

Penerapan Exponential Smoothing untuk Transformasi Data dalam Meningkatkan Akurasi Neural Network pada Prediksi Harga Emas

Indah Suryani

Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri
ihy.indah@gmail.com

Romi Satria Wahono

Fakultas Ilmu Komputer, Universitas Dian Nuswantoro
romi@brainmatics.com

Abstrak: Emas menjadi salah satu logam mulia yang paling banyak diminati baik untuk investasi maupun untuk dijadikan perhiasan. Memprediksi harga emas telah menjadi signifikan dan sangat penting bagi investor karena emas merupakan alat yang penting untuk perlindungan nilai resiko serta sebagai jalan investasi. Metode Neural Network merupakan salah satu model yang paling banyak digunakan dalam berbagai bidang penelitian. Neural Network memiliki banyak fitur yang diinginkan yang sangat cocok untuk aplikasi peramalan. Namun sebagai sistem *black box*, pemodelan Neural Network sepenuhnya tergantung pada input dan output data sehingga kualitas dan distribusi set sampel pembelajaran penting bagi kemampuan generalisasi jaringan. Maka pada penelitian ini, metode Exponential Smoothing digunakan untuk melakukan transformasi data guna meningkatkan kualitas data sehingga dapat meningkatkan akurasi prediksi pada Neural Network. Eksperimen yang dilakukan pada penelitian ini adalah untuk memperoleh arsitektur optimal sehingga menghasilkan prediksi harga emas yang akurat. Penelitian ini menggunakan Neural Network dan Exponential Smoothing dengan 10 kombinasi parameter pada eksperimen yang dilakukan. Kesimpulan yang didapatkan dari eksperimen yang dilakukan adalah bahwa prediksi harga emas menggunakan Neural Network dan Exponential Smoothing lebih akurat dibanding metode individual Neural Network.

Kata Kunci: emas, prediksi, neural network, exponential smoothing,

1 PENDAHULUAN

Emas merupakan barang berharga yang nilainya tak pernah lekang oleh waktu. Emas menjadi salah satu primadona logam mulia yang paling banyak diminati. Sepanjang sejarah, emas telah diperdagangkan secara aktif di pasar internasional (Zhou, Lai, & Yen, 2012). Dari masa ke masa meskipun nilai emas selalu mengalami perubahan seiring pertambahan zaman, namun emas tetap menjadi investasi yang menarik. Emas juga menjadi barang berharga yang tidak hanya sekedar menjadi simpanan yang aman, emas juga memainkan peranan penting dalam sistem moneter uang riil (Apergis, 2014). Disamping itu juga ditemukan hubungan sistematis yang kuat antara harga emas dan nilai tukar (Apergis, 2014). Maka dari itu pantaslah jika di masa lampau maupun di masa modern ini bahwa emas memang masih memiliki nilai tinggi dan menjanjikan.

Pasar emas telah memperlihatkan peningkatan harga yang

stabil selama beberapa dekade terakhir. Namun peramalan atau prediksi mengenai harga emas tetap menjadi hal yang penting karena menurut (Montgomery, 2008), peramalan kejadian masa depan adalah masukan penting dalam banyak jenis perencanaan dan proses pengambilan keputusan. Maka dari itu, memprediksi harga emas telah menjadi signifikan dan sangat penting bagi investor (Zhou et al., 2012), karena data survey dari perkiraan harga emas dan perak menyediakan lingkungan data yang sangat kaya bagi para pembuat kebijakan dan investor untuk mempelajari perkembangan di pasar emas dan perak (Pierdzioch, Risse, & Rohloff, 2014). Dengan adanya prediksi harga emas dengan hasil yang akurat, diharapkan dapat digunakan untuk membantu para pembuat kebijakan serta membantu para investor dalam mengambil keputusan yang tepat dalam investasi emas.

Penelitian mengenai harga emas juga telah banyak dilakukan oleh para peneliti sebelumnya diantaranya penelitian mengenai pasar emas yang telah dilakukan oleh Zhou et al (2012). Penelitian lainnya yang dilakukan oleh Apergis (2014) meneliti mengenai keterkaitan antara harga emas dengan pergerakan Dolar Australia dan penelitian mengenai efisiensi pasar emas oleh Pierdzioch et al. (2014).

Dalam *data mining*, penelitian mengenai peramalan atau prediksi telah banyak berkembang. Senada dengan hal ini, maka banyak penelitian yang hadir adalah menggunakan metode gabungan dalam melakukan prediksi. Ada peneliti yang menggabungkan Genetic Algorithm dengan BP Neural Network (Yu & Xu, 2014), PSO dengan Neural Network (Pulido, Melin, & Castillo, 2014), SVR dengan RBFNN (Ko & Lee, 2013). Dan metode pengembangan metode gabungan ARIMA dengan Neural Network seperti diantaranya (Babu & Reddy, 2014).

Neural Network merupakan salah satu model yang paling banyak digunakan dalam berbagai bidang penelitian. Neural Network menyediakan alat yang menjanjikan bagi peramal, Neural Network juga memiliki banyak fitur yang diinginkan yang sangat cocok untuk aplikasi peramalan praktis (Zhang, 2004). Sebagai *approximators* dan sistem pembelajaran yang fleksibel, jaringan saraf telah menarik meningkatnya minat dalam menggunakan mereka untuk pemodelan dan peramalan runtun waktu (Ouyang & Yin, 2014). Manfaat utama dari penggunaan Neural Network termasuk kemampuan mereka untuk menggeneralisasi, mengidentifikasi hubungan non-linear dan penerapan ke berbagai aplikasi (Bennett, Stewart, & Lu, 2014).

Selain memiliki banyak keunggulan, ternyata model Neural Network juga memiliki beberapa kelemahan yaitu Sebagai pembelajaran dengan jaringan saraf dapat dianggap

sebagai proses khusus fungsi pas atau pendekatan, dan solusi jaringan saraf terhadap masalah umumnya tidak akurat, ketepatan solusinya dan kemampuan fungsi pendekatan harus dipertimbangkan (He & Xu, 2009) dan ada juga kekurangan dalam Neural Network konvensional, seperti kecepatan pelatihan yang lambat dan menyelidiki solusi integrasi optimal yang lemah (Liao, 2014). Salah satu kekurangan dari Neural Network lainnya adalah ketidakmampuan mereka untuk mengidentifikasi variabel peramalan penting (Lu, Lee, & Lian, 2012). Sebagai sistem *black box*, pemodelan Neural Network sepenuhnya tergantung input dan output data, sehingga kualitas dan distribusi sampel set pembelajaran penting bagi kemampuan generalisasi jaringan. Seperti dalam prakteknya kita hanya bisa mendapatkan sampel data yang terbatas dengan diberi ruang lingkup dan kondisi tersebut, karena *noise pollution* dan analisis kesalahan, kualitas data sampel akan berkurang. Sehubungan dengan itu, dalam pemilihan sampel pembelajaran, kita harus membangun data lengkap pengumpulan dan analisis mekanisme untuk meningkatkan kepercayaan dalam *sample learning* (He & Xu, 2009). Data preprocessing adalah masalah lain yang sering direkomendasikan untuk menyorot hubungan penting atau untuk membuat data yang lebih seragam untuk memfasilitasi pembelajaran Neural Network, memenuhi persyaratan algoritma dan menghindari masalah perhitungan (Zhang, 2004).

Data harga emas merupakan salah satu data yang termasuk ke dalam data runtun waktu. Berbagai studi runtun waktu, terutama peramalan runtun waktu statistik telah menjadi teknik yang paling populer untuk skala waktu yang singkat. Analisis runtun waktu linier seperti Random Walk (RW), Autoregressive (AR), Moving Average (MA), Simple Exponential Smoothing (SES) dan metode Autoregressive Integrated Moving Average (ARIMA) yang banyak digunakan untuk pemodelan dan prediksi data radiasi matahari (Dong, Yang, Reindl, & Walsh, 2013). Pemulusan data runtun waktu adalah tugas yang terjadi pada banyak aplikasi dan digunakan pervasif sebagai alat untuk prediksi atau peramalan dan belajar dalam sistem berkembang. Di antara metode yang paling populer digunakan untuk melaksanakan proses ini adalah Moving Average dan Exponential Smoothing (Yager, 2013). Banyak penulis telah bekerja untuk mengembangkan Exponential Smoothing dalam kerangka statistik (Dong et al., 2013), selain itu Exponential Smoothing memiliki berbagai kelebihan diantaranya adalah metode Exponential Smoothing adalah kelas metode yang menghasilkan perkiraan dengan rumus sederhana, dengan mempertimbangkan tren dan efek musiman data (Tratar, 2015), selain itu model Exponential Smoothing merupakan alat prediksi yang penting baik dalam bisnis dan ekonomi makro (Sbrana & Silvestrini, 2014) dan metode Exponential Smoothing yang sangat sukses, mengalahkan banyak metode yang lebih canggih lainnya (Beaumont, 2014).

Persiapan data merupakan langkah penting dalam membangun sebuah model Neural Network yang sukses. Tanpa kumpulan data yang baik, memadai dan representatif, tidak mungkin untuk mengembangkan prediksi Model Neural Network yang berguna. Dengan demikian, keandalan model Neural Network tergantung pada sejauh seberapa besar kualitas data (Zhang, 2004). Maka pada penelitian ini metode Exponential Smoothing digunakan untuk memperbaiki kualitas data yang akan digunakan pada prediksi harga emas menggunakan metode Neural Network.

2 PENELITIAN TERKAIT

Anbazzhagan & Kumarappan (2014) menyatakan bahwa model Neural Network telah menunjukkan peningkatan dalam akurasi peramalan yang terhubung dengan model yang ditentukan dengan baik lainnya. Pada penelitiannya, (Anbazzhagan & Kumarappan, 2014) mengangkat masalah mengenai perlunya proses pra pengolahan data untuk mengekstrak informasi berlebihan dari sinyal asli. Metode yang digunakan dalam penelitian ini adalah metode Neural Network. Untuk dapat meningkatkan efisiensi pembelajaran pada Feed Forward Neural Network (FFNN), maka dilakukan proses pra pengolahan data dengan melakukan transformasi data menggunakan *Discrete Cosine Transform* (DCT), Model DCT-FFNN ini diramalkan dapat mendekati *state of the art* dengan pencapaian waktu komputasi yang lebih rendah. Adapun dataset yang digunakan adalah data harga listrik di Spanyol dan NewYork. Dengan ini maka pendekatan yang diusulkan tanpa melakukan hibridisasi terhadap model *hard* dan *soft computing*. Evaluasi terhadap *performance* dilakukan dengan membandingkan nilai MAPE, *Sum Squared Error* (SSE) dan *Standard Deviation of Error* (SDE). Hasil penelitian menunjukkan bahwa Model DCT-FFNN menyajikan kompleksitas pemodelan yang lebih rendah yang sangat cocok untuk *real-time* pasar listrik yang kompetitif. Selain itu, model DCT-FFNN juga menunjukkan waktu komputasi yang lebih rendah jika dibandingkan dengan 17 model lainnya.

Pada penelitian lainnya yang dilakukan oleh Jammazi & Aloui (2012) menggunakan dataset harga minyak mentah dunia dari IEA pada tahun 2011. Data harga minyak mentah dunia memiliki volatilitas yang tinggi dan non stasioner. Dalam penelitian ini, harga minyak mentah WTI bulanan digunakan untuk menilai *the A Haar Trous Wavelet Transforms* dalam mendapatkan pemulusan komponen tanpa kehilangan sifat yang mendasari dari sinyal yang bersangkutan. *Filter wavelet* yang digunakan untuk dekomposisi adalah *the discrete low filter*. Setelah dilakukan dekomposisi wavelet, selanjutnya pemodelan dilakukan menggunakan metode Neural Network yang diterapkan pada dataset yang dibagi menjadi *in-sample data* dan *out-of-sample data*. Berdasarkan simulasi yang dilakukan, dilakukan evaluasi *performance* dengan membandingkan tingkat *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE) yang dihasilkan.

Dalam penelitian yang dilakukan oleh (Beaumont, 2014), mengangkat permasalahan mengenai arti penting transformasi data dalam melakukan peramalan. Dataset yang digunakan dalam penelitian ini berupa data kompetisi M3 yang diterapkan untuk 645 seri tahunan, 756 seri triwulanan dan 1428 seri bulanan. *Log transform* dan *Box-Cox transform* diterapkan pada pengamatan seri, dan sisanya yaitu *Johnson Error Trend Seasonal (JETS) Transform*, *Heteroscedastic state space transform* dan *t transform* diterapkan dalam transformasi kesalahan. Evaluasi hasil dilakukan dengan membandingkan tingkat *Mean Absolutly Squared Error* (MASE), MAPE dan *Range Probability Score* (RPS) terendah serta membandingkan tingkat *Minus Log Prediction Likelihood* (MLPL) dengan tingkat tertinggi.

Dari hasil penelitian sebelumnya tersebut, maka dapat disimpulkan bahwa kualitas input data dapat membuktikan ketidakpuasan untuk ketidaklengkapan, kebisingan dan ketidakkonsistenan data (Vercellis, 2009). Atas berbagai kelebihan yang dimiliki oleh Exponential Smoothing maka diharapkan dengan adanya penerapan Exponential Smoothing dalam transformasi data dapat meningkatkan akurasi prediksi pada Neural Network, karena menurut Beaumont (2014), salah satu keterbatasan metode penelitian adalah bahwa mereka

mengabaikan potensi transformasi untuk meningkatkan perkiraan.

3 PENGUMPULAN DATA

Data yang dikumpulkan dalam penelitian ini merupakan data sekunder berupa data harga emas yang terdiri dari 1301 *record* yang menampilkan tanggal dan harga penutupan emas harian. Data harga emas harian tersebut dapat dilihat pada Tabel 1.

Tabel 1. Data Harga Emas Harian NYSE

Date	Close
June 30, 2014	1,322.00
June 27, 2014	1,320.00
June 26, 2014	1,316.10
June 25, 2014	1,322.20
June 24, 2014	1,320.90
June 23, 2014	1,318.00
June 20, 2014	1,316.20
June 19, 2014	1,313.70
June 18, 2014	1,272.40
June 17, 2014	1,271.70
June 16, 2014	1,274.90
June 13, 2014	1,273.70
June 12, 2014	1,273.60
June 11, 2014	1,260.80
June 10, 2014	1,259.80
June 9, 2014	1,253.50
June 6, 2014	1,252.10
June 5, 2014	1,253.00
June 4, 2014	1,244.00
June 3, 2014	1,244.30
June 2, 2014	1,243.70

4 PENGOLAHAN DATA AWAL

Pengolahan data awal yang dilakukan dalam penelitian ini terdiri dari:

1. *Replace Missing Values*

Dalam dataset yang digunakan dalam penelitian ini, masih ditemukan mengandung *missing values*, sehingga untuk mengatasi sebagian data yang tidak lengkap tersebut dapat mengadopsi teknik substitusi. Yaitu menggantikan nilai yang hilang dengan mengubahnya menjadi nilai yang diinginkan yaitu rata-rata atribut dihitung untuk pengamatan yang tersisa. Teknik ini dapat diterapkan untuk atribut yang bernilai numerik.

2. *Set Role*

Set role operator digunakan dalam penelitian ini untuk mengubah peran suatu atribut yaitu atribut *date* dari atribut regular menjadi atribut spesial yaitu sebagai *id*.

3. *Normalize*

Normalisasi data dilakukan sesuai dengan fungsi aktivasi yang digunakan, dalam penelitian ini menggunakan dua fungsi aktivasi yaitu fungsi *binary sigmoid* dan *bipolar*

sigmoid. Fungsi *binary sigmoid*, menormalisasikan data dalam range 0 sampai 1 (Yu & Xu, 2014). Adapun rumus untuk fungsi *binary sigmoid* (*Logsig*) adalah:

$$y' = \frac{x - x_{min}}{x_{max} - x_{min}} \times (0.9 - 0.1) + 0.1 \quad (1)$$

Sedangkan rumus untuk *bipolar sigmoid* (*Tansig*) adalah:

$$y' = \frac{x - x_{min}}{x_{max} - x_{min}} \times 2 - 1 \quad (2)$$

Keterangan:

y' = Hasil transformasi data

x = Nilai asli

x_{min} = Nilai minimal

x_{max} = Nilai maksimal

4. *Windowing*

Windowing merupakan salah satu teknik dalam menentukan data *input* dan data *output* dalam prediksi data runtun waktu dengan tipe univariat. Data univariat adalah distribusi data dengan melibatkan satu atribut atau variabel (Han et al., 2012). Dengan teknik *windowing* tersebut data univariat yang berupa harga penutupan yang diwakili oleh atribut *Close* pada data, selanjutnya akan dipecah menjadi 5 data *input* dan 1 data *output*. Data *input* merupakan data 5 hari sebelumnya dan data *output* adalah data 1 hari berikutnya

5. Transformasi Data dengan Exponential Smoothing

Exponential Smoothing pada penelitian ini digunakan dalam melakukan transformasi data guna memperbaiki kualitas data yang diharapkan dapat meningkatkan akurasi Neural Network. dengan contoh perhitungan sebagai berikut:

$$y't + 1 = y't + \alpha(yt - y't) \quad (3)$$

Berdasarkan salah satu *sample* nilai *output* (*class*) dataset harga emas setelah dilakukan normalisasi dengan *binary sigmoid* diketahui:

$y't + 1$ = Nilai peramalan periode berikutnya

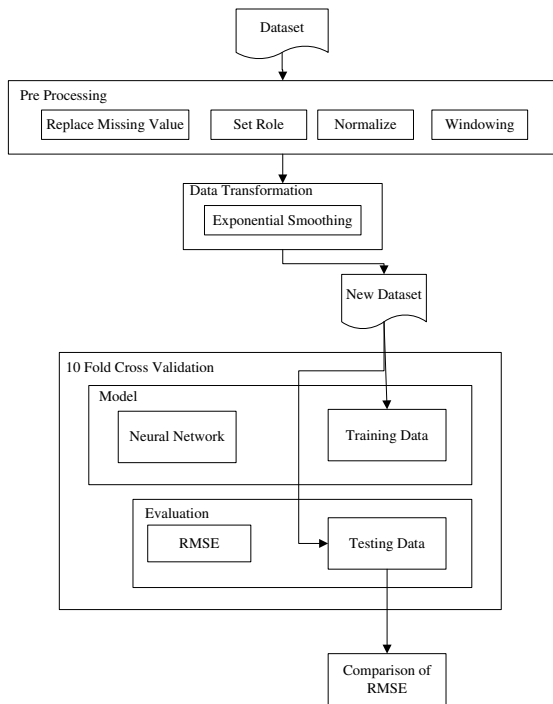
$y't$ = Nilai pemulusan yang lama atau rata-rata yang dimuluskan hingga periode t-1

yt = Data baru atau nilai y yang sebenarnya di periode t

α = Konstanta pemulusan ($0 < \alpha < 1$)

5 METODE YANG DIUSULKAN

Metode yang diusulkan pada penelitian ini yaitu penerapan metode Exponential Smoothing untuk transformasi data yang diterapkan pada metode Neural Network. Metode Exponential Smoothing yang digunakan adalah Simple Exponential Smoothing dan untuk metode Neural Network yang digunakan adalah Backpropagation Neural Network. Adapun metode yang diusulkan dapat dilihat pada Gambar 1.



Gambar 1. Metode yang Diusulkan

Alur penelitian yang digunakan dalam penelitian ini dimulai dengan penginputan data untuk selanjutnya dilakukan proses pra pengolahan data berupa *replace missing value*, *set role*, *normalize* dan *windowing*.

Replace missing value yaitu salah satu operator yang terdapat di *data cleansing* pada *RapidMiner* yang membantu menangani nilai null yang mungkin ada dalam data, yang dapat digunakan untuk menemukan nilai-nilai yang hilang dalam atribut atau serangkaian atribut dan merubahnya, dari nilai yang hilang ke nilai yang diinginkan (Hofmann, 2009). Langkah berikutnya adalah untuk mengatur peran pada atribut yang akan digunakan, dalam hal ini untuk operator yang digunakan pada *RapidMiner* adalah operator *set role*. Penetapan peran atribut ini sangat penting untuk menetapkan peran yang tepat untuk atribut dalam dataset. Kebanyakan operator klasifikasi tidak akan bekerja jika tidak ada atribut dengan peran label dalam *dataset* (atau bahkan jika ada beberapa atribut dengan peran label). Perlu memastikan bahwa hanya satu atribut (dan yang benar) Memiliki peran label. Dalam *setup* klasifikasi sangat dasar semua atribut lainnya akan memiliki peran reguler. Jika atribut unik mengidentifikasi contoh dapat diberikan peran *id* (Hofmann, 2009). Setelah dilakukan *set role*, kemudian dilakukan normalisasi dataset menggunakan operator *normalize* pada *RapidMiner*. Normalisasi diterapkan pada semua atribut, dan semua nilai atribut diubah menjadi kisaran 0-1. Langkah ini sangat penting karena atribut dalam *dataset* mungkin berbeda skala, yang mempengaruhi perhitungan jarak (Hofmann, 2009). Selanjutnya dilakukan proses *windowing*, *windowing* biasanya digunakan untuk mengubah data *time series* menjadi contoh set yang berisi contoh dengan beberapa atribut yang sesuai dengan poin berurutan. Ini contoh set kemudian dapat digunakan untuk pembentukan model, klasifikasi, atau analisis prediktif. Jendela juga dapat digunakan untuk memvisualisasikan data (Chisholm, 2013). Selanjutnya diterapkan metode *Exponential Smoothing* untuk melakukan transformasi data untuk kemudian dilakukan *training* dan *testing* menggunakan metode *Neural network*.

6 HASIL DAN PEMBAHASAN

Tahapan eksperimen yang dilakukan dalam penelitian ini adalah:

1. Menyiapkan dataset untuk penelitian
2. Melakukan pra pengolahan data
3. Merancang arsitektur *Neural Network* dengan memasukkan nilai parameter *Neural Network* yang terdiri dari *training cycle*, *learning rate*, *momentum* dan *hidden layer*
4. Melakukan *training* dan *testing* terhadap model *Neural Network*, kemudian mencatat hasil *RMSE* yang didapat
5. Merancang arsitektur *Neural Network* dengan memasukkan parameter *Neural Network* berupa *training cycle*, *learning rate*, *momentum* dan *hidden layer* dan parameter *Exponential Smoothing* yang berupa *alpha* (α)
6. Melakukan *training* dan *testing* terhadap model usulan berupa pengembangan *Neural Network* dengan *Exponential Smoothing*, kemudian mencatat hasil *RMSE* yang didapat

Melakukan perbandingan hasil *RMSE* pada kedua model dengan uji beda menggunakan *t-Test*. Setelah dilakukan pengujian model menggunakan *tools Rapidminer 5.3*, selanjutnya dilakukan evaluasi pebandingan hasil *RMSE* seluruh eksperimen dengan *10-fold cross validation*. Eksperimen dilakukan dengan metode *Neural Network*, kemudian dibandingkan dengan hasil eksperimen menggunakan metode *Neural Network* yang dikembangkan dengan *Exponential Smoothing*.

Pada eksperimen pertama ini percobaan dilakukan dengan melakukan inisialisasi parameter *Neural Network* yang terdiri dari *training cycle*, *learning rate*, *momentum* dan *hidden layer* dan dengan dilakukan normalisasi data terlebih dahulu menggunakan fungsi aktivasi *binary sigmoid* untuk kemudian diuji coba menggunakan sistem *random* dan *error* sehingga dihasilkan model terbaik yang ditandai dengan perolehan hasil *RMSE* dengan nilai terkecil seperti pada Tabel 2.

Tabel 2. Hasil Eksperimen Metode *Neural Network* (Fungsi Aktivasi *Binary Sigmoid*)

Hidden Layer	Hidden Layers Size	Training Cycle	Learning Rate	Momentum	Horizon	RMSE
1	1	500	0.3	0.2	1	0.015
1	1	500	0.6	0.3	1	0.015
1	3	1000	0.6	0.3	1	0.014
1	3	1000	0.9	0.6	1	0.014
1	3	500	0.9	0.6	1	0.014
1	1	300	0.5	0.5	1	0.015
1	1	300	0.1	0.3	1	0.019
1	3	500	0.3	0.2	1	0.015
2	2,2	500	0.6	0.3	1	0.015
2	3,3	500	0.9	0.6	1	0.014

Pada eksperimen selanjutnya dengan melakukan inisialisasi parameter *Neural Network* yang terdiri dari *training cycle*, *learning rate*, *momentum* dan *hidden layer* dan dengan dilakukan normalisasi data terlebih dahulu menggunakan fungsi aktivasi *bipolar sigmoid* untuk kemudian diuji coba menggunakan sistem *random* dan *error* sehingga dihasilkan model terbaik yang ditandai dengan perolehan hasil *RMSE* dengan nilai terkecil seperti pada Tabel 3.

Tabel 3. Hasil Eksperimen Metode *Neural Network* (Fungsi Aktivasi *Bipolar Sigmoid*)

Hidden Layer	Hidden Layers Size	Training Cycle	Learning Rate	Momentum	Horizon	RMSE
1	1	500	0.3	0.2	1	0.039
1	1	500	0.6	0.3	1	0.037
1	3	1000	0.6	0.3	1	0.035
1	3	1000	0.9	0.6	1	0.035
1	3	500	0.9	0.6	1	0.035
1	1	300	0.5	0.5	1	0.037
1	1	300	0.1	0.3	1	0.047
1	3	500	0.3	0.2	1	0.037
2	2,2	500	0.6	0.3	1	0.037
2	3,3	500	0.9	0.6	1	0.036

Pada eksperimen ketiga dan keempat, percobaan dilakukan dengan melakukan inialisasi parameter Neural Network yang terdiri dari *training cycle*, *learning rate*, *momentum* dan *hidden layer* dan dengan dilakukan normalisasi data terlebih dahulu menggunakan fungsi aktivasi *binary sigmoid* dan *bipolar sigmoid* untuk kemudian dikembangkan dengan metode Exponential Smoothing dan diuji coba menggunakan sistem *random* dan *error* sehingga dihasilkan model terbaik yang ditandai dengan perolehan hasil RMSE dengan nilai terkecil seperti pada Tabel 4 dan 5.

Tabel 6. Hasil Eksperimen Metode Neural Network dengan Fungsi Aktivasi *Binary Sigmoid* + Exponential Smoothing

Hidden Layer	Hidden Layers Size	Training Cycle	Learning Rate	Momentum	Horizon	Alpha	RMSE
1	1	500	0.3	0.2	1	0.5	0.010
1	1	500	0.6	0.3	1	0.7	0.006
1	3	1000	0.6	0.3	1	0.2	0.013
1	3	500	0.9	0.6	1	0.9	0.003
1	3	1000	0.9	0.6	1	0.9	0.003
1	1	300	0.5	0.5	1	0.6	0.007
1	1	300	0.1	0.3	1	0.9	0.015
1	3	500	0.3	0.2	1	0.3	0.013
2	2,2	500	0.6	0.3	1	0.9	0.007
2	3,3	500	0.9	0.6	1	0.9	0.004

Tabel 5. Hasil Eksperimen Metode Neural Network dengan Fungsi Aktivasi *Bipolar Sigmoid* + Exponential Smoothing

Hidden Layer	Hidden Layers Size	Training Cycle	Learning Rate	Momentum	Horizon	Alpha	RMSE
1	1	500	0.3	0.2	1	0.5	0.027
1	1	500	0.6	0.3	1	0.7	0.015
1	3	1000	0.6	0.3	1	0.2	0.033
1	3	1000	0.9	0.6	1	0.9	0.007
1	3	500	0.9	0.6	1	0.9	0.007
1	1	300	0.5	0.5	1	0.6	0.015
1	1	300	0.1	0.3	1	0.9	0.035
1	3	500	0.3	0.2	1	0.3	0.032
2	2,2	500	0.9	0.3	1	0.9	0.013
2	3,3	500	0.9	0.6	1	0.9	0.010

Pada eksperimen kelima dan keenam, percobaan dilakukan dengan melakukan inialisasi parameter Neural Network yang terdiri dari *training cycle*, *learning rate*, *momentum* dan *hidden layer* dan dengan dilakukan normalisasi data terlebih dahulu menggunakan fungsi aktivasi *binary sigmoid* dan *bipolar sigmoid* dengan transformasi menggunakan Discrete Cosine Transform seperti yang

dilakukan pada penelitian sebelumnya oleh Anbazhagan & Kumarappan (2014) dan selanjutnya diuji coba menggunakan sistem *random* dan *error* sehingga dihasilkan model terbaik yang ditandai dengan perolehan hasil RMSE dengan nilai terkecil seperti pada Tabel 6 dan Tabel 7.

Tabel 6. Hasil Eksperimen Metode Neural Network dengan Fungsi Aktivasi *Binary Sigmoid* + Discrete Cosine Transform

Neural Network dengan Fungsi Aktivasi Binary Sigmoid + Discrete Cosine Transform						
Hidden Layer	Hidden Layers Size	Training Cycle	Learning Rate	Momentum	Horizon	RMSE
1	1	500	0.3	0.2	1	0.016
1	1	500	0.6	0.3	1	0.015
1	3	1000	0.6	0.3	1	0.014
1	3	500	0.9	0.6	1	0.014
1	3	1000	0.9	0.6	1	0.014
1	1	300	0.5	0.5	1	0.015
1	1	300	0.1	0.3	1	0.017
1	3	500	0.3	0.2	1	0.015
2	2,2	500	0.6	0.3	1	0.015
2	3,3	500	0.9	0.6	1	0.014

Tabel 7. Hasil Eksperimen Metode Neural Network dengan Fungsi Aktivasi *Bipolar Sigmoid* + Discrete Cosine Transform

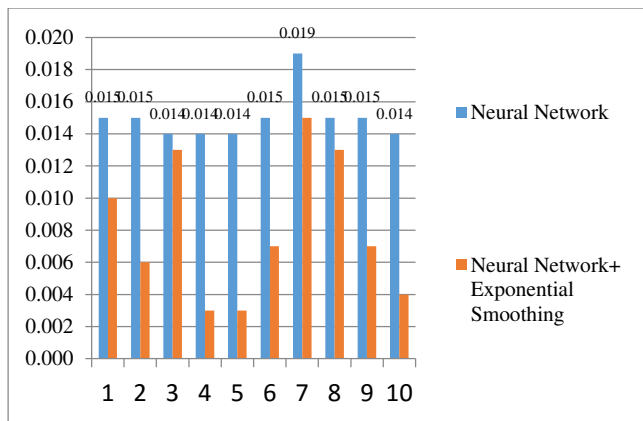
Neural Network dengan Fungsi Aktivasi Bipolar Sigmoid + Discrete Cosine Transform						
Hidden Layer	Hidden Layers Size	Training Cycle	Learning Rate	Momentum	Horizon	RMSE
1	1	500	0.3	0.2	1	0.039
1	1	500	0.6	0.3	1	0.037
1	3	1000	0.6	0.3	1	0.036
1	3	1000	0.9	0.6	1	0.035
1	3	500	0.9	0.6	1	0.035
1	1	300	0.5	0.5	1	0.037
1	1	300	0.1	0.3	1	0.040
1	3	500	0.3	0.2	1	0.036
2	2,2	500	0.9	0.3	1	0.037
2	3,3	500	0.9	0.6	1	0.036

Berdasarkan hasil eksperimen yang telah dilakukan, diperoleh perbedaan nilai rata-rata RMSE pada pengujian model Neural Network sebelum dan sesudah dilakukan transformasi data menggunakan Exponential Smoothing pada tingkat akurasi prediksi harga emas. Tingkat perbandingan rata-rata nilai RMSE yang dihasilkan tersebut dapat dilihat pada Tabel 8.

Tabel 8. Perbandingan Nilai RMSE Neural Network dengan Neural Network + Exponential Smoothing (Fungsi Aktivasi *Binary Sigmoid*)

Perbandingan RMSE	
Neural Network	Neural Network+ Exponential Smoothing
0.015	0.010
0.015	0.006
0.014	0.013
0.014	0.003
0.014	0.003
0.015	0.007
0.019	0.015
0.015	0.013
0.015	0.007
0.014	0.004

Berdasarkan data yang diperoleh dari Tabel 8 maka dapat ditampilkan grafik pada Gambar 2.



Gambar 2. Grafik Perbandingan RMSE Neural Network dan Neural Network + Exponential Smoothing (Fungsi Aktivasi Binary Sigmoid)

Untuk mengetahui ada tidaknya perbedaan antara dua model, maka dibutuhkan suatu pengujian, oleh karena itu dilakukan uji beda menggunakan t-Test untuk menguji hipotesa. Hipotesa nol (H_0) akan dihasilkan jika tidak terdapat perbedaan antara model Neural Network dengan model Neural Network dengan transformasi data Exponential Smoothing. Hipotesa alternatif (H_1) dihasilkan jika terdapat perbedaan antara model Neural Network dengan model Neural Network dengan transformasi data Exponential Smoothing. Adapun hasil dari uji sampel berpasangan untuk RMSE yang dihasilkan pada model Neural Network dengan model Neural Network dengan transformasi data Exponential Smoothing dengan fungsi aktivasi menggunakan binary sigmoid dapat dilihat pada Tabel 9.

Tabel 9. Paired Two Sample T-Test dengan metode Neural Network dan Neural Network + Exponential Smoothing (Fungsi Aktivasi Binary Sigmoid)

	Neural Network	Neural Network + Exponential Smoothing
Mean	0.015	0.0081
Variance	2.22222E-06	1.94333E-05
Observations	10	10
Pearson Correlation	0.625592915	
Hypothesized Mean Difference	0	
Df	9	
t Stat	5.953292143	
P(T<=t) one-tail	0.000107234	
t Critical one-tail	1.833112923	
P(T<=t) two-tail	0.000214468	
t Critical two-tail	2.262157158	

Berdasarkan hasil uji t dua sampel berpasangan pada Tabel 9, diketahui bahwa t hitung yang diwakili t stat dengan nilai sebesar 5.953292143 dan nilai t tabel yang diwakili oleh t critical two tail sebesar 2.262157158, maka nilai t hitung > dari nilai t tabel dan dapat disimpulkan bahwa H_0 ditolak dan H_1 diterima. Sedangkan untuk nilai probabilitas yang dihasilkan sebesar 0.000214468, artinya terdapat perbedaan signifikan antara RMSE model Neural Network dan model Neural Network + Exponential Smoothing dengan fungsi aktivasi menggunakan binary sigmoid.


Berdasarkan hasil eksperimen yang telah dilakukan, diperoleh perbedaan nilai rata-rata RMSE pada pengujian model Neural Network sebelum dan sesudah dilakukan transformasi data menggunakan Exponential Smoothing pada tingkat akurasi prediksi harga emas. Tingkat perbandingan

rata-rata nilai RMSE yang dihasilkan tersebut dapat dilihat pada Tabel 10.

Tabel 10. Perbandingan Nilai RMSE Neural Network dengan Neural Network + Exponential Smoothing (Fungsi Aktivasi Binary Sigmoid)

Perbandingan RMSE	
Neural Network	Neural Network + Exponential Smoothing
0.039	0.027
0.037	0.015
0.035	0.033
0.035	0.007
0.035	0.007
0.037	0.015
0.047	0.035
0.037	0.032
0.037	0.013
0.036	0.010

Berdasarkan data yang diperoleh dari Tabel 10 maka dapat ditampilkan grafik pada Gambar 3.



Gambar 3. Grafik Perbandingan RMSE Neural Network dan Neural Network + Exponential Smoothing (Fungsi Aktivasi Bipolar Sigmoid)

Untuk mengetahui ada tidaknya perbedaan antara hasil dari uji sampel berpasangan untuk RMSE yang dihasilkan pada model Neural Network dengan model Neural Network dengan transformasi data Exponential Smoothing dengan fungsi aktivasi menggunakan bipolar sigmoid dapat dilihat pada Tabel 11.

Tabel 11. Paired Two Sample T-Test dengan metode Neural Network dan Neural Network + Exponential Smoothing (Fungsi Aktivasi Bipolar Sigmoid)

	Neural Network	Neural Network + Exponential Smoothing
Mean	0.0375	0.0194
Variance	1.27222E-05	0.000124489
Observations	10	10
Pearson Correlation	0.566769857	
Hypothesized Mean Difference	0	
Df	9	
t Stat	5.964152777	
P(T<=t) one-tail	0.000105809	
t Critical one-tail	1.833112923	
P(T<=t) two-tail	0.000211618	
t Critical two-tail	2.262157158	

Berdasarkan hasil uji t dua sampel berpasangan pada Tabel 11, diketahui bahwa t hitung yang diwakili t stat dengan nilai

sebesar 5.964152777 dan nilai t tabel yang diwakili oleh *t critical two tail* sebesar 2.262157158, maka nilai titung > dari nilai t tabel dan dapat disimpulkan bahwa H_0 ditolak dan H_1 diterima. Sedangkan untuk nilai probabilitas yang dihasilkan sebesar 0.000211618, artinya terdapat perbedaan signifikan antara RMSE model Neural Network dan model Neural Network + Exponential Smoothing dengan fungsi aktivasi menggunakan *binary sigmoid*.

Keseluruhan eksperimen yang dilakukan menghasilkan 6 variasi model. Keenam variasi model terdiri dari metode individual Neural Network dengan fungsi aktivasi *binary sigmoid*, metode individual Neural Network dengan fungsi aktivasi *bipolar sigmoid*, metode Neural Network dan Exponential Smoothing dengan fungsi aktivasi *binary sigmoid*, metode Neural Network dan Exponential Smoothing dengan fungsi aktivasi *bipolar sigmoid*, metode Neural Network dan Discrete Cosine Transform dengan fungsi aktivasi *binary sigmoid* dan metode Neural Network dan Discrete Cosine Transform dengan fungsi aktivasi *bipolar sigmoid* dengan ringkasan yang tertera pada Tabel 12.

Tabel 12. Hasil Eksperimen Keseluruhan Metode

Perbandingan Nilai RMSE					
NN (Logsig)	NN (Tansig)	NN+ES (Logsig)	NN+ES (Tansig)	NN+DCT (Logsig)	NN+DCT (Tansig)
0.015	0.039	0.010	0.027	0.016	0.039
0.015	0.037	0.006	0.015	0.015	0.037
0.014	0.035	0.013	0.033	0.014	0.036
0.014	0.035	0.003	0.007	0.014	0.035
0.014	0.035	0.003	0.007	0.014	0.035
0.015	0.037	0.007	0.015	0.015	0.037
0.019	0.047	0.015	0.035	0.017	0.040
0.015	0.037	0.013	0.032	0.015	0.036
0.015	0.037	0.007	0.013	0.015	0.037
0.014	0.036	0.004	0.010	0.014	0.036

Untuk membandingkan keakuratan model yang berbeda, dapat dilakukan uji Friedman. Hal ini dilakukan untuk mencegah kemungkinan penolakan terhadap hipotesis homogenitas terhadap keakuratan model yang dibandingkan tersebut. Uji Friedman seringkali digunakan dengan sukses dengan praktek dalam variaebel diskrit yang mengambil banyak nilai. Uji Friedman ini dilakukan dengan menggunakan *Software XLSTAT*. Hasil perbandingan akurasi keenam model di atas yang dilakukan menggunakan uji Friedman dapat dilihat pada Tabel 13.

Tabel 13. Hasil Uji Friedman

Q (Observed value)	45.608
Q (Critical value)	11.070
DF	5
p-value (Two-tailed)	< 0.0001
Alpha	0.05

Dari hasil pengujian menggunakan Friedman test, dihasilkan nilai *p-value* < 0.0001 yang artinya lebih kecil dari nilai alpha 0.05, maka dengan demikian H_1 atau hipotesa alternatif diterima atau dengan kata lain, hipotesis nol ditolak. Hal ini mengindikasikan perbedaan signifikan antara keenam model yang dihasilkan. Ketika hipotesis nol ditolak, maka perlu dilakukan post-hoc test untuk mengidentifikasi pasangan

tertentu atau pasang faktor dengan perbedaan dalam peringkat jumlah yang signifikan secara statistik, dan yang mungkin telah menyebabkan penolakan hipotesis nol.

Tabel 14. Hasil Uji Nemenyi

Sample	Frequency	Sum of ranks	Mean of ranks	Groups
NN+ES (Logsig)	10	10.000	1.000	A
NN (Logsig)	10	30.000	3.000	A
NN+ES (Tansig)	10	30.000	3.000	A
NN+DCT (Logsig)	10	30.000	3.000	A
NN+DCT (Tansig)	10	54.500	5.450	B
NN (Tansig)	10	55.500	5.550	B

Selanjutnya pada Tabel 4. 14 dilakukan perbandingan hasil berpasangan dengan meringkas perbandingan berpasangan menggunakan analisis *post-hoc* yang dalam hal ini menggunakan uji Nemenyi. Hal ini dilakukan karena uji Friedman hanya menunjukkan adanya perbedaan model tetapi tidak menyediakan model yang berbeda. *Mean rank* pada Tabel 14 diperoleh dari perbandingan antar model. Semakin tinggi peringkat, semakin tinggi titik dan kemudian dibagi dengan jumlah sampel data.

Tabel 15. Hasil Uji Perbedaan Kinerja

	NN (Logsig)	NN (Tansig)	NN+ES (Logsig)	NN+ES (Tansig)	NN+DCT (Logsig)	NN+DCT (Tansig)
NN (Logsig)	0	-2.550	2.000	0.000	0.000	-2.450
NN (Tansig)	2.550	0	4.550	2.550	2.550	0.100
NN+ES (Logsig)	-2.000	-4.550	0	-2.000	-2.000	-4.450
NN+ES (Tansig)	0.000	-2.550	2.000	0	0.000	-2.450
NN+DCT (Logsig)	0.000	-2.550	2.000	0.000	0	-2.450
NN+DCT (Tansig)	2.450	-0.100	4.450	2.450	2.450	0
Critical difference: 2.3842						

Uji nemenyi menghitung semua perbandingan berpasangan antara model yang berbeda dan memeriksa kinerja mana yang berbeda dengan nilai *critical difference* (cd) 2.3842 seperti yang ditunjukkan pada Tabel 4.15.

Tabel 16. Nilai P-Value Hasil Uji Nemenyi

	NN (Logsig)	NN (Tansig)	NN+ES (Logsig)	NN+ES (Tansig)	NN+DCT (Logsig)	NN+DCT (Tansig)
NN (Logsig)	1	0,028	0,159	1,000	1,000	0,040
NN (Tansig)	0,028	1	< 0.0001	0,028	0,028	1,000
NN+ES (Logsig)	0,159	< 0.0001	1	0,159	0,159	< 0.0001
NN+ES (Tansig)	1,000	0,028	0,159	1	1,000	0,040
NN+DCT (Logsig)	1,000	0,028	0,159	1,000	1	0,040
NN+DCT (Tansig)	0,040	1,000	< 0.0001	0,040	0,040	1

Dapat dilihat pada Tabel 16, nilai *p-value* yang dicetak tebal merupakan nilai-nilai *p-value* yang memiliki nilai terkecil. Nilai *p-value* yang terkecil juga didapat pada angka 0,0001 dari hasil pengujian Model Neural Network dan Exponential Smoothing dengan fungsi aktivasi logsig atau *binary sigmoid* yang artinya angka tersebut kurang dari nilai $\alpha = 0,05$. Dengan demikian maka hipotesis nol ditolak yang berarti bahwa terdapat tingkat perbedaan yang signifikan secara statistik.

Tabel 17. Hasil Uji Signifikan Keseluruhan Model

	NN (Logsig)	NN (Tansig)	NN+ES (Logsig)	NN+ES (Tansig)	NN+DCT (Logsig)	NN+DCT (Tansig)
NN (Logsig)	No	Yes	No	No	No	Yes
NN (Tansig)	Yes	No	Yes	Yes	Yes	No
NN+ES (Logsig)	No	Yes	No	No	No	Yes
NN+ES (Tansig)	No	Yes	No	No	No	Yes
NN+DCT (Logsig)	No	Yes	No	No	No	Yes
NN+DCT (Tansig)	Yes	No	Yes	Yes	Yes	No

Hasil yang ditunjukkan pada Tabel 16 tersebut sesuai dengan hasil yang ditunjukkan pada Tabel 17, yang berarti bahwa model yang memiliki nilai p -value kurang dari nilai $\alpha=0.05$ maka akan menghasilkan nilai *Yes* pada Tabel 17. Pada Tabel 17 di atas, dapat dilihat bahwa model yang memiliki perbedaan signifikan ditunjukkan pada kolom dan baris yang bernilai *Yes*. Sedangkan untuk perbedaan yang tidak signifikan ditandai dengan nilai *No*. Dari hasil uji Friedman dan Nemenyi post-hoc di atas menunjukkan bahwa model Neural Network dengan Discrete Cosine Transform juga menunjukkan akurasi yang tinggi dengan perbedaan yang signifikan (Anbazhagan & Kumarappan, 2014). Selain itu model Neural Network dengan Exponential Smoothing pada fungsi aktivasi *binary sigmoid* menunjukkan hasil yang lebih tinggi dan menunjukkan hasil perbedaan yang signifikan.

7 KESIMPULAN

Pada penelitian ini dilakukan penerapan metode usulan berupa pengembangan metode Neural Network menggunakan metode Exponential Smoothing untuk transformasi data yang kemudian berdasarkan hasil eksperimen yang dilakukan terbukti meningkatkan hasil prediksi harga emas dengan membandingkan nilai RMSE yang dihasilkan. Nilai RMSE terkecil yang didapatkan dari penerapan metode Neural Network dengan fungsi aktivasi *binary sigmoid* adalah 0,014 dan RMSE terkecil yang dihasilkan dengan penerapan Neural Network dan Exponential Smoothing dengan fungsi aktivasi *binary sigmoid* adalah 0,003 dan penerapan Neural Network dan Exponential Smoothing dengan fungsi aktivasi *bipolar sigmoid* dengan nilai 0,007.

Melalui hasil t-Test dan Friedman Test menunjukkan bahwa adanya perbedaan atau pengaruh yang signifikan dari penerapan metode Neural Network yang dibandingkan dengan penerapan metode Neural Network dan Exponential Smoothing. Dengan demikian maka dapat disimpulkan bahwa penerapan transformasi data menggunakan Exponential Smoothing dapat memperbaiki kualitas data yang digunakan pada penerapan Neural Network sehingga mampu meningkatkan akurasi prediksi harga emas.

REFERENSI

- Anbazhagan, S., & Kumarappan, N. (2014). Day-ahead deregulated electricity market price forecasting using neural network input featured by DCT. *Energy Conversion and Management*, 78, 711–719.
- Apergis, N. (2014). Can gold prices forecast the Australian dollar movements? *International Review of Economics & Finance*, 29, 75–82.
- Babu, C. N., & Reddy, B. E. (2014). A moving-average filter based hybrid ARIMA – ANN model for forecasting time series data. *Applied Soft Computing Journal*, 23, 27–38.

- Beaumont, A. N. (2014). Data transforms with exponential smoothing methods of forecasting. *International Journal of Forecasting*, 30(4), 918–927.
- Bennett, C. J., Stewart, R. a., & Lu, J. W. (2014). Forecasting low voltage distribution network demand profiles using a pattern recognition based expert system. *Energy*, 67, 200–212.
- Berndtsson, M., Hansson, J., Olsson, B., & Lundell, B. (2008). *Thesis Projects*.
- Chatfield, C. (2000). *Time Series Forecasting*.
- Chisholm, A. (2013). *Exploring Data with RapidMiner*.
- Dong, Z., Yang, D., Reindl, T., & Walsh, W. M. (2013). Short-term solar irradiance forecasting using exponential smoothing state space model. *Energy*, 55, 1104–1113.
- Eisler, R. (2004). *Biogeochemical, Health, and Ecotoxicological Perspectives on Gold and Gold Mining*.
- Gorunescu. (2011). *Data Mining Concept Model Technique*.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques*.
- He & Xu, shaohua. (2009). *Process Neural Network*.
- Hofmann, M. (2009). *Data Mining and Knowledge Discovery Series*.
- Hyndman, Koehler, Ord, S. (2008). *Springer Series in Statistics Forecasting with Exponential Smoothing*.
- Jammazi, R., & Aloui, C. (2012). Crude oil price forecasting: Experimental evidence from wavelet decomposition and neural network modeling. *Energy Economics*, 34(3), 828–841.
- Kirchgässner, G., & Wolters, J. (2007). *Introduction to Modern Time Series Analysis*.
- Ko, C.-N., & Lee, C.-M. (2013). Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended Kalman filter. *Energy*, 49, 413–422.
- Larose, D. T. (2006). *Data Mining Methods and Models. Data Mining Methods and Models*.
- Lavrac, N., & Zupan, B. (2006). Data mining in medicine. In *Data Mining and Knowledge Discovery Handbook* (pp. 21–36).
- Liao, G. (2014). Electrical Power and Energy Systems Hybrid Improved Differential Evolution and Wavelet Neural Network with load forecasting problem of air conditioning. *International Journal of Electrical Power and Energy Systems*, 61, 673–682.
- Lu, C.-J., Lee, T.-S., & Lian, C.-M. (2012). Sales forecasting for computer wholesalers: A comparison of multivariate adaptive regression splines and artificial neural networks. *Decision Support Systems*, 54(1), 584–596.
- Montgomery, D. C. (2008). *Introduction to Time Series Analysis and Forecasting*.
- Ouyang, Y., & Yin, H. (2014). A neural gas mixture autoregressive network for modelling and forecasting FX time series. *Neurocomputing*, 135, 171–179.
- Pierdzioch, C., Risse, M., & Rohloff, S. (2014). On the efficiency of the gold market: Results of a real-time forecasting approach. *International Review of Financial Analysis*, 32, 95–108.
- Pulido, M., Melin, P., & Castillo, O. (2014). Particle swarm optimization of ensemble neural networks with fuzzy aggregation for time series prediction of the Mexican Stock Exchange. *Information Sciences*, 280, 188–204.
- Sbrana, G., & Silvestrini, A. (2014). Int . J . Production Economics Random switching exponential smoothing and inventory forecasting. *Intern. Journal of Production Economics*, 156, 283–294.
- Shumway, R. H., Shumway, R. H., Stoffer, D. S., & Stoffer, D. S. (2006). *Time Series Analysis and Its Applications. Design*.
- Tratar, L. F. (2015). Int . J . Production Economics. *Intern. Journal of Production Economics*, 161, 64–73.
- Vercellis, C. (2009). *Business Intelligence: Data Mining and Optimization for Decision Making*.
- Yager, R. R. (2013). Exponential smoothing with credibility weighted observations. *Information Sciences*, 252, 96–105.
- Yu, F., & Xu, X. (2014). A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network. *Applied Energy*, 134, 102–113.
- Zhang, G. P. (2004). *Neural Networks in Business Forecasting*. (G. P. Zhang, Ed.) *Review of Economic Sciences* (Vol. 6). IGI Global.

Zhou, S., Lai, K. K., & Yen, J. (2012). A dynamic meta-learning rate-based model for gold market forecasting. *Expert Systems with Applications*, 39(6), 6168–6173.

BIOGRAFI PENULIS



Indah Suryani. Menempuh pendidikan Strata 1 Sistem Informasi dan Strata 2 Magister Ilmu Komputer di Pasca Sarjana STMIK Nusa Mandiri Jakarta. Saat ini menjadi salah satu staf pengajar di salah satu perguruan tinggi swasta di Indonesia. Minat penelitian pada bidang data mining.



Romi Satria Wahono. Memperoleh gelar B.Eng dan M.Eng pada bidang Ilmu Komputer di Universitas Saitama, Jepang, dan Ph.D pada bidang Software Engineering di Universiti Teknikal Malaysia, Melaka. Menjadi pengajar dan peneliti di Fakultas Ilmu Komputer Universitas Dian Nuswantoro.

Merupakan pendiri dan CEO PT. Brainmatics, sebuah perusahaan yang bergerak dibidang pengembangan software. Minat penelitian pada bidang Software Engineering dan Machine Learning. Tergabung sebagai anggota profesional dari asosiasi ilmiah ACM, PMI dan IEEE Computer Society.