

Model Prediksi Jumlah Pakan menggunakan Algoritma Evolusi Pikiran Jaringan Syaraf Tiruan Rambat Balik untuk Budidaya Udang

Erwin Adriono*, Maman Somantri, Chrisna Adhi Suyono

Departemen Teknik Elektro, Fakultas Teknik, Universitas Diponegoro
Departemen Ilmu Kelautan, Fakultas Perikanan dan Ilmu Kelautan, Universitas Diponegoro
Jl. Prof. Soedarto, SH, Tembalang, Semarang, Jawa Tengah 50275 Indonesia
Email: erwinadriono@gmail.com

Abstract

Feeding Quantity Prediction Model using Mind Evolution Algorithm Back Propagation Neural Network for Shrimp Aquaculture

Determining the appropriate amount of feed is important in the aquaculture of *Litopenaeus Vannamei* shrimp. The amount of feed can be influenced by many factors including the number of shrimp, shrimp age, DO, salinity, alkalinity, temperature and PH. The relationship between these factors and the amount of feed is difficult to make in mathematical equations or with statistical methods. These problems can be solved using a neural network. Neural network is a solution for modeling complex input and output relationships. The relationship between the amount of feed and other factors will be modeled using the Backpropagation NN method combined with optimization algorithms such as Genetic Algorithm and Mind Evolutionary Algorithm. The BPNN, BPNN – GA and BPNN MEA models will be compared using MSE, RSME, MAE and MAPE. Of the three methods used, the best results were obtained on BPNN MEA, with values of MSE, RSME, MAE and MAPE respectively 40,92; 6,39; 6,51 and 20,29.

Keywords : *Litopenaeus Vannamei*, Prediction model, BPNN, MEA

Abstrak

Menentukan jumlah pakan yang sesuai merupakan hal penting dalam kegiatan budidaya udang berjenis *Litopenaeus Vannamei*. Jumlah pakan dapat dipengaruhi oleh banyak faktor antara lain Jumlah Udang, Umur udang, DO, Salinitas, Alkalinitas, Suhu dan PH. Hubungan antar faktor tersebut dengan jumlah pakan sulit dibuatkan dalam persamaan matematis maupun dengan metode statisik. Permasalahan tersebut dapat diselesaikan menggunakan Neural network. Neural network menjadi solusi untuk memodelkan hubungan input dan output yang kompleks. Hubungan Jumlah pakan dan faktor lainnya akan dimodelkan menggunakan metode Backpropagation NN yang dikombinasikan dengan algoritma optimasi seperti Genetic Algorithm dan Mind Evolutionary Algorithm. Model BPNN, BPNN – GA dan BPNN MEA akan dibandingkan performa menggunakan MSE, RSME, MAE dan MAPE. Dari ketiga metode yang digunakan didapatkan hasil paling baik adalah pada BPNN MEA yaitu nilai MSE, RSME, MAE dan MAPE berturut-turut adalah 40,92; 6,39; 6,51 dan 20,29.

Kata Kunci : *Litopenaeus Vannamei*, Model Prediksi, BPNN, MEA

PENDAHULUAN

Udang merupakan salah satu komoditas perikanan ekspor terbesar di Indonesia. Selama tahun 2007 sampai dengan 2016 Indonesia mengalami trend kenaikan nilai ekspor komoditas perikanan dengan pertumbuhan rata-rata mencapai 5,3 % tiap tahunnya. Berdasarkan nilai ekspor tersebut, udang berkontribusi sebesar 39% (Sitompul *et al.*, 2018). *Litopenaeus vannamei* merupakan salah satu jenis udang yang paling banyak dibudidayakan sekitar 70 % dari seluruh jenis udang (Bardera *et al.*, 2021).

Udang berjenis *Litopenaeus Vannamei* lebih cepat dibesarkan dan tahan terhadap penyakit dibandingkan jenis udang lainnya (Navghan *et al.*, 2015). Udang memiliki cara makan yang berbeda dengan jenis ikan ikanan. Udang mencari makan dengan menggunakan kaki depannya dan hanya dapat makan dalam jumlah sedikit dalam satu waktu (Bardera *et al.*, 2021). Jika jumlah pakan melebihi dari yang dibutuhkan oleh udang maka pakan tersebut dapat mencemari air. Penurunan kualitas air ini meningkatkan angka kematian dari udang (Bardera *et al.*, 2019).

Jumlah pakan dapat dihitung menggunakan persamaan matematis. Perhitungan jumlah pakan dapat dihitung berdasarkan jumlah, berat dan *feeding rate* (Mansyur *et al.*, 2014). *Feeding rate* merupakan persentase jumlah pakan berdasarkan berat udang (biomassa) dan biasanya didapatkan berdasarkan jenis pakan yang digunakan maupun hasil uji coba. Pada prakteknya jumlah pakan juga dapat ditambah ataupun dikurang dengan metode cek anco. Cek anco merupakan metode untuk mengukur nafsu makan dari udang dengan cara menaruh sebagian pakan pada jaring anco. Jika pakan pada jaring anco kosong maka pada pemberian pakan selanjutnya jumlah pakan akan ditambah. Hal berbeda jika pada jaring anco pakan tidak habis maka jumlah pakan akan dikurangi. Berdasarkan penelitian sebelumnya hal ini bisa terjadi karena nafsu makan udang dipengaruhi oleh kondisi lingkungannya seperti kualitas air. DO, Suhu, PH, Salinitas dan Alkalinitas merupakan beberapa faktor kualitas air. Jika kualitas air terjaga maka udang akan memiliki nafsu makan yang baik (Bardera *et al.*, 2021) (Ullman *et al.*, 2019). Nafsu makan yang baik akan menghasilkan udang dengan perkembangan yang optimal (Reis *et al.*, 2020; Ulumiah *et al.*, 2020).

Melalui perkembangan AI dan teknologi di bidang budidaya, jumlah pakan dapat ditentukan dengan hasil yang lebih baik. Berdasarkan (Zhou *et al.*, 2017) dan (Li *et al.*, 2020) terdapat beberapa metode untuk menentukan pakan menggunakan yaitu menggunakan AI, Model Matematis, Sensor acoustic (Suara) dan Sensor Penglihatan. Metode dengan menggunakan sensor penglihatan sudah diterapkan oleh (Zhou *et al.*, 2018) dinilai mampu secara akurat memprediksikan jumlah pakan pada budidaya. Metode lain yang termasuk dalam Metode sensor acoustic adalah dengan menggunakan acoustic tag. Hasil dari penelitian (Adegboye *et al.*, 2020) menunjukkan melalui menggunakan Acoustic tag yang tertanam pada ikan mampu menghasilkan sistem pemberian pakan pada ikan. Pemberian pakan dapat dilakukan kalkulasi dengan metode matematis. (Estevão *et al.*, 2020) menunjukkan melalui perhitungan biomassa kita dapat memperoleh kebutuhan pakan pada udang *Litopenaeus Vannamei*.

Neural network (NN) merupakan salah satu metode untuk memodelkan hubungan masukan dan keluaran. NN meniru konsep otak manusia dimana terdapat banyak neuron – neuron yang terhubung. Neuron- neuron yang terhubung ini akan menghasilkan suatu kecerdasan untuk dapat menyelesaikan suatu permasalahan. NN terdiri dari input layer, hidden layer dan output layer yang nantinya akan terhubung satu dengan lainnya untuk dapat memodelkan permasalahan. *Back Propagation Neural Network* (BPNN) merupakan salah satu metode pengembangan dari NN. BPNN sudah memiliki kemampuan untuk belajar. BPNN mampu untuk meminimalkan error dan memperoleh hasil yang stabil dengan cara mengumpukan balikan keluaran yang diperoleh (Chen *et al.*, 2020). Karena kemampuan ini, BPNN banyak digunakan oleh para peneliti untuk memodelkan beragam masalah pada budidaya (Adegboye *et al.*, 2020; Chen *et al.*, 2020; C. Li *et al.*, 2018; Liu *et al.*, 2020)

BPNN dapat ditingkatkan performanya menggunakan metode optimasi. Berdasarkan beberapa penelitian sebelumnya (Chen *et al.*, 2020; W. Wang *et al.*, 2018; Z. Wang *et al.*, 2019), Permasalahan model prediksi seperti prediksi gelombang laut, prediksi jumlah pakan ikan, prediksi profil dan kedataran dari plat besi dapat memiliki performa lebih baik. Berdasarkan hasil penelitian sebelumnya kombinasi BPNN MEA memiliki performa yang terbaik dibandingkan metode lainnya seperti, BPNN dan BPNN GA.

Penelitian ini bertujuan untuk membuat model jumlah pemberian pakan udang *L. vannamei* yang dibudidaya di tambak *Marine Science Tecnopark* (MSTP) UNDIP. Metode pemodelan yang akan digunakan adalah BPNN yang akan dipadukan dengan algoritma MEA. Metode ini akan dibandingkan performanya terhadap BPNN dan BPNN - GA. Performa dari masing-masing metode akan diukur dengan mean square error (MSE), mean absolute error (MAE), Mean Absolute Percentage Error (MAPE), dan root mean square error (RMSE). Keluaran yang diharapkan dari penelitian ini adalah didapatkan model jumlah pakan pada budidaya udang yang memiliki performa yang baik sehingga dapat dipergunakan oleh para petambak.

MATERI DAN METODE

Data yang digunakan diperoleh dari tambak udang *Marine Science Techno Park (MSTP)* Universitas Diponegoro yang berlokasi di kota Jepara. Tambak udang tersebut membudidayakan udang berjenis *Litopenaeus Vannamei*. Tambak udang tersebut memiliki 8 kolam dengan kapasitas tiap kali panen per siklus adalah sekitar 12 ton. Durasi untuk tiap siklusnya adalah selama 3 bulan.

Proses pembesaran udang dilakukan semenjak dilakukan penerapan benur udang. Udang pada fase ini akan berukuran sangat kecil yaitu berkisar 8 mm. Selama proses pembesaran udang akan terus diberi pakan dan dipantau kualitas air. Pada proses pembesaran udang akan dilakukan panen secara parsial. Panen parsial ini bertujuan agar kepadatan pada kolam berkurang sehingga udang yang tidak terpanen dapat tumbuh lebih baik. Pada saat udang sudah berukuran minimal size 70 (1 kg berisi 70 ekor udang) maka udang sudah dapat panen secara total.

Pada 30 hari pertama udang akan diberi pakan dengan metode *blind feeding*. *Blind feeding* adalah teknik pemberian pakan udang secara konstan dengan mengabaikan faktor-faktor lainnya seperti jumlah, berat dan cek anco. Apabila udang sudah berumur lebih dari 30 hari maka akan dilakukan sampling. Dari hasil sampling akan didapatkan jumlah udang dan berat rata-rata udang. Dari jumlah dan berat rata-rata udang akan dihitung kebutuhan jumlah pakan menggunakan rumus berikut (Mansyur *et al.*, 2014).

$$JP = JU \times S \times BU \times FR$$

Keterangan: JP = jumlah pakan yang diberikan dalam satuan kg, JU = Jumlah Udang dalam satuan ekor, S = Sintasan (*Survival Rate*) dalam persen, BU = berat udang dalam satuan gram dan FR = *Feeding Rate* dalam satuan persen.

Pada praktiknya jumlah pakan tidak selalu sesuai dengan hasil perhitungan. Pada proses pemberian pakan terdapat metode cek anco. Cek anco merupakan metode untuk mengetahui nafsu makan dari udang dengan cara memberikan sedikit pakan pada jaring anco untuk kemudian dicek kondisi pakan pada jaring tersebut. Jika jumlah pakan pada jaring anco habis maka pada pemberian pakan selanjutnya pakan akan ditambah dan jika pada jaring anco tersisa maka jumlah pakan akan dikurangi. Jumlah pakan yang ditambah dan dikurangi pada metode ini bergantung pada pengalaman dari petambak. Meskipun metode ini dinilai dapat lebih mengoptimalkan jumlah pakan namun pengalaman dari petambak berperan penting dalam jumlah pakan yang akan diatur.

Berdasarkan beberapa referensi seperti kualitas air perlu dipertahankan agar nafsu makan dari udang bisa optimal dan pertumbuhan udang dapat lebih baik. Beberapa parameter kualitas air yang penting untuk dijaga antara lain *dissolve oksigen (DO)*, PH, Salinitas dan Suhu. DO harus berkisar antara 4 – 7 ppm, PH antara 7,9 – 8,5, Suhu 28,72 – 29,22 °C, Salinitas 22 – 23 ppt (Ariadi *et al.*, 2020; Mansyur *et al.*, 2014)

Akuisisi data

Data parameter kualitas air akan diambil tiap harinya menggunakan alat ukur yang sudah terkalibrasi. Parameter DO, Suhu, PH dan Salinitas akan diambil 2 kali tiap harinya pada saat pagi hari dan sore hari. Pengambilan data dilakukan pada semua kolam. Data input terdiri dari data Jumlah, data berat, data umur, Salinitas, Suhu, PH dan DO. Data jumlah dan berat diperoleh melalui hasil sampling yang dilakukan 1 minggu sekali. Data Salinitas, Suhu, PH dan DO diperoleh melalui hasil pengukuran yang dilakukan setiap hari. Data output terdiri dari data jumlah pakan yang didapat dari pencatatan pemberian pakan. Tabel 1 adalah contoh dari data yang digunakan pada penelitian ini.

Tabel 1. Contoh data penelitian

Jumlah	Berat	Umur (Hari)	Suhu rata-rata	Salinitas rata-rata	DO rata-rata	PH rata-rata	Jumlah pakan
190.500	2,808989	35	24,84	11,6	4,522	7,56	40,0
190.500	3,128262	36	25,24	10,8	4,458	7,8	41,0
190.500	3,447536	37	25,42	10,2	3,808	7,66	39,0
190.500	3,766809	38	25,34	10,4	4,236	7,66	40,0
190.500	4,086082	39	25,44	14,8	4,012	7,68	41,0
190.500	4,405356	40	24,6	15	3,52	7,72	43,0
190.500	4,724629	41	24,66	14,2	4,264	7,54	44,0
190.500	5,043902	42	24,62	14,8	4,262	7,34	46,0
190.500	5,204408	43	23,76	14,6	4,418	7,36	47,0
190.500	5,364914	44	23,4	15	4,402	7,88	45,0
190.500	5,525419	45	23,64	15,6	4,74	7,88	36,0

Pra-pemrosesan data

Pra-pemrosesan data bertujuan agar pada pembuatan model memiliki performa yang terbaik. Data input akan diseleksi antara lain dengan menghilangkan data yang tidak lengkap, data yang terduplikat dan data anomali. Melalui pemrosesan data tersebut, data yang diolah akan berkurang jumlahnya dan menyisakan data yang siap untuk diolah.

Data selanjutnya akan melalui proses normalisasi. Proses normalisasi data bertujuan agar pada tiap parameter memiliki pengaruh yang sama terhadap keluaran dari model. Proses normalisasi diperlukan apabila antar data memiliki besaran yang berbeda. Perhitungan normalisasi menggunakan rumus sebagai berikut :

$$D_{norm} = \frac{D_i - D_{min}}{D_{max} - D_{min}}$$

Keterangan: D_{norm} = data hasil normalisasi, D_i = data yang dinormalisasi, D_{min} = data yang paling kecil nilainya, D_{max} = data yang paling besar nilainya.

Data yang melalui proses normalisasi akan menjadi normatif dimana nilai maksimal dari data akan sebesar 1 dan data minimal dari data akan menjadi 0. Berdasarkan (Chen *et al.*, 2020; Z. Wang *et al.*, 2019; Wu *et al.*, 2018) normalisasi data dapat menjadikan model memiliki kemampuan dan performa yang lebih baik .

Data yang sudah melalui proses normalisasi selanjutnya akan dibagi. Data akan dibagi menjadi 2 yaitu data latih dan data uji. Jumlah data latih adalah sebesar 80% dari keseluruhan data sedangkan data uji berjumlah 20% sisanya. Data latih digunakan untuk melatih model. Setelah model selesai dilatih model akan diuji menggunakan data uji.

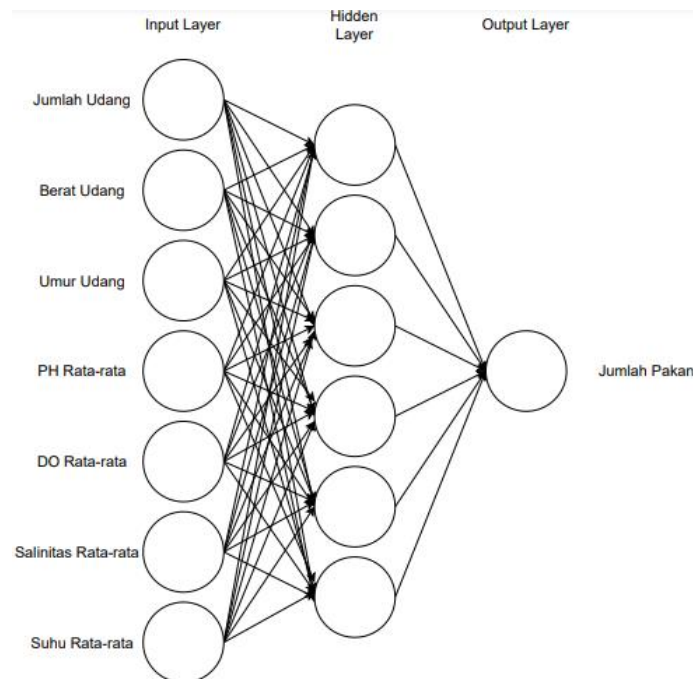
Backpropagation Neural Network (BPNN)

BPNN merupakan NN yang memiliki kemampuan untuk memperbaharui nilai beban dan bias agar keluaran dari NN dapat lebih dari segi performa. Kemampuan BPNN dalam melakukan meperbaharui nilai beban inilah yang menjadikan BPNN populer untuk digunakan. BPNN terdiri dari 3 layer yaitu *input layer*, *hidden layer* dan *output layer*. *Input layer* berisi data masukan dari model yang akan dibuat. *Hidden layer* merupakan *layer* tersembunyi yang menghubungkan *input layer* dan *output layer*. *Hidden layer* dapat terdiri dari 1 atau lebih. Jumlah node pada hidden layer dapat dihitung dengan menggunakan rumus sebagai berikut (Chen *et al.*, 2020):

$$h = \sqrt{i + o} + lr$$

Keterangan: h = Jumlah node pada *hidden layer*, i = Jumlah *layer input*, o = Jumlah *layer output*, lr = *learning rate*.

Berdasarkan perhitungan didapatkan Jumlah node pada *hidden layer* adalah 6 node. Gambar 1 menunjukkan keseluruhan arsitektur dari BPNN pada penelitian ini. Input layer terdiri dari 7 node. Node ini terdiri dari data Jumlah, data berat, data umur, Salinitas, Suhu, PH dan DO. Jumlah *layer* pada *hidden layer* adalah 1. *Hidden layer* tersebut terdiri dari 6 node. Layer output terdiri dari 1 node. Layer output berisi data jumlah pakan.



Gambar 1. Arsitektur BPNN

Perhitungan BPNN terdiri dari 2 tahapan. Tahapan ini didasarkan pada jumlah *layer* pada *hidden layer*. Berikut adalah rumus pada tahapan pertama.

$$H_j = f \left(\sum_{i=1}^n W_{ij} X_i + b_j \right) \quad j = 1, 2, \dots, l$$

Keterangan: H_j = Keluaran dari *hidden layer*, W_i = Bobot pada *hidden layer*, X = data masukan, b_j = bias pada *hidden layer*. $f()$ = *activation function*

Pada tahapan pertama nilai H_j akan dihitung berdasarkan data X , W_i dan b_j . Nilai W_i dan b_j didapatkan dari hasil pelatihan model. Pada tahapan ini *activation function* yang digunakan adalah fungsi *sigmoid*. Keluaran dari *hidden layer* (H_j) selanjutnya akan dijadikan masukan untuk menghitung *output layer* seperti pada rumus berikut :

$$Y_o = f \left(\sum_{i=1}^n H_j W_{jk} + b_k \right) \quad k = 1, 2, \dots, m$$

Keterangan: Y_o = keluaran model, W_j = Bobot pada *output layer*, H_j = keluaran dari *Hidden layer*, b_k = bias pada *output layer*. $f()$ = *activation function*

Yo merupakan nilai akhir dari model dengan masukan dari hidden layer (H_j). Pada tahapan terdapat juga W_j dan b_k yang diperoleh dari hasil pelatihan model. *Activation function* pada hasil akhir ini menggunakan fungsi linear. Keluaran dari model BPNN dapat dihitung nilai errornya menggunakan rumus berikut :

$$e_k = O_k - Y_k \quad k = 1, 2, \dots, m$$

Keterangan: e = error, O = data keluaran aktual, Y = keluaran dari *output layer*.

Nilai error (e_k) akan semakin kecil atau mendekati nilai 0 apabila nilai keluaran (Y_k) mendekati data aktual (O_k). Apabila nilai error besar tentunya data dapat memiliki performa yang kurang baik. Untuk memperbaiki nilai error agar kecil maka nilai Bobot dan bias perlu diperbaharui. Berikut adalah rumus untuk memperbaharui nilai Bobot dan bias.

$$\begin{aligned} W_{ij} &= W_{ij} + lr H_j W_{gh} \quad j = 1, 2, \dots, l \\ W_{jk} &= W_{jk} + lr Y_o W_{gy} \quad k = 1, 2, \dots, m \\ b_j &= b_j + lr H_j b_{gh} \quad j = 1, 2, \dots, l \\ b_k &= b_k + lr Y_o b_{gy} \quad k = 1, 2, \dots, m \end{aligned}$$

Keterangan: W_i = Bobot *hidden layer*, W_j = Bobot *output layer*, b_j = bias *hidden layer*, b_k = bias *output layer*, lr = *learning rate*, H_j = keluaran *hidden layer*, Y_o = keluaran *output layer*, W_{gh} = gradient bobot *hidden layer*, W_{gy} = gradient bobot *output layer*, b_{gh} = gradient bias *hidden layer*, b_{gy} = gradient bias *output layer* aktual, Y = keluaran dari *output layer*.

Nilai bobot dan bias akan terus diperbaharui sampai dengan jumlah iterasi terpenuhi. Setelah jumlah iterasi sudah terpenuhi maka akan didapatkan model BPNN yang siap untuk diuji. Penentuan nilai *hyperparameter* pada BPNN akan sangat berpengaruh pada nilai keluaran dan proses pelatihan. Umumnya nilai *hyperparameter* akan ditentukan berdasarkan hasil uji coba. *Hyperparameter* pada BPNN adalah *learning rate*, jumlah node pada *hidden layer* dan Jumlah iterasi. *Learning rate* akan berpengaruh pada kecepatan dalam BPNN untuk memperbaharui bobot. Beberapa hal yang perlu diperhatikan pada BPNN adalah nilai *learning rate* harus sesuai. Nilai *learning rate* yang terlalu kecil menghasilkan proses pembelajaran akan terlalu lama. Jika nilai *learning rate* terlalu besar dapat mengakibatkan nilai konvergensi tidak tercapai dan nilai akurasi menjadi kurang baik.

Optimasi BPNN menggunakan MEA

BPNN memiliki kemampuan untuk belajar dengan cara memperbaharui nilai bobot berdasarkan data latih. Meskipun BPNN sudah memiliki kemampuan untuk belajar namun performa dari BPNN pada beberapa penelitian sebelumnya masih dapat ditingkatkan. Peningkatan performa ini bertujuan agar model yang dibuat memiliki kemampuan yang lebih baik. Jika model digunakan pada kasus prediksi maka kemampuan prediksi dari model akan mendekati hasil aktualnya.

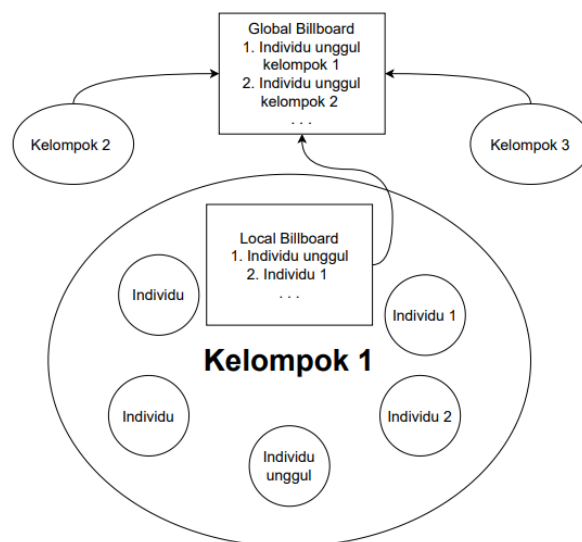
Pada BPNN pencarian nilai bobot dan bias yang sesuai dapat menggunakan metode optimasi. Salah satu metode optimasi yang memiliki performa yang baik adalah MEA. MEA merupakan metode optimasi yang meniru konsep evolusi berfikir pada manusia. Kemampuan berfikir manusia akan mengalami evolusi pada tiap generasinya. Generasi-generasi selanjutnya diharapkan menjadi semakin baik. Generasi-generasi lainnya akan meniru dan menjadikan generasi terbaik sebagai acuan dan akan melakukan pencarian untuk menjadi lebih baik. Konsep tersebut yang mendasari dari adanya MEA.

Konsep MEA dapat digambarkan pada gambar 2. Terdapat Individu yang terbentuk dan pada masing-masing individu memiliki nilai *fitness*. Nilai *fitness* dihitung berdasarkan rumus berikut (Z. Wang et al., 2019):

$$\text{Nilai Fitness} = \frac{1}{\sum_{i=1}^n (y_{\text{aktual}} - y_{\text{model}})^2 / n}$$

Keterangan : Y_{aktual} = nilai *output* aktual berdasarkan data lapangan, Y_{model} = nilai *output* pada model.

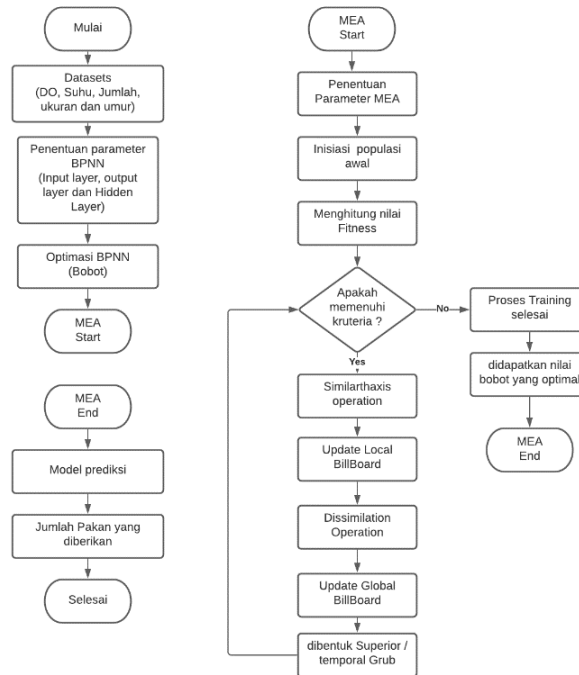
Nilai *fitness* yang semakin besar menunjukkan individu tersebut merupakan individu yang memiliki performa baik. Dari kumpulan dari individu tersebut akan membentuk kelompok. Masing-masing kelompok akan memiliki *local billboard*. *local billboard* berisi kumpulan nilai individu yang diurutkan berdasarkan yang terbaik. individu dengan nilai paling tinggi pada suatu kelompok akan menjadi kelompok unggul. Kumpulan dari individu unggul tiap kelompoknya akan membentuk *global billboard*. *global billboard* akan mengurutkan individu unggul terbaik pada tiap kelompok. Kelompok dengan nilai individu unggul terbaik akan menjadi kelompok unggul dan kelompok dengan nilai individu unggul dibawahnya akan menjadi kelompok temporal. Jika terdapat kelompok temporal yang memiliki nilai lebih tinggi dari kelompok unggul maka kelompok tersebut akan menggantikan kelompok tersebut dan berdasarkan nilai terbaik tersebut akan dibentuk individu dan grup baru untuk memenuhi jumlah kelompok. Berdasarkan konsep tersebut MEA memiliki beberapa hyperparameter yaitu Jumlah populasi individu, jumlah kelompok unggul, jumlah kelompok temporal, jumlah individu dalam satu kelompok, dan jumlah iterasi.



Gambar 2. Ilustrasi konsep MEA.

Langkah - langkah proses MEA adalah sebagai berikut : (1) Menentukan *Hyperparamer* pada MEA. (2) Membentuk individu unggul berdasarkan jumlah kelompok.(3) Membentuk individu baru berdasarkan individu unggul pada kelompok. (4) Membagi kelompok unggul dan kelompok temporal. (5) Menghitung *fitness* pada masing-masing individu menggunakan rumus (8). (6) Menentukan individu unggul pada tiap kelompok. (7) Pada masing-masing kelompok akan terjadi proses *similar-taxis*. Pada proses ini akan terjadi pencarian individu terbaik berdasarkan nilai *fitness*. Kumpulan nilai *fitness* akan menghasilkan *local billboard*. Jika terdapat individu memiliki nilai lebih tinggi dari pada individu unggul maka individu dengan nilai paling rendah pada local billboard akan dihapuskan dan akan dibentuk individu baru berdasarkan individu unggul yang baru. Proses ini akan terus berulang sampai tidak ada perubahan pada individu unggul. Jika proses ini sudah berakhir maka kelompok dapat dikatakan sudah dewasa dan telah siap untuk proses selanjutnya. (8) Pada tahapan selanjutnya seluruh kelompok akan mengalami proses disimilasi. Proses dissimilasi diawali dengan membentuk *global billboard*. kumpulan individu unggul dari seluruh kelompok yang ada

akan diurutkan menjadi global billboard. Jika ada kelompok temporal yang memiliki nilai lebih tinggi dari pada kelompok unggul maka kelompok dengan nilai terendah akan dieliminasi. Kelompok yang sudah dieliminasi akan membentuk individu baru dan kelompok baru berdasarkan individu unggul pada global billboard dan akan mengulang proses *similartaxis* pada kelompok tersebut. Proses dissimilasi akan berhenti tidak ada lagi perubahan pada jumlah kelompok unggul dan kelompok temporal atau jumlah iterasi sudah terpenuhi. (9) Setelah semua proses berakhir, individu dengan nilai paling tinggi dari *global billboard* akan dipilih menjadi solusi terbaik.



Gambar 3. Flow Chart BPNN MEA

Gambar 3 menunjukkan langkah dari pembuatan model. Pada tahap awal kumpulan data akan dipersiapkan dimana sebelumnya data sudah melalui pre-pemrosesan data. Setelah kumpulan data siap, maka langkah selanjutnya adalah menentukan *hyperparameter* pada BPNN. *Hyperparameter* mencakup jumlah iterasi, jumlah node hidden layer dan learning rate. Bobot dan bias selanjutnya akan ditentukan menggunakan metode MEA. Setelah proses MEA, model selanjutnya akan diuji menggunakan data uji.

Menghitung index performa

Index performa diperlukan untuk mengetahui kemampuan model dalam melakukan prediksi. Melalui perhitungan index performa akan diketahui model mana yang akan memiliki kemampuan prediksi terbaik. Index performa akan dibandingkan menggunakan *mean square error (MSE)*, *mean absolute error (MAE)*, *mean absolute percentage error (MAPE)*, dan *root mean square error (RSME)*. Perhitungan index performa dapat dilihat pada rumus berikut.

$$MSE = \frac{\sum_{i=1}^n (y_{aktual} - y_{model})^2}{n}$$

$$MAE = \frac{\sum_{i=1}^n |y_{aktual} - y_{model}|}{n}$$

$$RSME = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{aktual} - y_{model}}{y_{aktual}} \right|$$

$$MAPE = \sqrt{\frac{\sum_{i=1}^n |y_{aktual} - y_{model}|}{n}}$$

Keterangan : Y_{aktual} = nilai *output* aktual berdasarkan data lapangan, Y_{model} = nilai *output* pada model. n = jumlah data

Semakin kecil nilai Index performa menunjukkan model tersebut semakin baik dalam melakukan prediksi terhadap nilai aktualnya.

HASIL DAN PEMBAHASAN

Proses pemodelan berlangsung menjadi 2 tahapan yaitu pelatihan dan pengujian. Tahapan pelatihan dilakukan dengan memasukkan data latih. Setelah melalui proses pelatihan data selanjutnya akan diuji menggunakan data uji. Setelah melalui proses uji coba didapatkan *hyperparameter* terbaik dari masing-masing model yaitu BPNN MEA, BPNN GA dan BPNN. *Hyperparameter* hasil uji coba dapat dilihat pada tabel 2.

Tabel 2. Tabel *Hyperparameter* BPNN, MEA dan GA

Model	<i>Hyperparameter</i>	Nilai
MEA	Jumlah populasi	400
	Jumlah kelompok Unggul	10
	Jumlah kelompok Temporal	10
	Jumlah iterasi	20
GA	Jumlah populasi	400
	<i>Mutation rate</i>	0,25
	<i>Crossover rate</i>	0,01
	Jumlah iterasi	50
BPNN	Jumlah node <i>hidden layer</i>	6
	<i>Learning rate</i>	0,001
	Jumlah iterasi	100

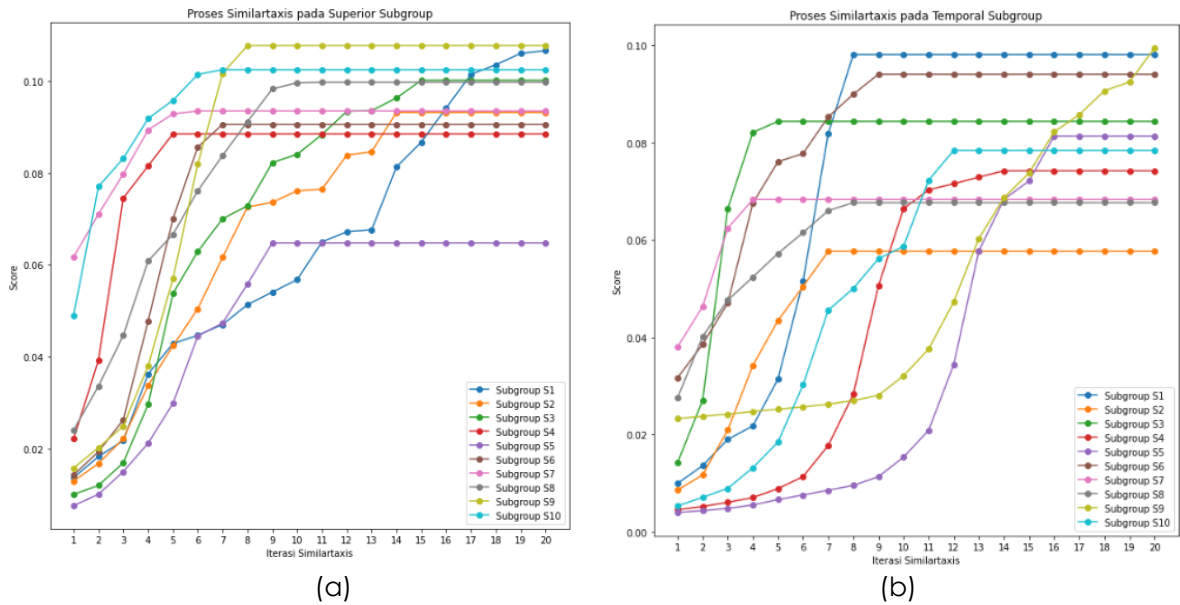
Model BPNN MEA akan melalui proses mencapai konvergensi melalui tahapan *similartaxis* dan *dissimilasi*. Proses ini akan berulang sampai didapatkan individu terbaik yang memiliki nilai paling tinggi dibandingkan dengan seluruh individu yang ada pada algoritma MEA. Proses *similartaxis* dan *dissimilasi* dapat diperlihatkan pada gambar 4 dan gambar 5.

Gambar 4 menunjukkan proses *similartaxis* pada BPNN - MEA. Gambar 4(a) menunjukkan proses *similartaxis* pada kelompok unggul dan gambar 4(b) menunjukkan proses pada kelompok temporal. Pada proses *similartaxis* akan ada perubahan nilai *fitness* dan akan berhenti apabila tidak ada perubahan pada nilai. Pada gambar 4(a) terlihat pada semua sub kelompok terjadi perubahan nilai individu unggul untuk mencapai kedewasaan. Pada kelompok unggul tercapai individu tertinggi mendapatkan *fitness* 0,1. Pada gambar 4(b) semua sub kelompok juga mengalami proses kedewasaan sampai dan mendapatkan nilai *fitness* tertinggi pada kelompok ini adalah 0,1. Pada tahapan *dissimilasi* kelompok temporal yang memiliki nilai tinggi seperti pada kelompok S1, S9 dan S8 akan bergabung dengan kelompok unggul. Sedangkan dari keseluruhan sub kelompok dengan nilai terendah seperti pada S2 kelompok temporal dan S5 kelompok unggul akan di eliminasi.

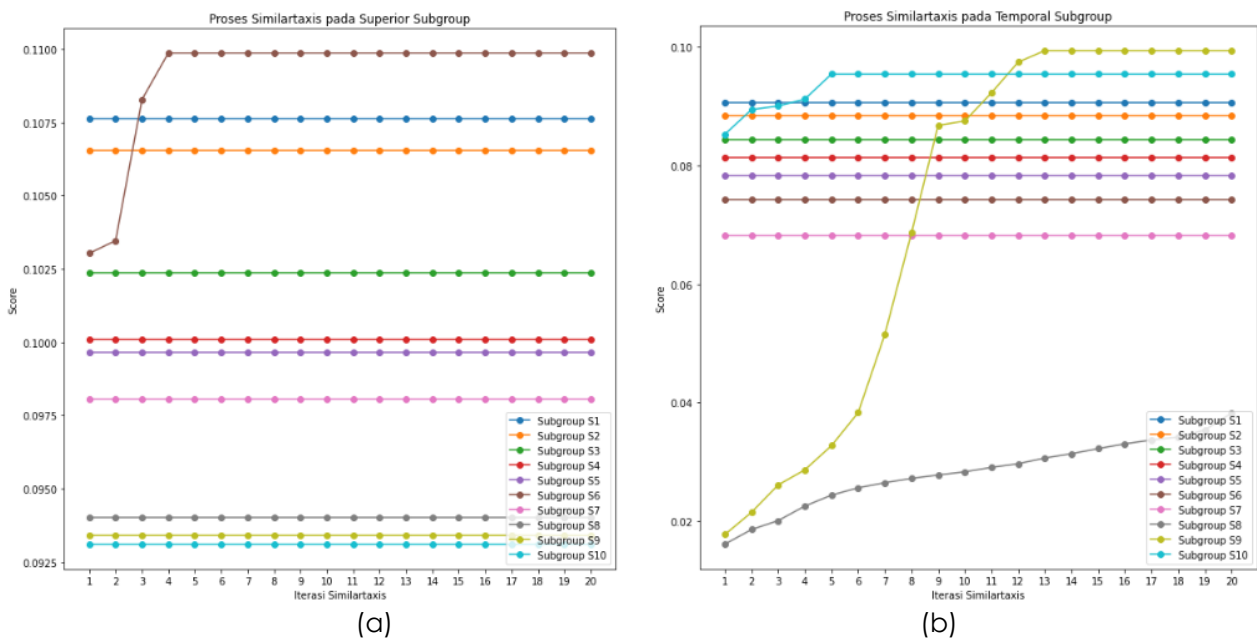
Gambar 5 menunjukkan proses *similartaxis* setelah dilakukan proses *dissimilasi*. Pada kumpulan kelompok temporal terdapat 2 sub kelompok baru yaitu S8 dan S9 . Sub kelompok S8 dan S9 akan mengulangi proses *similartaxis* sampai mencapai kedewasaan. Berdasarkan hasil akhir dari proses

MEA terdapat individu dengan nilai tertinggi adalah 0,11. Individu ini yang akan digunakan sebagai parameter pada BPNN.

Gambar 6 menunjukkan perbandingan keluaran model terhadap keluaran aktual. Data keluaran aktual didapatkan dari 20% dari keseluruhan data yang digunakan. Jumlah data yang digunakan untuk pengujian adalah sebanyak 120 data. Berdasarkan gambar 6 didapatkan BPNN MEA lebih mendekati data keluaran dibandingkan dengan BPNN GA dan BPNN. BPNN MEA memiliki akurasi tertinggi jika dibandingkan dengan BPNN GA dan BPNN pada penelitian ini.



Gambar 4. (a) Proses Similartaxis pada kelompok unggul, (b) Proses Similartaxis pada kelompok temporal



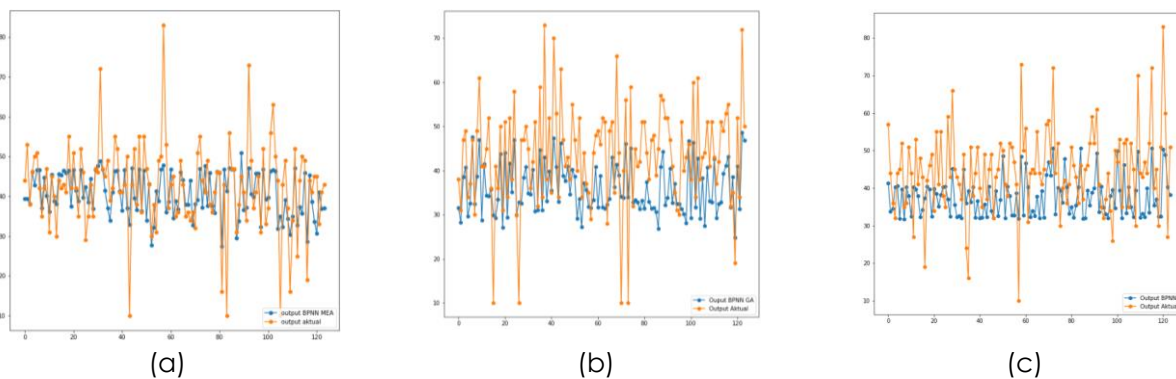
Gambar 5. (a) Proses Similartaxis pada kelompok unggul setelah proses dissimilasi, (b) Proses Similartaxis pada kelompok temporal setelah proses dissimilasi

Tabel 3 menunjukkan index performa dari masing – masing model. Nilai MSE, RSME, MAE dan MAPE yang terbaik adalah nilai yang paling kecil. Berdasarkan tabel 2, performa terbaik berturut turut dari yang terbaik adalah BPNN MEA, BPNN GA dan BPNN. BPNN MEA memiliki performa MSE 40,92, RSME 6,39, MAE 6,51 dan MAPE 20,29. Hal ini membuktikan BPNN dapat ditingkatkan performanya melalui penambahan algoritma optimasi. Performa BPNN MEA dan BPNN GA berada diatas performa BPNN.

Berdasarkan penelitian sebelumnya (Chen *et al.*, 2020; Liu *et al.*, 2015; W. Wang *et al.*, 2018; Z. Wang *et al.*, 2019) BPNN dapat ditingkatkan akurasi melalui penambahan algoritma optimasi. Pada hasil penelitian ini membuktikan BPNN memiliki performa dibawah BPNN GA dan BPNN MEA. Performa terbaik ada pada BPNN MEA. hal ini membuktikan metode optimasi MEA dapat mengungguli GA.

GA merupakan metode optimasi dengan banyak faktor *random* seperti pada proses pembentukan individu, Mutasi, *Crossover* dan proses pemilihan parent (W. Wang *et al.*, 2018). Sedangkan pada MEA faktor *random* hanya pada proses pembentukan individu. Faktor random akan membuat metode optimasi sulit dan lama dalam mencapai konvergensi.

MEA dapat memiliki performa terbaik disebabkan karena MEA mampu untuk mengolah banyak individu (parameter solusi) dalam satu waktu (Qiu & Xie, 2009; Sakharov *et al.*, 2015; Xu *et al.*, 2018). Berbeda dengan metode optimasi lainnya yang hanya berfokus pada beberapa individu. Karena banyak individu yang dapat diolah maka MEA mampu untuk mencari solusi terbaik dengan cepat. Masalah dengan banyak global minimal / maksimal palsu dapat diketahui dan tidak terjebak.



Gambar 6. (a) Grafik keluaran BPNN MEA dibandingkan dengan keluaran aktual. (b) Grafik keluaran BPNN GA dibandingkan dengan keluaran aktual. (c) Grafik keluaran BPNN dibandingkan dengan keluaran aktual.

Tabel 3. Index performa BPNN MEA, BPNN GA dan BPNN

Model	Index performa	Nilai
BPNN MAE	MSE	40,92
	RSME	6,39
	MAE	6,51
	MAPE	20,29
BPNN GA	MSE	69,94
	RSME	8,36
	MAE	9,66
	MAPE	25,91
BPNN	MSE	74,44
	RSME	12,20
	MAE	10,55
	MAPE	25,17

KESIMPULAN

Melalui penelitian ini model pemberian pakan menggunakan model BPNN - MEA menghasilkan performa terbaik jika dibandingkan dengan BPNN GA dan BPNN. BPNN dapat ditingkatkan performanya melalui penambahan algoritma optimasi seperti MEA dan GA. Model dibuat berdasarkan data masukan berupa Jumlah udang, berat udang, umur udang, DO, PH, Suhu dan Salinitas. Data yang digunakan adalah data yang dapat dari tambak udang milik MSTP UNDIP. BPNN MEA memiliki index performa terbaik dengan nilai MSE 40,92, RSME 6,39, MAE 6,51 dan MAPE 20,29. Pada penelitian kedepannya perlu dibandingkan performa dari model ini dengan model lainnya seperti RNN dan metode *Deep Learning* lainnya. Model juga bisa dibandingkan dengan algoritma lainnya seperti *Particle Swamp Optimization* dan *Ant colony*.

DAFTAR PUSTAKA

- Adegboye, M.A., Aibinu, A.M., Kolo, J.G., Aliyu, I., Folorunso, T.A. & Lee, S.H. (2020). Incorporating Intelligence in Fish Feeding System for Dispensing Feed Based on Fish Feeding Intensity. *IEEE Journals & Magazine*, 8, 91948–91960. doi: 10.1109/ACCESS.2020.2994442
- Ariadi, H., Wafi, A. & Supriatna. (2020). Water Quality Relationship with FCR Value in Intensive Shrimp Culture of Vannamei (*Litopenaeus vannamei*). *Jurnal Ilmu Perikanan*, 11(1), 44–50. doi: 10.35316/jsapi.v11i1.653
- Bardera, G., Owen, M.A.G., Façanha, F.N., Alcaraz-calero, J.M., Alexander, M.E. & Sloman, K.A. (2021). The influence of density and dominance on Pacific white shrimp (*Litopenaeus vannamei*) feeding behaviour. *Aquaculture*, 531, p.735949. doi: 10.1016/j.aquaculture.2020.735949
- Bardera, G., Owen, M.A.G., Pountney, D., Alexander, M.E. & Sloman, K.A. (2019). The effect of short-term feed-deprivation and moult status on feeding behaviour of the Pacific white shrimp (*Litopenaeus vannamei*). *Aquaculture*, 511, 734222. doi: 10.1016/j.aquaculture.2019.734222
- Chen, L., Yang, X., Sun, C., Wang, Y., Xu, D. & Zhou, C. (2020). Feed intake prediction model for group fish using the MEA-BP neural network in intensive aquaculture. *Information Processing in Agriculture*, 7(2), 261–271. doi: 10.1016/j.inpa.2019.09.001
- Estevão, M., Melo, S. De, Shizuo, M., Luiz, J., Mouriño, P., Augusto, B., Carciofi, M. & Moreira, H. (2020). Empirical modeling of feed conversion in Pacific white shrimp (*Litopenaeus vannamei*) growth. *Ecological Modelling*, 437, p.109291. doi: 10.1016/j.ecolmodel.2020.109291
- Li, C., Li, Z., Wu, J., Zhu, L. & Yue, J. (2018). A hybrid model for dissolved oxygen prediction in aquaculture based on multi-scale features. *Information Processing in Agriculture*, 5(1), 11–20. doi: 10.1016/j.inpa.2017.11.002
- Li, D., Wang, Z., Wu, S., Miao, Z. & Du, L. (2020). Automatic recognition methods of fish feeding behavior in aquaculture : A review. *Aquaculture*, 528, 735508. doi: 10.1016/j.aquaculture.2020.735508
- Liu, H., Tian, H., Liang, X. & Li, Y. (2015). New wind speed forecasting approaches using fast ensemble empirical model decomposition, genetic algorithm, Mind Evolutionary Algorithm and Artificial Neural Networks. *Renewable Energy*, 83, 1066–1075. doi: 10.1016/j.renene.2015.06.004
- Liu, H., Yang, R., Duan, Z. & Wu, H. (2020). Artificial Intelligence — Article A Hybrid Neural Network Model for Marine Dissolved Oxygen Concentrations Time-Series Forecasting Based on Multi-Factor Analysis and a Multi-Model Ensemble. *Engineering*, 7(2), 1751-1765. doi: 10.1016/j.eng.2020.10.023
- Mansyur, A., Mangampa, M., Suryanto Suwoyo, H., Pantjara, B. & Syah, R. (Eds.). (2014). *Strategi pengelolaan pakan pada budidaya udang vaname* (3rd ed.). Balai Penelitian dan Pengembangan Budidaya Air Payau.
- Navghan, M., Kumar, N. R., Delhi, N. & Prakash, S. (2015). Economics of shrimp aquaculture and factors associated with shrimp aquaculture in Navsari District of Gujarat , India. *Eco. Env. & Cons*, 21(4), 247–253.
- Qiu, Y. & Xie, K. (2009). A new mind evolutionary algorithm based on information entropy. *Proceedings - 2009 International Conference on Computer Engineering and Technology*, 1, 191–194. doi: 10.1109/ICCET.2009.43

- Reis, J., Novriadi, R., Swanepoel, A., Jingping, G., Rhodes, M. & Davis, D.A. (2020). Optimizing feed automation : improving timer-feeders and on demand systems in semi-intensive pond culture of shrimp *Litopenaeus vannamei*. *Aquaculture*, 519, 734759. doi: 10.1016/j.aquaculture.2019.734759
- Sakharov, Karpenko, & Velisevich. (2015). Multi-memetic Mind Evolutionary Computation Algorithm for Loosely Coupled Systems of Desktop Computers. *Science and Education of the Bauman MSTU*, 10, 438–452. doi: 10.7463/1015.0814435
- Sitompul, T.K., Sahara, & Anggraeni, L. (2018). THE EFFECTS OF TRADE FACILITATION ON INDONESIAN FISHERIES EXPORT. *Jurnal Manajemen dan Agribisnis*, 15(3), 230–238. doi: 10.17358/jma.15.3.230
- Ullman, C., Rhodes, M.A. & Davis, D.A. (2019). Feed management and the use of automatic feeders in the pond production of Pacific white shrimp *Litopenaeus vannamei*. *Aquaculture*, 498, 44–49. doi: 10.1016/j.aquaculture.2018.08.040
- Ulumiah, M., Lamid, M., Soepranianondo, K. & Al-arif, M.A. (2020). Manajemen Pakan dan Analisis Usaha Budidaya Udang Vaname (*Litopenaeus vannamei*) Pada Lokasi yang Berbeda di Kabupaten Bangkalan dan Kabupaten Sidoarjo Feed Management and Analysis of Vannamei Shrimp (*Litopenaeus vannamei*) Culture at Different Location. *Journal of Aquaculture and Fish Health*, 9, 95–103. doi: 10.20473/jafh.v9i2.15783
- Wang, W., Tang, R., Li, C., Liu, P. & Luo, L. (2018). A BP neural network model optimized by Mind Evolutionary Algorithm for predicting the ocean wave heights. *Ocean Engineering*, 162, 98–107. doi: 10.1016/j.oceaneng.2018.04.039
- Wang, Z., Ma, G., Gong, D., Sun, J. & Zhang, D. (2019). Application of Mind Evolutionary Algorithm and Artificial Strip Rolling Process. *Neural Processing Letters*. doi: 10.1007/s11063-019-10021-z
- Wu, J., Li, Z., Zhu, L., Li, G., Niu, B. & Peng, F. (2018). Optimized BP neural network for Dissolved Oxygen prediction. *IFAC-PapersOnLine*, 51(17), 596–601. doi: 10.1016/j.ifacol.2018.08.132
- Xu, L., Du, X. & Wang, B. (2018). Short-Term Traffic Flow Prediction Model of Wavelet Neural Network Based on Mind Evolutionary Algorithm. *International Journal of Pattern Recognition and Artificial Intelligence*, 32(12), 1–14. doi: 10.1142/S0218001418500416
- Zhou, C. (2017). Intelligent feeding control methods in aquaculture with an emphasis on fish : a review. *Reviews in Aquaculture*, 10(4), 975-993. doi: 10.1111/raq.12218
- Zhou, C., Lin, K., Xu, D., Chen, L., Guo, Q. & Sun, C. (2018). Near infrared computer vision and neuro-fuzzy model-based feeding decision system for fish in aquaculture. *Computers and Electronics in Agriculture*, 146, 114–124. doi: 10.1016/j.compag.2018.02.006