



JURNAL SEGARA

<http://ejournal-balitbang.kkp.go.id/index.php/segara>

ISSN : 1907-0659

e-ISSN : 2461-1166

Nomor Akreditasi: 766/AU3/P2MI-LIPI/10/2016

ESTIMASI KEDALAMAN PERAIRAN DANGKAL MENGUNAKAN CITRA SATELIT MULTISPEKTRAL SENTINEL-2A

DEPTH ESTIMATION OF SHALLOW WATER USING MULTISPECTRAL SATELLITE IMAGERY SENTINEL-2A

Arip Rahman¹⁾, Vincentius P. Siregar²⁾, & James P. Panjaitan²⁾

¹⁾Mahasiswa Departemen Ilmu dan Teknologi Kelautan,
Fakultas Perikanan dan Ilmu Kelautan Institut Pertanian Bogor

²⁾Staf Pengajar Departemen Ilmu dan Teknologi Kelautan,
Fakultas Perikanan dan Ilmu Kelautan Institut Pertanian Bogor

Diterima: 14 Januari 2020; Diterima Setelah Perbaikan: 5 November 2020; Disetujui Terbit: 9 November 2020

ABSTRAK

Estimasi kedalaman perairan dangkal menggunakan data penginderaan jauh menjadi salah satu alternatif pengukuran kedalaman yang terkendala masalah teknis dan logistik. Ekstraksi kedalaman menggunakan citra Sentinel-2A dilakukan di sekitar perairan Pulau Kemujan Taman Nasional Perairan Karimunjawa Jawa Tengah. Sebanyak 2134 data (1280 data *training* dan 854 data *test*) hasil pemeruman digunakan pada saat analisis. *Dark Object Substraction* (DOS) digunakan pada proses awal pengolahan citra Sentinel 2A untuk menghasilkan citra yang terkoreksi atmosferik. Metode algoritma yang digunakan untuk mengestimasi kedalaman antara lain: *linear transform*, *ratio transform* dan *support vector machine* (SVM). Hasil korelasi antara data prediksi kedalaman dan hasil pemeruman tertinggi dihasilkan dari metode algoritma SVM dengan koefisien determinasi (R^2) 0,71 (data *training*) dan 0,56 (data *test*). Hasil penilaian akurasi menggunakan nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE), metode algoritma SVM memiliki nilai penyimpangan terkecil (< 1 m). Hal tersebut mengindikasikan bahwa metode algoritma SVM memiliki tingkat akurasi yang lebih tinggi dibandingkan dengan kedua metode lainnya.

Kata kunci: Perairan dangkal, penginderaan jauh, karimunjawa, *liner transform*, *ratio transform*, *svm*.

ABSTRACT

Shallow water bathymetry estimation from remote sensing data as an alternative to bathymetry measurement that has disturbed by technical and logistic problem. Deriving bathymetry data from Sentinel 2A images, at visible wavelength (blue, green and red) 10 meter spatial resolution was carried out around the waters of the Kemujan Island Karimunjawa National Park Central Java. Amount of 2134 data (1280 points data are used as training data sets and 854 points data as test data set) produced from sounding. Dark Object Substraction (DOS) has been to correct atmospherically the Sentinel-2A images. Several algorithm has been applied to derive bathymetry data, including: linear transform, ratio transform and support vector machine (SVM). The highest correlation between depth prediction and observe resulted from SVM algorithm with a coefficient of determination (R^2) 0.71 (training data) and 0.56 (test data). The assessment of the accuracy using RMSE and MAE values, the SVM algorithm has the smallest value (< 1 m). This indicates that the SVM algorithm has a high accuracy compared to the other two methods.

Keywords: *Shallow water, remote sensing, karimunjawa, linear transform, ratio transform, support vector machine.*

PENDAHULUAN

Pembaharuan informasi kedalaman perairan pantai semakin diperlukan untuk berbagai keperluan antara lain penelitian, manajemen dan monitoring, serta pemetaan habitat bentik pada perairan dangkal (Chust *et al.*, 2010; Kabiri *et al.*, 2014). Hal tersebut berkaitan dengan kondisi lingkungan pantai yang dinamis. Pemetaan kedalaman menggunakan pemeruman pada perairan dangkal banyak terkendala masalah teknis dan logistik (Brown, *et al.*, 2012). Beberapa perairan dangkal tidak dapat diakses oleh kapal karena terhalang oleh bebatuan, terumbu karang atau perairan yang terlalu dangkal untuk dilalui oleh kapal survey. Lyzenga (1978) pertama kali membangun metode untuk mengestimasi nilai kedalaman menggunakan citra satelit multispektral. Literatur terkini memperlihatkan peningkatan potensi data penginderaan jauh dalam penelitian kedalaman perairan (Doxani *et al.*, 2012; Eugenio *et al.*, 2015). Namun, dalam banyak kasus, metode ini membutuhkan masukan nilai kedalaman yang diketahui (Lyzenga, 1978). Bagaimanapun juga penggunaan sensor satelit pada perairan dangkal sangat kompleks dengan bauran sinyal dari atmosfer, perairan dan dasar perairan (Jerlov, 1976).

Data penginderaan jauh multispektral yang memiliki karakteristik dengan resolusi spasial dan temporal yang tinggi sering digunakan untuk mengestimasi kedalaman perairan dangkal, daerah pantai, *estuary*, sungai dan danau (Gao, 2009). Perairan dangkal menyerap lebih sedikit energi daripada perairan dalam dan oleh karena itu memiliki reflektansi yang tinggi dari radiasi sinar matahari (Pope *et al.*, 2016). Kelebihan penginderaan jauh untuk memperoleh data kedalaman dibandingkan dengan metode pemeruman secara konvensional antara lain ketersediaan data yang luas, cakupan permukaan sinoptik, dan resolusi spasial yang tinggi (Su, *et al.*, 2008). Penginderaan jauh optik dapat memperoleh citra secara periodik namun dibatasi oleh kekeruhan perairan (Sánchez-Carnero, *et al.*, 2014). Deteksi kedalaman perairan dangkal dari citra satelit multispektral telah banyak dilakukan, diantaranya, menggunakan Landsat OLI (Vinayaraj *et al.*, 2016), Sentinel-2 (Hedley *et al.*, 2018), SPOT 4 dan SPOT 5 (Sánchez-Carnero *et al.*, 2014). Di Indonesia sendiri, penentuan kedalaman menggunakan citra satelit banyak digunakan diantaranya, menggunakan SPOT 4 (Arief, 2012), SPOT 6 (Arief *et al.*, 2017), SPOT 7 (Setiawan *et al.*, 2019), Landsat 8 dan Sentinel-2A (Bobsaid & Jaelani, 2017), Worldview-2 (Syaiful *et al.*, 2019).

Analisis regresi kuadrat terkecil digunakan untuk melihat hubungan antara model reflektansi hasil pendekatan empiris dan hasil pengukuran kedalaman

(Leon & Cohen, 2012). Pantulan yang diterima dari panjang gelombang biru dan hijau dapat digunakan untuk menduga kedalaman karena energi dari spektrum antara 400 dan 600 nm memiliki penetrasi yang paling besar kedalam kolom air (Monteys, *et al.*, 2015). Beberapa algoritma telah banyak diterapkan dalam penelitian kedalaman perairan antara lain: *linear transform algorithm* (Lyzenga, 1985), *ratio transform method* (Stumpf *et al.*, 2003) dan *algoritma machine learning* yang digunakan untuk mengestimasi data kedalaman, salah satunya adalah *support vector machines* (SVM) (Misra *et al.*, 2018; Vojinovic *et al.*, 2013)

Penelitian ini bertujuan untuk melihat kemampuan Sentinel 2A untuk mengestimasi nilai kedalaman perairan dangkal di sekitar perairan Pulau Kemujan, Perairan Taman Nasional Karimunjawa Jawa Tengah. Beberapa algoritma yang digunakan dalam penelitian ini antara lain: *linear transform algorithm*, *ratio transform method* dan SVM. Algoritma tersebut digunakan untuk mengestimasi nilai kedalaman pada setiap piksel Citra Sentinel 2A dengan mempertimbangkan kombinasi *Band* dan rasio *Band* (*Band* 2: biru (458-523 nm), *Band* 3: hijau (543-578 nm), dan *Band* 4: merah (650-680 nm), resolusi spasial 10 m).


METODE PENELITIAN

Waktu dan Lokasi Penelitian

Penelitian dilakukan di sekitar perairan Pulau Kemujan, Taman Nasional Perairan Karimunjawa Jawa Tengah (Gambar 1). Taman Nasional Perairan Karimunjawa merupakan kawasan konservasi perairan yang terdiri dari 24 pulau yang pengelolaannya berdasarkan sistem zonasi. Berdasarkan informasi dan pengamatan langsung di lapangan, kondisi perairan di lokasi penelitian relatif tenang selama musim timur karena terlindung oleh pulau dan pada musim barat akan dipengaruhi oleh angin dari barat yang akan langsung berpengaruh pada kondisi perairan disekitar Pulau Kemujan. Komposisi dasar perairan terdiri dari karang hidup, karang mati yang ditumbuhi alga, pecahan karang yang ditutupi alga dan pasir yang sebagian ditutupi dengan alga. Daerah di sekitar lokasi penelitian terdapat pembukaan tambak, pemukiman penduduk dan mangrove yang tumbuh disekitar pinggiran pantai. Kedalaman lokasi penelitian berkisar antara 0-10 m dengan kecerahan *sechi disk* yang relatif rendah sekitar 3,5 m. Perairan disekitar Pulau Kemujan termasuk dalam zona budidaya dan zona pemanfaatan tradisional.

Data Penelitian

Data kedalaman insitu diperoleh dari pemeruman dengan menggunakan *echo-sounder single beam*, GPS Map 527xs, pada 20 Agustus 2019 di perairan



Gambar 1. Lokasi penelitian Pulau Kemujan (batas garis merah pada insert peta Pulau Kemujan) Taman Nasional Karimunjawa, Jawa Tengah.

bagian barat Pulau Kemujan. *Echo-sounder* dipasang pada kapal yang melalui lintasan yang sudah dibuat (*tracking*) untuk memperoleh data kedalaman (Z) dan data posisi geografis (X,Y).

Data satelit penginderaan jauh yang digunakan pada penelitian ini adalah citra satelit multispektral Sentinel-2A (akuisisi 20 Agustus 2019, tutupan awan 0) yang diunduh dari laman *glovis.usgs.gov*. Kanal citra Sentinel-2A yang digunakan dalam proses estimasi kedalaman adalah kanal sinar tampak (*Band 2*: biru, *Band 3*: hijau, *Band 4*: merah, dengan resolusi spasial 10 m).

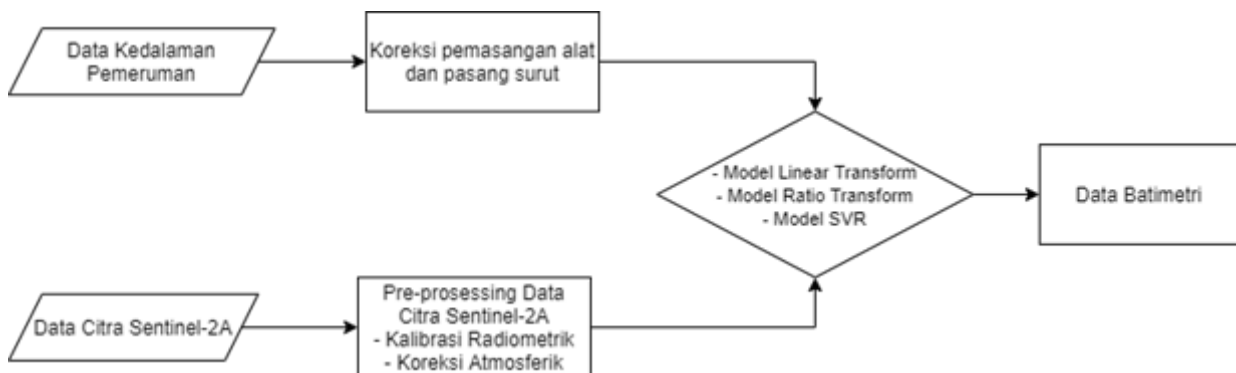
Data kedalaman hasil pemeruman dikoreksi terhadap posisi pemasangan alat pada kapal dan pasang surut. Data pasang surut yang digunakan untuk koreksi diperoleh dari Badan Informasi

Geospasial pada bulan Agustus 2019 (31 hari). Data kedalaman hasil pemeruman dikoreksi terhadap rata-rata muka air laut rendah terendah (LLWL, *Lowest Low Water Level*). Kalibrasi radiometrik dan koreksi atmosferik dilakukan terhadap citra Sentinel-2A sebelum proses analisis lebih lanjut. Alur pemrosesan data dijelaskan pada Gambar 2.

Metode

Kalibrasi radiometrik

Kalibrasi radiometrik dilakukan untuk mengkonversi nilai digital numbers (DN) pada data citra Sentinel-2A menjadi nilai reflektan *Top of Atmospheric* (TOA). Konversi ini memperhitungkan spektrum matahari *extra-terrestrial* (ES) yang setara, arah sinar matahari yang datang ditentukan oleh sudut zenith (θ_s) untuk setiap piksel pada gambar dan kalibrasi absolut (Ak) instrumen MSI. Kalibrasi



Gambar 2. Alur pemrosesan data.

radiometrik untuk citra satelit dilakukan dengan menggunakan metode yang terdapat pada perangkat lunak *Quantum GIS* (QGIS).

Koreksi atmosferik

Dark Object Substraction (DOS) merupakan metode empiris koreksi atmosfer untuk citra satelit yang terdapat dalam *Quantum GIS* (QGIS) yang mana mengasumsikan bahwa reflektansi dari objek-objek gelap termasuk komponen substansial dari hamburan atmosfer. DOS mencari setiap band untuk nilai piksel yang paling gelap. Hamburan dihilangkan dengan mengurangi nilai dari setiap piksel yang terdapat dalam *band*.

Penerapan algoritma untuk mendapatkan data kedalaman dari citra satelit

Linear transform algoritma

Kesalahan yang disebabkan oleh perbedaan tipe dasar perairan dapat dikoreksi dengan menggunakan dua band yang tersedia bahwa rasio refleksi dasar perairan antara dua band untuk semua tipe dasar perairan adalah konstan. Model yang digunakan (Lyzenga, 1985):

$$Z = a_0 + a_i X_i + a_j X_j \dots\dots\dots 1)$$

dimana,

Z = kedalaman;

a_0, a_i, a_j = koefisien yang ditentukan melalui *multiple regression*

X_i = $\ln(R_{ac}, i)$

X_j = $\ln(R_{ac}, j)$

(R_{ac}, i dan R_{ac}, j adalah nilai reflektansi band i dan j yang sudah dikoreksi)

Ratio transform method

Stumpf *et al.* (2003) menemukan metode rasio *transform* untuk mengestimasi kedalaman perairan dangkal. Model ini secara prinsip berdasarkan pada konsep bahwa cahaya mengalami pelemahan secara eksponensial terhadap kedalaman perairan dan mengusulkan bahwa pengaruh dari albedo substrat dapat diperkecil menggunakan dua band untuk mendapatkan nilai kedalaman. Berdasarkan model ini, spektral band yang berbeda mengalami pelemahan pada tingkat yang berbeda, dan oleh karena itu rasio antara dua spektral band akan bervariasi dengan kedalaman. Secara matematis model dapat diekspresikan sebagai berikut:

$$Z = m_1 \frac{\ln(nR_w(\lambda_i))}{\ln(nR_w(\lambda_j))} - m_0 \dots\dots\dots 2)$$

dimana z merupakan nilai kedalaman yang dicari, m_0 dan m_1 diperoleh dari persamaan regresi antara data kedalaman insitu perairan dengan rasio nilai reflektansi

($\ln R_w$) dari band i (λ_i) dan band j (λ_j).

Support Vector Machines

Dalam prakteknya hubungan antara rasio dan kedalaman perairan tidak selalu linear. Oleh karena itu, hal ini menjadi peluang dengan mengeksplorasi fungsi (f) nonlinear untuk memetakan kedalaman perairan.

$$Z = f \left(\frac{\ln(nR_w(\lambda_i))}{\ln(nR_w(\lambda_j))} \right) \dots\dots\dots 3)$$

Dalam penelitian ini mencoba menerapkan fungsi tersebut dengan menggunakan *machine learning Support Vector Machines* (Vojinovic *et al.*, 2013). Algoritma *machine learning* digunakan untuk mengestimasi data yang tidak diketahui dengan penerapan sistem *input* dan *output* menggunakan data yang tersedia. Persamaan regresi secara umum yang digunakan dalam SVM ditunjukkan dengan persamaan 4.

$$E = \sum_{i=1}^p L_{si} + \lambda \|Pf\|^2 = \sum_{i=1}^p L_{si} + \Omega(h, I) \dots\dots\dots 4)$$

Pada persamaan 4 terdapat dua terminologi, yang pertama meminimalkan *empirical risk* dan terminologi ke dua untuk menghaluskan fungsi (Vapnik, 1998). Dimana:

E = umumnya mengacu dalam literatur sebagai fungsi *cost* atau *generalization error* untuk mengukur performa suatu model, *goodness of fit*;

L_{si} = menunjukkan kedekatan data, yaitu jumlah perbedaan pengukuran dan output model yang dihitung dalam fase pelatihan (*training phase*);

ρ = mengacu pada besarnya pengukuran atau *training data*;

Pf = menunjukkan kapasitas dari SVM, yaitu mengontrol parameter untuk meminimalkan E;

Ω = fungsi VC (*Vapnik and Chervon*) disebut juga sebagai selang kepercayaan atau interval kepercayaan dan berhubungan dengan kehalusan perkiraan;

λ = menunjukkan parameter regulasi;

h = dimensi VC

I = menunjukkan jumlah dari support vektor.

Training vektor dipetakan kedalam ruang dimensi yang lebih tinggi dengan menggunakan fungsi *kernel* nonlinear. Fungsi *kernel* adalah mengambil data sebagai input dan mengubahnya kedalam bentuk yang diperlukan. Beberapa fungsi *kernel* yang dapat diaplikasikan dalam model SVM antara lain: *liner function, polynomial function, radial basis function* (RBF) atau *sigmoid function*. Kernel RBF digunakan dalam penelitian ini karena dianggap memiliki sifat generalisasi yang baik dibandingkan *kernel* yang

lainnya (Girosi & Poggio, 1990). Persamaan *Kernel RBF* yang digunakan adalah:

$$K(x_i, x_j) = \exp(-\varphi \|x_i - x_j\|^2), \varphi > 0 \dots\dots\dots 5)$$

dimana (φ = adalah fungsi *Gaussian*, x_i, x_j = fitur vektor)

Setelah penentuan fungsi kernel yang digunakan, selanjutnya menentukan parameter C, γ dan ϵ terbaik yang akan digunakan pada model SVM dengan menggunakan perangkat lunak R (package 'e1071'). Parameter C berpengaruh terhadap nilai penalti yang diberikan pada data set. Nilai C yang rendah menunjukkan toleransi kesalahan prediksi rendah dan sebaliknya. Parameter γ berpengaruh terhadap pengaturan kecepatan proses learning. Semakin tinggi nilai γ , proses learning akan semakin cepat. Parameter ϵ menurunkan jumlah hasil *support vector* dalam kompresi data. Peningkatan nilai ϵ memiliki efek menghaluskan pada data *noise* yang dapat mengurangi tingkat akurasi (Vojinovic *et al.*, 2013).

Analisis Statistik

Perbandingan akurasi dari tiga algoritma tersebut dilihat dari beberapa parameter, antara lain:

$$RMSE(Z_{sat}, Z_{echo}) = \sqrt{Var_{sat} + (Bias(Z_{sat}, Z_{echo}))^2} \dots 6)$$

$$MAE(Z_{sat}, Z_{echo}) = \frac{1}{N} \sum_{i=1}^N |Z_{sat} - Z_{echo}| \dots\dots\dots 7)$$

$$MAPE(Z_{sat}, Z_{echo}) = \left(\frac{1}{n} \sum \left(\frac{|Z_{echo} - Z_{sat}|}{Z_{echo}} \right) \right) \times 100 \dots\dots\dots 8)$$

dimana N adalah jumlah dari observasi


RMSE mengukur seberapa besar kesalahan yang terjadi diantara dua set data, yang membandingkan nilai prediksi dan nilai observasi yang diketahui. Semakin kecil nilai RMSE semakin dekat antara nilai prediksi dan nilai observasi. MAE mengukur seberapa jauh nilai prediksi dari nilai observasi yang diketahui. Sedangkan MAPE merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui persentase penyimpangan hasil prediksi.

HASIL DAN PEMBAHASAN

Field observations

Data kedalaman yang diperoleh dari hasil pemeruman (observasi) mewakili piksel dari citra satelit yang akan digunakan dalam penentuan data *training* dan *data test* dalam perhitungan algoritma. Gambar 2 memperlihatkan distribusi data observasi yang di overlay dengan piksel dari citra Sentinel 2A pada saluran sinar tampak (10x10 m).


Data yang dihasilkan pada saat observasi sebanyak 2.823 data. Setelah dilakukan pemrosesan dengan menghilangkan *noise*, diperoleh sebanyak 2134 data dengan kedalaman berkisar 0,5-10,6 m. Frekuensi kedalaman yang tercatat banyak berada pada kisaran 2-4 meter (Gambar 3) dengan dasar perairan pasir, karang, pecahan karang yang sebagian ditutupi alga. Pada bagian tengah lokasi penelitian, diantara pantai dan terumbu karang, terdapat daerah dengan kedalaman 5-7 m yang digunakan sebagai daerah budidaya rumput laut oleh nelayan setempat. Sedangkan daerah dengan kedalaman > 10 m berada pada daerah tubir karang sampai ke lautan lepas. Pembagian untuk data *training* dan *test* digunakan



Gambar 3. Overlay data observasi dengan piksel citra Sentinel 2A.

Tabel 1. Statistik data *training* dan *test*

Data	Jumlah	Kedalaman Minimum (m)	Kedalaman Maksimum (m)	Kedalaman Rata-Rata (m)
<i>Training</i>	1.280	0,5	10,6	2,8
<i>Test</i>	854	0,6	7	2.1



Gambar 4. Histogram kedalaman observasi.

perbandingan 60 dan 40% (Vojinovic *et al.*, 2013). Sehingga diperoleh *data training* 1.280 (60%) dan *data test* 854 (40%) (Tabel. 1).

diperoleh koefisien regresi $a_0=7,791$, $a_1=14,883$ dan $a_2=-12,646$, sehingga diperoleh persamaan model *linear transform*:

Penerapan algoritma untuk mendapatkan data kedalaman dari citra satelit

$$Z = 7,79 + 14,88X_i - 12,64X_j \dots\dots\dots 9)$$

Pemilihan kombinasi *band* terbaik untuk penerapan model linear dan *ratio transform* telah dilakukan dengan melihat hubungan antara nilai reflektansi kombinasi Band biru (B2), Band hijau (B3) dan Band merah (B4) dengan data training. Hasil regresi kombinasi antara ln B2 dan ln B3 dengan data training memiliki korelasi tertinggi untuk kedua metode yang digunakan Tabel 2. Hal tersebut sesuai dengan pernyataan bahwa radiasi 0,48 μm (B2) sampai 0,60 μm (B3) dapat menembus perairan yang jernih dan tenang sekitar 15-20 m (Gao, 2009) dengan deteksi terbaik pada kedalaman sekitar 10 m (Bagheri, *et al.*, 1998).

dimana, Z= nilai kedalaman prediksi (m), X_i = nilai reflektansi ln band i (biru), X_j = nilai reflektansi ln band j (hijau)

Sedangkan hasil regresi linear untuk model *ratio transform* diperoleh nilai $m_0=29,54$ dan $m_1=-27,58$ sehingga diperoleh persamaan model *ratio transform*:

$$Z = -27,58X + 29,54 \dots\dots\dots 10)$$

(X= ratio ln B2/ln B3)

Hasil *multiregresi* untuk model *linear transform*

Hasil persamaan model tersebut diatas digunakan untuk memprediksi kedalaman baik pada

Tabel 2. Koefisien korelasi (r) dan determinasi (R^2) hasil regresi antara kombinasi band (B2, B3 dan B4) dengan kedalaman observasi

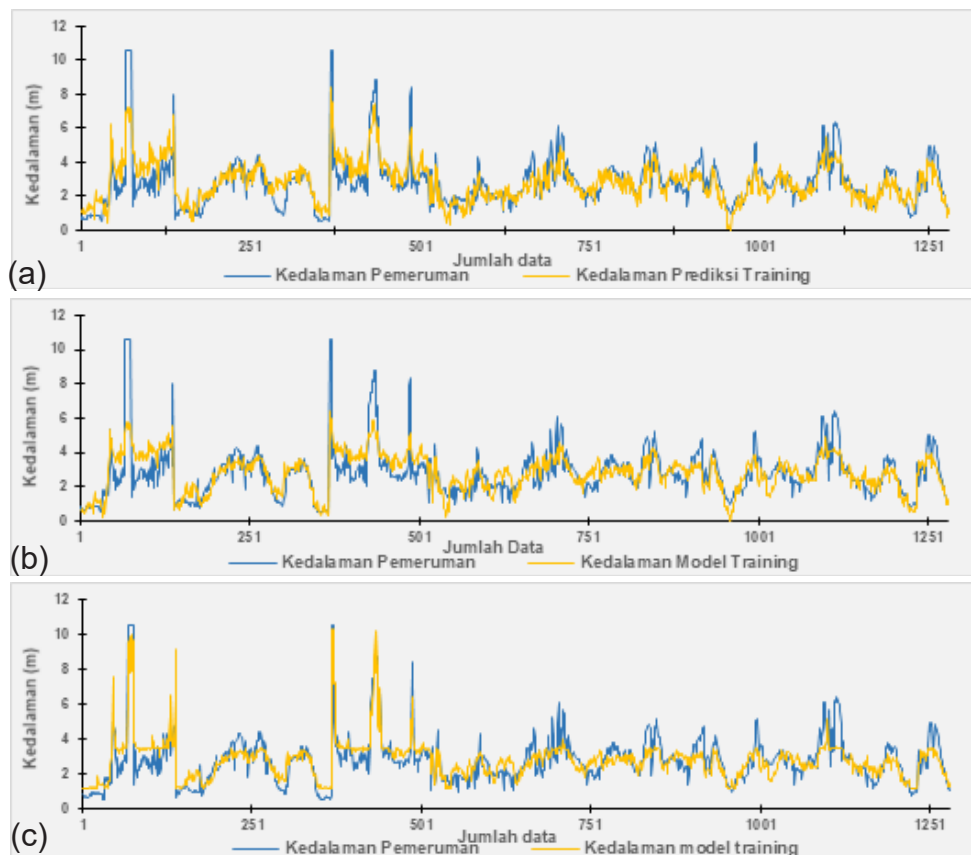
Kombinasi Band	Linear Transform		Ratio Transform	
	r	R^2	r	R^2
ln B2, ln B3	0,80	0,64	0,75	0,57
ln B2, ln B4	0,58	0,34	0,08	0,006
ln B3, ln B4	0,60	0,35	0,39	0,15

data *training* maupun *test*. Persamaan model SVM diperoleh dengan menggunakan perangkat lunak R (package 'e1071') dengan input data ratio B2/B3 dengan data training. Setelah ditentukan kernel RBF yang digunakan untuk aplikasi SVM, selanjutnya ditentukan nilai parameter C dan ϵ terbaik sedangkan untuk γ , nilainya dibuat otomatis. Hasil tuning dengan menggunakan perangkat lunak R, diperoleh nilai parameter C dan ϵ terbaik, yaitu 4 dan 0,5 yang akan digunakan dalam aplikasi SVM. Jumlah *support vector* yang diperoleh pada fase training sebanyak 378 data (29,53% dari *training data set*). *Support vector* dalam SVM adalah data training yang terletak pada dan diluar batas dari fungsi keputusan.

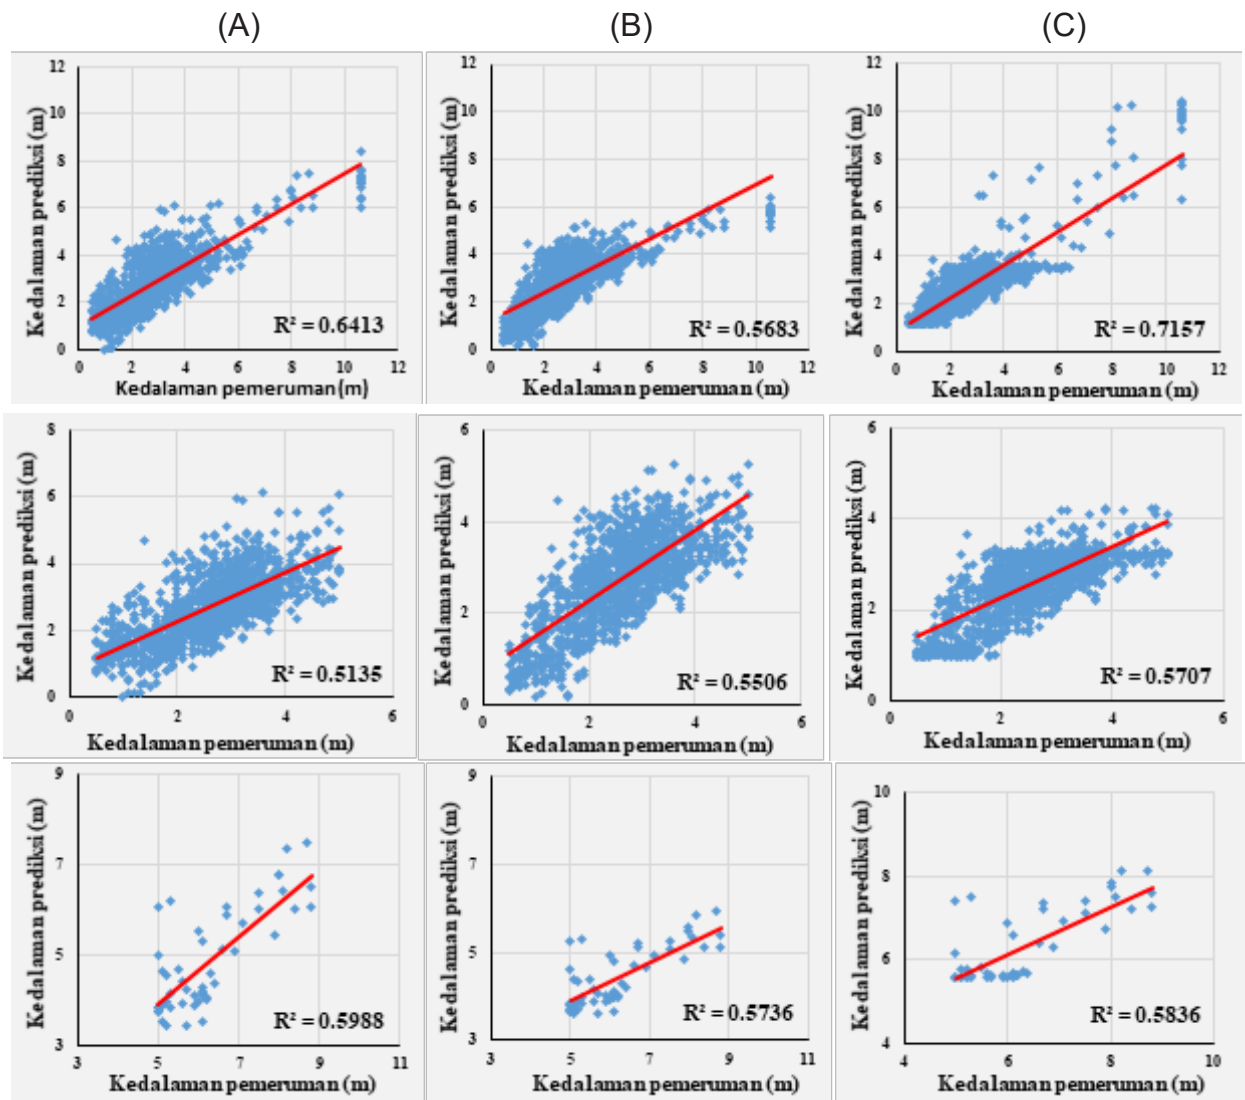
Hasil tampilan antara data observasi dan prediksi (data *training*) disajikan pada Gambar 4 yang memperlihatkan adanya penyimpangan data kedalaman prediksi terhadap data observasi. Persentase penyimpangan antara data prediksi dan observasi, berdasarkan perhitungan MAPE, model linear transform (28,49%), model *ratio transform* (26,03%) sedangkan untuk model SVR (25,09%). Nilai persentase kesalahan model SVR lebih kecil dibandingkan dengan kedua model yang lainnya. Hal tersebut menunjukkan bahwa model SVR memiliki hasil prediksi yang lebih baik dibandingkan dengan

kedua model lainnya. Pada perairan yang jernih dan sangat dangkal dengan kondisi transparansi yang bagus, perbandingan akurasi dengan data hidrografik memperlihatkan rata-rata kesalahan sekitar 10-30% (McIntyre *et al*, 2006), dengan kedalaman efektif maksimum antara 8-10 m (Lafon *et al.*, 2002). Berdasarkan pengamatan pada saat pengambilan data observasi, kecerahan di sekitar perairan Pulau Kemujan berdasarkan pengukuran *sechi disk* cukup rendah sekitar 3,5 m. Hal tersebut diduga menjadi penyebab tingginya persentase kesalahan antara data prediksi dengan data observasi. Pada kondisi kekeruhan yang tinggi, faktor pelemahan pada kolom air menjadi sumber kesalahan yang paling besar dibandingkan dengan faktor atmosfer (Densham, 2005).

Berdasarkan pengamatan pada Gambar 4, setiap model yang digunakan memperlihatkan hasil prediksi yang lebih baik pada kedalaman 5-10 m, Hal tersebut terlihat dengan hampir berhimpitnya garis data prediksi dan observasi. Korelasi antara data prediksi dan pemeruman untuk data training disajikan pada *Scatter plot* Gambar 5. Sedangkan hasil lengkap perhitungan akurasi data training dan test setiap model pada setiap fase kedalaman disajikan pada Tabel 3. Pembagian fase kedalaman pada perhitungan akurasi



Gambar 5. Hasil tampilan data pemeruman (observasi) dan prediksi model (prediksi) *data training*, (a) model *linear transform*, (b) model *ratio transform*, (c) model SVR.



Gambar 6. Scatter plot data prediksi dan observasi untuk data training, (A) model linear, (B) model ratio, (C) model SVM.

Tabel 3. Hasil perhitungan akurasi setiap model berdasarkan pembagian kedalaman

Model	Kedalaman	Fase Training			Fase Test		
		R2	RMSE (m)	MAE (m)	R2	RMSE (m)	MAE (m)
Linear Transform	Semua data	0,64	1,15	0,64	0,55	1,06	0,59
	0-5 m	0,51	0,98	0,58	0,5	0,99	0,59
	5-10 m	0,59	1,78	1,47	0,81	1,64	1,14
Ratio Transform	Semua data	0,56	0,67	0,67	0,55	1,08	0,62
	0-5 m	0,55	1,01	0,57	0,52	1,05	0,61
	5-10 m	0,57	1,93	1,82	0,82	1,52	1,24
SVM	Semua data	0,71	0,5	0,58	0,56	0,96	0,57
	0-5 m	0,57	0,72	0,5	0,53	0,79	0,54
	5-10 m	0,58	0,85	0,57	0,73	1,23	0,71

berdasarkan hasil tampilan pada Gambar 4, yaitu fase kedalaman 0-5 m dan 5-10 m.

Hasil perhitungan nilai akurasi pada fase training dan test yang disajikan pada Tabel 3 memperlihatkan

bahwa akurasi pada fase kedalaman 5-10 m lebih baik dibandingkan dengan 0-5 m terutama untuk model SVR. Hal tersebut sesuai dengan hasil kajian Vojinovic *et al.* (2013) yang menggunakan model SVM untuk memprediksi kedalaman, memperlihatkan nilai

akurasi yang berbeda berdasarkan kedalaman. Model SVM memiliki nilai RMSE dan MAE yang relatif kecil dibandingkan dengan kedua model lainnya yaitu < 1 m kecuali pada fase test 5-10 m nilai RMSE nya 1,23 m. Model yang memiliki nilai RMSE dan MAE yang lebih kecil dibandingkan dengan model lainnya dikatakan memiliki tingkat akurasi yang lebih tinggi. Perbedaan nilai akurasi setiap kedalaman yang terjadi di lokasi penelitian diduga disebabkan oleh kondisi habitat benthik dasar perairan yang berbeda yang menyebabkan perbedaan nilai reflektansi

KESIMPULAN

Estimasi kedalaman perairan disekitar Pulau Kemujan dilakukan berdasarkan data citra satelit multispectral Sentinel-2A dan data observasi menggunakan *echo sounder single beam* dengan menggunakan algoritma *linear transform*, *ratio transform* dan SVM. Setiap persamaan model menghasilkan perhitungan persentase kesalahan yang berbeda-beda. Hasil tampilan data observasi dan prediksi untuk model SVM memiliki nilai persentase kesalahan yang lebih kecil dibandingkan dengan kedua model lainnya. Model SVM dapat memprediksi kedalaman lebih baik dibandingkan dengan kedua model yang lainnya dengan nilai koefisien determinasi yang lebih tinggi dari kedua model lainnya baik untuk *data training* maupun *test*. Berdasarkan nilai RMSE dan MAE, model SVM memiliki nilai kesalahan yang lebih kecil dibandingkan dengan kedua model lainnya yaitu < 1 m, yang mengindikasikan model SVM memiliki akurasi yang lebih baik. Berdasarkan hasil tersebut diatas, menunjukkan bahwa data citra Sentinel-2A dengan metode algoritma SVM dapat menjadi salah satu alternatif untuk mengestimasi kedalaman pada perairan dangkal.

PERSANTUNAN

Ucapan terima kasih penulis sampaikan kepada Balai Riset Pemulihan Sumberdaya Ikan (BRPSDI) KKP tempat penulis bekerja yang telah menyediakan peralatan survey yang digunakan penulis pada saat penelitian, kepada Pusat Pendidikan (PUSDIK) KKP yang telah memberikan pendanaan untuk tugas belajar penulis, Kepada Program Pascasarjana IPB Program Studi Teknologi Kelautan tempat penulis menimba ilmu atas segala bimbingan dan ilmu yang telah diberikan. Kontributor utama dalam tulisan ini adalah Arip Rahman dan Vincentius P. Siregar.

DAFTAR PUSTAKA

Arief, M. (2012). Pendekatan Baru Pemetaan Bathimetric Menggunakan Data Penginderaan Jauh SPOT Studi Kasus: Teluk Perigi dan Teluk

Popoh. *Jurnal Teknologi Dirgantara*, 10(1), 71–80.

Arief, M., Adawiah, S.W., Parwati, E., & Marpaung, S. (2017). Metode Dual Kanal Untuk Estimasi Kedalaman Di Perairan Dangkal Menggunakan Data Spot 6 Studi Kasus : Teluk Lampung (Dual Band Method for Bathymetry Estimation in Shallow Waters Depth Using Spot 6 Data Case Study: Lampung Bay). *Jurnal Penginderaan Jauh Dan Pengolahan Data Citra Digital*, 14(1), 37–50. <https://doi.org/10.30536/j.pjpdcd.2017.v14.a2618>

Bagheri, S., Stein, M., & Dios, R. (1998). Utility of hyperspectral data for bathymetric mapping in a turbid estuary. *International Journal of Remote Sensing*, 19(6), 1179-1188. <https://doi.org/10.1080/014311698215676>

Bobsaid, M.W., & Jaelani, L.M. (2017). Studi Pemetaan Batimetri Perairan Dangkal Menggunakan Citra Satelit Landsat 8 dan Sentinel-2A. *Jurnal Teknik ITS*, 6(2), 564-569.

Brown, C.J., Sameoto, J.A., & Smith, S.J. (2012). Multiple methods, maps, and management applications: Purpose made seafloor maps in support of ocean management. *Journal of Sea Research*. <https://doi.org/10.1016/j.seares.2012.04.009>

Chust, G., Grande, M., Galparsoro, I., Uriarte, A., & Borja, Á. (2010). Capabilities of the bathymetric Hawk Eye LiDAR for coastal habitat mapping: A case study within a Basque estuary. *Estuarine, Coastal and Shelf Science*, 89(3), 200-213. <https://doi.org/10.1016/j.ecss.2010.07.002>

Densham, M. (2005). "Bathymetric Mapping with Quickbird Data." *PhD diss.* Naval Postgraduated School.

Dixon, T.H., Naraghi, M., McNutt, M.K., & Smith, S.M. (1983). Bathymetric Prediction From SEASAT Altimeter Data by poorly atmospheric • Now at Department of Earth Science , Massachusetts. *Journal of Geophysical Research*, 88, 1563-1571.

Doxani, G., Papadopoulou, M., Lafazani, P., Pikridas, C., & Tsakiri-Strati, M. (2012). Shallow-Water Bathymetry Over Variable Bottom Types Using Multispectral Worldview-2 Image. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIX-B8(September), 159-164. <https://doi.org/10.5194/isprsarchives-xxxix-b8-159-2012>

Eugenio, F., Marcello, J., & Martin, J. (2015). High-Resolution Maps of Bathymetry and Benthic Habitats in Shallow-Water Environments Using

- Multispectral Remote Sensing Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7). <https://doi.org/10.1109/TGRS.2014.2377300>
- Gao, J. (2009). Bathymetric mapping by means of remotesensing: Methods, accuracy and limitations. *Progress in Physical Geography*, 33(1), 103-116. <https://doi.org/10.1177/0309133309105657>
- Girosi, F., & Poggio, T. (1990). Networks and the best approximation property. *Biological Cybernetics*, 63(3), 169-176. <https://doi.org/10.1007/BF00195855>
- Hedley, J.D., Roelfsema, C., Brando, V., Giardino, C., Kutser, T., Phinn, S., ... Koetz, B. (2018). Coral reef applications of Sentinel-2: Coverage, characteristics, bathymetry and benthic mapping with comparison to Landsat 8. *Remote Sensing of Environment*, 216, 598-614. <https://doi.org/10.1016/j.rse.2018.07.014>
- Jerlov, N.G. (1976). *Marine Optics*. Elsevier.
- Kabiri, K., Rezai, H., Moradi, M., & Pourjomeh, F. (2014). Coral reefs mapping using parasailing aerial photography- feasibility study: Kish Island, Persian Gulf. *Journal of Coastal Conservation*, 18(6), 691-699. <https://doi.org/10.1007/s11852-014-0345-9>
- Lafon, V., Froidefond, J.M., Lahet, F., & Castaing, P. (2002). SPOT shallow water bathymetry of a moderately turbid tidal inlet based on field measurements. *Remote Sensing of Environment*, 81(1), 136-148. [https://doi.org/10.1016/S0034-4257\(01\)00340-6](https://doi.org/10.1016/S0034-4257(01)00340-6)
- Leon, J.X., & Cohen, T.J. (2012). An improved bathymetric model for the modern and palaeo Lake Eyre. *Geomorphology*, 173-174, 69-79. <https://doi.org/10.1016/j.geomorph.2012.05.029>
- Lyzenga, D.R. (1978). Passive remote sensing techniques for mapping water depth and bottom features. *Applied Optics*, 17(3), 379. <https://doi.org/10.1364/ao.17.000379>
- Lyzenga, D. R. (1985). International Journal of Remote Sensing Shallow-water bathymetry using combined lidar and passive multispectral scanner data. *International Journal of Remote Sensing*, 6(1), 115-125.
- McIntyre, M. L., Naar, D. F., Carder, K. L., Donahue, B. T., & Mallinson, D. J. (2006). Coastal Bathymetry from Hyperspectral Remote Sensing Data: Comparisons with High Resolution Multibeam Bathymetry. *Marine Geophysical Researches*, 27(2), 129-136. <https://doi.org/10.1007/s11001-005-0266-y>
- Misra, A., Vojinovic, Z., Ramakrishnan, B., Luijendijk, A., & Ranasinghe, R. (2018). Shallow water bathymetry mapping using Support Vector Machine (SVM) technique and multispectral imagery. *International Journal of Remote Sensing*, 39(13). <https://doi.org/10.1080/01431161.2017.1421796>
- Monteys, X., Harris, P., Caloca, S., & Cahalane, C. (2015). Spatial prediction of coastal bathymetry based on multispectral satellite imagery and multibeam data. *Remote Sensing*, 7(10), 13782-13806. <https://doi.org/10.3390/rs71013782>
- Pope, A., Scambos, T.A., Moussavi, M., Tedesco, M., Willis, M., Shean, D., & Grigsby, S. (2016). Estimating supraglacial lake depth in West Greenland using Landsat 8 and comparison with other multispectral methods. *Cryosphere*, 10(1), 15-27. <https://doi.org/10.5194/tc-10-15-2016>
- Sánchez-Carnero, N., Ojeda-Zujar, J., Rodríguez-Pérez, D., & Marquez-Perez, J. (2014). Assessment of different models for bathymetry calculation using SPOT multispectral images in a high-turbidity area: The mouth of the Guadiana Estuary. *International Journal of Remote Sensing*, 35(2), 493-514. <https://doi.org/10.1080/01431161.2013.871402>
- Setiawan, K. T., Dwi, M., Manessa, M., Winarso, G., & Anggraini, N. (2019). Estimasi Batimetri dari Data SPOT 7 Studi Kasus Perairan Gili Matra Nusa Tenggara Barat. *Jurnal Penginderaan Jauh Dan Pengolahan Data Citra Digital*, 15(2), 69-82.
- Stumpf, R.P., Holderied, K., Spring, S., & Sinclair, M. (2003). Determination of water depth with high-resolution satellite imagery over variable bottom types, 48, 547-556.
- Su, H., Liu, H., & Heyman, W. (2008). Automated derivation of bathymetric information from multi-spectral satellite imagery using a non-linear inversion model. *In Marine Geodesy*, 31, pp. 281-298. <https://doi.org/10.1080/01490410802466652>
- Syaiful, S.N., Helmi, M., Widada, S., Widiaratih, R., Subhardjo, P., & Suryoputro, A. (2019). Analisis Digital Citra Satelit Worldview-2 untuk Ekstraksi Kedalaman Perairan Laut di. *Indonesian Journal of Oceanography*, 01, 6-11.
- Vapnik, V.N. (1998). *Statistical Learning Theory (Vol. 3)*.

New York: Wiley.

- Vinayaraj, P., Raghavan, V., & Masumoto, S. (2016). Satellite-Derived Bathymetry using Adaptive Geographically Weighted Regression Model. *Marine Geodesy*, 39(6), 458-478. <https://doi.org/10.1080/01490419.2016.1245227>
- Vojinovic, Z., Abebe, Y. A., Ranasinghe, R., Vacher, A., Martens, P., Mandl, D. J., ...De Zeeuw, R. (2013). A machine learning approach for estimation of shallow water depths from optical satellite images and sonar measurements. *Journal of Hydroinformatics*, 15(4), 1408-1424. <https://doi.org/10.2166/hydro.2013.234>

