

Klasifikasi Gelembung Gas Menggunakan Multibeam Echosounder dan Machine Learning

Mochamad Rafif Rabbani¹, Henry Munandar Manik^{2*}, Totok Hestirianoto²

¹Program Studi Magister Teknologi Kelautan, Fakultas Perikanan dan Ilmu Kelautan, Institut Pertanian Bogor

²Departemen Ilmu dan Teknologi Kelautan, Fakultas Perikanan dan Ilmu Kelautan, Institut Pertanian Bogor
Jl. Raya Dramaga Bogor Jawa Barat, 16680 Indonesia
Email: henrymanik@apps.ipb.ac.id

Abstract

Gas Bubble Classification Using Multibeam Echosounder and Machine Learning

The urgency of detecting gas bubbles in the water column is crucial in various fields, ranging from environmental monitoring to detecting underwater gas leaks. One method that can be used to detect gas bubbles is the Multibeam Echosounder. However, processing Multibeam Echosounder data is prone to human error and inefficient in terms of time, necessitating a more practical approach, such as utilizing Artificial Intelligence, specifically Machine Learning. This study aims to classify gas bubbles using Multibeam Echosounder and Machine Learning and determine the best algorithm. The acquired acoustic data were first processed using FMMidwater Fledermaus software for feature extraction and depth analysis in the water column, followed by target tagging on the echogram as a visual labeling process for Machine Learning model input. Three algorithms were tested: Random Forest, K-Nearest Neighbor, and Support Vector Machine. Model evaluation was conducted using a confusion matrix to generate accuracy, F1-score, and kappa coefficient values. The evaluation results showed that the Random Forest algorithm achieved the highest accuracy of 89.02%, followed by Support Vector Machine with 86.76% and K-Nearest Neighbor with 85.41%. These findings demonstrate that the Machine Learning approach effectively classifies gas bubbles in the water column and distinguishes them from other objects in the water column.

Keyword: Multibeam Echosounder, Machine Learning, Confusion Matrix, Karangantu

Abstrak

Kepentingan pendeteksian gelembung gas di kolom air menjadi urgensi dalam berbagai bidang, misalnya dalam pemantauan lingkungan hingga deteksi kebocoran gas bawah laut. Salah satu metode yang dapat digunakan dalam mendeteksi gelembung gas adalah dengan menggunakan Multibeam Echosounder. Namun, pengolahan data Multibeam Echosounder rawan terjadi *human error* dan tidak cukup efisien dalam skala waktu, sehingga diperlukan metode praktis dalam pengolahan data Multibeam, salah satunya adalah dengan menggunakan bantuan Artificial Intelligence, yaitu Machine Learning. Penelitian ini bertujuan untuk mengklasifikasikan gelembung gas dengan menggunakan Multibeam Echosounder dan Machine Learning, serta menentukan algoritma terbaik. Data akustik yang telah diakusisi diolah terlebih dahulu dengan bantuan perangkat lunak FMMidwater Fledermaus untuk ekstraksi fitur dan kedalaman objek di kolom air, serta proses *tagging* target pada echogram sebagai proses pelabelan secara visual untuk input pada model Machine Learning. Terdapat tiga algoritma yang diuji, yaitu Random Forest, K-Nearest Neighbor dan Support Vector Machine. Evaluasi model menggunakan *confusion matrix* untuk menghasilkan nilai akurasi, F1-Score dan koefisien kappa. Evaluasi performa model menunjukkan algoritma Random Forest memiliki nilai akurasi tertinggi yaitu 89.02 % diikuti oleh Support Vector Machine dengan akurasi 86.76% dan K-Nearest Neighbor dengan akurasi 85.41%. Hasil ini membuktikan bahwa pendekatan Machine Learning mampu mengklasifikasikan gelembung gas di kolom air serta dapat membedakannya terhadap objek lain di kolom air

Kata kunci: Multibeam Echosounder, Machine Learning, Matrix Confusion, Karangantu

PENDAHULUAN

Gelembung gas merupakan sebuah fenomena terperangkapnya gas-gas di dalam kolom air yang terbentuk akibat proses-proses baik akibat proses fisika seperti gelombang pecah hingga aktivitas vulkanik yang terjadi di dasar perairan (Merey and Longinos, 2018; Spain *et al.*, 2021). Namun, gelembung gas juga dapat terbentuk sebagai akibat adanya indikasi kebocoran gas pada pipa bawah laut (Wang *et al.*, 2024 ; Nadimi *et al.*, 2021). Sifat dari gelembung gas yang memiliki massa jenis yang lebih rendah dalam beberapa kasus mampu menenggelamkan benda yang terapung seperti kapal (Fang *et al.*, 2022). Oleh karena itu, penelitian terkait pendeteksian gelembung gas di kolom air memiliki potensi yang tinggi. Salah satu metode yang dapat digunakan dalam mendeteksi objek bawah laut adalah dengan menggunakan *Echosounder* (Meng *et al.*, 2021).

Echosounder bekerja dengan memanfaatkan gelombang suara yang dipancarkan oleh *transmitter*, kemudian menerima pantulan balik dari objek yang ada di kolom air melalui *transmitter* (Manik & Dwinovantyo, 2018). *Echosounder* yang paling umum digunakan adalah *Singlebeam Echosounder* dan *Multibeam Echosounder*, keduanya dibedakan berdasarkan jumlah beam yang dipancarkan. *Multibeam Echosounder* memancarkan beam dalam jumlah yang sangat banyak dibandingkan dengan *Singlebeam Echosounder* yang hanya memancarkan satu beam. Jumlah beam yang banyak dari *Multibeam Echosounder* ini memungkinkan survey lebih efektif dan efisien dalam segi biaya dan waktu (Nugroho *et al.*, 2022). Selain itu, *Multibeam Echosounder* mampu memberikan gambaran objek di kolom air yang baik dengan *Water Column Imaging*, sehingga sangat sesuai untuk pendeteksian gelembung gas (Meng *et al.*, 2022).

Pendeteksian gelembung gas di kolom air dengan menggunakan *Multibeam Echosounder* menjadi salah satu topik penelitian yang berkembang pesat (Xu *et al.*, 2020). Namun, pendeteksian gelembung gas masih menggunakan tenaga manusia dalam melakukan pengolahan, sehingga meningkatkan risiko terjadinya *human error*, sehingga diperlukan pendekatan baru dalam pendeteksian dan pengklasifikasian gelembung gas di kolom air. Salah satu pendekatan yang dapat diterapkan adalah dengan menggunakan *Machine Learning* (Minelli *et al.*, 2021).

Machine Learning merupakan cabang dari *Artificial Intelligence* (AI) yang menggunakan pendekatan statistika dan matematis terhadap pola dari suatu data (Rebala *et al.*, 2019). Terdapat beberapa metode pembelajaran yang digunakan dalam *Machine Learning*, diantaranya *Supervised Learning*, dan *Unsupervised Learning*, keduanya dibedakan berdasarkan penggunaan label pada data (Goodfellow *et al.*, 2016). Pada *Supervised Learning*, data telah dilabeli terlebih dahulu untuk melatih model dalam memprediksi output terhadap input yang diberikan. Beberapa algoritma yang sering digunakan adalah *Random Forest*, *K-Nearest Neighbor* (KNN), dan *Support Vector Machine* (SVM) (Deisenroth *et al.*, 2020).

Penggunaan *Machine Learning* dalam pengklasifikasian gelembung gas telah dilakukan dengan beberapa algoritma *Supervised Learning* (Minelli *et al.*, 2021). Namun, performa dari algoritma-algoritma tersebut belum pernah dikomparasikan terhadap algoritma lainnya. Penelitian ini bertujuan untuk mengevaluasi serta membandingkan algoritma-algoritma pada *Machine Learning* untuk menentukan algoritma terbaik berdasarkan hasil model dari tiap algoritma. Algoritma *Random Forest*, *K-Nearest Neighbor*, dan *Support Vector Machines* menjadi fokus utama pada penelitian ini.

MATERI DAN METODE

Penelitian ini dilakukan pada bulan September 2024 di perairan Karangantu, Serang, Banten. Alat dan bahan yang digunakan dalam penelitian ini terdiri atas *Multibeam Echosounder* Norbit, GPS *Trimble*, kapal nelayan dengan ukuran 10 GT, tabung selam, pemberat (dummy), *Fledermaus*


FMMidwater dan bahasa pemrograman *Python 3.13.0*. Penelitian ini menggunakan *Multibeam Echosounder* jenis Norbit IWBMSH STX dengan spesifikasi pada Tabel 1, dipasangkan ke kapal nelayan. Penelitian ini meliputi pengambilan data berdasarkan peta lajur (Gambar 1). Simulasi pelepasan gelembung gas di kolom air dibuat secara *artificial* dengan menggunakan tabung selam sebagai sumber gelembung gas yang ditenggelamkan dan ditempatkan di dasar perairan dengan kedalaman 11 m, serta penyelam yang berperan sebagai salah satu objek yang dideteksi oleh alat yang terletak di antara kapal dan sumber. Proses akusisi dilakukan dengan kapal yang berjalan melalui sumber dan penyelam untuk akusisi data kolom air.

Data yang telah diakusisi memiliki ekstensi *.s7k akan diolah menggunakan perangkat lunak *FMMidwater* dengan bantuan perangkat komputer. Perangkat lunak *FMMidwater* akan menghasilkan file *export* fitur-fitur berupa amplitudo dalam satuan desibel, kedalaman objek, dan lainnya. Proses *tagging* dilakukan untuk melabeli target berdasarkan pengamatan secara visual pada *FMMidwater*. Data-data yang dihasilkan kemudian dilakukan proses penyesuaian dari data hasil *export* dengan data *tagging* untuk kemudian dimasukkan ke dalam model *Machine Learning*.

Algoritma *Machine Learning* yang digunakan adalah *Random Forest*, *K-Nearest Neighbor (KNN)*, dan *Support Vector Machine (SVM)*. Setiap model akan optimasi *hyperparameter* yang cocok untuk menghasilkan prediksi yang akurat, sehingga dapat ditentukan algoritma terbaik berdasarkan akurasi, *f1 score*, dan koefisien kappa yang diperoleh dari *confusion matrix* hasil model.

Tabel 1. Spesifikasi *Multibeam Echosounder* Norbit IWBMSH STX

No	Parameter	Spesifikasi
1	Frekuensi	80-400 kHz
2	Swath Coverage	70-179°
3	Ping Rate	50 Hz
4	Kedalaman Maksimum Operasional	50 m
5	Kedalaman Maksimum Deteksi	160 m



Gambar 1. Peta Lajur

Ketiga parameter tersebut berbeda, namun menggambarkan performa dari model *Machine Learning*. Akurasi mengukur jumlah prediksi yang benar dari total seluruh dataset (Miao and Niu, 2016).

$$Accuracy = \frac{\sum True Prediction}{\sum Sample}$$

F1-score mengukur keseimbangan data, namun tidak mengurangi bias ke data mayoritas yang memiliki jumlah data lebih banyak secara langsung. Bias dapat dikurangi dengan menggunakan beberapa pendekatan, misalnya dengan *Weighted*, yaitu mengukur dengan mempertimbangkan jumlah sampel tiap kelas (Lee et al., 2024).

$$F1_{weighted} = \sum_{i=1}^N w_i \cdot F1_i$$

$$w_i = \frac{n_i}{\sum_{j=1}^N n_j}$$

Koefisien Kappa mengukur kesesuaian antara hasil prediksi model terhadap *true label* yang sangat dipengaruhi oleh disitribusi populasi dari tiap kelas (Hafid, 2023). Formulasi koefisien kappa dipengaruhi oleh 2 variabel yaitu *observed agreement* (p_o) dan *expected argument* (p_e) (Perez et al., 2020):

$$k = \frac{p_o - p_e}{1 - p_e}$$

Dimana,

$$p_o = \frac{\sum_{i=1}^k n_{ii}}{N}$$

$$p_e = \sum_{i=1}^k \left(\frac{(n_{i+} \times n_{+i})}{N^2} \right)$$

Setelah didapatkan nilai dari parameter-parameter tiap model, algoritma terbaik akan diambil berdasarkan nilai tertinggi dari ketiga parameter tersebut.

HASIL DAN PEMBAHASAN


Hasil akusisi data pada *Multibeam Echosounder* menunjukkan hasil terdeteksinya gelembung gas pada echogram *R-Stack* (Gambar 2). Warna yang ada pada echogram menggambarkan besarnya pantulan yang diberikan oleh objek, semakin besar kekuatan pantulan objek akan ditandai dengan warna merah, dan sebaliknya untuk objek yang memiliki kekuatan pantulan kecil yang ditandai dengan warna biru pada echogram (Hamuna, 2018). Pada gambar 2, terlihat adanya *flare* yang merupakan semburan dari gelembung gas yang dibentuk oleh tabung gas yang ditandai dengan warna hijau dan penyelam yang juga terdeteksi oleh *Multibeam Echosounder* dan ditandai dengan warna merah yang menggambarkan nilai pantulan objek yang kuat.

Citra kolom air disajikan pada Gambar 3, terlihat bahwa *Multibeam Echosounder* telah mendeteksi objek selain gelembung gas, dimana terdapat penyelam yang terdeteksi pada kedalaman ± 6 meter dan sumber gelembung gas berupa tabung selam yang berada di dasar perairan. Terlihat pada Gambar 3 bahwa pancaran gelembung gas tidak memiliki jalur yang vertikal tegak lurus terhadap dasar perairan, melainkan terdapat pergeseran yang disebabkan oleh adanya arus laut (Emerson and Bushinsky, 2016). Platform gelembung gas yang digunakan sebagai sumber gelembung gas juga terdeteksi pada citra kolom air yang terdapat di area dekat dengan dasar perairan.


Berdasarkan citra kolom air, didapatkan nilai *Uncalibrated Amplitude* dB berkisar antara 3.01 – 40.40 dB, kemudian data dapat dilakukan *tagging* dan *export* data untuk kemudian dimasukkan sebagai input model *machine learning*. Data dibagi menjadi 2 jenis yaitu 70% data digunakan untuk data training (Tabel 2) dan 30% untuk data test (Tabel 3).

Tabel 2. Dataset Pelatihan yang Digunakan Dalam Proses Klasifikasi

X	Y	Z	dB Value	Ping Number	Beam Number	Sound Speed	Beam Elevation	Label	True Label
628323.5	9338924	-7.66	12.79	57	263	1544.7	11.56	Non Bubbles	0
628321.1	9338924	-5.24	24.53	59	263	1544.2	11.97	Bubbles	1
628323.4	9338922	-1.63	18.63	58	63	1544.7	63.02	Bubbles	1
628323	9338924	-7.33	11.76	58	264	1544.7	12.78	Non Bubbles	0
628318.6	9338921	-4.8	11.46	65	224	1544.5	28.67	Non Bubbles	0



Gambar 2. Echogram R-Stack Multibeam Echosounder



Gambar 3. Citra Kolom Air Multibeam Echosounder

Tabel 3. Dataset Pengujian dalam Validasi Performa Model

X	Y	Z	dB Value	Ping Number	Beam Number	Sound Speed	Beam Elevation
628322.8	9338924	-6	18.57	58	273	1544.7	7.54
628323.7	9338925	-6.7	6.02	56	277	1544.8	2.71
628322.3	9338919	-4.11	20.33	59	136	1544.2	54.59
628323.3	9338924	-5.06	6.99	57	266	1544.7	9.84
628322.8	9338924	-6	15.68	58	273	1544.7	7.54

Optimasi *hyperparameter* untuk ketiga algoritma menunjukkan *Random Forest* optimal pada *n tree* bernilai 60, *K-Nearest Neighbor* optimal pada nilai *n neighbor* 18, dan *Support Vector Machines* optimal pada nilai *C* 10 dengan kernel *radial basis function* dengan akurasi data training masing-masing 88.65%, 86.91% dan 87.68%.

Hasil uji performa model *machine learning* pada ketiga algoritma menggunakan data test disajikan pada tabel 4, dimana hasil performa menunjukkan akurasi 89.02% untuk *Random Forest*, 85.41% pada *K-Nearest Neighbor*, dan 86.76% pada *Support Vector Machine*. Berdasarkan nilai akurasi, ketiga algoritma tergolong memiliki performa yang baik dan mampu memprediksi *output* dengan baik *machine learning* (Zheng, 2015). Namun, metrik evaluasi performa model tidak hanya ditentukan oleh nilai akurasi, terdapat metrik *precision*, *recall*, *F1-Score* serta koefisien kappa yang menunjukkan kesesuaian prediksi model yang benar dengan yang salah (Elson, 2025).

Precision menggambarkan kemampuan suatu model memprediksi suatu kelas dengan baik, yaitu ukuran seberapa baiknya prediksi positif yang relevan terhadap kelas, sedangkan, *recall* yang menggambarkan kemampuan model untuk mengidentifikasi kasus positif suatu kelas yaitu ukuran kasus positif yang berhasil diidentifikasi model (Franti dan Mariescu-Istodor, 2023). Pada *precision* didapatkan nilai 89.09% pada *Random Forest*, 83.66% pada *K-Nearest Neighbor*, dan 83.66% pada *Support Vector Machine*, sedangkan pada *recall*, didapatkan 89.02% pada *Random Forest*, 85.41% pada *K-Nearest Neighbor*, dan 85.41% pada *Support Vector Machines*. Berdasarkan *precision* dan *recall*, maka didapatkan nilai *F1-Score* yang merupakan rata-rata harmonik dari *precision* dan *recall* (Hand, et al., 2021). Pada *Random Forest* memiliki *F1-Score* 88.78 %, kemudian *K-Nearest Neighbor* memiliki *F1-Score* 84.52%, dan *Support Vector Machine* memiliki *F1-Score* 86.50%. Nilai *precision*, *recall*, dan *F1-Score* ini menggunakan metode *average weighted*, dimana metode ini menghitung performa model dengan mempertimbangkan jumlah sampel tiap kelas, hal ini dikarenakan terdapatnya kelas dengan jumlah yang sangat sedikit (kelas 2 dan 3) dimana kelas tersebut memiliki frekuensi dibawah 30 pada keseluruhan data baik data training maupun data test (Bacevicius dan Paulauskaite-Taraseviciene, 2023)

Pada koefisien kappa, didapatkan nilai 78.25% pada *Random Forest*, 70.79% pada *K-Nearest Neighbor*, dan 73.67% pada *Support Vector Machine*. Koefisien kappa menunjukkan tingkat kesepakatan antara hasil prediksi dengan *true label*, sehingga semakin tinggi nilai koefisien kappa, maka semakin tinggi tingkat kesesuaian antara hasil prediksi dengan *true label* (Rau dan Shih, 2021). Berdasarkan nilai koefisien kappa, ketiga algoritma memiliki nilai kappa yang tergolong dalam kategori kesepakatan substansial. Kategori substansial menggambarkan bahwa model memiliki performa yang lebih baik dibandingkan dengan tebakan acak (Andres & Hernandex, 2024).

Berdasarkan seluruh metrik hasil evaluasi model, meliputi akurasi, *F1-Score*, hingga koefisien kappa, model *Random Forest* menunjukkan hasil performa terbaik dibandingkan dengan model *Support Vector Machine* dan *K-Nearest Neighbor* pada seluruh metrik evaluasi, yaitu akurasi 89.02%, *F1-Score* 88.78%, serta koefisien kappa 78.25%. Temuan ini sejalan dengan pendapat

Tabel 4. Perbandingan Hasil Evaluasi Performa Model Machine Learning

Model	Akurasi	Precision	Recall	F1-Score	Kappa
Random Forest	89.02 %	89.09 %	89.02 %	88.78 %	78.25 %
K-Nearest Neighbor	85.41 %	83.66 %	85.41 %	84.52 %	70.79 %
Support Vector Machine	86.76 %	83.66 %	85.41 %	86.50 %	73.67 %

Hamuna et al. (2024), yang berpendapat bahwa *Random Forest* memiliki kemampuan klasifikasi lebih unggul dibandingkan *Support Vector Machine* pada data echosounder. Pernyataan serupa juga didukung oleh Raihandika dan Suryono (2025), yang berpendapat bahwa model *Random Forest* memiliki kemampuan klasifikasi yang lebih baik dibandingkan dengan *Support Vector Machine* dan *K-Nearest Neighbor*, baik dalam *binary class* maupun *multiclass*.

KESIMPULAN

Berdasarkan hasil penelitian, *Multibeam Echosounder* mampu mendeteksi objek berupa gelembung gas yang berada di kolom air. Pengolahan data yang menggunakan perangkat lunak *FMMidwater* serta klasifikasi objek dengan menggunakan pendekatan Machine Learning, didapatkan parameter metrik evaluasi berupa akurasi, *F1-Score* dan Koefisien Kappa, dimana *Random Forest* menghasilkan akurasi 89.02 %, *F1-Score* 88.78 %, serta koefisien kappa 78.25%, lebih tinggi dibandingkan dengan model *Support Vector Machine* pada akurasi 86.76%, *F1-Score* 86.50%, koefisien kappa 73.67%, serta *K-Nearest Neighbor* pada akurasi 85.41%, *F1-Score* 84.52%, serta koefisien kappa 70.79%, sehingga didapatkan bahwa algoritma *Random Forest* memberikan performa terbaik dibandingkan *Support Vector Machine* dan *K-Nearest Neighbor*. Seluruh model menghasilkan akurasi yang termasuk dalam kategori performa yang baik (80%-90%), serta *F1-Score* yang berada pada kategori performa tinggi (80%-90%) dengan menggunakan metode *average weighted* yang mempertimbangkan bobot pada kelas dengan frekuensi yang kecil, serta koefisien kappa dari ketiga model tergolong dalam kategori kesepakatan substansial (70%-80%), menunjukkan bahwa model memiliki tingkat kesepakatan antara hasil prediksi dengan true label yang sangat tinggi. Oleh karena itu, pendekatan *machine learning* terbukti mampu untuk mengidentifikasi objek bawah laut seperti gelembung gas pada data citra kolom air.

UCAPAN TERIMA KASIH

Terima kasih kepada Sekolah Tinggi Teknik Angkatan Laut (STTAL) Jakarta yang telah membantu dalam pengambilan data di perairan Karangantu, Serang, Banten.

DAFTAR PUSTAKA

- Andrés, Martín A., & Hernández, M.Á. (2025). Estimators of various kappa coefficients based on the unbiased estimator of the expected index of agreements. *Advances in Data Analysis and Classification*, 19, 177-207, doi: 10.1007/s11634-024-00581-x.
- Bacevicius, M., & Paulauskaite-Taraseviciene, A. (2023). Machine learning algorithms for raw and unbalanced intrusion detection data in a multi-class classification problem. *Applied Sciences*, 13(12), 7328, doi: 10.3390/app13127328.
- Deisenroth, M.P., Faisal, A.A., & Ong, C.S. (2020). *Mathematics for Machine Learning*, Cambridge University Press, New York.
- Emerson, S., & Bushinsky, S. (2016). The role of bubbles during air-sea gas exchange. *Journal of Geophysical Research: Oceans*, 121, 4360–4376, doi: 10.1002/2016JC011744.
- Fang, X.L., Ming, F.R., Wang, P., Sun, P., & Zhang, A. (2022). Application of SPH Method In The Study of Ship Capsizing Induced by Large Scale Rising Bubble. *Ocean Engineering*, 257(1), 111629, doi: 10.1016/j.oceaneng.2022.111629.
- Fränti, P., & Mariescu-Istodor, R. (2023). Soft precision and recall. *Pattern Recognition Letters*, 167, 115–121, doi: 10.1016/j.patrec.2023.02.005.

- Goodfellow, I., Courville, A., & Bengio, Y. (2016). Deep Learning. MIT Press, London.
- Hafid, J. (2023). Penerapan K-Fold Cross Validation untuk menganalisis Kinerja Algoritma K-Nearest Neighbor Pada Data Kasus Covid-19 di Indonesia. *Journal of Mathematics, Computations and Statistics*, 6(2), 161-168, doi: 10.35580/jmathcos.v6i2.53043.
- Hamuna, B., Dimara, L., Pujiyati, S., & Natih, N.M.N. (2018). Hambur Balik Akustik Permukaan Substrat Dasar Perairan Menggunakan Echosounder Bim Tunggal, *Jurnal Kelautan*, 11(1), 31-37. doi: 10.21107/jk.v11i1.2892.
- Hamuna, B., Pujiyati, S., Gaol, J.L., & Hestirianoto, T. (2024). Classification And Prediction of Benthic Habitat From Scientific Echosounder Data: Application of Machine Learning Algorithms. *Applied Computer Science*, 20(4), 100–116, doi: 10.35784/acs-2024-42
- Hand, D. J., Christen, P., & Kirielle, N., (2021). F*: An interpretable transformation of the F-measure. *Machine Learning*, 110, 451–456, doi: 10.1007/s10994-021-05964-1
- Hazare, S.R., Patil, C.P., Vala, S.V., Joshi, A.J., Joshi, J.B., Vitankar, V.S. & Patwardan, A.P. (2022). Predictive analysis of gas holdup in bubble column using machine learning methods. *Chemical Engineering Research and Design*, 184, 724-739, doi: 10.1016/j.cherd.2022.06.007.
- Lee, M. C. H., Braet, J., & Springael, J. (2024). Performance Metrics for Multilabel Emotion Classification: Comparing Micro, Macro, and Weighted F1-Scores. *Applied Sciences*, 14(21), 9863, doi: 10.3390/app14219863.
- Manik, H.M. & Dwinovantyo, A. (2018). Teknik Deteksi Bawah Air, Penerbit IPB Press, Bogor.
- Meng, J., Yan, J., & Zhao, J., 2022, Bubble Plume Target Detection Method of Multibeam Water Column Images Based on Bags of Visual Word Features, *Remote Sensing*, 14(14), 3296, doi: 10.3390/rs14143296
- Meng, J., Yan, J., & Zhang, Q. (2024). Anti-Interference Bottom Detection Method of Multibeam Echosounders Based on Deep Learning Models, *Remote Sensing*, 16(3), 530. doi : 10.3390/rs16030530
- Merey, S., & Longinos, S.N. (2018). Investigation of gas seepages in Thessaloniki mud volcano in the Mediterranean Sea. *Journal of Petroleum Science and Engineering*, 168, 81–97, doi: 10.1016/j.petrol.2018.05.014
- Miao, J., & Niu, L. (2016). A Survey on Feature Selection. *Procedia Computer Science*, 91, 919-926, doi: 10.1016/j.procs.2016.07.111.
- Minelli, A., Tasetti, A.N., Hutton, B., Cozzolino, G.N.P., Jarvis, T., & Fabi, G. (2021). Semi-Automated Data Processing and Semi-Supervised Machine Learning for the Detection and Classification of Water-Column Fish Schools and Gas Seeps with a Multibeam Echosounder, *Sensors*, 21(9), 2999, doi: 10.3390/s21092999
- Nadimi, N., Javidan, R., & Layeghi, K. (2021). Efficient Detection of Underwater Natural Gas Pipeline Leak Based on Synthetic Aperture Sonar (SAS) Systems, *Journal of Marine Science and Engineering*, 9(11), 1273. doi: 10.3390/jmse9111273
- Rau, G., & Shih, Y.S. (2021). Evaluation of Cohen's kappa and other measures of inter-rater agreement for genre analysis and other nominal data. *Journal of English for Academic Purposes*, 53, 101026. doi: 10.1016/j.jeap.2021.101026
- Rebala, G., Ravi, A., & Churiwala, S. (2019) An Introduction to Machine Learning, Springer, USA.
- Spain E., Lamarche, G., Lucieer, V., Watson, S. J., Ladroit, Y., Heffron, E., Pallentin, A., & Whittaker J.M., (2022). Acoustic Predictors of Active Fluid Expulsion From a Hydrothermal Vent Field, Offshore Taupō Volcanic Zone, New Zealand. *Frontiers in Earth Science*, 9, 785396. doi: 10.3389/feart.2021.785396
- Wang, H., Jia, Y., Liu, X., Liu, J., Wang, K., Jiang, J., Xu, H., Tang, J., & Sun, C. (2024). Study on the fountain effect of the bubble plume formed by submarine gas pipeline leakage, *Frontiers in Earth Science*, V11, 1402784, doi: 10.3389/feart.2024.1402784
- Xu, C., Wu, M., Zhou, T., Li, J., Du, W., Zhang, W., & White, P.R. (2020) Optical Flow-Based Detection of Gas Leaks from Pipelines Using Multibeam Water Column Images. *Remote Sensing*, 12(119), 1-20, doi: 10.3390/rs12010119