 m/tahun. Tepat di sebelah timur Kecamatan Losari, terjadi akresi yang sangat besar mencapai 100 m/tahun, kemudian di sebelah timurnya juga terjadi erosi yang mencapai minus 110 m/tahun. Terjadinya akresi atau bertambahnya garis pantai di area Kabupaten Brebes ini, dapat berasal dari berkurangnya garis pantai di Kecamatan Losari dan juga di Kabupaten Brebes (Bappelitbangda & ITB, 2021).

BAHAN DAN METODE

Metodologi Penelitian yang digunakan adalah menggunakan analisa penginderaan jarak jauh (*Remote Sensing*) Citra Satelit Sentinel 2A dengan

metoda pembelajaran mesin (*Machine Learning*). Penginderaan jarak jauh telah berkembang sebagai teknologi observasi bumi baru selama beberapa dekade terakhir, dan telah banyak digunakan dalam pemantauan lingkungan tanah karena keunggulannya berupa cakupan yang luas, pemutakhiran data yang cepat, dan biaya perolehan yang rendah. Penelitian sebelumnya (Mahajan *et al.*, 2021; Wang *et al.*, 2018) dalam kondisi laboratorium terkontrol menggunakan teknologi analisis spektral kuantitatif menunjukkan bahwa terdapat pita respons pasti untuk kandungan garam tanah pada rentang panjang gelombang 450–680 nm dan inframerah gelombang pendek yang dapat digunakan sebagai variabel masukan untuk model estimasi spektral kuantitatif kandungan garam tanah. Demikian pula, kelayakan metode estimasi kuantitatif spektral kandungan dalam kondisi lapangan telah



Tabel 3. Laju Akresi dan Abrasi di Pesisir Pantai Kabupaten Cirebon.

Figure 3. Accretion and Abrasion Rate on the Coast of Cirebon Regency.

dibuktikan (Kahaer & Tashpolat, 2019; Nawar *et al.*, 2014; Wang *et al.*, 2019).

Model estimasi citra satelit telah dibuat untuk menganalisis distribusi kandungan garam tanah pada skala regional (Wang *et al.*, 2019). Citra satelit hiperspektral dapat memberikan sejumlah besar sinyal spektral dari sifat tanah yang berguna untuk pemetaan tanah bergaram, namun jumlah satelit hiperspektral yang terbatas di orbit tidak dapat sepenuhnya menutupi permukaan bumi, dan data hiperspektral tersebut mahal untuk diperoleh. Gambar multispektral juga merupakan komponen penting dari data citra satelit, dan ditandai dengan peninjauan kembali temporal secara global, ketersediaan data yang besar, dan biaya pengumpulan yang rendah. Oleh karena itu, data ini dianggap sebagai sumber data primer untuk pemetaan tanah bergaram pada skala regional (Wang *et al.*, 2020). Secara keseluruhan, data citra satelit multispektral yang digunakan dengan model matematika canggih memperkuat dasar pemetaan regional tanah bergaram (Xu *et al.*, 2023).

Akumulasi garam merupakan proses kompleks yang terjadi melalui interaksi geomorfologi, curah hujan, dan aktivitas antropogenik di permukaan tanah (McBratney *et al.*, 2003). Akurasi rendah dalam pemetaan kandungan garam tanah biasanya diperoleh ketika menggunakan pendekatan statistik linier untuk memodelkan hubungan antara kandungan garam tanah dan data spektral yang diterima oleh sensor satelit (Wang *et al.*, 2020).

Pembelajaran Mesin (*Machine Learning*)

Algoritma pembelajaran mesin berbasis teknologi regresi nonlinier telah menunjukkan hasil yang memuaskan dalam membangun model estimasi penginderaan jauh kandungan garam tanah. Berbagai teknologi pembelajaran mesin (jaringan saraf tiruan, mesin vektor pendukung, dan hutan acak) telah dikembangkan dan diterapkan untuk pemetaan kandungan garam tanah pada skala regional berdasarkan data citra satelit (Wang *et al.*, 2020.; Wang *et al.*, 2018). Hasilnya mengkonfirmasi akurasi dan stabilitas yang tinggi dari pendekatan pemasangan nonlinier yang didukung oleh algoritma pembelajaran mesin untuk estimasi dan pemetaan kandungan garam tanah, dan model yang dibangun memenuhi kebutuhan dasar pemantauan dan pengenalan kandungan garam tanah pada skala regional (Xu *et al.*, 2023)..

Variabel prediktor yang berpengaruh dan kumpulan sampel kalibrasi yang sesuai sangat penting untuk

membangun model pembelajaran mesin yang kuat (Zare *et al.*, 2021). Indeks spektral merupakan pendekatan yang ampuh untuk mendeteksi informasi garam tanah, dan dapat mengurangi redundansi informasi matriks spektral. Dengan demikian, indeks spektral terkait kandungan garam tanah telah menjadi kovariat spektral yang ideal untuk membangun model pemetaan kandungan garam tanah (Wang *et al.*, 2020.). Namun, indeks salinitas tanah umumnya diterapkan secara lokal dalam penilaian status tanah yang terkena dampak garam. Setiap indeks spektral yang dipublikasikan telah dirancang secara lokal untuk kondisi lingkungan tertentu, yang menunjukkan bahwa indeks tersebut mungkin tidak valid jika lingkungan lokal berbeda dari lingkungan awal (Xu *et al.*, 2023).

Pembelajaran mesin (*machine learning*) (Gambar 4) adalah cabang kecerdasan buatan yang bertujuan agar mesin dapat melakukan pekerjaan mereka dengan terampil menggunakan aplikasi cerdas. Dalam pembelajaran mesin, metode statistik merupakan salah satu dasar dari aplikasi cerdas untuk pengembangan kecerdasan mesin. Algoritma pembelajaran mesin membutuhkan data untuk dipelajari, sehingga disiplin ilmunya memiliki hubungan dengan disiplin ilmu basis data. Hampir sama dengan istilah Penemuan Pengetahuan dari Data (*Knowledge Discovery from Data*, KDD), Penggalian Data (*Data Mining*), dan Pengenalan Pola (*Pattern Recognition*). (Mohammed *et al.*, 2017).

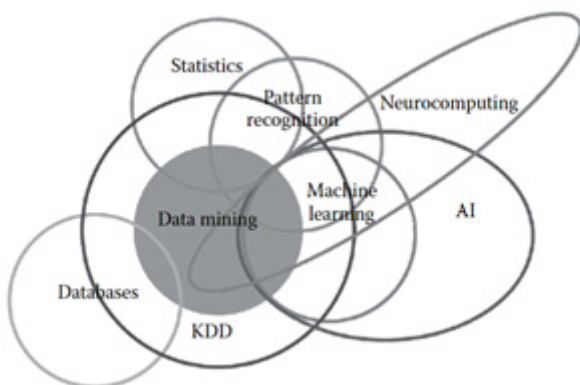
Menurut Ibnu Daqiqil (Daqiqil, 2021), *Machine Learning* (ML) merupakan bidang studi yang fokus kepada desain dan analisis algoritma sehingga memungkinkan komputer untuk belajar. Menurut Samuel, ML berisi sebuah algoritma yang bersifat generic (umum) dimana algoritma tersebut dapat menghasilkan sesuatu yang menarik atau bermanfaat dari sejumlah data tanpa harus menulis kode yang spesifik. Pada intinya, algoritma yang generic tersebut ketika diberikan sejumlah data maka ia dapat membangun sebuah aturan atau model atau inferensi dari data tersebut. Sebagai contoh sebuah Algoritma untuk mengenali tulisan tangan dapat digunakan untuk mendeteksi email yang berisi spam dan bukan spam tanpa mengganti kode. Algoritma sama ketika diberikan data pelatihan yang berbeda menghasilkan logika klasifikasi yang berbeda. *Machine Learning* juga dapat diartikan sebuah komputer yang memiliki kemampuan belajar tanpa diprogram secara eksplisit. Program tersebut memanfaatkan data untuk membangun model dan mengambil keputusan berdasarkan model yang telah dibangun.

Menurut Mitchel (Mitchell, 1997), *Machine Learning* adalah “Satu program komputer yang dikatakan telah melakukan pembelajaran dari pengalaman (*Experience*) terhadap tugas (*Task*) dan mengukur peningkatan kinerja (*Performance Measure*). Berikut ini adalah beberapa contoh *Task* yang ada di program ML (Daqiqil, 2021) yaitu:

1. Klasifikasi adalah sebuah pengelompokan data di mana data yang digunakan tersebut mempunyai kelas label atau target. Pada jenis task ini, program komputer diminta untuk “menebak” atau memilih kelompok/kategori/kelas dari data. Pada task ini kelas telah ditetapkan sebelumnya.
2. Regresi, sederhananya adalah sebuah tugas di mana aplikasi ML diminta untuk menebak angka (bilangan continue) berdasarkan sejumlah data.
3. Transkripsi, adalah sebuah tipe Task dimana aplikasi ML mencoba “memahami” sebuah data tidak terstruktur yang mempresentasikan data lain.
4. *Machine Translation*, task ini merupakan proses mengubah sekumpulan input terurut yang berisi simbol-simbol tertentu menjadi simbol tertentu di bahasa lainnya.
5. *Anomaly Detection*. Task ini bertujuan untuk menggunakan aplikasi ML untuk memeriksa sejumlah data atau event lalu menandainya sebagai sesuatu yang tidak biasa.
6. *Syntesis dan Sampling*, Task ini bertujuan untuk membuat atau generate sesuatu berdasarkan contoh.

Machine learning dapat dikelompokkan berdasarkan bagaimana cara belajar sehingga dapat melakukan tugasnya. Pembagian *Machine Learning* berdasarkan cara belajarnya dibagi menjadi tiga kelompok (Daqiqil, 2021) yaitu:

1. *Supervised Learning*, adalah pembelajaran terarah/



Tabel 4. Berbagai disiplin ilmu dan disiplin ilmu pembelajaran mesin.

Figure 4. Multiple disciplines and disciplines of Machine Learning.

terawasi. Jika dianalogikan pada proses pembelajaran, komputer atau mesin akan mempelajari data yang berisi label. Contoh algoritma kategori Supervised ini adalah *Linear Regression* (Regresi Linear), *Logistic Regression* (Regresi Logistik), *Linear Discriminant Analysis*, *K-Nearest Neighbours*, *Support Vector Machines* (SVMs), *Random Forests*, dan *Neural Networks*.

2. *Unsupervised Learning*, adalah proses pembelajaran tanpa petunjuk. Algoritma komputerlah yang bekerja untuk menemukan pola-pola di dalam data. Beberapa kategori algoritma ini adalah Clustering dan K-Means.
3. *Reinforcement Learning*, dimana sebuah komputer akan berinteraksi dengan sebuah lingkungan yang sangat dinamis dan komputer tersebut harus melakukan tugas tertentu, contohnya self-driving car. Melalui sebuah algoritma, mesin akan mempelajari bagaimana membuat keputusan spesifik berdasarkan lingkungan yang berubah-ubah.

Algoritma Hutan Acak (*Random Forests*)

Teknik *Random forest* merupakan salah satu teknik pembelajaran mesin (*machine learning*). Teknik ini membangun beberapa pohon keputusan berdasarkan kumpulan data pelatihan (*training data*) dan data keluaran masing-masing pohon untuk menentukan kelas akhir suatu objek yang dikembangkan oleh (Breiman, 2001). (Vermeulen & van Niekerk, 2016) menggunakan citra *WorldView-2* beresolusi sangat tinggi untuk menentukan tanah memiliki kandungan garam di Afrika Selatan oleh menerapkan beberapa algoritma pembelajaran mesin dengan metode *random forest* memiliki akurasi keseluruhan sebesar 80%. Yahiaoui (Yahiaoui *et al.*, 2021) menggunakan kombinasi buffering geospasial dan algoritma *random forest* pada data Sentinel-2 untuk memprediksi dan memetakan salinitas tanah di dataran Lower-Cheliff di Algeria dengan akurasi keseluruhan 99%. Pada penelitian yang dilakukan di India (Rani *et al.*, 2022) untuk meneliti tanah yang terdampak garam, diperoleh tingkat akurasi 96,34% dan koefisien Kappa sebesar 0,9258 dengan menggunakan algoritma hutan acak (*Random Forest*) pada kumpulan data pengujian, dan batasannya berupa ukuran piksel dari kumpulan data masukan. Secara keseluruhan, penelitian itu menyimpulkan bahwa teknik hutan acak mampu mengidentifikasi tanah bergaram dengan tingkat akurasi yang dapat diterima.

Algoritma *Random forest* (Gambar 5) diperkenalkan pertama kali oleh Tin Kam Ho (Ho, 1995) yang mengusulkan sebuah metode untuk meningkatkan

akurasi umum teknik klasifikasi pohon keputusan (*Forest Tree*), yang diakibatkan pertukaran training data. *Random forest* (RF) (Wikipedia, 2023) adalah suatu algoritma yang digunakan pada klasifikasi data dalam jumlah yang besar. Klasifikasi *random forest* dilakukan melalui penggabungan pohon (*tree*) dengan melakukan training pada sampel data yang dimiliki.

Penggunaan pohon (*tree*) yang semakin banyak akan mempengaruhi akurasi yang akan didapatkan menjadi lebih baik. Penentuan klasifikasi dengan *random forest* diambil berdasarkan hasil voting dari *tree* yang terbentuk. Pemenang dari pohon yang terbentuk ditentukan dengan *vote* terbanyak. Pembangunan pohon pada *random forest* sampai dengan mencapai ukuran maksimum dari pohon data. Namun, pembangunan pohon *random forest* tidak dilakukan pemangkasan (*pruning*) yang merupakan sebuah metode untuk mengurangi kompleksitas ruang.

Pembangunan pohon keputusan dilakukan dengan penerapan metode *random feature selection* untuk meminimalisir kesalahan. Pembentukan pohon dengan sample data menggunakan variabel yang diambil secara acak dan menjalankan klasifikasi pada semua tree yang terbentuk. *Random forest* menggunakan *Decision Tree* untuk melakukan proses seleksi. Pohon yang dibangun dibagi secara rekursif dari data pada kelas yang sama.


Pemecahan (*split*) digunakan untuk membagi data berdasarkan jenis atribut yang digunakan. Pembuatan pohon keputusan pada saat penentuan klasifikasi, pohon yang buruk akan membuat prediksi acak yang saling bertentangan. Sehingga, beberapa pohon keputusan akan menghasilkan jawaban yang baik. *Random forest* merupakan salah satu cara penerapan dari pendekatan

diskriminasi stokastik pada klasifikasi.

Proses Klasifikasi akan berjalan jika semua pohon telah terbentuk. Pada saat proses klasifikasi selesai dilakukan, inialisasi dilakukan dengan sebanyak data berdasarkan nilai akurasinya. Keuntungan penggunaan *random forest* yaitu mampu mengklasifikasi data yang memiliki atribut yang tidak lengkap, dapat digunakan untuk klasifikasi dan regresi akan tetapi tidak terlalu bagus untuk regresi, lebih cocok untuk pengklasifikasian data serta dapat digunakan untuk menangani data sampel yang banyak. Proses klasifikasi pada *random forest* berawal dari memecah data sampel yang ada kedalam pohon keputusan secara acak. Setelah pohon terbentuk, maka akan dilakukan voting pada setiap kelas dari data sampel. Kemudian, mengkombinasikan *vote* dari setiap kelas kemudian diambil *vote* yang paling banyak. Dengan menggunakan *random forest* pada klasifikasi data maka, akan menghasilkan *vote* yang paling baik.

Menurut Breiman (Breiman, 2001), prinsip dasar hutan acak adalah sebagai berikut

1. Tentukan dataset sampel asli D dan jumlah variabel M ;
2. Gunakan metode *resampling bootstrap* pada dataset sampel asli D untuk mengekstrak unit sampel N darinya dengan jumlah sampel yang sama di D seperti dalam sub-training yang ditetapkan untuk membangun pohon keputusan N_{tree} .
3. Tentukan jumlah variabel pada node pohon M_{try} ($m < M$), dimana M_{try} mewakili jumlah variabel yang digunakan dalam pengambilan keputusan pada node pohon keputusan;
4. Biarkan setiap pohon tumbuh secara maksimal, menghasilkan semua pohon keputusan secara keseluruhan, dan beberapa iterasi untuk mendapatkan hutan acak dari n pohon keputusan;
5. Hasil akhir dari hutan acak adalah rata-rata hasil dari setiap pohon keputusan. Keakuratan model hutan acak tergantung pada N_{tree} dan M_{try} , dengan N_{tree} yang menentukan ukuran keseluruhan hutan acak dan M_{try} yang menentukan pertumbuhan pohon individu dan keduanya menentukan keakuratan model hutan acak pada tingkat makro dan mikro.



Tabel 5. Algoritma Random Forest.
Figure 5. Random Forest Algorithm.

Uji Akurasi Hasil Klasifikasi Citra Satelit

Penilaian akurasi dilakukan untuk mengetahui tingkat keakuratan klasifikasi. Keakuratan tersebut meliputi jumlah training sample piksel yang diklasifikasikan dengan benar atau salah dan presentase banyaknya piksel dalam masing-masing kelas serta presentase kesalahan total. Penilaian akurasi menggunakan suatu

matrik kontingensi yaitu matrik bujur sangkar yang memuat jumlah piksel yang terklasifikasi, biasanya disebut matrik konfusi, Dalam matrik kontingensi ini, analisis dapat menghitung besarnya akurasi produser (producer accuracy) dan akurasi pengguna (user accuracy) dari setiap kelas liputan lahan.

Akurasi pembuat adalah akurasi yang diperoleh dengan membagi piksel yang benar dengan jumlah total piksel per kelas liputan lahan. Pada akurasi ini akan terjadi kesalahan omisi, oleh karena itu akurasi pembuat ini dikenal juga dengan istilah “omission error”. Sebaliknya, jika jumlah piksel yang benar dengan total piksel dalam kolom akan menghasilkan akurasi pengguna, yang dikenal dengan “comission error” (Congalton, 1991).

Persamaan akurasi dapat dinyatakan dengan rumusan sebagai berikut :

$$\begin{aligned} \text{Akurasi Pengguna} &= (X_{ii}/X_{+i}) \times 100\% \\ \text{Akurasi Produser} &= (X_{ii}/X_{i+}) \times 100\% \\ \text{Akurasi Total} &= ((\sum_{i=1} X_{ii}/N) \times 100\% \\ \text{Akurasi Kappa} &= \\ &[(\sum_{i=1} X_{ii} - \sum_{i=1} X_{i+} + X_{+i}) / (N_2 - \sum_{i=1} X_{i+} + X_{+i})] \times 100\% \end{aligned}$$

Keterangan :

N = Banyaknya piksel dalam sampel

X_{i+} = Jumlah piksel dalam baris ke-i

X_{+i} = Jumlah piksel dalam kolom ke-i

X_{ii} = Nilai diagonal dari matrik kontingensi baris ke-i dan kolom ke-i

Jadi penentuan tingkat akurasi klasifikasi dapat dinilai dari nilai akurasi p, akurasi pengguna, akurasi total, dan indeks kappa. Nilai akurasi produser berfungsi sebagai penilaian secara tematik, yaitu menunjukkan tingkat kebenaran hasil klasifikasi terhadap kondisi di lapangan. Akurasi pengguna menjelaskan mengenai ketelitian hasil klasifikasi terhadap seluruh obyek yang dapat diidentifikasi. Akurasi total menggambarkan nilai akurasi total kenampakan objek yang benar di peta klasifikasi dengan lapangan.

Nilai indeks kappa mempertimbangkan faktor kesalahan proses klasifikasi, sehingga nilai indeks kappa lebih rendah dari nilai akurasi total dimana hanya mempertimbangkan data yang benar antara hasil klasifikasi dan kondisi dilapangan. Akurasi total menggambarkan nilai akurasi total kenampakan objek yang benar di peta klasifikasi dengan lapangan. Nilai indeks kappa mempertimbangkan faktor kesalahan proses klasifikasi, sehingga nilai indeks kappa

lebih rendah dari nilai akurasi total dimana hanya mempertimbangkan data yang benar antara hasil klasifikasi dan kondisi dilapangan (Wiweka *et al.*, 2014).

Menurut (Landis & Koch, 1977) nilai koefisien Kappa dibawah 0,4 kategori kurang baik, antara 0,4–0,8 kategori sedang, diatas 0,8 kategori dipercaya. Dalam menggunakan citra hasil klasifikasi perlu kecermatan yang lebih dan kewaspadaan, hasil klasifikasi tidak dapat dipercaya sepenuhnya karena melihat nilai koefisien Kappa yang tergolong dalam kategori sedang tersebut.

Nilai akurasi yang kurang baik ini dapat disebabkan oleh beberapa faktor yaitu proses pembentukan segmen yang *oversegmented*. Kemampuan seseorang dalam mengolah data dengan suatu pendekatan tidaklah sama, sehingga faktor pengguna/ pengolah data sangat berperan penting dalam mengekstrasi informasi. Selain hal tersebut kurang baiknya akurasi dapat pula disebabkan pada proses pengambilan sampel area/ training area (Wiweka *et al.*, 2014)

Sentinel-2 MSI: MultiSpectral Instrument, Level-2A

Beberapa peneliti telah menganalisis korelasi antara reflektansi pita citra satelit (Landsat-5, Landsat-8, Sentinel-2, dan HJ-1) dan salinitas tanah, dan telah mengeksplorasi hubungan halus antara karakteristik penyerapan pita spektral dan mineral garam seperti seperti gipsum, kalsium karbonat, dan natrium sulfat (Xu *et al.*, 2023).

Sentinel-2 adalah citra satelit multi-spektral pita lebar dan beresolusi tinggi untuk studi Pemantauan Tanah Program Copernicus, *The European Space Agency* (ESA), digunakan untuk pemantauan vegetasi, tutupan tanah dan air, serta pengamatan saluran air di wilayah pedalaman dan pesisir (Google Earth Engine Data Catalog, 2023).

Citra satelit Sentinel dikelompokkan pada citra beresolusi menengah. Setelah sukses di *launching* 23 Juni 2015, Sentinel-2 terdiri dari dua satelit konstelasi yaitu Sentinel-2A dan Sentinel-2B berada yang mengorbit kutub pada orbit sun-synchronous pada ketinggian 786 km. Dua satelit identik tersebut berjarak 180 derajat satu sama lain, mampu berulang 5 harian di wilayah khatulistiwa dan 2-3 hari di lintang tengah, dengan lebar sapuan 290 km, memiliki resolusi spektral 10-60 meter untuk tampak mata, VNIR dan SWIR (Dimiyati, 2022). Pada gambar 6 adalah Citra


Sentinel 2A yang diambil dari berbagai komposisi band di Kecamatan Kapetakan dan Suranenggala

Tabel 8 adalah multi spektral Citra Sentinel 2A yang memiliki 12 pita spektral yang mewakili jangkauan spektral yang diskalakan sebesar 10.000 (tidak seperti pada L1, Citra Sentinel 2A tidak memiliki band B10) (Google Earth Engine Data Catalog, 2023).

HASIL DAN PEMBAHASAN

Analisa Penginderaan Jarak Jauh (Remote Sensing)

Berikut ini langkah-langkah analisa identifikasi lahan Garam di wilayah Kajian Desa Bungko Lor, Kabupaten Cirebon. Citra satelit yang digunakan adalah Citra Sentinel 2A menggunakan Google Earth Engine. Google Earth Engine (GEE) adalah platform komputasi awan yang dirancang untuk menyimpan dan memproses kumpulan data besar (pada skala petabyte) untuk analisis dan pengambilan keputusan akhir (Mutanga & Kumar, 2019). GEE menawarkan banyak kemudahan dalam mengolah data, baik dari sudut pandang perangkat keras maupun perangkat lunak (Gorelick, *et al.*, 2017). Bahasa pemrograman



Tabel 6. Citra Sentinel 2A dari berbagai komposisi band di Kecamatan Kapetakan dan Suranenggala.

Figure 6. Sentinel 2A imagery of various band compositions in Kapetakan and Suranenggala sub-districts.

Tabel 8. Multispektral Citra Sentinel 2A
Table 8. Multispectral Sentinel 2A Imagery

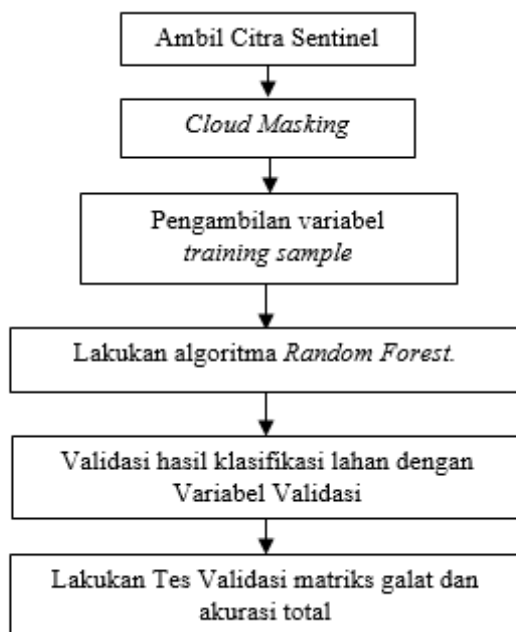
Nama	Deskripsi	Resolusi	Panjang Gelombang
B1	Aerosols	60 meters	443.9nm (S2A) / 442.3nm (S2B)
B2	Blue	10 meter	496.6nm (S2A) / 492.1nm (S2B)
B3	Green	10 meter	560nm (S2A) / 559nm (S2B)
B4	Red	10 meter	664.5nm (S2A) / 665nm (S2B)
B5	Red Edge 1	20 meter	703.9nm (S2A) / 703.8nm (S2B)
B6	Red Edge 2	20 meter	740.2nm (S2A) / 739.1nm (S2B)
B7	Red Edge 3	20 meter	782.5nm (S2A) / 779.7nm (S2B)
B8	NIR	10 meter	835.1nm (S2A) / 833nm (S2B)
B8A	Red Edge 4	20 meter	864.8nm (S2A) / 864nm (S2B)
B9	Water vapor	60 meter	945nm (S2A) / 943.2nm (S2B)
B11	SWIR 1	20 meter	1613.7nm (S2A) / 1610.4nm (S2B)
B12	SWIR 2	20 meter	2202.4nm (S2A) / 2185.7nm (S2B)

yang digunakan adalah Javascript dan Algoritma yang digunakan adalah *Random Forest*.

1. Ambil Citra Sentinel di lokasi data Google Earth Engine Catalog, dan filter luasan geometri yang digunakan.
2. Lakukan *cloud masking* pada Citra Sentinel untuk mengeliminasi tutupan awan pada citra sehingga hanya mencapai 5%. Menurut Danoedero (2012), satelit sumber daya dikatakan baik jika luasan liputan awannya kurang dari 10%. Tutupan awan sudah menjadi dilema primer pada penggunaan citra satelit, terutama di Indonesia yang terletak di sepanjang khatulistiwa atau wilayah tropis diman proses pembentukan awan relatif tinggi dan terjadi hampir sepanjang tahun. Kebutuhan citra satelit yang bebas awan menjadi salah satu syarat utama dalam proses klasifikasi dan analisis sejenis.

```
//Ambil Peta Sentinel
```

```
var S2A = ee.ImageCollection('COPERNICUS/S2_SR').  
filterBounds(geometry);
```



Tabel 7. langkah-langkah analisa identifikasi lahan Garam.
Figure 7. land identification analysis steps.

Ketelitian dalam proses analisis citra ditentukan seberapa besar kualitas citra sebagai bahan utama analisis. Semakin rendah tutupan awan semakin baik data yang dapat diekstrak dan memberikan informasi yang lebih baik dalam proses pengambilan keputusan (Braaten *et al.*,2015).

3. Lakukan pengambilan training sample untuk beberapa variabel tutupan lahan seperti pasir, air, tambak, sawah, dan bangunan pada di beberapa lokasi secara manual pada Citra Sentinel.

```

//Fungsi Cloud Masking Sentinel-2A

function maskS2clouds(image){
var qa = image.select('QA60');

//Bits 10 and 11 adalah awan tebal dan awan tipis

var cloudBitMask = 1 << 10;
var cirrusBitMask = 1 << 11;

//variabel masking

Var mask = qa.bitwiseAnd(cloudBitMask)
.eq(0).and(qa.bitwiseAnd(cirrusBitMask)
.eq(0));

return image.updateMask(mask).divide(10000);
}

//variabel cloud masking persentase dibawah 5%, filter waktu
pengambilan citra tahun 2022, dan filter lokasi geometri.
  
```

```

var maskS2A =
S2A.filterDate('2022-01-01','2022-12-31')
.filter(ee.Filter.lt
('CLOUDY_PIXEL_PERCENTAGE',5))
.map(maskS2clouds)
.first()
.clip(geometry);

//variabel band Citra Sentinel

var sentinel = maskS2A.select('B2', 'B3', 'B4', 'B5', 'B6', 'B7',
'B8', 'B8A', 'B11', 'B12');

//variabel visualisasi Band B4, B3 dan B2

var visualization = {
min: 0.0,
max: 0.3,
bands: ['B4', 'B3', 'B2'],
};
  
```

```

Imports (14 entries)
var geometry: Polygon, 4 vertices
var Mangrove: FeatureCollection (12 elements)
var Air: FeatureCollection (32 elements)
var Bangunan: FeatureCollection (34 elements)
var Pasir: FeatureCollection (22 elements)
var Tambak: FeatureCollection (24 elements)
var Val_Air: FeatureCollection (14 elements)
var Val_Mangrove: FeatureCollection (5 elements)
var Val_bangunan: FeatureCollection (11 elements)
var Val_Tambak: FeatureCollection (14 elements)
var Val_Pasir: FeatureCollection (4 elements)
var imageVisParam: classification from 0 to 5
var Sawah: FeatureCollection (30 elements)
var Val_Sawah: FeatureCollection (21 elements)
  
```

4. Gabung seluruh training sample dan jalankan algoritma *Random Forest*.

```

//Gabung Training Sampel dalam variabel aoi

var aoi = Mangrove.merge(Air).merge(Bangunan).merge(Pasir).
merge(Tambak).merge(Sawah);

//Overlay Image dengan training sampel

var bands = (['B2', 'B3', 'B4', 'B5', 'B6', 'B7', 'B8', 'B8A', 'B11',
'B12']);

var training = sentinel.select(bands).sampleRegions({
collection: aoi,
properties: ['class'],
scale: 10
})

//Variabel Classifier
  
```

```

var classifier = ee.Classifier.smileRandomForest(50).train({
  features: training,
  classProperty: 'class',
  inputProperties: bands
});

//Variabel Klasifikasi

var classified = sentinel.classify(classifier);

//Tampilkan peta

Map.addLayer(classified, imageVisParam, 'RF Classification');

//Pusatkan obyek

Map.centerObject(sentinel, 13)

```

5. Validasi hasil klasifikasi lahan dengan mengambil variabel-variabel validasi seperti Val_Air, Val_Mangrove, Val_Bangunan, Val_Tambak, Val_Pasir, dan Val_Sawah.

6. Lakukan tes validasi akurasi matrik galat dan akurasi total.

```

// Proses Validasi

var validationData = Val_Air.merge(Val_Mangrove).merge(Val_bangunan).merge(Val_Tambak).merge(Val_Pasir).merge(Val_Sawah);

var validation = sentinel.sampleRegions({collection: validationData, properties: ['class'], scale:20, tileScale: 16});

var validated = validation.classify(classifier);

// Matriks confusion dan akurasi, akurasi total dan kappa

var testAccuracy =
  validated.errorMatrix('class', 'classification');
  print('Validation error matrix: ', testAccuracy);
  print('Validation overall accuracy: ', testAccuracy.accuracy(),
  testAccuracy.consumersAccuracy(), testAccuracy.kappa(),
  testAccuracy.producersAccuracy());

```

7. Tampilkan hasil matriks error dan akurasi total.


```

Validation overall accuracy:          JSON
0.927536231884058
* [[ [0.7142857142857143, 0.875, 1, 1, 0.95] ] ]      JSON
0.9086818422445738
* List (6 elements)                          JSON
  * 0: [1]
  * 1: [1]
  * 2: [0.9090909090909091]
  * 3: [0.75]
  * 4: [0.9285714285714286]
  * 5: [0.9047619047619048]

```

Hasil Analisa

Langkah berikutnya adalah melakukan analisa identifikasi lahan Garam di lokasi penelitian Kecamatan Kapetakan dan Suranenggala Kabupaten Cirebon (gambar 8) dengan bantuan *Software* Quantum GIS (QGIS) untuk mengukur luas lahan garam.



Gambar 8. Lokasi Penelitian Kecamatan Kapetakan dan Suranenggala.

Figure 8. Research Location of Kapetakan and Suranenggala Districts.

Dari hasil perhitungan, potensi lahan garam yang di Kecamatan Kapetakan adalah sebesar 2.002,44 ha (Gambar 9).


Potensi lahan garam di Kecamatan Kapetakan diperkirakan sebesar 2.002,44 ha atau 30% dari luas total kecamatan, dengan potensi lahan garam di Desa Bungko Lor sebesar 602,83 ha atau 41% dari luas desa, Desa Bungko sebesar 974,11 ha atau 57% dari luas desa, Desa Pegagan Lor sebesar 218,04 ha atau 32% dari luas desa, Desa Grogol sebesar 66,87 ha atau 19%

Tabel 9. Potensi Lahan Garam di Kecamatan Kapetakan dan Suranenggala, Kab. Cirebon

Table 9. Salt Land Potential in Kapetakan and Suranenggala Districts, Cirebon Regency

No	Kecamatan	Potensi Lahan Produksi (ha)
1	Kapetakan	2.002,44
2	Suranenggala	417,02

Sumber : Hasil analisa, 2023.



Gambar 9. Lokasi Penelitian Kecamatan Kapetakan dan Suranenggala.

Figure 9. Research Location of Kapetakan and Suranenggala Districts.

dari luas desa, Desa Pegagan Kidul sebesar 85,28 ha atau 11% dari luas desa, dan Desa Kertasura sebesar 55,31 ha atau 15% dari luas desa (Tabel 9).

Dari sisi prosentase potensi lahan garam terbesar berada di Desa Bungko, Kecamatan Kapetakan dengan prosentase sebesar 57% dari total luas desa. Potensi lahan garam di Kecamatan Kapetakan sebesar 30% lebih besar dari Kecamatan Suranenggala yang hanya 8% dari luas Kecamatan (Tabel 10).


Hasil analisa dengan algoritma *Machine Learning Random forest* ini dapat ketahui juga matriks galatnya untuk memperkirakan kesalahan yang ditimbulkan oleh kesalahan pengambilan training sample, dimana galat matriks untuk tambak garam bernilai 0 yang berarti antara training sampel dengan sampel validasi sudah sesuai. Pada gambar 10 ini adalah pembagian wilayah penelitian berdasarkan batas administrasi desa di Kecamatan.

Statistik Akurasi Hasil Klasifikasi

Dalam menilai hasil akurasi klasifikasi citra satelit digunakan matriks konfusi, akurasi produser, akurasi pengguna dan akurasi total. Prinsip konfusi matriks sangat sederhana yaitu membandingkan hasil prediksi dengan data aktual melalui kunjungan lapangan data primer. Dalam analisa citra satelit, matriks konfusi adalah suatu matriks yang mengindikasikan tingkat akurasi citra yang telah terklasifikasi terhadap data

Tabel 10. Potensi Lahan Garam Desa-Desa di Kecamatan Kapetakan dan Suranenggala, Kab. Cirebon
Table 10. Salt Land Potential in Villages in Kapetakan and Suranenggala Districts, Kab. Cirebon

No	Kecamatan	Desa	Potensi Lahan Garam		Luas (Ha)
1	Kapetakan		2.002,44	30	6.685,94
		Bungko Lor	602,83	41	1.437,00
		Bungko	974,11	57	1.699,21
		Pegagan Lor	218,04	32	674,89
		Grogol	66,87	19	339,03
		Pegagan Kidul	85,28	11	719,70
		Kertasura	55,31	15	353,3
2	Suranenggala		417,02	16	2.550,12
		Sura-nenggala Lor	37,59	12	320,14
		Muara	169,02	40	413,51
		Sura-nenggala	158,81	30	530,82
		Kidul	51,6	32	160,79
		Karang-reja			



Gambar 10. Hasil Analisa Potensi Lahan Garam Per Desa dengan Algoritma Random Forest.

Figure 10. Results of Salt Land Potential Analysis Per Village using Random Forest Algorithm.

referensi. Tabel 11 merupakan hasil perhitungan matriks konfusi.

Pada Tabel 11, nilai akurasi konsumen merupakan nilai akurasi dalam kolom dibagi akurasi total dan diperoleh hasil klasifikasi konsumen adalah [0,71, 0,87, 1, 1, 1, 0,95] sehingga dapat disimpulkan bahwa nilai untuk setiap kolom obyek data lebih besar dari 0,7 sehingga disimpulkan akurasi sedang sampai tinggi. Untuk akurasi klasifikasi tambak gambar bernilai 1 dengan akurasi sangat tinggi.

Akurasi produsen merupakan nilai akurasi dalam baris dibagi akurasi total dan untuk setiap baris akurasi produsennya lebih besar dari 0,7 sehingga dapat disimpulkan akurasi sedang sampai tinggi. Untuk klasifikasi tambak garam 0,93 dengan akurasi tinggi.

Nilai Kappa matriks konfusi bernilai 0,90 sehingga dapat disimpulkan bahwa hasil klasifikasi dikategorikan sangat dapat dipercaya.

Akurasi total bernilai 0,927 sehingga dapat disimpulkan

Tabel 11. Matriks Konfusi.
Table 11. Confusion Matrix.

	X1	X2	X3	X4	X5	X6	AP
V1	5	0	0	0	0	0	1
V2	0	14	0	0	0	0	1
V3	0	0	10	0	0	1	0,91
V4	0	1	0	3	0	0	0,75
V5	0	1	0	0	13	0	0,93
V6	2	0	0	0	0	19	0,90
AK	0,71	0,87	1	1	1	0,95	

Ket:

X1 = Vegetasi

X2 = Perairan/sungai

X3 = Wilayah terbangun

X4 = Pantai berpasir

X5 = Tambak Garam

X6 = Pesawahan

V1 = Validasi Vegetasi

V2 = Validasi Perairan/sungai

V3 = Validasi Wilayah terbangun

V4 = Validasi Pantai berpasir

V5 = Validasi Tambak Garam

V6 = Validasi Pesawahan

AK = Akurasi Konsumen

AP = Akurasi Produsen

bahwa akurasi total kategori tinggi.

KESIMPULAN DAN SARAN

Dalam penelitian ini, diperoleh hasil kesimpulan dan saran :

1. Kecamatan Kapetakan memiliki luas lahan yang potensial sebesar 2.002,44 ha atau 30% dari luas total kecamatan untuk dikembangkan sebagai Sentra Ekonomi Garam Rakyat (SEGAR).
2. Potensi lahan garam di Kecamatan Kapetakan diantaranya berada di Desa Bungko Lor sebesar 602,83 ha atau 41% dari luas desa, Desa Bungko sebesar 974,11 ha atau 57% dari luas desa, Desa Pegagan Lor sebesar 218,04 ha atau 32% dari luas desa, Desa Grogol sebesar 66,87 ha atau 19% dari luas desa, Desa Pegagan Kidul sebesar 85,28 ha atau 11% dari luas desa, dan Desa Kertasura sebesar 55,31 ha atau 15% dari luas desa
3. Pengembangan Sentra Ekonomi Garam Rakyat (SEGAR) berpotensi untuk dikembangkan ke Kecamatan yang bersebelahan dengan Kecamatan Kapetakan yaitu Kecamatan Suranenggala dengan potensi lahan garam diperkirakan sebesar 417,02 ha atau 16% dari luas total kecamatan,
4. Potensi lahan garam di Kecamatan Suranenggala diantaranya di Desa Sura Lor sebesar 37,59 ha atau

- 12% dari luas desa, Desa Muara sebesar 169,02 ha atau 40% dari luas desa, Desa Suranenggala sebesar 158,81 ha atau 30% dari luas desa, dan Desa Karangreja 51,6 ha atau 32% dari luas desa.
5. Aspek lainnya yang mendukung potensi pengembangan garam di Kecamatan Kapetakan adalah :
- Adanya sejumlah gudang garam yang dikelola swasta dan masyarakat.
 - Kecocokan kesesuaian tata ruang dengan RTRW Kabupaten Cirebon.
 - Rata-rata petak lahan kepemilikan petambak garam lebih besar dari 5 ha sehingga memudahkan proses konsolidasi lahan.
 - Aspek sosial masyarakat yang mendukung program pemerintah daerah, seperti masyarakat yang partisipatif, dan komunikatif.

UCAPAN TERIMA KASIH

Penelitian ini dilaksanakan secara swakelola oleh para peneliti dan perencana di Bappelitbangda Kabupaten Cirebon. Kami mengucapkan banyak terima kasih kepada Dinas Ketahanan Pangan dan Perikanan (DKPP) Kabupaten Cirebon, Institut Teknologi Bandung (ITB) dan Kementerian Kelautan dan Perikanan atas perhatian dan upayanya mendorong kesejahteraan para petambak garam di Kabupaten Cirebon. Yusa Inderapermana, Dangi, Fitri Nurliasari, Eva Rahmifa, Dwi Kusumayanti sebagai kontributor

DAFTAR PUSTAKA

- Harahap, S. A., Purba, N. P., & Syamsuddin, M. L. (2019). Trend of coastline change for twenty years (1994-2014) in Cirebon, Indonesia. *World Scientific News*, 138(2), 79-92.
- Heriati, A., & Husrin, S. (2017). Perubahan garis Pantai di Pesisir Cirebon berdasarkan Analisis Spasial. *Reka Geomatika*, 2017(2), 52-60.
- Kenedi, B. (2017). Analisis Perubahan Garis Pantai Menggunakan Citra Satelit Landsat di Pesisir Cirebon. Thesis. Bogor: Indonesia, Institut Pertanian Bogor.
- Bappelitbangda, & ITB. (2021). Kajian Pembentukan Kawasan Konservasi Mangrove dan Proyeksi Laju Pembentukan Akresi dan Abrasi di Pesisir Kabupaten Cirebon. Cirebon: Pemerintahan Kabupaten Cirebon.

- Mahajan, G. R., Das, B., Gaikwad, B., Murgaonkar, D., Desai, A., Morajkar, S., Patel, K. P., & Kulkarni, R. M. (2021). Monitoring properties of the salt-affected soils by multivariate analysis of the visible and near-infrared hyperspectral data. *CATENA*, 198, 105041. <https://doi.org/10.1016/J.CATENA.2020.105041>
- Wang, X., Zhang, F., Ding, J., Kung, H. te, Latif, A., & Johnson, V. C. (2018). Estimation of soil salt content (SSC) in the Ebinur Lake Wetland National Nature Reserve (ELWNNR), Northwest China, based on a Bootstrap-BP neural network model and optimal spectral indices. *Science of The Total Environment*, 615, 918–930. <https://doi.org/10.1016/J.SCITOTENV.2017.10.025>
- Kahaer, Y., & Tashpolat, N. (2019). Estimating Salt Concentrations Based on Optimized Spectral Indices in Soils with Regional Heterogeneity. *Journal of Spectroscopy*, 2019. <https://doi.org/10.1155/2019/2402749>
- Nawar, S., Buddenbaum, H., Hill, J., & Kozak, J. (2014). Modeling and mapping of soil salinity with reflectance spectroscopy and landsat data using two quantitative methods (PLSR and MARS). *Remote Sensing*, 6(11), 10813–10834. <https://doi.org/10.3390/RS61110813>
- Wang, J., Ding, J., Yu, D., Ma, X., Zhang, Z., Ge, X., Teng, D., Li, X., Liang, J., Lizaga, I., Chen, X., Yuan, L., & Guo, Y. (2019). Capability of Sentinel-2 MSI data for monitoring and mapping of soil salinity in dry and wet seasons in the Ebinur Lake region, Xinjiang, China. *Geoderma*, 353, 172–187. <https://doi.org/10.1016/J.GEODERMA.2019.06.040>
- Wang, J., Ding, J., Yu, D., Teng, D., He, B., Chen, X., Ge, X., Zhang, Z., Wang, Y., Yang, X., Shi, T., & Su, F. (2020). Machine learning-based detection of soil salinity in an arid desert region, Northwest China: A comparison between Landsat-8 OLI and Sentinel-2 MSI. *Science of The Total Environment*, 707, 136092. <https://doi.org/10.1016/J.SCITOTENV.2019.136092>
- Wang, Z., Zhang, X., Zhang, F., Chan, N. weng, Kung, H. te, Liu, S., & Deng, L. (2020). Estimation of soil salt content using machine learning techniques based on remote-sensing fractional derivatives,

- a case study in the Ebinur Lake Wetland National Nature Reserve, *Northwest China. Ecological Indicators*, 119, 106869. <https://doi.org/10.1016/J.ECOLIND.2020.106869>
- Xu, X., Wang, X., Yang, P., Meng, Y., Yu, D., & Li, C. (2023). Strategy for mapping soil salt contents during the bare soil period through a satellite image: Optimal calibration set combined with random forest. *CATENA*, 223, 106900. <https://doi.org/10.1016/J.CATENA.2022.106900>
- McBratney, A. B., Mendonça Santos, M. L., & Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117(1–2), 3–52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
- Wang, N., Xue, J., Peng, J., Biswas, A., He, Y., Sensing, Z. S.-R., (2020). Integrating remote sensing and landscape characteristics to estimate soil salinity using machine learning methods: a case study from Southern Xinjiang, China. *Mdpi.Com*, 12, 4118. <https://doi.org/10.3390/rs12244118>
- Zare, S., Abtahi, A., Fallah Shamsi, S. R., & Lagacherie, P. (2021). Combining laboratory measurements and proximal soil sensing data in digital soil mapping approaches. *CATENA*, 207, 105702. <https://doi.org/10.1016/J.CATENA.2021.105702>
- Mohammed, M., Khan, M. B., & Bashier, E. B. (2017). *Machine Learning : Algorithms and Applications*. Boca Raton: CRC Press Taylor & Francis Group 6000 Broken Sound Parkway NW, Suite 300 Boca Raton, FL 33487-2742.
- Daqiqil, I. (2021). *Machine Learning, Teori, Studi Kasus dan Implementasi Menggunakan Python*. Pekanbaru, Riau: Badan Penerbit Universitas Riau, UR PRESS, Indonesia.
- Mitchell, T. M. (1997). *Machine Learning*. New York, Amerika Serikat: McGraw-Hill Science/Engineering/Math.
- Breiman, L. (2001). *Machine Learning*. Statistics Department, University of California, Berkeley, CA 94720: Kluwer Academic Publishers. Manufactured in The Netherlands.
- Vermeulen, D., & van Niekerk, A. (2016). Evaluation of a WorldView-2 image for soil salinity monitoring in a moderately affected irrigated area. *Journal of Applied Remote Sensing*, 10(2), 026025. <https://doi.org/10.1117/1.JRS.10.026025>
- Yahiaoui, I., Bradai, A., Douaoui, A., & Abdennour, M. A. (2021). Performance of *random forest* and buffer analysis of Sentinel-2 data for modelling soil salinity in the Lower-Cheliff plain (Algeria). *International Journal of Remote Sensing*, 42(1), 128–151. <https://doi.org/10.1080/01431161.2020.1823515>
- Rani, A., Kumar, N., Sinha, N., Geosciences, J. K.-A. J. of, & 2022, (2022). Identification of salt-affected soils using remote sensing data through *random forest* technique: A case study from India. *Springer*, 15(5). <https://doi.org/10.1007/s12517-022-09682-3>
- Ho, T. K. (1995). Random Decision Forests. *Proceedings of the 3rd International Conference on Document Analysis and Recognition*, 278-282.
- Wikipedia. (2023). Diambil kembali dari https://id.wikipedia.org/wiki/Random_forest
- Congalton, R. G. (1991). A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing. Environmental*, 37, 35-46.
- Landis, J., & Koch, G. (1977). Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33, 159-174.
- Wiweka, Parwati, E., Prayogo, T., Marini, Y., & Budiman, S. (2014). Uji Akurasi Training Sample untuk Klasifikasi Terawasi. *Seminar Nasional IDEC*, (hal. 559-566). Surakarta.
- Google Earth Engine Data Catalog. (2023, 2 11). Diambil kembali dari https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED
- Dimiyati, M. (2022). *Memahami Penginderaan Jauh Mandiri*. Jakarta, Indonesia: UI Publishing, Universitas Indonesia.
- Mutanga, O., & Kumar, L. (2019). Google Earth Engine Applications. *Journal Remote Sensing*, 11, 591.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine. Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ*, 202, 18-27.