

PENGGUNAAN *ISO CLUSTER UNSUPERVISED CLASSIFICATION* DALAM MENGENALI GARIS PANTAI, STUDI KASUS: RAROWATU UTARA, SULAWESI TENGGARA

Taufiq Ejaz Ahmad^{1*}, Amien Rais¹, Dhea Rahma Azhari¹,
La Ode Alam Minsaris¹, Della Ayu Lestari¹, Wildan Aprizal Arifin¹

Sistem Informasi Kelautan, Universitas Pendidikan Indonesia, Jl. Dr Setiabudi No.229, Isola, Kec.
Sukasari, Kota Bandung, Jawa Barat 40154
Email: taufiqejazahmad@upi.edu

ABSTRACT

Natural or anthropogenic activities often result in changes in natural conditions, in particular, changes in the coastline can have a sistem informasi geografis significant effect on the socio-economic effects of humans who are bound therein. Moreover, the coast is the earth's surface which is always experiencing dynamic changes. This study focuses on knowing how the influence of variability, area, and linearity of the coast in influencing the Iso Cluster Unsupervised Classification machine learning method which has high accuracy in extracting shoreline information. Satellite image data used is Landsat 8 ETM imagery, with observation times in the range 2013-2020. The use of this approach serves to increase effectiveness and efficiency and reduce the required resources. A case study was conducted in Southeast Sulawesi. Where the coastline in North Rarowatu District has been extracted. This shows that the Iso Cluster Unsupervised Classification can work and produce output as expected by making the necessary customizations. It is noted that the variability, area, and physical linearity of the coast affect the process of extracting information from the shoreline.

Keywords: Garis Pantai, Machine Learning, Iso Cluster Unsupervised Classification, Delineasi

ABSTRAK

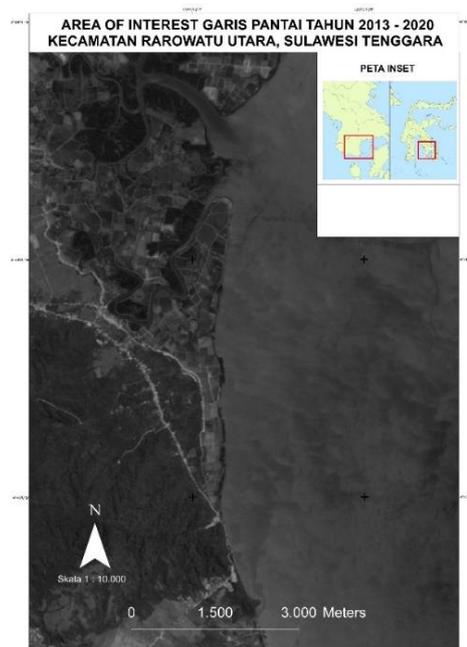
Aktivitas alami ataupun antropogenik seringkali mengakibatkan perubahan kondisi alam, secara khusus perubahan garis pantai dapat mengakibatkan efek yang signifikan terhadap sosial ekonomi manusia yang terikat didalamnya, telebih pantai adalah permukaan bumi yang selalu mengalami perubahan dinamis. Studi ini berfokus untuk mengetahui bagaimana pengaruh variabilitas, luasan dan linearitas pantai dalam memengaruhi metode *machine learning Iso Cluster Unsupervised Classification* yang memiliki akurasi tinggi dalam mengekstraksi informasi garis pantai. Data citra satelit yang digunakan adalah citra Landsat 8 ETM, dengan waktu pengamatan dalam rentang 2013-2020. Penggunaan pendekatan ini berfungsi untuk meningkatkan efektivitas dan efisiensi serta menurunkan sumber daya yang dibutuhkan. Studi kasus yang dilakukan di Sulawesi Tenggara. Dimana garis pantai pada Kecamatan Rarowatu utara telah diekstraksi. Hal ini menunjukkan bahwa *Iso Cluster Unsupervised Classification* dapat bekerja dan menghasilkan output sesuai harapan dengan melakukan kustomisasi yang dibutuhkan. Tercatat bahwa variabilitas, luasan dan linearitas fisik pantai memengaruhi proses ekstraksi informasi dari garis pantai.

Kata kunci: Garis Pantai, *Machine Learning*, *Iso Cluster Unsupervised Classification*, Delineasi

PENDAHULUAN

Area pesisir merupakan wilayah yang penting bagi kehidupan manusia, dimana didalamnya tidak hanya kaitan perekonomian, namun juga berbagai aspek lain yang menunjang bagi kehidupan manusia. Pemenuhan kebutuhan manusia dari wilayah pesisir mendorong terjadinya pemanfaatan sumber daya pesisir yang meningkatkan urbanisasi serta beberapa pembangunan di kawasan terkait, yang kemudian memberikan tekanan antropogenik pada lingkungan pesisir yang mengarah pada perubahan berupa erosi, intrusi air laut, dll. Sehingga terjadi perubahan garis pantai. Garis pantai sendiri secara alamiah merupakan area yang sangat dinamis, hal ini dikarenakan faktor alam dan faktor antropogenik. Garis pantai juga merupakan ketampakan alam unik yang didefinisikan sebagai garis batas dari pertemuan antara air laut dan daratan, hal ini menjadikannya sangat mudah didefinisikan namun sulit untuk ditandai secara pasti.

Perubahan garis pantai memiliki dampak signifikan terhadap manusia, dampak ini memiliki ketergantungan terhadap faktor yang dimanfaatkan oleh manusia yang terkait didalamnya. seperti perubahan garis pantai di Semarang, dimana properti fisik menjadi terendam, sehingga dibutuhkan sumber daya lebih untuk proses perpindahan lokasi tempat tinggal (Safitri et al., 2019). Untuk menyikapi perubahan garis pantai, terlebih dahulu dibutuhkan pemantauan yang akurat untuk memahami berbagai perubahan dinamis dari garis pantai.



Gambar 1. *Area of interest* dalam penelitian ini

Perubahan garis pantai tidak hanya terjadi di satu titik lokasi, namun sepanjang garis pantai yang ada, sehingga dibutuhkan metode paling efektif untuk melakukan pemantauan, terlebih dibutuhkan rentang waktu tertentu dalam memahami arti perubahan

dari garis pantai, penggunaan sistem informasi geografi merupakan jawaban atas tantangan dari luas wilayah pemantauan yang tidak kecil, serta menjadi jawaban atas kebutuhan dari rentang waktu tertentu dalam mengambil kesimpulan dari perubahan garis pantai.

Sistem informasi geografi cukup banyak digunakan dalam berbagai proses untuk mengambil kesimpulan dari wilayah pesisir, seperti studi terbaru yang memanfaatkan sistem informasi geografi dalam menduga luasan inundasi jika terjadi tsunami di pesisir timur Provinsi Banten (Lestari et al., 2021). Sistem informasi geografi merupakan metode pendekatan paling efektif untuk melakukan proses ekstraksi informasi dari bentuk rupa muka bumi secara luas dan temporal (Ahmad et al., 2020). Dalam pemantauan perubahan garis pantai, sistem informasi geografi memiliki akurasi tinggi untuk dimanfaatkan sebagai metode pendekatan yang paling efektif dan efisien (Esmail et al., 2019). Dalam beberapa tahun ini sangat banyak penggunaan *machine learning* untuk meningkatkan efektifitas dan efisiensi serta menurunkan kebutuhan sumber daya yang dibutuhkan, hal ini menjadi jawaban atas tantangan pekerjaan yang bersifat repetitif dalam pendekatan lewat sistem informasi geografi (Omar et al., 2013).

Studi berkenaan dengan penggunaan metode pendekatan *machine learning* untuk proses rekognisi objek pada muka bumi, Area (Area, 2014) menjelaskan bahwa *machine learning* dapat melakukan serangkaian proses yang jika dikerjakan secara manual merupakan proses repetitif yang banyak menghabiskan waktu dan sumber daya. Dalam pengaplikasiannya, pendekatan metode *machine learning* pada proses rekognisi objek muka bumi dibagi menjadi dua, yaitu: *supervised learning* dan *unsupervised learning*, pada beberapa kasus *unsupervised learning* dapat memiliki akurasi yang lebih tinggi, seperti pada monitoring gunung api oleh (Fitria et al., 2014). Namun pada umumnya *supervised learning* memberikan akurasi yang lebih menjanjikan, hal ini dikarenakan pengaruh dari faktor luasan *area of interest* yang diamati serta variabilitas objek yang harus direkognisi, serta informasi dan verifikasi data lapangan yang menambah kesesuaian terhadap realitas. Studi oleh (Arjasakusuma et al., 2021) menyarankan peningkatan akurasi terhadap ekstraksi informasi dari batas antara laut dan darat, mengingat begitu dinamisnya perubahan yang terjadi setiap saat. Penelitian ini berfokus pada penggunaan dan pengujian dari pendekatan *machine learning* dengan metode *Iso Cluster Unsupervised Classification* yang memiliki akurasi tinggi, tidak banyak memerlukan sumber daya, cepat dalam pengakuisian proses, efektif untuk diterapkan dalam skala luasan yang tidak kecil serta efisien dalam menunjang kebutuhan secara statistik ataupun penunjang keputusan lewat perbandingan langsung.

Bagian 2 adalah ringkasan singkat dari studi berbasis *Machine learning* dan sistem informasi geografi yang ditinjau di berbagai lokasi dan waktu yang beragam untuk ekstraksi informasi pada permukaan bumi berupa batasan antara daratan dan perairan, baik itu sungai ataupun laut. Bagian 3 menjelaskan model pengolahan dari metode yang digunakan dalam penelitian ini. Bagian 4 menguraikan bagaimana variabilitas objek yang harus dikenali, luasan wilayah, dan linearitas pantai berpengaruh untuk mengidentifikasi garis pantai.

TINJAUAN PUSTAKA DAN PENGEMBANGAN HIPOTESIS

Perubahan garis pantai merupakan hal yang lumrah, perubahan garis pantai dapat memiliki variasi dan fluktuasi yang berbeda dalam setiap jangka waktu pemantauannya, baik perubahan berupa pergeseran positif ke arah laut atau dapat disebut sebagai akresi dan perubahan negative ke arah darat atau dapat disebut sebagai erosi.

Studi terbaru berkenaan dengan pemantauan dari perubahan garis pantai banyak mengarah pada deteksi *shoreline change rate*, hal ini merupakan pendekatan statistik dalam memetakan rating perubahan pada garis pantai yang diteliti dari minimal 2 informasi garis pantai yang telah terekstraksi, sehingga garis pantai sebagai inputan harus menjadi tolak ukur yang akurat dan merepresentasikan keadaan pada realitas (Esmail et al., 2019; Niang, 2020). Untuk meningkatkan representasi dari realitas, penggunaan *machine learning* yang teradaptasi dengan sistem informasi geografi memberikan jawaban untuk kebutuhan akurasi, berbagai metode rekognisi dengan *machine learning* memberikan keragaman yang dapat memenuhi akurasi yang dibutuhkan dan dapat diterapkan untuk berbagai kebutuhan ekstraksi informasi dari citra satelit (Omar et al., 2013).

a) Monitoring Berbasis Sistem Informasi Geografi

Perkembangan dari sistem informasi geografi yang telah diintegrasikan dengan *machine learning* untuk melakukan serangkaian proses rekognisi dalam beberapa tahun kebelakang memberikan nilai peningkatan yang ditandai dengan adanya berbagai improvisasi sehingga meningkatkan efisiensi dan akurasi yang dibutuhkan dari pemantauan perubahan garis pantai terutama dalam membedakan daratan dan perairan. Tabel 1 adalah ringkasan singkat tinjauan studi dari beberapa penerapan sistem informasi geografi-*machine learning*.

Sejumlah studi yang berfokus pada wilayah pemantauan dengan skala kecil hingga yang cukup luas, termasuk didalamnya terdapat wilayah yang memiliki permukaan linear dan tidak, Islam et al. (Islam et al., 2016) menggunakan metode manual on screen digitizing untuk mengekstraksi garis pantai, didalam studinya titik fokus berada pada faktor inputan berupa resolusi *radiometric* yang tinggi serta persentase nilai awan yang rendah untuk menghasilkan akurasi yang memenuhi kebutuhan analisa statistik untuk menghasilkan nilai korelasi dari rasio perubahan yang tinggi. Kebutuhan akurasi merupakan syarat dari analisa statistik, bahkan jika hanya untuk analisa dengan metode komparasi langsung (Islam et al., 2016). Dalam wilayah pemantauan yang kecil maka citra yang ada akan semakin terpotong, hal ini menghasilkan perbesaran gambar yang mengaburkan garis batas antara air dan daratan. Baral et al. (Baral et al., 2018) menggunakan metode interpolasi untuk meningkatkan differensiasi pada perbedaan antara setiap pixel dari darat dan setiap pixel dari laut, namun metode ini hanya dapat membantu jika pantai yang menjadi area pengamatan merupakan pantai yang linear, didalam studi oleh Baral et al (Baral et al., 2018) juga dibahas bagaimana pengaruh akurasi dalam merepresentasikan pengamatan perubahan garis pantai jangka pendek dan jangka panjang. Proses ekstraksi manual yang dilakukan oleh Muskananfola et al. (Muskananfola et al., 2020) pada pesisir Demak merupakan improvisasi atas kebutuhan akurasi yang dibutuhkan, hal ini dikarenakan pantai heterogen non linear memiliki variabilitas objek yang harus dipisahkan terlebih memiliki luasan wilayah yang sangat luas. Dimana faktor peningkatan keragaman serta luasan dan non-linearitas pantai merupakan tantangan yang meningkatkan kebutuhan konsumsi sumber daya untuk menghasilkan *output* optimal dalam metode rekognisi objek muka bumi dengan *machine learning* (Sublime, 2021).

Berkenaan dengan studi yang mengkombinasikan *Machine learning* dengan sistem informasi geografi untuk mengekstraksi garis pantai cukup banyak digunakan, metode ini digemari karena kemudahan yang diberikan untuk tidak melakukan proses manual berulang seperti *on screen digitization*. Metode *support vector machine* (SVM) memiliki

nilai efisiensi yang baik dalam proses ekstraksi garis pantai, dimana kemampuan klasifikasi yang dimiliki cukup baik dan memiliki performa untuk membedakan nilai setiap *pixel* yang lebih baik dari metode klasifikasi tradisional seperti *maximum likelihood algorithm*, sehingga dipilih dan digunakan dalam ekstraksi garis pantai yang linear oleh Konko et al (Konko et al., 2020). Untuk mengenali pantai non linear dibutuhkan kemampuan untuk mengenali daerah *white water*, daerah ini merupakan bagian dari pantai, merupakan area dinamis yang terdiri dari campuran wilayah perairan sangat dangkal, serta daratan yang basah. Esmail et al. (Esmail et al., 2019) menggunakan *iso cluster unsupervised classification* dalam mengenali pantai yang non linear, studi oleh Esmail et al. juga berhasil mengenali daerah yang merupakan *white water* dan kemudian membedakan wilayah perairan sangat dangkal dan daratan yang basah, selain itu hal ini yang menjadikan *iso cluster unsupervised classification* merupakan metode yang memiliki superioritas dibandingkan metode *machine learning* lainnya untuk mengekstraksi garis pantai secara statistika dikarenakan cukup merepresentasikan realitas, namun tidak banyak membutuhkan sumberdaya kalkulasi tambahan serta keahlian tinggi dari pengguna. Superioritas *iso cluster unsupervised classification* dapat ditandai dengan nilai *root mean square error* (RMSE) yang didapat dari metode ini memiliki nilai yang lebih baik bahkan jika dibandingkan dengan nilai RMSE dari proses *on screen Digitizing* (Esmail et al., 2018). *Iso cluster unsupervised classification* juga memiliki kapabilitas untuk membedakan wilayah dengan tingkat heterogenitas rendah pada wilayah terbatas (Hatibovic & Kulagic, 2019).

platform	hasil	Shoreline delineation rate
ArcMap	Prediksi perubahan garis pantai.	45.60 – 77 m/tahun
Erdas Imagine, ArcMap	Hubungan korelasi antar metode statistic.	2.05 – 28.62 m/tahun
ArcMap	Rate erosi dan rate akresi.	2.49 – 5.07 m/tahun
ArcMap	Perubahan garis pantai jangka pendek, dan perubahan garis pantai jangka Panjang.	1.5 – 10.73 m/tahun
ArcMap	Perubahan aliran sungai	-
ArcMap	Perubahan garis pantai, rating erosi, dan akresi.	4 – 65 m/tahun

Tabel 1. Studi litelatur

studi	wilayah	Waktu pemantauan	Input dataset	Metode <i>machine learning</i>	Pengolahan data
(Esmail et al., 2019)	Damietta coast, Egypt	1990, 1999, 2003, 2015	Landsat	Iso cluster	Epr + Irr
(Islam et al., 2016)	Kutubdia island, south east Bangladesh	1972, 1976, 1980, 1989, 1999, 2004,	Landsat	-	Epr, Irr, W/Ir, Lms
(Konko et al., 2020)	Togo (West Africa)	1988 - 2018	Landsat, Sentinel-2A	Iso cluster, support vector machine	Irr
(Baral et al., 2018)	Chilika Lagoon Coast, India	1975-2015	Landsat MSS, IRS-ID, IRS P6 LISS III	-	Epr + Irr
(Hatibovic & Kulagic, 2019)	Bosnia and Herzegovina	2008, 2012	Ortophoto dari UltraCam X, S/N UCX-SX-1-20915097.	Iso cluster	Komparasi langsung
(Muskananfolo et al., 2020)	Sayung Demak, Indonesia	1994, 2000, 2005,2011,2018	Landsat 5, Landsat 7, sentinel-2A	-	Epr + nsm

b) Kebaruan dari Studi Ini

Studi berbasis *machine learning* – sistem informasi geografi sebelumnya (Esmail et al., 2019; Hatibovic & Kulagic, 2019; Konko et al., 2020) berfokus pada bagaimana menghasilkan rekognisi yang paling efektif dari masing masing karakter objek pantai pengamatan dan kapabilitas *machine learning* yang paling sesuai, namun Indonesia sebagai negara kepulauan memiliki pantai linear dan nonlinear. Studi kami melakukan pemantauan pada pantai nonlinear pada wilayah Kecamatan Rarowatu Utara, Provinsi Sulawesi Tenggara (Gambar 1) dengan metode *machine learning iso cluster unsupervised classification*, paper ini bertujuan untuk membahas mengenai bagaimana variabilitas objek permukaan bumi, luasan yang relative besar, dan kondisi pantai yang nonlinear memengaruhi performa dari proses rekognisi untuk ekstraksi garis pantai.

MATERIAL DAN METODE PENELITIAN

a) Area Studi

Studi ini berlokasi pada pesisir Kabupaten Rarowatu Utara, Provinsi Sulawesi Tenggara, Indonesia, yang dibatasi dengan garis lintang timur 122°1'40" hingga 122°3'20", serta garis bujur lintang selatan 4°38'20" hingga 4°43'0" (Gambar 1). Dengan karakteristik beriklim tropis dengan 2 musim, yaitu musim kemarau dan musim hujan. Serta komoditas ekonomi pesisir berupa pemanfaatan lahan dengan alih guna lahan untuk dijadikan sebagai tambak.

b) Citra Satelit

Citra satelit dari Landsat 8 digunakan dalam studi ini, dengan waktu pengamatan pada tahun 2013 - 2020 yang merepresentasikan perubahan dinamis selama 7 tahun. Citra yang ada dipilih berdasarkan penilihan jumlah persentase akumulasi awan yang ditoleransi maksimal sebesar 10% dengan ketentuan bahwa awan yang terakumulasi tidak menghalangi area pengamatan pantai, citra yang digunakan memiliki resolusi spasial 30 m. Data citra yang digunakan berasal dari Landsat 8 *Enhanced Thematic Mapper* (ETM).

c) Pre-Processing Citra

Seluruh citra yang digunakan terlebih dahulu harus melalui proses *pre-processing*, untuk melakukan operasi ini *software* ArcMap digunakan untuk melakukan serangkaian proses yang terdiri dari proses koreksi *radiometric*, dan koreksi *geometric*. Koreksi *radiometric* sendiri merupakan proses yang berfungsi untuk mereduksi efek atmosferik, proses ini merupakan Langkah konversi nilai pancaran dari sensor yang diubah menjadi nilai reflektansi permukaan dengan model FLAASH (Wang et al., 2017) koreksi *geometric* merupakan proses yang berfungsi untuk menghilangkan efek dari distorsi geometris (Padró et al., 2018; Tu et al., 2018).

Beberapa metode untuk meningkatkan differensiasi dari area perairan dan daratan dari citra satelit telah dikembangkan, diantaranya: *Normalized difference water index* (Frazier & Page, 2000), *modified normalized difference water index* (Wang et al., 2017), dll. Dalam studi ini index spectral perairan didapatkan dengan metode *Normalized difference water index* (NDWI), penggunaan NDWI dikarenakan efisiensi dan kemudahannya, dengan persamaan NDWI (1) dimana NIR merujuk pada near infrared band. Green merujuk pada band hijau.

NDWI bertujuan untuk memaksimalkan reflektansi air menggunakan panjang gelombang hijau, serta meminimalkan reflektansi dari band near infrared dengan nilai air sehingga dapat memanfaatkan reflektansi NIR yang tinggi oleh vegetasi ataupun tanah.

Sehingga pada hasilnya, air memiliki nilai positif, sedangkan tanah atau vegetasi memiliki nilai negatif.

$$NDWI = \frac{\text{Green}-\text{NIR}}{\text{Green}+\text{NIR}} \quad (1)$$

d) Ekstraksi Garis Pantai

Berbagai metode untuk ekstraksi garis pantai dan pendeteksian dari perubahan garis pantai dengan sumber ekstraksi dari citra satelit telah banyak dikembangkan, diantaranya adalah: *on screen digitizing* (metode manual), *write function* dengan inserti memori, *density slice* dengan band tunggal ataupun dual band, klasifikasi multi spectral, *image enhancement*, klasifikasi dengan tanggal berganda, dan komparasi dari dua klasifikasi tutupan lahan, serta metode rekognisi *supervised* dan *unsupervised* sebagai metode yang paling sering digunakan (Burningham & French, 2017; Frazier & Page, 2000; Konko et al., 2018; Mas, 1999; Stanchev et al., 2013; Wang et al., 2017).

Tahapan awal dari ekstraksi garis pantai adalah penggunaan algoritma NDWI, hal ini berfungsi untuk mempermudah metode rekognisi. NDWI menghasilkan differensiasi antara area darat dengan laut, dengan peningkatan performa rekognisi maka akurasi akan lebih merepresentasikan realitas. Batas antara laut dan darat yang menjadi garis pantai diekstraksi dengan *iso cluster unsupervised classification*. Metode ini melakukan proses *unsupervised classification* pada citra raster inputan dan mengkombinasikan fungsi dari *iso cluster* dan *maximum likelihood classification* (Norzaki & Tahar, 2019). *Iso cluster* yang digunakan menggunakan modifikasi dari optimalisasi iterasi pada prosedur *clustering* (Nijhawan et al., 2017). Sedangkan dalam algoritma *maximum likelihood classification* memiliki dua prinsip: *pixel* di setiap sampel *class* dalam ruang multidimensi terdistribusi normal dan teorema pengambilan keputusan Bayes. Alat ini mempertimbangkan varian dan kovarian setiap *cluster* saat menetapkan setiap *pixel* ke salah satu *class* yang direpresentasikan dalam setiap *cluster* yang telah ditentukan pada pengaturan awal *preset* (Lin et al., 2020; Verbovšek & Popit, 2018).

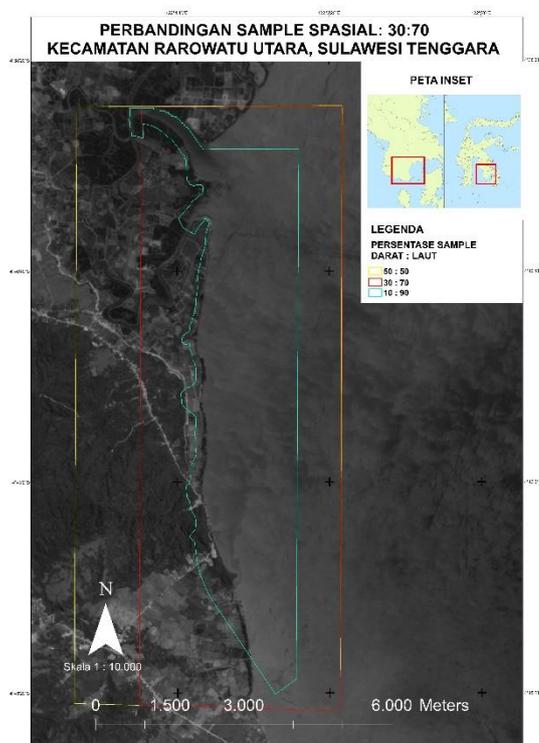
Teknik berbasis cluster ini bekerja pada domain *spectral*, proses ini mencari kemiripan pada setiap *pixel* diantara citra *input* dan *cluster pixel* yang telah ditentukan. Dalam penelitian ini kami membagi menjadi dua *cluster*, yaitu darat dan laut. Teknik segmentasi berbasis *cluster* bertujuan untuk menemukan struktur yang berbeda dalam ruang nilai spectral citra. Dengan demikian, pengelompokan adalah proses pemartisian lengkap dari satu set *pixel* pada gambar inputan menjadi kelompok *pixel* homogen (Esmail et al., 2019). Kemudian citra tersebut diubah menjadi citra biner dengan garis yang membelahnya menjadi air dan daratan. Garis ini merupakan garis pantai, posisi garis ini berdasarkan ketinggian air, sehingga *white water* dan daratan basah dapat dipisahkan. Proses ekstraksi garis pantai ini dilakukan dengan penggunaan *Spatial Analyst tool > Iso Cluster Unsupervised Classification* yang ada dalam aplikasi ArcMap. Hasil yang diperoleh kemudian dibandingkan untuk mendapatkan hasil yang paling dapat merepresentasikan garis pantai asli.

HASIL DAN PEMBAHASAN

a) Pengaruh Variabilitas, Luasan, Dan Kondisi Pantai Untuk Ekstraksi Garis Pantai

Variabilitas dari keragaman objek yang perlu dibedakan cukup banyak dalam daerah pengamatan di Kecamatan Rarowatu Utara ini (gambar 1), dimana variabilitas tutupan lahan berupa air terdiri dari: perairan laut sangat dangkal (*white water*), laut yang lebih dalam, tambak, dan muara estuari. Selain itu terdapat berbagai nutrient yang tampak pada permukaan perairan, hal ini menyebabkan pixel value pada bagian laut tidak murni lebih dari 0 atau bernilai positif, melainkan beragam dari 0 hingga negatif.

Tutupan lahan darat sendiri terdiri: pasir pantai, daratan basah, vegetasi, dan ketampakan buatan manusia. Kondisi tutupan lahan ini juga menjadi hal yang perlu diperhatikan, dimana tambak dan laut dapat dikelompokkan pada kategori class yang sama, dan ini perlu dihindari karena menimbulkan inefisiensi proses ekstraksi informasi garis pantai. Luasan *sampling rate* yang di uji coba dibagi menjadi 3, meliputi daratan dan perairan terbuka persentase dari 50:50, 30:70, dan 10:90 (Gambar 2).



Gambar 2. Luasan sample spasial

Pengaruh variabilitas yang semakin meningkat ketika luasan wilayah pengamatan yang semakin meluas serta fisik pantai yang nonlinear memengaruhi jumlah inputan yang harus diidentifikasi untuk selanjutnya dimasukkan pada *class* yang telah ditentukan, kategori perbandingan akurasi dibagi menjadi 4 kategori tolak ukur yang dapat menggambarkan kemampuan dalam membedakan air laut dan daratan, yaitu: air laut dengan *nutrient* yang ditandai warna biru tua, pantai berpasir dan *white water* yang ditandai dengan warna biru muda, Kawasan tambak dan ketampakan buatan manusia yang ditandai warna kuning, serta keragaman air laut yang ditandai dengan warna hijau.

Meningkatnya luasan yang juga meningkatkan variabilitas objek menjadi tantangan dalam rekognisi ini, peningkatan persentase terhadap ruang sample berupa luasan spasial

di darat yang harus direkognisi menghasilkan keberagaman yang meningkat secara linear, Keberagaman objek ini yang menurunkan hasil akurasi rekognisi, hal ini diindikasikan oleh perbedaan persentase *sample* darat dan *sample* laut. Ketika persentase *sample* citra darat menurun dan dengan meningkatkan persentase *sample* laut maka akurasi rekognisi meningkat drastis.

Pada persentase darat berbanding laut dengan nilai 50:50 (Gambar 3a.) keempat indicator rekognisi menghadapi kesulitan untuk dikenali, pada bagian estuari yang ditandai dengan warna biru menghasilkan rekognisi yang salah, dimana nutrient dikenali sebagai wilayah daratan, hal ini juga sama dengan persentase wilayah sample 30:70 (gambar 3b). Bagian estuary ini dapat dikenali dengan baik sebagai perairan dan dikelompokkan kedalam class laut Ketika persentase darat diturunkan menjadi 10:90 (gambar 3c).

Secara keseluruhan, rekognisi dengan akurasi tertinggi didapatkan dengan menurunkan persentase daratan. Hal ini terjadi pada proses rekognisi pasir pantai dan *white water*, kemudian pada wilayah tambak dan objek antropogenik, serta pada keragaman air laut. Penyebab perbedaan hasil rekognisi ini berada pada variabilitas, luasan, dan kelinieran pantai, dimana dengan ketetapan awal yang difungsikan hanya untuk mengenali dan membagi menjadi 2 objek yaitu darat dan laut, sehingga *class* campuran seperti tambak, dan estuari dengan *nutrient* pada persentase 50:50 dan 30:70 menjadi terekognisi sebagai daratan, sementara itu, pantai dengan *white water*, dan *noise* yang tampil pada perairan terekognisi menjadi daratan. Oleh karena itu Langkah paling efektif untuk menghindari kesalahan rekognisi ini adalah dengan menurunkan presentase input dari *sample class* daratan.



Gambar 3. Hasil rekognisi citra

Selain faktor *sample*, faktor preset yang telah ditentukan sebelumnya dapat diubah untuk dapat merekognisi setiap *pixel* berdasarkan class yang dibutuhkan. Terdapat opsi kustomisasi terhadap jumlah *cluster*, jumlah iterasi, *max number of cluster merges per iteration*, *max merge distance*, *min number of samples per cluster*, dan *skip factor*. Seluruh preset ini dapat dioptimalkan untuk melatih *Iso Cluster Unsupervised Classification* yang terkustomisasi terhadap penggunaan spesifik yang dikhususkan secara advance untuk menyesuaikan perolehan *output* dari citra yang digunakan.

Metode yang digunakan dalam penelitian ini bergantung secara fundamental terhadap resolusi *spectral* dan resolusi spasial. Artinya ini merupakan factor yang bergantung pada kemampuan satelit untuk merekam panjang gelombang cahaya dan luasan dunia nyata dalam setiap *pixel* citra, secara umum ini merupakan kapabilitas yang lumrah dalam menentukan kualitas citra satelit. Kesulitan berbagai metode *machine learning* untuk melakukan ekstraksi informasi dari kualitas citra yang rendah merupakan hal yang tidak dapat dihindari.

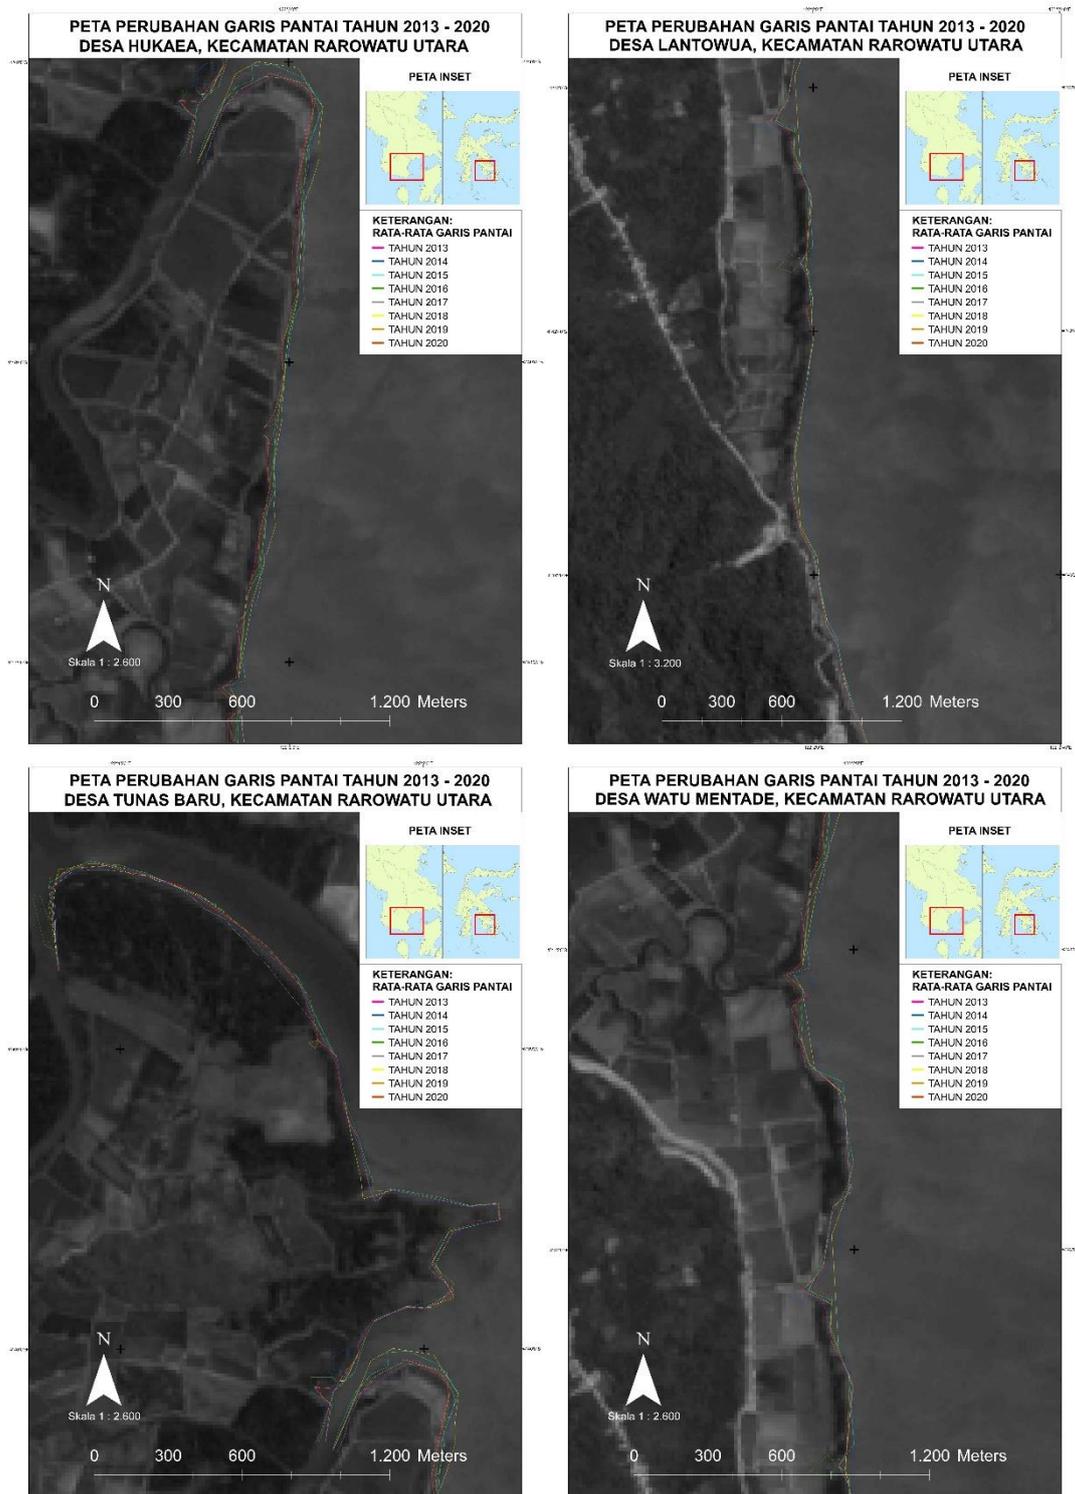
b) Studi Kasus

Output rekognisi memiliki akurasi yang baik digunakan dalam tahapan selanjutnya untuk mempelajari perubahan dinamis yang terjadi pada perubahan garis pantai. Terdapat perubahan baik akresi ataupun erosi yang terjadi setiap tahunnya, pemantauan dilakukan pada setiap tahun dengan *mask* area pada setiap Desa yang terdiri dari: Desa Hukea, Desa Lantowua, Desa Tunas Baru, Desa Watu Mentade (Gambar 5). Ketidak sesuaian garis pantai hasil rekognisi terhadap basemap disebabkan oleh perbedaan tahun dari basemap itu sendiri dan data pengolahan ekstraksi garis pantai. total jarak Erosi dan akresi yang terjadi pada Kecamatan Rarowatu utara dari tahun 2013 hingga 2020 ditampilkan dalam Gambar 4. Dengan rata-rata perubahan garis pantai sebesar 24,34 meter, hampir keseluruhan lahan pada pesisir digunakan sebagai tambak ikan, dengan minimnya vegetasi tanaman pelindung abrasi seperti mangrove, jarak rata rata abrasi pada masa mendatang memiliki peluang untuk meningkat.

Detail perubahan pantai dengan jangka waktu pengamatan dari tahun 2013 – 2020 menunjukkan terjadinya erosi dan akresi. Dengan nilai terkecil sebesar 1.09 meter hingga 38.61 meter. Perubahan terbanyak terjadi pada jarak sebesar 28,21 meter. perubahan sebesar ini berbeda beda dalam setiap tahunnya, dan berbeda beda pada setiap daerah.



Gambar 4. Chart perubahan garis pantai



Gambar 5. Perubahan garis pantai pada setiap Desa di setiap tahun

KESIMPULAN

Penggunaan *Iso Cluster Unsupervised Classification* dalam merekognisi dan mengekstraksi garis pantai dapat dioptimalkan dengan melakukan pengaturan yang dapat diinisiasi oleh pengguna, diawali dengan serangkaian *pre-procces*, selanjutnya

penyesuaian dan ujicoba preset untuk melatih *machine learning*, kemudian penyesuaian luasan, dan variabilitas citra yang diolah, hingga penggunaan citra dengan resolusi spectral dan spasial yang tinggi. Kustomisasi pada variabilitas dan luasan yang digunakan menunjukkan bahwa *Iso Cluster Unsupervised Classification* dapat menjadi jawaban dari proses ekstraksi informasi dari citra satelit dan memiliki akurasi tinggi. Namun factor fisik kelautan tidak dapat terkustomisasi, dalam hal ini adalah kelinearan muka pantai. Terdapat opsi lain untuk menggunakan metode diluar *Iso Cluster Unsupervised Classification*, seperti SVM, random forest dll. Namun penggunaan *Unsupervised Classification* dapat diandalkan untuk mengatasi keurangan dari factor ketidaktahuan kondisi realitas, faktor ketidaktahuan akibat ketidaktersediaanya data mengenai kondisi realitas seperti pasang surut merupakan faktor lain yang dipertimbangkan untuk menggunakan metode *unsupervised*.

LIMITASI DAN STUDI LANJUTAN

Iso Cluster Unsupervised Classification merupakan pendekatan paling efektif dari *machine learning* untuk mengekstraksi garis pantai. namun memiliki kekurangan untuk mengenali dan merekognisi objek yang kompleks, dari hasil percobaan didapati bahwa luasan dan variabilitas menjadi tantangan tersendiri untuk *Iso Cluster Unsupervised Classification*, terlebih jika terjadi hasil yang jauh dari yang diharapkan, meski dapat dilakukan kustomisasi preset, namun variabilitas dan luasan yang menggambarkan kompleksitas citra yang harus direkognisi dan dikenali tetap menjadi permasalahan dalam metode ini. *Iso Cluster Unsupervised Classification* menjadi pendekatan paling efektif apabila kompleksitas citra yang diamati tidak terlalu tinggi. Namun sebaliknya, jika kebutuhan mengharuskan untuk menggunakan citra dengan tingkat kompleksitas tertentu yang tinggi, kemudian proses rekognisi yang kompleks serta capaian target rekognisi yang beragam maka metode ini tidak disarankan untuk digunakan. *Iso Cluster Unsupervised Classification* sangat superior untuk digunakan pada wilayah yang tidak memiliki ketersediaan terhadap data lapangan serta keperluan verifikasi yang rendah. Studi lanjutan yang disarankan berkenaan dengan kekurangan dan kelebihan dari metode *Iso Cluster Unsupervised Classification* adalah dengan membandingkan keadaan lapangan dengan hasil rekognisi yang kemudian dapat dikembangkan untuk meningkatkan akurasi dengan cara melakukan kustomisasi yang diperlukan, terlebih sangat disarankan jika memiliki sumberdaya lebih untuk menggunakan citra satelit yang memiliki resolusi spectral dan spasial yang lebih baik.

DEKLARASI PERSAINGAN KEPENTINGAN

Seluruh penulis dalam paper ini menyatakan bahwa kami tidak mengetahui persaingan kepentingan berkenaan dengan keuangan atau hubungan sosial yang ada sehingga bisa memengaruhi keadaan lapangan yang dapat mempengaruhi pekerjaan yang dilaporkan dalam paper ini

UCAPAN TERIMA KASIH

Studi ini tidak didanai oleh pihak manapun, seluruh sumberdaya yang digunakan berasal dari penulis. Kami sangat menghargai kontribusi dari Ibu Novi Sofia Fitriasari, Ibu lutfhi Anzani, Ibu Ayang Armelita Rosalia, Bapak Wildan Aprizal Arifin, dan Bapak

Ishak ariawan dari Universitas Pendidikan Indonesia atas diskusi dalam penentuan dan pengembangan machine learning *Iso Cluster Unsupervised Classification* dalam studi ini

REFERENSI

- Ahmad, T. E., Rahayu, G., Cahya, D., Lestari, D. A., Stocks, M., & Blakers, A. (2020). *Penggunaan Sistem Informasi Geografi Untuk Mencari Lokasi yang Tepat Sebagai Penyimpanan Energi Hydro Terpompa*. 68–79.
- Area, K. C. (2014). *Accuracy Assessment of Pixel-Based Image Classification Of*. 4(22), 133–140.
- Arjasakusuma, S., Kusuma, S. S., Saringatin, S., Wicaksono, P., Mutaqin, B. W., & Rafif, R. (2021). Shoreline dynamics in East Java Province, Indonesia, from 2000 to 2019 using multi-sensor remote sensing data. *Land*, 10(2), 1–17. <https://doi.org/10.3390/land10020100>
- Baral, R., Pradhan, S., Samal, R. N., & Mishra, S. K. (2018). Shoreline Change Analysis at Chilika Lagoon Coast, India Using Digital Shoreline Analysis System. *Journal of the Indian Society of Remote Sensing*, 46(10), 1637–1644. <https://doi.org/10.1007/s12524-018-0818-7>
- Burningham, H., & French, J. (2017). Understanding coastal change using shoreline trend analysis supported by cluster-based segmentation. *Geomorphology*, 282, 131–149. <https://doi.org/https://doi.org/10.1016/j.geomorph.2016.12.029>
- Esmail, M., Mahmud, W. E., & Fath, H. (2019). Assessment and prediction of shoreline change using multi-temporal satellite images and statistics: Case study of Damietta coast, Egypt. *Applied Ocean Research*, 82(March 2018), 274–282. <https://doi.org/10.1016/j.apor.2018.11.009>
- Esmail, M., Mahmud, W., & Fath, H. (2018). Influence of Coastal Measures on Shoreline Kinematics Along Damietta coast Using Geospatial Tools. *IOP Conference Series: Earth and Environmental Science*, 151(1). <https://doi.org/10.1088/1755-1315/151/1/012027>
- Fitria, D., Ma'sum, M. A., Imah, E. M., & Gunawan, A. A. . (2014). Automatic Arrhythmias Detection Using Various Types of Artificial. *Journal of Computer Science and Information*, 2, 90–100.
- Frazier, P. S., & Page, K. J. (2000). Water body detection and delineation with Landsat TM data. *Photogrammetric Engineering and Remote Sensing*, 66(12), 1461–1467.
- Hatibovic, E., & Kulagic, A. (2019). Change Detection of Hydrologic Networks Using Orthophoto Images in Bosnia and Herzegovina. In *Lecture Notes in Networks and Systems* (Vol. 60). Springer International Publishing. https://doi.org/10.1007/978-3-030-02577-9_46
- Islam, M. A., Hossain, M. S., Hasan, T., & Murshed, S. (2016). Shoreline changes along the Kutubdia Island, south east Bangladesh using digital shoreline analysis system. *Bangladesh Journal of Scientific Research*, 27(1), 99–108. <https://doi.org/10.3329/bjsr.v27i1.26228>
- Konko, Y., Bagaram, B., Julien, F., Akpamou, K. G., & Kokou, K. (2018). Multitemporal Analysis of Coastal Erosion Based on Multisource Satellite Images in the South of the Mono Transboundary Biosphere Reserve in Togo (West Africa). *OALib*, 05(04), 1–21. <https://doi.org/10.4236/oalib.1104526>
- Konko, Y., Okhimambe, A., Nimon, P., Asaana, J., Rudant, J. P., & Kokou, K. (2020). Coastline Change Modelling Induced by Climate Change Using Geospatial Techniques in Togo (West Africa). *Advances in Remote Sensing*, 09(02), 85–100. <https://doi.org/10.4236/ars.2020.92005>

- Lestari, D. A., Fitriasari, N. S., Ahmad, T. E., Rais, A., & Azhari, D. R. (2021). Geographical influence on Tsunami Predictions in Pandeglang Regency, West Java, Indonesia. *Forum Geografi*, 35(1). <https://doi.org/https://doi.org/10.23917/forgeo.v35i1.12367>
- Lin, K., Chen, H., Xu, C.-Y., Yan, P., Lan, T., Liu, Z., & Dong, C. (2020). Assessment of flash flood risk based on improved analytic hierarchy process method and integrated maximum likelihood clustering algorithm. *Journal of Hydrology*, 584, 124696. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2020.124696>
- Mas, J.-F. (1999). Monitoring land-cover changes: A comparison of change detection techniques. *International Journal of Remote Sensing*, 20(1), 139–152. <https://doi.org/10.1080/014311699213659>
- Muskananfolo, M. R., Supriharyono, & Febrianto, S. (2020). Spatio-temporal analysis of shoreline change along the coast of Sayung Demak, Indonesia using Digital Shoreline Analysis System. *Regional Studies in Marine Science*, 34, 101060. <https://doi.org/10.1016/j.risma.2020.101060>
- Niang, A. J. (2020). Monitoring long-term shoreline changes along Yanbu, Kingdom of Saudi Arabia using remote sensing and GIS techniques. *Journal of Taibah University for Science*, 14(1), 762–776. <https://doi.org/10.1080/16583655.2020.1773623>
- Nijhawan, R., Srivastava, I., & Shukla, P. (2017). Land cover classification using supervised and unsupervised learning techniques. *2017 International Conference on Computational Intelligence in Data Science (ICCIDS)*, 1–6. <https://doi.org/10.1109/ICCIDS.2017.8272630>
- Norzaki, N., & Tahar, K. N. (2019). A comparative study of template matching, ISO cluster segmentation, and tree canopy segmentation for homogeneous tree counting. *International Journal of Remote Sensing*, 40(19), 7477–7499. <https://doi.org/10.1080/01431161.2018.1524182>
- Omar, S., Ngadi, A., & H. Jebur, H. (2013). Machine Learning Techniques for Anomaly Detection: An Overview. *International Journal of Computer Applications*, 79(2), 33–41. <https://doi.org/10.5120/13715-1478>
- Padró, J. C., Muñoz, F. J., Ávila, L. Á., Pesquer, L., & Pons, X. (2018). Radiometric correction of Landsat-8 and Sentinel-2A scenes using drone imagery in synergy with field spectroradiometry. *Remote Sensing*, 10(11). <https://doi.org/10.3390/rs10111687>
- Safitri, F., Suryanti, S., & Febrianto, S. (2019). Analisis Perubahan Garis Pantai Akibat Erosi Di Pesisir Kota Semarang. *Geomatika*, 25(1), 37. <https://doi.org/10.24895/jig.2019.25-1.958>
- Stanchev, H., Young, R., & Stancheva, M. (2013). Integrating GIS and high resolution orthophoto images for the development of a geomorphic shoreline classification and risk assessment—a case study of cliff/bluff erosion along the Bulgarian coast. *Journal of Coastal Conservation*, 17(4), 719–728. <https://doi.org/10.1007/s11852-013-0271-2>
- Sublime, J. (2021). The 2011 tohoku tsunami from the sky: A review on the evolution of artificial intelligence methods for damage assessment. *Geosciences (Switzerland)*, 11(3). <https://doi.org/10.3390/geosciences11030133>
- Tu, Y.-H., Phinn, S., Johansen, K., & Robson, A. (2018). Assessing Radiometric Correction Approaches for Multi-Spectral UAS Imagery for Horticultural Applications. *Remote Sensing*, 10(11). <https://doi.org/10.3390/rs10111684>

- Verbovšek, T., & Popit, T. (2018). GIS-assisted classification of litho-geomorphological units using Maximum Likelihood Classification, Vipava Valley, SW Slovenia. *Landslides*, 15(7), 1415–1424. <https://doi.org/10.1007/s10346-018-1004-2>
- Wang, X., Liu, Y., Ling, F., Liu, Y., & Fang, F. (2017). Spatio-Temporal Change Detection of Ningbo Coastline Using Landsat Time-Series Images during 1976–2015. *ISPRS International Journal of Geo-Information*, 6(3). <https://doi.org/10.3390/ijgi6030068>