

INTISARI

Deep learning telah banyak digunakan di berbagai bidang industri karena kemampuannya mengenali dan mengolah data visual dengan tingkat akurasi tinggi. Dalam konteks data ortofoto maupun citra satelit, teknik segmentasi objek menjadi salah satu penerapan yang umum digunakan untuk mengklasifikasikan setiap piksel ke dalam kelas tertentu, sehingga memungkinkan identifikasi objek atau fitur geografis secara lebih rinci dan presisi. Salah satu bidang yang mulai mengadopsi pendekatan ini adalah pemantauan wilayah pesisir, khususnya dalam deteksi dan ekstraksi garis pantai. Deteksi garis pantai memiliki peran penting dalam mitigasi bencana, perencanaan tata ruang wilayah, serta pengelolaan sumber daya pesisir secara berkelanjutan. Selama ini, pemantauan wilayah pesisir banyak memanfaatkan data ortofoto beresolusi tinggi dan citra satelit dengan informasi spasial dan spektral yang kaya. Beberapa penelitian sebelumnya telah menggunakan algoritma *machine learning* maupun digitasi manual untuk mengekstraksi garis pantai dari data tersebut, namun metode tersebut masih memiliki keterbatasan dari segi akurasi, efisiensi, dan konsistensi pada cakupan wilayah yang luas.

Tahapan proyek akhir ini diawali dengan pengumpulan data, dilanjutkan dengan proses *masking* untuk memberi label kelas perairan dan daratan. Data hasil *masking* dibagi ke dalam 3 jenis data, yaitu data *training*, *validation*, dan *testing*. *Deep learning* kemudian dilatih pada masing-masing data, yaitu ortofoto dan citra sentinel-2. Selama pelatihan, performa *deep learning* dipantau menggunakan metrik *dice loss* dan *pixel accuracy*. Jika terjadi *overfitting*, dilakukan penyesuaian arsitektur dengan menambahkan *dropout* pada arsitektur *deep learning* dan menurunkan *learning rate* pelatihan. *Deep learning* yang telah terlatih diuji karakteristik performanya menggunakan metrik *Intersection over Union* (IoU) dan *pixel accuracy*. Selanjutnya, segmentasi dilakukan terhadap 10 sampel data uji dengan lokasi yang berbeda sesuai dengan kebutuhan skala dan hasil segmentasi dari masing-masing data dibandingkan berdasarkan uji akurasi spasial garis pantai menggunakan *cross section* terhadap data referensi.

Hasil uji akurasi garis pantai dengan *cross section* menunjukkan bahwa kedua *deep learning* yang dikembangkan menggunakan ortofoto dan citra sentinel-2 memiliki performa yang kompetitif dengan keunggulan masing-masing saat dilakukan segmentasi dengan 10 data sampel. Data ortofoto menghasilkan rata-rata *error* spasial sebesar 3.32 meter dengan standar deviasi 1.38 meter, serta nilai *Intersection over Union* (IoU) tertinggi pada kelas *Water* sebesar 86.16%. Sementara itu, citra sentinel-2 menghasilkan rata-rata *error* spasial sebesar 18.95 meter dengan standar deviasi 14.23 meter, serta nilai *Intersection over Union* (IoU) tertinggi pada kelas *Water* sebesar 86.16%. Variasi performa ini mencerminkan pengaruh resolusi spasial data *input* terhadap hasil segmentasi, yang di mana data ortofoto lebih teratur untuk deliniasi garis pantai, sedangkan model sentinel-2 lebih efektif dalam representasi spasial kelas air secara luas karena memiliki tambahan *channel* spektral.

Kata kunci: garis pantai, *deep learning*, ortofoto, sentinel-2

ABSTRACT

Deep learning has been widely applied across various industrial sectors due to its ability to recognize and process visual data with high accuracy. In the context of orthophoto and satellite imagery, object segmentation techniques are commonly used to classify each pixel into specific classes, enabling more detailed and precise identification of geographic features. One field that has begun to adopt this approach is coastal monitoring, particularly in coastline detection and extraction. Accurate coastline detection plays a crucial role in disaster mitigation, spatial planning, and sustainable management of coastal resources. Traditionally, coastal monitoring has relied on high-resolution orthophotos and satellite imagery that provide rich spatial and spectral information. Previous studies have employed machine learning algorithms or manual digitization to extract coastlines from such data; however, these methods are still limited in terms of accuracy, efficiency, and consistency over large areas.

This final project begins with data collection, followed by a masking process to label water and land classes. The masked data are divided into three sets: training, validation, and testing. Deep learning models are then trained on each data type, namely orthophotos and sentinel-2 imagery. During training, the model performance is monitored using dice loss and pixel accuracy metrics. In cases of overfitting, adjustments are made by incorporating dropout layers and reducing the learning rate. The trained models are evaluated using Intersection over Union (IoU) and pixel accuracy metrics. Subsequently, segmentation is performed on 10 test samples from different locations, and the results are compared using spatial accuracy testing of the coastline through cross-sections against reference data.

The coastline accuracy assessment with cross section indicates that both deep learning models developed from orthophotos and sentinel-2 imagery exhibit competitive performance, each with its own strengths when segmenting the 10 test samples. Orthophoto-based data achieved an average spatial error of 3.32 meters with a standard deviation of 1.38 meters and the highest IoU for the Water class at 86.16%. Meanwhile, sentinel-2 imagery produced an average spatial error of 18.95 meters with a standard deviation of 14.23 meters, and the highest IoU for the Water class at 86.16%. These performance variations reflect the influence of the spatial resolution of the input data on segmentation results, where orthophotos provide more precise coastline delineation, while sentinel-2 models are more effective in broadly representing the water class due to additional spectral channels.

Keywords: shoreline, deep learning, orthophoto, sentinel-2