

Peningkatan Kinerja Pengklasifikasi Objek Bawah Laut Dengan Deep Learning

Improved Undersea Object Classifier Performance With Deep Learning Neural Network

Aris Tjahyanto¹, Faisal Johan Atletiko²
Institut Teknologi Sepuluh Nopember, Indonesia

Informasi Artikel

Genesis Artikel:

Diterima, 18 Oktober 2021
Direvisi, 13 Februari 2022
Disetujui, 07 Mei 2022

Kata Kunci:

Deep learning
Pembangkit gema
Pembelajaran mesin
SONAR
Sorot-tunggal

Keywords:

Deep learning
Echo sounder
Machine learning
SONAR
Single-beam

ABSTRAK

Pengenalan objek bawah laut dapat dilakukan berdasarkan pola hamburan SONAR, seperti untuk deteksi ranjau dan deteksi batu yang terletak di dasar laut. Kesulitan yang dihadapi pada pengenalan objek bawah laut antara lain adalah pemilihan metode ekstraksi fitur, adanya rotasi objek yang menghasilkan pola hamburan yang berbeda, lingkungan atau latar belakang bervariasi, dan kemampuan pengklasifikasi yang berbeda untuk lingkungan yang lebih kompleks. Pada penelitian ini, kami menggunakan *deep learning neural network* untuk meningkatkan kinerja klasifikasi dua buah objek bawah laut. Secara khusus, dibandingkan jumlah neuron pada lapisan tersembunyi dan fungsi aktivasi yang dapat menghasilkan kinerja yang lebih tinggi dari penelitian sebelumnya. Pada penelitian sebelumnya, proses klasifikasi dilakukan dengan menggunakan *neural network* dengan 12 buah lapisan tersembunyi, dan menghasilkan akurasi maksimal sebesar 90.4%. Dilakukan percobaan pada struktur jaringan syaraf tiruan berupa *multilayer perceptron* dengan 2 buah lapisan tersembunyi dan 7 macam fungsi aktivasi. Dari percobaan yang dilakukan diperoleh bahwa *deep learning neural network* memberikan rata-rata akurasi terbaik sebesar 85,9% dengan akurasi maksimal sebesar 96,15% lebih baik dibandingkan hasil penelitian sebelumnya. Akurasi terbaik tersebut diperoleh dengan memanfaatkan jumlah neuron pada lapisan tersembunyi sebanyak 140 buah, dan fungsi aktivasi reLU untuk lapisan tersembunyi fungsi aktivasi Linear untuk lapisan output.

ABSTRACT

Recognition of undersea objects can be done based on SONAR scattering patterns, such as mine and rocks detection located on the seabed. Difficulties encountered in recognizing undersea objects include selecting feature extraction methods, rotating objects that produce different scattering patterns, varying environments or backgrounds, and different classifier abilities for more complex environments. In this study, we use a deep learning neural network to improve the classification performance of two underwater objects. In particular, compared to the number of neurons in the hidden layer and the activation function, which can result in higher performance than previous studies. The previous study carried out the classification process using a neural network with 12 hidden layers and resulted in a maximum accuracy of 90.4%. An experiment was conducted on the structure of the artificial neural network in the form of a multilayer perceptron with two hidden layers and seven kinds of activation functions. The experiments showed that the deep learning neural network provides the best average accuracy of 85.9%, with a maximum accuracy of 96.15% better than the results of previous studies. The best accuracy is obtained by utilizing the number of neurons in the hidden layer as many as 140 units and the reLU activation function for the hidden layer Linear activation function for the output layer.

This is an open access article under the [CC BY-SA](#) license.



Penulis Korespondensi:

Aris Tjahyanto,
Departemen Sistem Informasi,
Institut Teknologi Sepuluh Nopember,
Email: aristj@its.ac.id

1. PENDAHULUAN

Echo sounder adalah salah satu jenis *Sound Navigation and Ranging* (SONAR), berupa perangkat yang digunakan oleh kapal laut dan ditaruh di bawah air. Sebuah *echo sounder* saat beroperasi akan memancarkan sinyal dan menerima sinyal yang dipantulkan oleh objek bawah air. *Echo sounder* atau pembangkit gema dapat digunakan untuk menemukan objek seperti gerombolan ikan, kolom gelembung yang muncul dari dasar laut, ataupun mengetahui bentuk dasar laut. Mengetahui suasana kedalaman air adalah hal penting dalam navigasi kapal laut dan kegiatan penangkapan ikan. Hal tersebut penting pada kegiatan navigasi agar kapal laut tidak terdampar di laut dangkal. Pada pelabuhan laut utama, terdapat peta akurat yang menjelaskan perairan di sekitarnya. Sedangkan untuk tempat lain yang belum memiliki peta akurat, maka diperlukan perangkat semacam *echo sounder* yang mampu untuk mengukur kedalaman air agar kapal tidak menabrak dasar laut.

Selain untuk membantu navigasi kapal laut, *echo sounder* dapat juga dimanfaatkan untuk mengetahui keberadaan gerombolan ikan. Dengan teknik dual-beam, ukuran ikan dapat diperkirakan berdasarkan kekuatan sinyal yang dipantulkan. Pembangkit gema sorot tunggal atau *single-beam echo sounder* (SBES) awalnya digunakan untuk melakukan survey kedalaman perairan di sekitar pelabuhan dan sungai untuk kebutuhan navigasi. Meskipun sistem sorot-banyak makin meningkat penggunaannya, masih banyak pihak yang memanfaatkan sistem sorot tunggal karena kesederhanaannya. Pada sistem sorot tunggal, sebuah transduser biasanya dipasang pada bagian lambung kapal, tegak lurus dengan permukaan air laut atau sungai. Sinyal akustik dengan frekuensi tertentu kemudian dipancarkan dari *transducer* menembus air di bawah kapal dan dipantulkan kembali oleh objek yang berada di bawah air. Jenis objek dapat diperkirakan dengan mengamati karakteristik sinyal gema yang dipantulkan kembali oleh objek bawah laut [1]. Selain untuk mengukur kedalaman air, SBES dapat dimanfaatkan untuk melakukan klasifikasi objek dasar laut. Amiri et al. telah melakukan penelitian klasifikasi dasar laut dengan menggunakan sinyal *single-beam echo sounder* (SBES). Dasar laut diklasifikasikan menjadi beberapa kategori antara lain lumpur, lumpur berpasir, lumpur berkerikil, pasir, pasir berlumpur, kerikil, kerikil berpasir, dan sebagainya. Proses klasifikasi dilakukan berdasarkan sejumlah fitur yang diekstrak dari sinyal gema sinyal *single-beam echo sounder* (SBES), yaitu fitur profil energi, persebaran waktu, kecondongan (*skewness*), kedataran (*flatness*), dan *principal component analysis* (PCA) dari sinyal gema [2]. *Echo sounder* dapat juga dimanfaatkan untuk melakukan deteksi ikan. Sebagai contoh, Cook et.al menggunakan *multi-beam* SONAR dengan frekuensi tinggi yang memungkinkan penentuan karakteristik dan perkiraan ukuran dari ikan yang terdapat dalam perairan dengan kondisi sangat keruh serta cahaya yang rendah ketika metode yang lebih tradisional, seperti kamera bawah air tidak dapat diterapkan karena kondisi perairan yang keruh [3]. Sedangkan Helminen et.al. menggunakan *echo sounder* jenis yang sama untuk menghasilkan rekaman video sonar yang terus menerus, serta menerapkannya dalam upaya menghitung dan mengukur ikan yang bermigrasi di sungai [4].

Sejumlah penelitian telah mencoba menerapkan pemakaian beberapa metode pengklasifikasi dalam upaya untuk mengenali objek bawah laut. Metode *support vector machines* (SVM) dan *bagging tree* telah digunakan untuk meneliti terkait dengan arah pergerakan target menggunakan data akustik yang diterima oleh sonar susunan horizontal di lingkungan perairan dangkal [5]. Selain itu juga telah digunakan metode terkini yaitu *deep learning* dalam pengenalan target otomatis menggunakan kendaraan bawah air otonom dan melibatkan citra sonar pemindaian samping sangat menarik dalam aplikasi militer dan komersial. Model jaringan syaraf tiruan yang dipergunakan adalah *convolutional neural network* [6]. Sedangkan Steiniger et.al. melakukan penelitian terkait dengan permasalahan dataset dari sonar yang tidak seimbang (*balance*) untuk tugas klasifikasi dengan menggunakan *deep learning* [7]. Penelitian yang terkait SONAR juga dilakukan oleh Ghosh, dengan membandingkan 29 macam algoritme pembelajaran mesin antara lain: *Logistic Regression*, *Decision Tree*, *K-Nearest Neighbor* (KNN), *Nave Bayes*, *Support Vector Machines*, *Random Forest*, *Ada Boost*, dan lain sebagainya [8]. Pada kesempatan lain, Wei et.al menggunakan spektrogram *Mel-Frequency Cepstrum Coefficients* (MFCC) sebagai fitur dari sinyal akustik objek bawah laut, serta menggunakan *deep learning* untuk melakukan klasifikasi [9]. Pemakaian *deep learning* untuk mengenali objek bawah air juga diterapkan untuk sejumlah tugas seperti : segmentasi citra yang berisi kelompok ikan dan citra bukan-ikan [10], deteksi jenis ikan tuna sirip biru [11], dan identifikasi jenis-jenis ikan [12]. Kebanyakan arsitektur jaringan syaraf tiruan yang digunakan pada penelitian tersebut adalah berupa *Convolutional Neural Network* (CNN).

Pada paper ini dijelaskan model klasifikasi objek bawah laut. Klasifikasi dilakukan dengan menggunakan *Deep Learning Neural Network* (DNN) berdasarkan sejumlah fitur yang diekstrak dari sinyal hamburan atau gema yang diterima kembali oleh SBES setelah dipantulkan oleh objek bawah laut berupa silinder logam dan batu. Dataset berbasis sinyal SONAR yang digunakan ini memiliki dua kategori kelas dengan jumlah fitur sebanyak 60 buah dan merupakan dataset yang penuh dengan gangguan (*noise*). Dataset yang penuh dengan noise ini terlihat membingungkan atau terlihat seperti tanpa pola dan seperti acak sehingga meningkatkan faktor kesulitan bagi algoritme pembelajaran, seperti yang disampaikan oleh Seok [13]. Dengan demikian ini dapat dianggap sebagai dataset yang ideal untuk dipakai sebagai data uji dalam upaya mengetahui tangguh tidaknya suatu pengklasifikasi. Dalam upaya meningkatkan kinerja klasifikasi, selain dicoba menggunakan algoritme *deep learning* yang merupakan terobosan pada dekade ini, juga dilakukan pengolahan pendahuluan terhadap dataset yang digunakan dengan menggunakan metode normalisasi Min-Max agar mengurangi pengaruh dominan fitur tertentu yang memiliki nilai numerik lebih besar, dan pada akhirnya dapat memberikan kesempatan yang setara bagi seluruh fitur yang digunakan. Model DNN kemudian dilatih untuk mampu mengklasifikasikan benda logam dan batu berbentuk silinder, yang berukuran panjang sekitar 152 cm yang terletak di dasar laut berpasir. Dengan model klasifikasi yang dijelaskan tersebut, dapat memberikan kinerja yang lebih baik dibandingkan cara yang digunakan sebelumnya.

Echo sounder atau pembangkit gema merupakan sejenis SONAR yang secara garis besar dapat dikelompokkan menjadi dua jenis, yaitu *multi beam echo sounder* (MBES) dan *single beam echo sounder* (SBES). Perbedaan antara MBES dan SBES antara lain ditentukan dari jumlah titik kedalaman yang diukur pada saat yang sama. Pada SBES, titik kedalaman yang diukur hanya satu buah, sedangkan MBES lebih dari satu yang diukur dalam waktu yang sama. *Echo sounder* dapat dimanfaatkan untuk mengukur kedalaman air dengan cara memancarkan sinyal denyut bunyi (*sound pulse*) ke dalam air. Selang waktu antara pengiriman dan kedatangan sinyal denyut di-

catat, kemudian digunakan untuk menentukan kedalaman air berdasarkan kecepatan rambat bunyi dalam air. Pada MBES, sinyal denyut dibangkitkan dengan sudut yang lebar berbentuk kipas di bawah lambung kapal. Pantulan sinyal gema oleh objek dasar laut diterima dari sejumlah sinyal denyut yang dipancarkan dalam sudut yang sempit. Kedalaman air kemudian diekstrapolasi sepanjang pita yang terbentuk dari petak-petak kedalaman dasar laut.

Echo sounder dapat dipasang pada perahu atau kapal untuk mengetahui gerombolan ikan dan pola penyebarannya. Selain itu, *echo sounder* dapat pula dipasang pada lokasi yang tetap seperti pada pintu air sungai untuk memantau ikan-ikan yang berlalu lalang. Akurasi dari *echo sounder* dalam mendeteksi objek bawah air ditentukan antara lain oleh daya atau kekuatan sinyal yang dipancarkan. Semakin besar daya yang dimiliki *echo sounder*, maka semakin tinggi peluang untuk memperoleh pantulan sinyal gema dari kedalaman air, dengan kata lain semakin besar kedalaman yang dapat dicapai. Selain itu, semakin besar daya yang dipancarkan, maka semakin mudah untuk membedakan sinyal gema yang berasal dari objek seperti ikan dengan sinyal gema yang berasal dari dasar laut. Selain faktor daya, akurasi *echo sounder* juga ditentukan oleh frekuensi yang digunakan. Frekuensi tinggi cocok digunakan untuk kedalaman air hingga 60 meter. Sedangkan frekuensi rendah lebih cocok untuk air yang lebih dalam karena air menyerap lebih lambat gelombang bunyi yang memiliki frekuensi rendah sehingga sinyal gema dapat merambat lebih jauh dibanding frekuensi tinggi. Hanya saja sinyal frekuensi rendah memiliki sudut sorot yang lebih lebar yang mengakibatkan kurang tajamnya gambaran yang diberikan. Objek dasar laut seperti lumpur, pasir lembut, dan tumbuhan yang berada di dasar akan menyerap dan atau menghamburkan sinyal gema yang mengakibatkan tampilan dasar yang gelap dan tebal.

Pilihan frekuensi SONAR yang tersedia di pasaran adalah sangat banyak. Perbedaan frekuensi akan memberikan tingkat kejelasan gambar yang berbeda pula. Sebagai contoh, frekuensi 1600 kHz menghasilkan gambar yang lebih tajam atau memiliki resolusi yang lebih baik dari pada SONAR dengan frekuensi 400 kHz. Akan tetapi apabila yang dipentingkan adalah area pencarian yang lebih luas, maka frekuensi yang lebih rendah adalah pilihan yang cocok. Secara praktis, biasanya setiap transduser SONAR dilengkapi dengan frekuensi ganda, sebagai contoh sebuah SONAR dilengkapi dengan frekuensi 200 kHz dan 50 kHz. Frekuensi yang lebih tinggi digunakan untuk memperoleh hasil resolusi yang tinggi, sedangkan frekuensi rendah untuk keperluan area pencarian yang lebih luas.

Pada identifikasi objek bawah air; target objek yang dideteksi biasanya meliputi pasir, lumpur, kerikil, tanaman, ranjau, batu, dan lainnya. Target objek tersebut menyebabkan mekanisme penghamburan sinyal menjadi kompleks, karena targetnya bukanlah sebuah objek yang kaku. Pada SONAR monostatik, hal yang pertama kali didengar oleh penerima adalah suara sinyal ping yang telah dikirim. Secara teori, adalah tidak mungkin untuk mendeteksi gema pada durasi τ atau dengan kata lain sebuah target tidak dapat terdeteksi pada radius sebesar $\frac{1}{2}\tau c$, dengan c adalah kecepatan bunyi dalam air. Objek target tidaklah memantulkan sinyal ke segala arah. Mekanisme pemantulannya adalah kompleks. Tingkat sinyal gema yang dipantulkan tergantung pada sudut β dan sudut pantul α . Mekanisme pantulan juga menjadi lebih kompleks jika objek target terkubur atau setengah terkubur sedimen dasar laut seperti ranjau laut, sampah, kapal karam, dan sebagainya [14].

Klasifikasi merupakan salah satu fungsi penggalian data (*data mining*) dan pembelajaran mesin (*machine learning*) yang akan menempatkan sebuah butir data ke dalam kategori atau kelas tertentu. Tujuan dari klasifikasi adalah secara akurat memprediksi kelas tujuan untuk setiap kasus butir data yang diamati. Terdapat banyak permasalahan klasifikasi, sebagai contoh adalah kategorisasi teks (misal: penyaringan spam), deteksi penggelapan (*fraud*), pengenalan huruf, pengenalan suara, deteksi wajah, pengolahan bahasa alami, segmentasi pasar, bioinformatika dan lain-lain. Satu *decade* yang lalu terdapat sejumlah algoritma klasifikasi yang biasa digunakan oleh peneliti. Menurut Xindong Wu et.al., terdapat sepuluh algoritma klasifikasi yang meliputi antara lain: C4.5, k-Means, SVM, Apriori, EM, PageRank, AdaBoost, kNN, Naive Bayes, dan CART. Sepuluh buah algoritma klasifikasi tersebut adalah yang paling berpengaruh dalam komunitas penelitian [15].

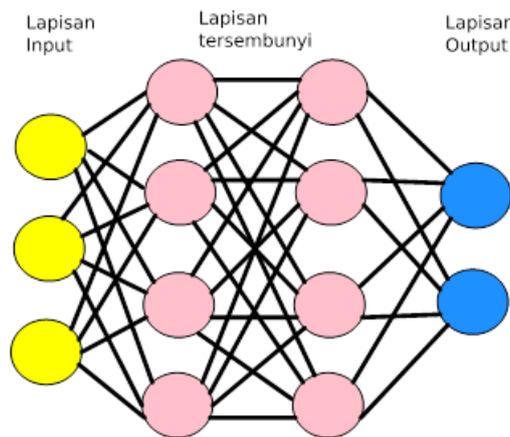
Pada era sekarang, *support vector machines* (SVM) adalah algoritma yang perlu dipertimbangkan dan dicoba. SVM menawarkan sebuah metode yang akurat dan tangguh di antara algoritma yang lain. SVM memberikan peluang untuk proses optimasi hyper parameter agar diperoleh model pengklasifikasi yang dengan kinerja yang diharapkan. SVM memiliki dasar teori yang masuk akal, memerlukan hanya satu lusin data untuk tahap pelatihan serta tidak sensitif terhadap ukuran atau dimensi data. Akan tetapi dengan makin berkembangnya ilmu pembelajaran mesin, semakin banyak algoritma pembelajaran yang dapat digunakan. Saat ini yang sedang trend adalah *deep learning* dan memberikan potensi pengklasifikasi dengan kinerja yang lebih baik dibandingkan dengan algoritme lainnya. Algoritme *deep learning* telah diterapkan pada banyak bidang, misalnya adalah Hamidur Rahman et.al memanfaatkan *deep learning* untuk mendeteksi kondisi salju dan hujan di lokasi konstruksi menggunakan citra drone [16].

Deep learning merupakan cabang dari pembelajaran mesin yang lebih luas dengan menggunakan jaringan syaraf tiruan. Arsitektur *deep learning* dapat berupa jaringan syaraf tiruan, jaringan syaraf berulang (*recurrent neural network*), dan jaringan syaraf konvolusional; telah diterapkan ke berbagai bidang seperti pengenalan pola, pengenalan suara, pemrosesan bahasa alami, pengenalan audio, pemfilteran jaringan sosial, terjemahan mesin, bioinformatika, analisis citra medis, dan bidang lainnya dengan hasil yang cukup memuaskan. Kata "deep" pada *deep learning* mengacu pada penggunaan sejumlah lapisan di dalam penelitian jaringan syaraf tiruan yang merupakan *new-generation of neural networks* [17]. Studi sebelumnya menunjukkan bahwa perceptron linier tidak dapat menjadi pengklasifikasi universal, dan kemudian sebuah jaringan dengan fungsi aktivasi *nonpolynomial* pada satu lapisan tersembunyi (*hidden layer*) memiliki hasil yang lebih baik. *Deep learning* adalah versi modern dari perceptron yang berkaitan dengan menggunakan sejumlah lapisan tersembunyi, yang memungkinkan aplikasi praktis dan implementasi lebih optimal.

Pada paper ini ditulis dengan susunan antara lain berupa Abstrak, Pendahuluan, Metodologi, Hasil dan Analisis serta ditutup dengan Kesimpulan termasuk dengan saran pengembangan atau lanjutan penelitian yang dapat dilaksanakan pada masa mendatang.

2. METODE PENELITIAN

Pada penelitian kuantitatif ini, digunakan salah satu model jaringan syaraf tiruan yang biasa diterapkan untuk *deep learning*. Model jaringan syaraf tiruan yang digunakan dalam *deep learning* (*deep leaning neural network* atau disingkat dengan DNN) biasanya merupakan jaringan *feedforward* dengan data yang mengalir dari lapisan masukan sampai ke lapisan luaran tanpa umpan balik. Pada awalnya, DNN memberikan nilai numerik acak atau biasa disebut sebagai "bobot", ke koneksi antara neuron artifisial. Kemudian bobot dan data masukan dikalikan dan menghasilkan luaran antara 0 dan 1 sesuai dengan fungsi aktivasi yang digunakan. Jika jaringan belum mampu secara akurat mengenali pola tertentu yang digunakan untuk proses pembelajaran, algoritme akan menghitung ulang dan menyesuaikan nilai bobotnya. DNN memiliki sejumlah hal yang perlu diatur agar mampu menjalankan fungsi yang telah direncanakan sebelumnya dan dapat memberikan performa yang optimal. Hal yang pertama dilakukan adalah merancang model jaringan syaraf tiruan (JST) yang akan digunakan. Model JST yang biasa digunakan untuk DNN antara lain adalah *Multilayer Perceptron* (MLP) yang strukturnya dapat dilihat pada Gambar 1, *Convolution neural network* (CNN), *Recurrent Neural Networks* (RNN), dan *Deep Belief Networks* (DBN) [18].



Gambar 1. Model *multilayer perceptron* untuk jaringan syaraf tiruan pada *deep learning*

Lapisan tersembunyi dalam JST adalah lapisan yang menerima masukan dari lapisan lain (seperti lapisan tersembunyi atau lapisan masukan lainnya) dan memberikan hasil ke lapisan lain (seperti lapisan tersembunyi atau lapisan keluaran lainnya). JST mungkin memiliki nol atau lebih lapisan tersembunyi. Sampai sekarang belum ada panduan yang disepakati dalam menentukan berapa jumlah lapisan tersembunyi yang paling optimal. Selain itu juga belum ada rumus khusus untuk menentukan berapa jumlah neuron di setiap lapisan tersembunyi. Hal ini karena tergantung pada masalah yang akan diselesaikan. Dengan demikian perlu dilakukan *trial and error* dalam menentukan jumlah lapisan dan jumlah neuronnya, akan tetapi tidak ada jaminan bahwa itu akan menghasilkan solusi yang optimal. Dengan demikian perlu dilakukan pencarian tapis (*grid-search*) untuk menemukan solusi yang optimal dalam setiap kasus. Pada paper ini lapisan tersembunyi yang digunakan adalah 2 lapis saja. Sedangkan jumlah neuron akan dicoba beberapa variasi, yaitu 10, 40, 50, 60, 70, 80, 90, 100, 110, 120, 121, 130, 140 buah per lapisan tersembunyi.

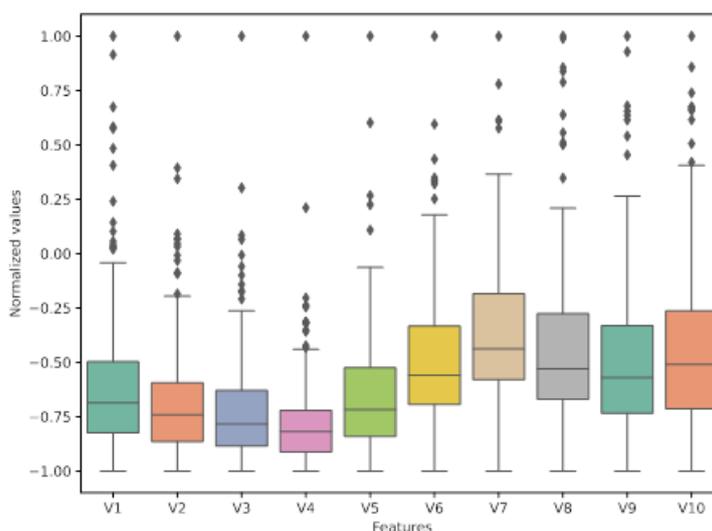
Setelah struktur JST ditentukan, langkah selanjutnya adalah memilih fungsi aktivasi yang digunakan pada lapisan tersembunyi dan lapisan luaran. Fungsi aktivasi dalam jaringan syaraf menentukan bagaimana jumlah bobot masukan diubah menjadi luaran. Pilihan fungsi aktivasi berdampak besar pada kemampuan dan kinerja jaringan syaraf. Fungsi aktivasi yang berbeda dapat digunakan di berbagai bagian model. Secara teknis, fungsi aktivasi digunakan di dalam atau setelah pemrosesan internal setiap node atau neuron dalam jaringan. Meskipun jaringan dirancang untuk menggunakan fungsi aktivasi yang sama untuk semua neuron dalam satu lapisan. Jaringan mungkin memiliki tiga jenis lapisan: lapisan masukan yang mengambil data masukan, lapisan tersembunyi yang mengambil masukan dari satu lapisan dan meneruskan luaran ke lapisan lainnya, dan yang terakhir adalah lapisan luaran yang membuat prediksi akhir.

Semua lapisan tersembunyi biasanya menggunakan fungsi aktivasi yang sama. Dengan kata lain, tidak biasa menggunakan fungsi aktivasi yang berbeda untuk lapisan tersembunyi lainnya. Lapisan luaran biasanya akan menggunakan fungsi aktivasi yang berbeda dari lapisan tersembunyi dan bergantung pada jenis prediksi yang diperlukan oleh model. Secara tradisi, sigmoid adalah fungsi aktivasi yang banyak digunakan pada tahun 1990-an. Sekitar tahun 1990-an hingga 2010-an, fungsi tanh adalah fungsi aktivasi yang populer untuk lapisan tersembunyi [17]. Sedangkan saat ini, fungsi aktivasi yang direkomendasikan adalah menggunakan satuan *linier* tersearah (*rectified linear unit* atau ReLU).

Pada paper ini dibahas upaya peningkatan kinerja pengklasifikasi objek bawah laut dengan menggunakan *deep learning*. Struktur jaringan yang digunakan adalah *multi layer perceptron* (MLP) dengan sejumlah lapisan tersembunyi seperti yang terlihat pada Gambar 1. *Multilayer perceptron* adalah jaringan syaraf tiruan jenis *feedforward*. Model ini disebut *feedforward* karena informasi mengalir melalui fungsi yang dievaluasi dari data input, melalui perhitungan antara yang digunakan untuk menentukan sementara sebelum dilewatkan ke fungsi aktivasi, dan akhirnya ke lapisan luaran/output. Tidak ada koneksi umpan balik di mana luaran dari model diumpangkan kembali ke dalam dirinya sendiri. Lapisan paling kiri dalam jaringan ini disebut lapisan input, dan neuron di dalam lapisan ini disebut neuron input. Lapisan paling kanan atau keluaran berisi neuron luaran, atau, seperti dalam kasus ini, neuron luaran ganda. Lapisan tengah disebut lapisan tersembunyi (*hidden layer*), karena neuron pada lapisan ini bukan merupakan input maupun output [19]. Untuk fungsi aktivasi pada

lapisan tersembunyi digunakan enam jenis fungsi aktivasi seperti sigmoid, linier, *rectified linear unit* (reLU), *scaled exponential linear unit* (seLU), *exponential linear unit* (eLU), dan *hyperbolic tangent* (*tanh*). Sedangkan untuk lapisan luaran digunakan fungsi aktivasi *sigmoid*, *softmax*, dan *linier*. Parameter lainnya seperti jumlah *batch* pada saat menjalankan algoritme *deep learning* dipilih nilai yang umum sesuai *best practice*.

Pada penelitian ini digunakan data uji yang dibuat oleh Paul Gorman dan Terry Sejnowski (Salk Institute dan University of California at San Diego). Data uji diekstraksi dari sinyal SONAR yang dihamburkan oleh ranjau yang berbentuk silinder logam dan batu berbentuk mirip atau mendekati silinder. SONAR yang ditransmisikan berupa sinyal chirp yang termodulasi frekuensi, yang semakin bertambah semakin besar frekuensinya. Data uji berisi sinyal yang diperoleh dari berbagai sudut yang berbeda, mulai dari 90 sampai 180 derajat. Data uji berjumlah 208 buah, terdiri dari 111 buah berlabel ranjau dan 97 buah berlabel batu seperti yang dijelaskan oleh Ghosh [8]. Data uji terdiri dari 60 buah fitur yang bernilai numerik yang sudah dinormalisasi seperti yang terlihat pada Gambar 2. Pada gambar tersebut, terlihat bahwa seluruh fitur sehingga bernilai dari 0,0 sampai dengan 1,0 dengan nilai minimal dan maksimal bervariasi. Setiap fitur mewakili energi pada jalur frekuensi tertentu yang diintegrasikan pada periode waktu tertentu.



Gambar 2. Grafik boxplot dari sepuluh fitur yang pertama

Data uji dibagi secara acak menjadi dua bagian yang saling *disjoint* atau terpisah satu sama lain alias tidak saling beririsan. Pada setiap percobaan, 75% data digunakan sebagai pelatihan atau *training*, sedangkan sisanya digunakan sebagai data pengujian. Percobaan diulangi sebanyak 20 kali. Percobaan dilakukan dengan menggunakan model *multilayer perceptron* (MLP) dengan beberapa variasi jumlah neuron yang berbeda lapisan tersembunyi, sehingga terdapat 13 buah struktur JST yang berbeda. Pada paper ini lapisan tersembunyi yang digunakan adalah 2 lapis saja, dengan demikian arsitektur JST yang digunakan adalah seperti yang terlihat pada Gambar 1. Setiap struktur JST kemudian dicoba dengan menggunakan fungsi aktivasi 6 jenis untuk lapisan tersembunyi serta 3 jenis untuk lapisan luaran. Dengan demikian jumlah total percobaan yang dilakukan adalah sebanyak $13 \times 6 \times 3 \times 20$ atau sebanyak 4680 kali percobaan.

3. HASIL DAN ANALISIS

Agar model DNN menghasilkan kinerja yang optimal, diperlukan ketepatan dalam memilih struktur JST, fungsi aktivasi untuk lapisan tersembunyi, fungsi aktivasi untuk lapisan luaran, dan penentuan jumlah *batch* yang digunakan saat proses pembelajaran. Dan tentu saja hal itu selain masalah umum yang terdapat di proses pembelajaran mesin pada umumnya seperti pemilihan fitur, pra-proses untuk menghasilkan dataset yang bermutu, dan lain sebagainya. Untuk mendapatkan DNN dengan hasil yang optimal dapat dilakukan secara *trial and error*, karena model yang cocok hanyalah untuk problem spesifik yang sedang diselesaikan alias tidak berlaku umum. Proses *trial and error* untuk memperoleh model yang tepat dapat dilakukan dengan mencoba seluruh kombinasi yang mungkin. Kombinasi yang dapat digunakan antara lain meliputi pemilihan struktur DNN, jenis fungsi aktivasi untuk lapisan tersembunyi dan lapisan luaran, jumlah *batch*, algoritme yang dipakai untuk optimasi, dan sebagainya.

Penelitian ini menggunakan struktur JST yang sederhana yaitu *multilayer perceptron* (MLP) dengan lapisan tersembunyi sebanyak 2 buah yang masing-masing terdiri dari sejumlah n neuron seperti yang terlihat pada Gambar 1. Fungsi aktivasi yang digunakan terdiri dari 6 jenis untuk lapisan tersembunyi; yaitu *reLU*, *sigmoid*, *tanh*, *eLU*, *seLU*, dan *linear*. Sedangkan fungsi aktivasi yang digunakan untuk lapisan luaran adalah 3 jenis; yaitu *softmax*, *sigmoid*, dan *linear*. Secara lengkap, fungsi aktivasi yang digunakan seperti yang terlihat pada Tabel 1. Sedangkan algoritme atau metode yang digunakan untuk mengubah nilai atribut JST seperti bobot dan kecepatan pembelajaran adalah *adaptive moment estimation*.

Tabel 1. Fungsi aktivasi yang digunakan pada lapisan tersembunyi dan lapisan luaran

Lapisan Tersembunyi	Lapisan Luaran
reLU	softmax
sigmoid	sigmoid
tanh	linear
eLU	
seLU	
linear	

Dengan menggunakan dataset yang telah disiapkan dan sejumlah model telah dibentuk, kemudian percobaan dilakukan sebanyak 4680 kali. Dari setiap percobaan dicatat berapa nilai akurasi yang diperoleh dari masing-masing percobaan. Dari sejumlah percobaan tersebut, kemudian dipilih akurasi minimal, maksimal, dan rata-rata seperti yang terlihat pada Tabel 2. Sebelum dilakukan percobaan, dataset dibagi menjadi dua bagian. Bagian pertama adalah untuk pelatihan (*training*) sebanyak 75% dari total dataset, digunakan untuk membentuk model pengklasifikasi. Sedangkan sisanya sebanyak 25% digunakan sebagai data uji coba (*testing*).

Tabel 2. Akurasi MIN, MAX, dan AVG yang diperoleh dari 4680 kali percobaan

Aktivasi Lapisan Tersembunyi	Fungsi aktivasi Lapisan Luaran								
	linear			sigmoid			softmax		
	MIN	MAX	AVG	MIN	MAX	AVG	MIN	MAX	AVG
eLU	44.23	88.46	67.60	76.92	88.46	81.86	76.92	88.46	81.68
linear	42.31	86.54	59.73	73.08	80.77	76.48	73.08	82.69	76.64
reLU	42.31	96.15	81.42	76.92	92.31	85.90	78.85	92.31	85.71
seLU	34.62	92.31	59.01	76.92	86.54	81.49	76.92	88.46	81.66
sigmoid	38.46	90.38	61.57	80.77	88.46	84.03	80.77	88.46	84.01
tanh	44.23	90.38	68.39	76.92	86.54	82.24	75.01	88.46	82.23

Pada Tabel 2 terlihat bahwa secara umum fungsi aktivasi *rectified linear unit* (reLU) yang digunakan untuk fungsi tersembunyi memberikan hasil yang lebih memuaskan dibandingkan dengan fungsi aktivasi jenis lainnya. Bahkan fungsi aktivasi reLU yang diterapkan pada lapisan tersembunyi juga tetap memberikan akurasi yang tetap baik walaupun menggunakan lapisan luarnya memakai fungsi aktivasi yang berbeda. Secara rata-rata kombinasi reLU-sigmoid adalah memberikan akurasi yang paling besar yaitu sebesar 85.9%. Sehingga hasil ini dapat digunakan sebagai justifikasi bahwa secara umum untuk awal percobaan dapat dipilih kombinasi fungsi aktivasi *reLU-sigmoid*.

Hal yang menarik adalah ternyata kombinasi *reLU-linear* memberikan hasil akurasi yang paling besar yaitu sebesar 96.15%. Pada sisi lain, kombinasi *reLU-linear* juga memberikan akurasi yang paling jelek yaitu sebesar 42.3%. Hal ini dapat terjadi karena proses penentuan bobot yang dilakukan teknik *adaptive moment estimation* adalah berdasarkan nilai acak yang berikan. Akan tetapi apabila ternyata nilai bobot dari neuron yang telah diperoleh melalui deep learning akan memberikan kinerja yang baik dan stabil, maka proses pencarian model DNN dapat dihentikan jika telah memenuhi syarat akurasi minimal yang ditentukan. Dengan demikian pada penelitian selanjutnya perlu diteliti lagi apakah akurasi sebesar itu mampu dan memberikan hasil yang stabil untuk berbagai kondisi data ujicoba.

Dari Tabel 1 dapat dilihat bahwa secara umum, untuk fungsi aktivasi *sigmoid* dan *softmax* yang digunakan pada lapisan luaran memberikan akurasi yang lebih baik jika dibandingkan dengan fungsi aktivasi linier. Akurasi yang lebih baik ini terutama apabila menggunakan *reLU* sebagai fungsi aktivasi pada lapisan tersembunyi. Selain itu, akurasi yang dihasilkan sigmoid adalah sedikit lebih baik dibandingkan *softmax*. Hal ini dapat dilihat pada Tabel 3 yang berisi hasil rekapitulasi yang diperoleh dari sejumlah percobaan yang menerapkan *reLU* pada lapisan tersembunyi untuk berbagai jumlah neuron.

Tabel 3. Rerata akurasi dengan *ReLU* sebagai fungsi aktivasi pada lapisan tersembunyi

Jumlah Neuron per lapisan	Fungsi aktivasi Lapisan Luaran		
	linear	sigmoid	softmax
10	80.10	84.23	84.52
40	77.21	85.19	84.90
50	81.35	84.13	84.90
60	84.71	85.10	86.15
70	80.19	85.77	85.48
80	82.98	86.73	85.67
90	82.31	86.92	87.02
100	83.37	87.60	84.90
110	83.37	87.12	85.58
120	82.31	85.38	86.35
121	79.71	85.48	86.15
130	80.38	86.25	85.58
140	80.48	86.83	87.02
AVG	81.42	85.90	85.71

Pada percobaan ini masih belum terlihat perbedaan akurasi secara signifikan untuk jumlah neuron yang berbeda. Akan tetapi tingkat akurasi yang diperoleh pada penelitian ini secara rata-rata lebih baik dibandingkan dengan akurasi yang dilakukan oleh Gorman

dan Sejnowski. Gorman dan Sejnowski melakukan klasifikasi ranjau dan batu dengan memanfaatkan jaringan syaraf tiruan dengan jumlah *hidden unit* yang bervariasi mulai dari 0 sampai dengan 24 buah. Maksimal akurasi yang didapatkan oleh Gorman dan Sejnowski adalah sebesar 84,7% dan 90,4%. Akurasi tersebut diperoleh pada jaringan syaraf tiruan dengan *hidden unit* berjumlah 12 untuk data uji *angle-independent* dan *angle-dependent*.

Rata-rata akurasi terbaik yang diperoleh dengan menggunakan *deep learning* adalah sebesar 85,9% dengan akurasi maksimal sebesar 96,15% ini kemungkinan masih dapat ditingkatkan lagi dengan cara menjalankan ulang proses *training* atau pun mengubah arsitektur atau struktur JST yang dipakai. Alternatif yang mudah dilakukan antara lain adalah dengan melakukan pengulangan percobaan sampai diperoleh akurasi maksimal yang diinginkan dan menyimpan model tersebut untuk dipakai pada keperluan selanjutnya. Potensi untuk memperoleh akurasi yang maksimal dengan pengulangan proses *training* adalah mungkin dilakukan karena sifat dari penentuan bobot awal dari DNN dilakukan secara acak oleh sistem. Dapat juga dilakukan dengan menambah lapisan tersembunyi sehingga melibatkan jumlah lapisan yang lebih banyak. Selain itu dapat juga digunakan alternatif arsitektur JST yang lain seperti CNN dan RNN, serta tentu saja pemilihan fungsi aktivasi yang tepat pada setiap lapisan tersembunyi dan lapisan output.

4. KESIMPULAN

Pada penelitian ini telah ditunjukkan pemakaian DNN untuk membedakan ranjau bentuk silinder dan batu berbentuk bulat. Struktur jaringan syaraf tiruan yang digunakan adalah *multilayer perceptron* dengan 2 buah lapisan tersembunyi dan sejumlah fungsi aktivasi yang digunakan pada lapisan tersembunyi dan lapisan luaran. Model DNN menghasilkan rata-rata akurasi sebesar 85,9% dan maksimal akurasi sebesar 96,15% pada *multilayer perceptron* dengan jumlah neuron sebanyak 140 buah dengan fungsi aktivasi *rectified linear unit* (ReLU) bagi lapisan tersembunyi (*hidden layer*) dan *linear* untuk lapisan output. Hasil DNN ini lebih bagus dari penelitian sebelumnya yang menggunakan jaringan syaraf tiruan dengan 12 buah neuron pada lapisan tersembunyi.

Pada penelitian berikutnya akan akan dieksploitasi sejumlah struktur jaringan syaraf tiruan seperti *convolutional neural network* dan *recurrent neural network* yang berpotensi mampu meningkatkan kinerja. Selain itu perlu juga mengeksplorasi model DNN yang telah diperoleh dan diketahui memiliki akurasi terbesar apakah masih tetap stabil untuk berbagai data input masukan.

REFERENSI

- [1] L. Lu, H. Ni, W. Wang, L. Ma, J. Huang, and Q. Ren, "Experimental Results of Sediment Characterization by Processing Backscatter Envelope of Single-beam Sonar*," in *OCEANS 2019 - Marseille*, 2019, pp. 1–5.
- [2] H. Li, F. Yin, and C. Li, "A High-accuracy Target Tracking Method and Its Application in Acoustic Engineering," in *2019 IEEE 4th International Conference on Signal and Image Processing (ICSIP)*, 2019, pp. 690–694.
- [3] D. Cook, K. Middlemiss, P. Jaksons, W. Davison, and A. Jerrett, "Validation of fish length estimations from a high frequency multi-beam sonar (ARIS) and its utilisation as a field-based measurement technique," *Fisheries Research*, vol. 218, pp. 59–68, 2019.
- [4] J. Helminen and T. Linnansaari, "Object and behavior differentiation for improved automated counts of migrating river fish using imaging sonar data," *Fisheries Research*, vol. 237, p. 105883, 2021.
- [5] Y. Seo, B. Jang, and S. Im, "A Comparison of Machine Learning Schemes for Moving Direction Estimation with Acoustic Data," in *2019 International Conference on Electronics, Information, and Communication (ICEIC)*, 2019, pp. 1–3.
- [6] D. Einsidler, M. Dhanak, and P.-P. Beaujean, "A Deep Learning Approach to Target Recognition in Side-Scan Sonar Imagery," in *OCEANS 2018 MTS/IEEE Charleston*, 2018, pp. 1–4.
- [7] Y. Steiniger, J. Stoppe, T. Meisen, and D. Kraus, "Dealing With Highly Unbalanced Sidescan Sonar Image Datasets for Deep Learning Classification Tasks," in *Global Oceans 2020: Singapore U.S. Gulf Coast*, 2020, pp. 1–7.
- [8] R. Ghosh, "Sonar Target Classification Problem : Machine Learning Models," vol. 9, no. 1, pp. 247–248, 2020.
- [9] Z. Wei, Y. Ju, and M. Song, "A Method of Underwater Acoustic Signal Classification Based on Deep Neural Network," in *2018 5th International Conference on Information Science and Control Engineering (ICISCE)*, 2018, pp. 46–50.
- [10] J. H. Christensen, L. V. Mogensen, and O. Ravn, "Deep Learning based Segmentation of Fish in Noisy Forward Looking MBES Images," *IFAC-PapersOnLine*, vol. 53, no. 2, pp. 14 546–14 551, 2020.
- [11] G. Xu, Q. Chen, T. Yoshida, K. Teravama, Y. Mizukami, Q. Li, and D. Kitazawa, "Detection of Bluefin Tuna by Cascade Classifier and Deep Learning for Monitoring Fish Resources," in *Global Oceans 2020: Singapore U.S. Gulf Coast*, 2020, pp. 1–4.
- [12] B. V. Deep and R. Dash, "Underwater Fish Species Recognition Using Deep Learning Techniques," in *2019 6th International Conference on Signal Processing and Integrated Networks (SPIN)*, 2019, pp. 665–669.
- [13] J. Seok, "Active sonar target classification using multi-aspect sensing and deep belief networks," *International Journal of Engineering Research and Technology*, vol. 11, pp. 1999–2008, 2018.

-
- [14] L. J. Ziomek, *An Introduction to Sonar Systems Engineering*, 1st ed. Boca Raton: CRC Press, 2017.
- [15] X. Wu, V. Kumar, Q. J. Ross, J. Ghosh, Q. Yang, H. Motoda, G. J. McLachlan, A. Ng, B. Liu, P. S. Yu, Z. H. Zhou, M. Steinbach, D. J. Hand, and D. Steinberg, *Top 10 algorithms in data mining*. Chapman and Hall/CRC, dec 2009.
- [16] H. Rahman, M. U. Ahmed, S. Begum, M. Fridberg, and A. Hoflin, “Deep Learning in Remote Sensing: An Application to Detect Snow and Water in Construction Sites,” in *2021 4th International Conference on Artificial Intelligence for Industries (AII)*, 2021, pp. 52–56.
- [17] L. Deng and D. Yu, *Deep Learning: Methods and Applications*. Now Foundations and Trends, 2014.
- [18] T. Arif, *Introduction to Deep Learning for Engineers: Using Python and Google Cloud Platform*. Morgan & Claypool, 2020, vol. 5.
- [19] R. Vang-Mata, *Multilayer Perceptrons: Theory and Applications*. Nova Science, 2020.