

PENYUSUNAN *COMPOSITE LEADING INDICATOR* SIKLUS BISNIS DI INDONESIA MENGGUNAKAN *ARTIFICIAL NEURAL NETWORK*

Hertoto Dwiyo

Fakultas Ekonomi Universitas Gajayana

Yohanes Hadi Susilo

Fakultas Ekonomi Universitas Kristen Malang

ABSTRACT

After the 1997 financial crisis, like many developing Asian countries, Indonesia have taken major initiatives to improve their national statistical systems as part of their efforts in strengthening national economic monitoring and surveillance and crisis prevention measure. Composite leading indicators are becoming more widely recognized in predicting business cycles in Indonesia.

This article attempts to construct composite leading indicators of business cycles in Indonesia using monthly economic and financial data during the sample period of 1970–2001. This article also explore the possibility of constructing composite leading indicators of business cycles by using artificial neural network method. The result show that the composite leading indicators constructed by artificial neural network method is able to predict all of the turning points of business cycles in Indonesia. The performance of this method is comparable to the other prediction method such as regression.

Keywords: *Aggregate economic activity, business cycles, artificial neural network, predicting, composite leading indicators, turning points*

A. LATAR BELAKANG

Output dari suatu perekonomian, biasa diukur dengan gross domestic product (GDP), adalah produk nasional yang dihasilkan oleh penduduk dalam suatu negara (Sukirno, 1999). Output bisa diposisikan sebagai indikator prestasi kegiatan suatu perekonomian. Karena itu, fluktuasi dari output juga mencerminkan fluktuasi dari kegiatan suatu perekonomian. Demikian pula, ketika suatu perekonomian tengah bergelut dengan krisis, juga akan tercermin pada fluktuasi outputnya. Ketika krisis finansial menghantam negeri ini pada pertengahan 1997, yang dampaknya mampu menyentuh semua sektor, akhirnya baru disadari akan perlunya mencermati fluktuasi output (*business cycles*). Mengapa output bisa berfluktuasi sehingga membentuk suatu siklus? Apakah fluktuasi tersebut bisa diprediksi sehingga memungkinkan langkah antisipatif terhadap dampak yang tidak diinginkan?

Banyak penelitian yang telah dilakukan dalam upaya melakukan prediksi terhadap fluktuasi tersebut, seperti yang dilakukan oleh Kim dan Choi (1997), serta Zhang dan Zhuang (2002). Prediksi terhadap *business cycles*, kebanyakan dilakukan dengan cara menyusun indikator-indikator ekonomi yang mampu memberikan sinyal atau tanda-tanda secara dini apabila terdapat kecenderungan perubahan pergerakan siklus, lebih populer dengan sebutan *leading indicators*. Indikator-indikator ini dapat disusun dalam bentuk gabungan (*composite leading indicators*) dari *time series* data variabel-variabel makroekonomi yang juga bergerak fluktuatif mendahului pergerakan siklus. *Composite leading indicators* (CLIs) merupakan salah satu dari tiga indikator yang banyak dipergunakan untuk melihat perekonomian ke depan. Dua indikator yang lain adalah *coincident indicators* dan *lagging indicators*. Menyusun CLIs untuk memprediksi *business cycles* sebenarnya identik dengan

membangun early warning system karena CLIs merupakan salah satu komponen dari early warning system.

Sutomo dan Irawan (2004) mengungkapkan beberapa alasan utama mengapa CLIs menjadi begitu penting. Pertama, CLIs dapat digunakan untuk meramalkan turning points dari *business cycles*, sehingga memungkinkan penyusunan kebijakan untuk secara dini mengambil langkah antisipatif terhadap dampak yang tidak diinginkan. Kedua, untuk memenuhi kebutuhan *private sector*, CLIs bisa dipergunakan oleh para pelaku bisnis untuk menyesuaikan strategi penjualan dan investasi mereka, serta realokasi resources di antara berbagai alternatif investasi dalam rangka optimalisasi return. Informasi dari CLIs juga sangat diperlukan untuk perencanaan peningkatan produksi, investasi, ekspansi serta diversifikasi aktivitas bisnis. Ketiga, sebagai open economy country. Perekonomian Indonesia dipengaruhi tidak hanya oleh faktor-faktor internal, tetapi juga faktor-faktor eksternal seperti nilai tukar rupiah dan world interest rate.

Artikel ini berbicara banyak tentang bagaimana memprediksi business cycles, terutama untuk kasus Indonesia. Masih sama dengan penelitian-penelitian dengan topik serupa, prediksi dilakukan dengan cara menyusun CLIs. Namun yang membedakannya dengan penelitian-penelitian tersebut, CLIs disusun dengan menggunakan *metode artificial neural network* (ANN).

B. METODE PENELITIAN DAN ANALISIS DATA

Studi ini didasarkan pada data empiris bulanan IFS (IMF) dan Bank Indonesia mulai akhir 1970 sampai dengan akhir 2001, tentunya untuk kasus di Indonesia. Ada beberapa tahapan yang perlu dilakukan untuk mencapai tujuan dari studi ini. Pertama, menentukan reference series untuk mengukur business cycles sebagai fluktuasi dari *aggregate economic activity*. Kedua, menentukan dan memilih sejumlah variabel ekonomi tertentu yang akan dijadikan predictors dari turning point siklus. Penentuan variabel-variabel tersebut berdasarkan klasifikasi dalam enam kelompok *financial vulnerability* seperti yang dilakukan oleh Regional Economic Monitoring Unit ADB, yaitu kelompok current account, capital account, financial sector, fiscal account, real sector, serta global economy, dan diharapkan variabel-variabel terpilih dapat mewakili masing-masing kelompok. Pemilihan variabel-variabel tersebut juga berdasarkan rasional ekonomi yang merupakan temuan studi-studi empiris di bidang krisis keuangan dan perbankan di berbagai negara termasuk di Asia Timur. Kemudian, baik reference series maupun seluruh predictor ditransformasikan ke dalam bentuk logarithms, kecuali variabel-variabel dalam *rate, growth* atau *change form*.

Ketiga, melakukan *detrending* terhadap series dengan menggunakan metode *filtering* HP filter (Hodrick dan Prescott, 1997). Mengapa *detrending* diperlukan? Ramanathan (1994) mengatakan, jika garis trend menunjukkan adanya serial *correlation* pada residual, maka forecasting bisa diperbaiki dengan mengeksplorasi *residual structure*. Metode yang biasa digunakan adalah dengan mengeluarkan garis trend-nya (disebut dengan *detrending*). Setelah diperoleh nilai residualnya, nilai ini yang kemudian direlasikan dengan variabel-variabel lain yang mungkin dapat menjelaskan fluktuasi di sekitar garis trend tersebut. Pendekatan seperti ini banyak dipergunakan pada analisis business cycles.

Dalam definisi business cycles selalu menyebutkan fluktuasi, atau pergerakan, tentu maksudnya adalah fluktuasi atau pergerakan di sekitar garis trend-nya. Karena itu, konsep *business cycles* yang lebih luas diartikan sebagai pergerakan deviasi suatu series dari trend-nya (Lucas; dalam Kim dan Choi, 1997). Sehingga diperlukan untuk mengestimasi trend dari series, yang kemudian bisa didapatkan pergerakan deviasi series tersebut dari trend-nya. Banyak model *business cycles* disertai dengan asumsi yang sulit diterima baik secara teoritis maupun empiris. Model-model tersebut memodifikasi *neoclassical growth model* yang mengekspresikan business cycles sebagai fluktuasi di sekitar garis edar growth (growth path), di mana produktivitas tumbuh dalam tingkat yang konstan (trend-nya linier). Untuk menghindari asumsi produktivitas tumbuh dalam tingkat yang konstan tersebut, metode *filtering* HP filter digunakan. Sebenarnya ada beberapa metode *filtering* selain HP filter ini, tetapi

dalam prakteknya tidak terdapat perbedaan yang signifikan di antaranya (Cooley dan Prescott; dalam Zhang dan Zhuang, 2002).

Metode filtering HP filter ini, selain mengestimasi trend dari series, juga mendekomposisikan series y_t ke dalam trend component y_t^G dan cyclical component y_t^C . Lalu, dengan menggunakan trend component y_t^G , dilakukan minimisasi atas fungsi berikut:

λ adalah parameter yang merefleksikan relative variance dari trend component ke cyclical component. Ketika $\lambda=0$, trend component merupakan original series-nya, ketika $\lambda \rightarrow \infty$, trend component mendekati bentuk linear trend. Untuk mendapatkan hasil yang optimal, Rahn dan Uhling (1999), juga Burnside (dalam Rahman dan Yamagata, 2004), menyarankan nilai λ adalah sebesar 129,600 untuk series bulanan.

Keempat, melakukan uji akar unit (*unit root test*) terhadap series dengan metode Augmented Dickey-Fuller (ADF) test untuk menguji apakah series bisa disebut sebagai *stationarity time series*. Gujarati (1995) menyebutkan bahwa *stationarity time series* merupakan syarat dari forecasting. Mengupayakan series pada kondisi stationary adalah untuk menghindari *spurious cyclicalilty problem*. Sebenarnya, proses filtering juga dapat mereduksi masalah *nonstationarity time series*, namun untuk lebih meyakinkannya tetap akan dilakukan uji akar unit.

Kelima, *turning points (peaks dan troughs)* siklus dari *reference series* ditentukan, termasuk juga menentukan durasi dari peak ke trough maupun dari trough ke peak. Keenam, menyeleksi sejumlah variabel ekonomi yang terpilih sebagai predictors untuk ditentukan apakah suatu variabel itu merupakan *leading indicator, coincident indicator, atau lagging indicators* dari *business cycles*. *Cross-correlations* antara *reference series* dengan seluruh kandidat indikator diterapkan untuk melakukan seleksi. Dari nilai koefisien korelasinya dapat ditentukan dua hal, yaitu *direction (procyclical, countercyclical, dan acyclical)* dan *timing (leading, coincident, dan lagging)* dari *turning point*.

Ketujuh, salah satu kriteria pemilihan indikator adalah kandidat indikator memiliki nilai koefisien korelasi relatif tinggi terhadap *reference series*, di atas 0,5 (Sutomo dan Irawan, 2004). Namun, karena penyusunan *composite leading, coincident, dan lagging indicators* menggunakan metode ANN, maka selain memperhatikan nilai koefisien korelasi juga mengevaluasi nilai *akaike information criterion, AIC* (Ramanathan, 1994). Kandidat indikator akan ditambahkan satu per satu ke dalam penyusunan *composite indicators*, jika nilai AIC makin tinggi dengan ditambahkan jumlah kandidat indikator, maka berarti indikator yang terakhir ditambahkan tersebut adalah kandidat indikator partisipatif.

$$AIC = \left[\frac{RSS}{n} \right] e^{(2k/n)}$$

RSS adalah *residual sum of square*, n adalah jumlah observasi, dan k adalah jumlah kandidat indikator yang telah dimasukkan ditambah *reference series*.

Kedelapan, setelah kandidat indikator partisipatif berhasil ditentukan, selanjutnya adalah menentukan range observasi untuk training dan testing dengan mencari nilai bobot dan range observasi yang dapat meminimumkan kuadrat kesalahan rata-rata (*mean square error*) model, di mana arsitektur model ANN yang dipilih adalah *backpropagation*. Penjelasan lebih detail mengenai ANN beserta propertinya akan disampaikan pada bagian-bagian selanjutnya. Kesembilan, melakukan evaluasi terhadap kinerja dari metode ANN dengan cara membandingkannya dengan metode lain, regresi misalnya. Tolok ukur yang dipergunakan adalah koefisien determinasi (R^2), residual sum of square (RSS), *mean square error* (MSE), dan *root mean square error* (RMSE).

$$RSS = \sum \hat{Y}^2 - \sum Y^2$$

$$MSE = \frac{RSS}{(n - k)}$$

$$RMSE = \sqrt{MSE}$$


$$R^2 = \frac{\sum (\hat{Y} - \bar{Y})^2}{\sum (Y - \bar{Y})^2} = \frac{ESS}{TSS}$$

Di mana \hat{Y} adalah predicted series, \bar{Y} average series, dan Y actual series.

Business cycles dan Implementasinya di Indonesia

Mankiw (1997) menuliskan bahwa *business cycles* adalah fluktuasi yang terjadi dalam output, pendapatan, dan kesempatan kerja. Samuelson dan Nordhaus (1992) juga menyebut *business cycles* sebagai fluktuasi dalam output nasional, pendapatan, dan kesempatan kerja total. Fluktuasi tersebut biasanya selama periode dua sampai sepuluh tahun dan bercirikan ekspansi atau kontraksi pada beberapa sektor perekonomian. Sedangkan menurut Abel dan Bernanke (2005), merupakan fluktuasi dari *aggregate economic activity*, jadi bukan merupakan fluktuasi *single economic variable*, dengan durasi yang bervariasi dari lebih satu tahunan, sepuluh tahunan, atau dua puluh tahunan. Lucas (dalam Kim dan Choi, 1997), mendefinisikan *business cycles* sebagai pergerakan *gross national product* di sekitar trend-nya, dan ditambahkannya bahwa konsep *business cycles* yang lebih luas dapat diartikan sebagai pergerakan deviasi suatu series dari trend-nya.

Aggregate
economic activity



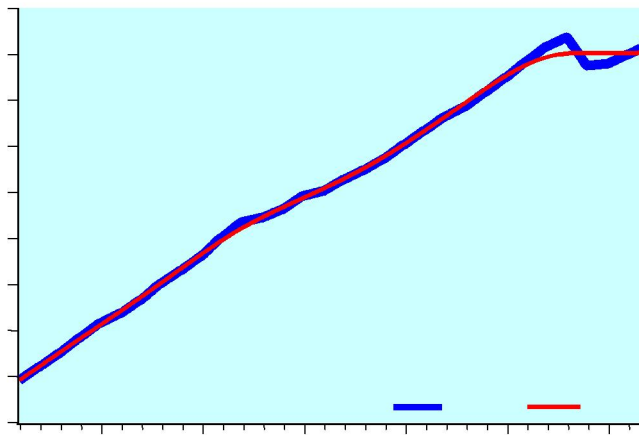
Gambar 1. Pola dari Siklus Bisnis

Satu episode *business cycles* dimulai dari trough sampai trough berikutnya melewati satu peak, atau dimulai dari peak sampai peak berikutnya melewati satu trough. Di dalamnya selalu ada fase ekspansi yang terjadi pada banyak aktivitas ekonomi secara bersamaan, juga selalu ada fase kontraksi atau penyusutan. Kedua fase ini silih berganti dari satu siklus ke siklus berikutnya, dan semua siklus berhubungan antara yang satu dengan yang lain, di bagian akhir yang satu dengan bagian awal yang lain. Rangkaian perubahan tersebut berulang kembali tetapi tidak secara periodik atau berkala, satu siklus tidak selalu sama durasi waktunya.

Resesi terjadi ketika siklus berada pada fase kontraksi, yaitu antara *business peak* dan *business trough*. Secara informalnya, fase kontraksi dikatakan telah masuk kategori resesi ketika terjadi penurunan *gross national product* selama dua kuartal berturut-turut. *National bureau of economic*

research, NBER, memiliki ukuran sendiri untuk mengatakan bahwa fase kontraksi telah masuk kategori resesi, yaitu ketika terjadi penurunan pada *output, income, employment, dan trade*, yang biasanya bertahan antara enam bulan sampai satu tahun serta ditandai dengan kontraksi yang menyebar luas pada banyak sektor perekonomian. Dan ketika fase kontraksi terjadi secara ekstra dengan durasi yang lebih lama lagi, maka disebut sebagai depresi.

Dalam konteks Indonesia, menentukan *reference series* untuk mengukur *business cycles* sebagai fluktuasi dari *aggregate economic activity* merupakan suatu hal yang krusial. Pada kasus ini GDP dipilih sebagai indikator aktivitas ekonomi, atau disebut juga sebagai *reference series*. Dasarnya, walaupun *business cycles* didefinisikan secara luas sebagai fluktuasi *aggregate economic activity* yang berarti bukan fluktuasi dari satu variabel saja, namun GDP merupakan *single variable* yang paling mendekati untuk mengukur *aggregate economic activity* (Abel dan Bernanke, 2005). Pada Gambar 2 disajikan actual dan trend GDP series dalam *logarithmic form* mulai Tahun 1970 sampai 2001.



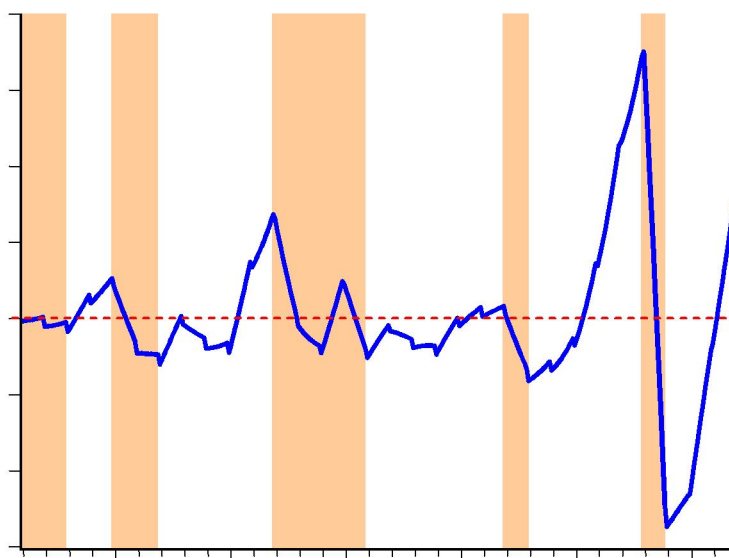
Gambar 2. PDB Aktual dan Trend-nya dalam Daftar Logaritma

Sedangkan gambar selanjutnya (Gambar 3), menunjukkan siklus dari GDP dengan menerapkan metode *filtering HP filter*. Selama periode akhir 1970 sampai akhir 2001, terdapat empat siklus di dalam perekonomian Indonesia dengan pola seperti tampak pada Gambar 3 tersebut. Siklus pertama C1 diawali dengan trough T1 pada Desember 1972 dan berakhir sampai trough T2 pada Desember 1976. Demikian pula siklus kedua C2 berlangsung antara T2 – T3, periode Desember 1976 - Desember 1985. Siklus ketiga C3 berlangsung antara T3 – T4, periode periode Desember 1985 - Desember 1992. Dan terakhir siklus keempat C4 yang berlangsung antara T3 – T4, periode periode Desember 1992 - Desember 1998.

Pada keempat siklus tersebut terdapat lima trough dan empat peak pada perekonomian Indonesia selama periode sampel dengan turning points yang rata-rata terjadi pada akhir tahun. Total durasi waktu dari keempat siklus tersebut adalah 312 bulan dan didominasi oleh fase ekspansi, yaitu 68% atau 213 bulan. Sedangkan porsi dari fase kontraksi adalah 32% atau 99 bulan. Dominasi fase ekspansi juga tercermin dari rata-rata durasinya, rata-rata durasi fase ekspansi adalah 53 bulan per siklus. Sedangkan rata-rata durasi fase kontraksi adalah 25 bulan per siklus. Mengingat lebih dari dua per tiga total durasi waktu dari keempat siklus tersebut didominasi oleh fase ekspansi, ini menunjukkan bahwa lebih dari duapertiga kegiatan perekonomian Indonesia berada pada fase ekspansi, dan sepertiga sisanya adalah fase kontraksi.

Kesimpulan bahwa aktivitas perekonomian Indonesia selama periode sampel didominasi oleh fase ekspansi didukung oleh lebih besarnya nilai rata-rata per bulan amplitudo siklus pada fase ekspansi, yaitu sebesar 0,551% (Tabel 2 di atas). Sedangkan nilai rata-rata per bulan amplitudo siklus

pada fase kontraksi adalah sebesar 0,501%. Ini memang menunjukkan bahwa siklus lebih banyak berada pada fase ekspansi.



Keterangan: * = low, ** = very low

Gambar 3. Siklus PDB Indonesia: Penyimpangan dari Trend

C. HASIL DAN PEMBAHASAN

Indikator-indikator Kandidat

Sebelum dilakukan seleksi terhadap sejumlah variabel ekonomi yang terpilih sebagai predictors untuk ditentukan apakah suatu variabel itu merupakan *leading indicator*, *coincident indicator*, atau *lagging indicators* dari *business cycles*, *cross-correlations* antara *reference series* dengan seluruh kandidat indikator diterapkan untuk melakukan seleksi. Dan sebelum itu pula akan dilakukan uji akar unit (*unit root test*) terhadap seluruh series dengan metode *Augmented Dickey-Fuller (ADF)* test untuk menguji apakah suatu series bisa disebut sebagai *stationarity time series*. *Stationarity time series* merupakan syarat dari fungsi *forecasting* karena dengan mengupayakan series pada kondisi *stationary* merupakan upaya untuk menghindari *spurious cyclical problem*. Setelah dilakukan beberapa perhitungan pendahuluan, maka diperoleh nilai koefisien korelasi. Berdasarkan data-data tersebut dapat ditentukan dua hal, yaitu *direction (procyclical, countercyclical, dan acyclical)* dan *timing (leading, coincident, dan lagging)* dari *turning point*. Selanjutnya semua kandidat kini dapat dikelompokkan berdasarkan *leading, coincident, atau lagging indicators*, seperti tampak pada Tabel 1.

Sutomo dan Irawan (2004) menyarankan bahwa salah satu kriteria pemilihan indikator adalah kandidat indikator yang memiliki nilai koefisien korelasi relatif tinggi terhadap *reference series*, yaitu di atas 0.5. Jadi, sebenarnya cukup hanya dengan melihat apakah nilai koefisien korelasi relatif tinggi, maka indikator partisipatif telah dapat ditentukan. Namun, karena penyusunan *composite leading, coincident, dan lagging indicators* adalah menggunakan metode ANN, maka selain memperhatikan nilai koefisien korelasi juga mengevaluasi nilai *akaike information criterion, AIC* (Ramanathan, 1994). Kandidat indikator akan ditambahkan satu per satu ke dalam penyusunan *composite indicators*. Jika nilai AIC makin tinggi dengan ditambahkannya jumlah kandidat indikator, maka berarti indikator yang terakhir ditambahkan tersebut merupakan indikator partisipatif. Berdasarkan kriteria AIC tersebut, maka kandidat indikator berhasil diseleksi dengan mengeliminasi tiga kandidat

yang tidak memenuhi kriteria AIC, yaitu *domestic credit*, *percapita income*, dan *money supply*. Hasilnya dapat dilihat pada Tabel 2.

Berkenalan dengan *Artificial Neural Network*

Artificial neural network (ANN) atau jaringan syaraf tiruan, merupakan suatu model pengelolaan informasi dengan karakteristik dan ide dasar yang berasal dari struktur dan cara kerja otak serta sel

Tabel 1. Cyclical Candidate of Participant Leading, Coincident, and Lagging Indicators of

Candidate indicators	Cross-correlation		Absolut AIC	Direction
	Lead or Lag	Coefficient		
Leading				
1 Consumer price index	+1	-0.903	8.2403	Counter cyclical
2 Govern. expend. to GDP	+7	-0.729	8.2582	Counter cyclical
3 Demand deposit	+1	0.333	8.7137	Procyclical*
4 Government expenditure	+8	-0.255	8.7670	Countercyclical*
Coincident				
1 Domestic credit to GDP	0	-0.865	7.8535	Counter cyclical
2 Export	0	0.539	8.0085	Procyclical
3 Import	0	0.503	8.0499	Procyclical
4 House-hold consumption	0	-0.449	8.1052	Counter cyclical
5 Domestic credit	0	-0.414	8.1018	Counter cyclical
Lagging				
1 Domestic interest rate	-6	-0.615	7.0255	Counter cyclical
2 Inflation	-5	-0.514	7.0658	Counter cyclical
3 Yen per US \$	-17	-0.502	7.2588	Counter cyclical
4 Exchange rate	-1	-0.480	7.4877	Counter cyclical
5 World interest rate	-2	0.335	7.4926	Procyclical*
6 Per-capita income	-4	-0.269	7.4875	Countercyclical*
7 Gross net-income	-4	-0.259	7.5381	Countercyclical*
8 Investment	-2	-0.207	7.8079	Countercyclical*
9 US GDP	-3	0.113	7.9634	Procyclical**
10 Money supply	-3	0.073	7.9596	Procyclical**

Keterangan: * = low, ** = very low

syaraf manusia (*neuron*). ANN dilahirkan sebagai salah satu upaya generalisasi model matematik dengan diilhami dari model jaringan syaraf biologis. Skema *fisiologis neuron* seperti ditunjukkan Gambar 4. Mekanisme kerja *neuron* adalah, apabila terdapat sejumlah sinyal yang berasal dari *axon* (pengirim sinyal) *neuron* lain dan masuk melalui *dendrite* (penerima sinyal), akan dikalikan dengan pembobot *synapse* (sinapsis, unit yang menghubungkan *neuron* yang satu dengan yang lainnya). Ada dua jenis *synapse*, yaitu *synapse* yang bersifat membangkitkan (*exite*) dan *synapse* yang bersifat menghambat (*inhibit*). Proses pembelajaran terjadi dengan adanya perubahan pada *synapse*. Jika potensial listrik mencapai suatu batas tertentu (*threshold*), *neuron* akan bereaksi. Sinyal yang masuk kemudian dijumlahkan oleh badan sel dan dikonversi oleh fungsi aktivasi tertentu, sehingga menghasilkan sinyal pemicu yang dialirkan ke neuron lain melalui axon. Mekanisme tersebut yang kemudian ditiru ke dalam bentuk model hubungan matematis.

Tabel 2. Cyclical Behavior of Participant Leading, Coincident, and Lagging Indicators of Business Cycles in Indonesia

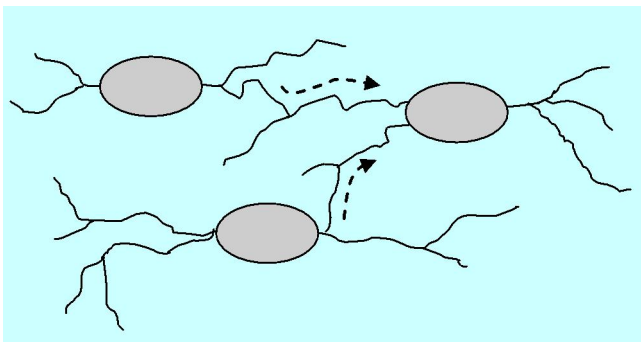
Participant indicators	Cross-correlation		Absolut AIC	Direction
	Lead or Lag	Coefficient		
Leading				
1 Consumer price index	+1	-0.903	8.2403	Countercyclical
2 Govern. expend. to GDP	+7	-0.729	8.2582	Countercyclical
3 Demand deposit	+1	0.333	8.7137	Procyclical*
4 Government expenditure	+8	-0.255	8.7670	Countercyclical*
Coincident				
1 Domestic credit to GDP	0	-0.865	7.8535	Countercyclical
2 Export	0	0.539	8.0085	Procyclical
3 Import	0	0.503	8.0499	Procyclical
4 House-hold consumption	0	-0.449	8.1052	Countercyclical
Lagging				
1 Domestic interest rate	-6	-0.615	7.0255	Countercyclical
2 Inflation	-5	-0.514	7.0658	Countercyclical
3 Yen per US \$	-17	-0.502	7.2588	Countercyclical
4 Exchange rate	-1	-0.480	7.4877	Countercyclical
5 World interest rate	-2	0.335	7.4926	Procyclical*
6 Gross net-income	-4	-0.259	7.5381	Countercyclical*
7 Investment	-2	-0.207	7.8079	Countercyclical*
8 US GDP	-3	0.113	7.9634	Procyclical**

Keterangan: * = low, ** = very low

Lebih lanjut, seperti nampak pada Gambar 5, sebuah neuron menerima sinyal dari *neuron* X_1 , X_2 , dan X_3 dengan bobot hubungan masing-masing w_1 , w_2 , dan w_3 . Neuron hanya menjumlahkan dan memberikan nilai pembatas (*threshold*) terhadap ketiga impuls yang masuk, sehingga menghasilkan nilai aktivasi α .

$$\alpha = w_1x_1 + w_2x_2 + \dots + w_nx_n$$


Besarnya impuls yang diterima mengikuti fungsi aktivasi $y = f(\alpha)$. Jika nilai fungsi aktivasi tersebut cukup kuat, maka sinyal akan diteruskan. Nilai fungsi aktivasi merupakan output dari ANN, nilai ini dapat pula dipergunakan sebagai dasar untuk merubah bobot.



Gambar 4. Mekanisme Psikologi Neuron

Jika dianalogikan dengan *neuron biologis*, munculnya aksi potensial disimbolkan dengan nilai biner 1. Dan sebaliknya jika tidak, disimbolkan dengan nilai biner 0. *Perceptron* terbatas penggunaannya sebagai metode perhitungan pada aplikasi nyata, masalah akan timbul jika masukan yang diumpangkan adalah bilangan real, dan bilangan real pada keluaran. Proses analisis matematis untuk jaringan semacam ini cukup kompleks, dan dapat dilakukan dengan salah satu varian dari ANN, yaitu *multilayer perceptron*.

Penggunaan bilangan real untuk masukan dan keluaran mensyaratkan penggunaan threshold dengan fungsi matematis antara lain fungsi *sigmoid*, *arctangen*, *arcsin*, dan lain-lain. Fungsi yang digunakan haruslah mulus dan kontinu (tidak diperkenankan menggunakan potongan fungsi linear atau fungsi step) dan mempunyai nilai batas atas dan batas bawah absolut. Fungsi *sigmoid* merupakan fungsi yang umum digunakan dalam ANN.



Gambar 5. Mathematical Form dari Mekanisme Psikologi Neuron

ANN Untuk Menyusun *Composite Leading, Coincident, dan Lagging Indicators*

Setelah kandidat indikator partisipatif berhasil ditentukan, tahap selanjutnya adalah menyusun *composite leading, coincident, dan lagging indicators* dengan arsitektur model yang dipilih adalah *backpropagation (feed forward backpropagation)*. Terdapat tiga tahapan training dalam *backpropagation*. Pertama, fase maju (*feed forward*). Pada fase ini pola input dihitung maju mulai dari input layer hingga *output layer* dengan menggunakan fungsi aktivasi yang ditentukan. Kedua, fase mundur. Pada fase ini selisih antara output jaringan dengan target yang diharapkan, dipropagasi mundur mulai dari garis yang berhubungan langsung dengan unit-unit pada *output layer*. Ketiga, modifikasi bobot untuk meminimumkan kesalahan yang mungkin terjadi. Dilakukan iterasi terhadap tahapan-tahapan tersebut hingga kriteria penghentian terpenuhi. Kriteria penghentian yang umum dipakai adalah pada jumlah iterasi, yaitu jika telah melebihi jumlah maksimum iterasi, atau pada tingkat kesalahan, yaitu jika tingkat kesalahan telah lebih kecil dari batas yang bisa ditoleransi.

Proses training merupakan pembelajaran bagi komputer untuk melakukan prediksi, sedangkan testing merupakan langkah evaluasi dari proses pembelajaran (*training*). Setelah proses training tersebut selesai, maka dilakukan testing terhadap jaringan untuk mengenali pola dengan seperangkat observasi data yang berbeda dengan yang dipergunakan saat training. Namun sebelumnya, ditentukan dahulu range observasi untuk proses training dan testing dengan mencari nilai bobot dan range observasi yang dapat meminimumkan kuadrat kesalahan rata-rata (*mean square error; MSE*). Setelah itu ditentukan pula jumlah *hidden layer*-nya, yaitu satu, dengan jumlah neuron tertentu yang juga dapat meminimumkan nilai *MSE*. Sebagai patokan awal untuk menentukan jumlah neuron dalam *hidden layer* ditentukan dengan:


$$\text{Jumlah neuron} = 0.5 (\text{neuron input} - \text{neuron output}) + \text{jumlah pola training set}$$

Di bawah ini disajikan hasil proses penyusunan *composite leading, coincident, dan lagging indicators* menggunakan metode ANN.

Composite leading indicators

Dengan jumlah range observasi untuk proses training adalah 274 observasi (12:1970%09:1993) dan 91 observasi (10:1993%04:2001) untuk proses testing, serta dengan *hidden layer* sebanyak 8,


diperoleh nilai MSE minimal untuk proses training, yaitu sebesar 0,00000300. Ilustrasi network-nya disajikan pada Gambar 6.



Gambar 6. Ilustrasi Jaringan untuk Perhitungan *Composite Leading Indicators*

Composite Coincident Indicators

Dengan jumlah range observasi untuk proses training adalah 274 observasi (12:1970%09:1993) dan 99 observasi (10:1993%12:2001) untuk proses testing, serta dengan hidden layer sebanyak 9, diperoleh nilai MSE minimal untuk proses training yaitu sebesar 0.00000683. Ilustrasi network-nya disajikan pada Gambar 7.




Gambar 7. Ilustrasi Jaringan Untuk Perhitungan *Composite Coincident Indicators*

Composite Lagging Indicators

Dengan jumlah range observasi untuk proses training adalah 274 observasi (05:1972%02:1995) dan 82 observasi (03:1995%12:2001) untuk proses testing, serta dengan hidden layer sebanyak 9, diperoleh nilai MSE minimal untuk proses training, yaitu sebesar 0,00000055. Ilustrasi network-nya disajikan pada Gambar 8.

Dari ketiga model network di atas, diperoleh kriteria performance dari masing-masing network, seperti ditunjukkan oleh Tabel 3. Tampaknya semua kriteria untuk ketiga model penyusunan composite leading, coincident, dan lagging indicators, menunjukkan hasil yang baik karena nilai MSE dan RSS-nya adalah minimal, sehingga RMSE juga minimal, dan karena itu pula nilai R dan R² adalah maksimal. Tetapi, untuk lebih meyakinkannya, akan dibuat perbandingan seandainya persoalan penyusunan *composite leading, coincident, dan lagging indicators* tersebut diselesaikan dengan metode regresi.



Gambar 8. Ilustrasi Jaringan Untuk Perhitungan *Composite Lagging Indicators*

Performance jika ketiga model network di atas diselesaikan dengan metode regresi disajikan pada Tabel 4. Jika dibandingkan dengan metode regresi, maka metode ANN mempunyai kemampuan prediksi yang lebih baik, yang ditunjukkan oleh lebih rendahnya nilai-nilai RSS, MSE, dan RMSE baik pada proses training maupun pada proses testing pada semua kelompok indikator. Kelebihan ANN juga ditunjukkan oleh lebih tingginya nilai R dan R² baik pada proses training maupun pada proses testing pada semua kelompok indikator jika dibandingkan dengan metode regresi.

Tabel 3. Kinerja Metode ANN

Composite Indicators	ANN Performance Criterion				
	RSS	MSE	RMSE	R	R ²
Leading					
Training	0.00080619	0.00000300	0.00173118	0.909	0.825
Testing	0.00256073	0.00002978	0.00545673	0.954	0.909
Coincident					
Training	0.00183793	0.00000683	0.00261390	0.754	0.568
Testing	0.00072798	0.00000774	0.00278289	0.988	0.976
Lagging					
Training	0.00014509	0.00000055	0.00073994	0.958	0.918
Testing	0.00111517	0.00001528	0.00390850	0.982	0.964

Prediksi *Turning Point* Siklus Bisnis di Indonesia

Salah satu tujuan menyusun CLIs adalah untuk memprediksi turning points dari *business cycles*. CLIs yang disusun dengan ANN method ternyata mampu berfungsi dengan baik sebagai prediktor *turning point* siklus bisnis di Indonesia. Namun, sebagai pembanding, juga disajikan prediksi turning point siklus bisnis di Indonesia menggunakan CLIs yang disusun dengan regression method.

Tabel 4. Kinerja dari Metode Regresi

Composite Indicators	Regression Performance Criterion				
	RSS	MSE	RMSE	R	R ²
Leading					
Training	0.00217455	0.00000808	0.00284321	0.707	0.500
Testing	0.01971618	0.00022926	0.01514127	0.543	0.295
Coincident					
Training	0.00313923	0.00001167	0.00284321	0.527	0.278
Testing	0.02723216	0.00028970	0.01514127	0.258	0.067
Lagging					
Training	0.00170680	0.00000644	0.00253787	0.796	0.633
Testing	0.02760012	0.00037808	0.01944438	0.245	0.060

CLIs yang disusun dengan *regression method* mengalami dua kali kegagalan dalam memprediksi *turning point* yaitu pada akhir siklus C1 atau awal siklus C2, tepatnya pada trough T2 (lihat Tabel 5). Juga pada akhir siklus C4, yaitu pada trough T5. Pada kedua trough ini, CLIs tidak mampu memberikan indikasi dengan tegas akan terjadinya *turning point*. Untuk T2, keterlambatan CLIs dalam memberikan sinyal adalah 23 bulan, sedangkan untuk T5 terlambat 10 bulan. Suatu keterlambatan yang tampaknya akan sulit untuk ditolerir.

Tabel 5. Prediksi Turning Point Menggunakan Metode Regresi

Cycles	Trough Or Peak	Date		Leading Time (Month)
		CLIs	Actual GDP	
C1	T1	11:1971	12:1972	13
	P1	05:1973	11:1974	18
C2	T2	11:1978	12:1976	-23
	P2	10:1981	11:1981	1
C3	T3	11:1983	12:1985	25
	P3	11:1989	11:1991	24
C4	T4	11:1992	12:1992	1
	P4	11:1997	12:1997	1
	T5	10:1999	12:1998	-10
Average				12.9
Average for trough				14.4
Average for peak				11.0

Dibandingkan dengan yang disusun menggunakan *regression method*, CLIs yang disusun dengan ANN method ternyata lebih mampu memprediksi dengan baik, mampu memberi indikasi terhadap semua *turning point* baik trough maupun peak dari seluruh siklus dalam periode sampel. Rata-rata leading time-nya berkisar 6,3 bulan. Artinya, rata-rata 6,3 bulan sebelum terjadinya *turning points* dari business cycles, CLIs telah memberikan tanda akan terjadinya *turning points* tersebut. Rata-rata durasi leading time CLIs kasus Indonesia ini ternyata tidak jauh berbeda dengan rata-rata durasi leading time CLIs di Malaysia hasil penelitian Zhang dan Zhuang (2002), yaitu berkisar 6,55 bulan (6,8 untuk trough dan 6.3 untuk peak).

Tabel 6. Prediksi Turning Point Menggunakan Metode ANN

Cycles	Trough or Peak	Date		Leading Time (Month)
		CLIs	Actual GDP	
C1	T1	11:1971	12:1972	13
	P1	07:1973	11:1974	16
C2	T2	10:1976	12:1976	2
	P2	10:1981	11:1981	1
C3	T3	04:1985	12:1985	8
	P3	10:1990	11:1991	13
C4	T4	11:1992	12:1992	1
	P4	11:1997	12:1997	1
	T5	10:1998	12:1998	2
Average				6.3
Average for trough				5.2
Average for peak				7.8

Dengan rata-rata leading time sekitar 6,3 bulan, CLIs ternyata juga mampu memberikan sinyal akan terjadinya krisis finansial di Tahun 1997. Akhirnya, tulisan ini masih menyisakan sepenggal tanya, yaitu cukupkah rata-rata waktu 6,3 bulan tersebut bagi otoritas makroekonomi untuk melakukan tindakan countercyclical terhadap prediksi pergerakan *business cycles* yang tidak diharapkan?

D. KESIMPULAN DAN REKOMENDASI

Di Indonesia, selama periode akhir 1970 sampai dengan akhir 2001, berhasil diidentifikasi empat siklus. Keempat siklus tersebut didominasi oleh fase ekspansi sebesar duapertiga dari total durasi siklus, ini menunjukkan bahwa lebih dari duapertiga kegiatan perekonomian Indonesia berada pada fase ekspansi, dan sepertiga sisanya adalah fase kontraksi. Dibandingkan dengan Malaysia dan Filipina, Indonesia ternyata lebih mampu mempertahankan fase ekspansi yang ditunjukkan oleh rata-rata durasi fase ekspansi per siklus lebih tinggi dibanding kedua negara tersebut. Namun Malaysia lebih cepat untuk bangkit dari keterpurukan dibanding, yang ditunjukkan oleh rata-rata durasi fase kontraksi per siklus Malaysia adalah terendah dibanding Indonesia dan Filipina.

Penyusunan *composite leading, coincident, dan lagging indicators* dengan metode ANN, menunjukkan hasil yang baik karena nilai MSE dan RSS-nya adalah minimal sehingga RMSE juga minimal, dan karena itu pula nilai R dan R² adalah maksimal. Dan jika dibandingkan dengan metode regresi, maka metode ANN mempunyai kemampuan prediksi yang lebih baik pada proses training maupun pada proses testing, serta pada semua kelompok indikator. CLIs yang disusun dengan regression method mengalami dua kali kegagalan dalam memprediksi turning point dari business cycles di Indonesia. Sedangkan CLIs yang disusun dengan ANN method ternyata lebih mampu memprediksi dengan baik, mampu memberi indikasi terhadap semua turning point baik trough maupun peak dari seluruh siklus dalam periode sampel.

Dengan rata-rata leading time yang berkisar 6,3 bulan, berarti rata-rata 6,3 bulan sebelum terjadinya *turning points* dari *business cycles*, CLIs telah memberikan tanda akan terjadinya turning points tersebut. Rata-rata leading time ini ternyata tidak jauh berbeda dengan rata-rata durasi leading time CLIs di Malaysia, yaitu berkisar 6,55 bulan.

DAFTAR PUSTAKA

- Abel, Andrew B. dan Bernanke, Ben S. 2005. *Macroeconomics*. Fifth Edition. Pearson Addison Wesley
- Anonymous. 2003. *A Regional Early Warning System Prototype for East Asia. Regional Economic Monitoring Unit*. Asian Development Bank. <http://www.mof.go.jp/jouhou/kokkin/tyousa/tyou052.pdf>
- Gujarati, Damodar N. 1995. *Basic Econometrics*. Third Edition. McGraw-Hill
- Hodrick, Robert J. dan Prescott, Edward C. 1997. Post-war U.S. Business Cycles: An Empirical Investigation. *Journal of Money, Credit, and Banking*, Vol.29, No.1
- Kim, Kunhong dan Choi, Yong-Yil. 1997. Business Cycles in Korea, Is There Any Stylized Feature? *Journal of Economic Studies*, Vol.21, No.5. MCB University Press
- Mankiw, N. Gregory. 1997. *Macroeconomics*. Third Edition. Worth Publishers
- Mishkin, Frederic S. 1997. *The Economics of Money, Banking, and Financial Markets*. Fifth Edition. Addison-Wesley, USA
- Rahman, Pk. Md. Motiur dan Yamagata, Tatsufumi. 2004. *Business Cycles and Seasonal Cycles in Bangladesh*. Discussion Paper. Institute of Developing Economies. http://www.ide.go.jp/english/publish/dp/pdf/001_yamagata.pdf
- Ramanathan, Ramu. 1994. *Introductory Econometrics With Applications*. Third Edition. Dryden Press
- Rebelo, Sergio A. 2005. *Real Business Cycle Models: Past, Present, and Future*. Northwestern University, NBER, CEPR. <http://www.nyu.edu/econ/user/gertlerm/medterm.pdf>
- Samuelson, Paul A. dan Nordhaus, William D. 1992. *Macroeconomics*. Fourteenth Edition. McGraw-Hill, Inc
- Siang, Jong Jek. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Cetakan Pertama. Penerbit Andi. Yogyakarta
- Sukirno, Sadono. 1999. *Pengantar Teori Makroekonomi*. Edisi Kedua. PT RajaGrafindo Persada, Jakarta
- Sutomo, Slamet dan Irawan, Puguh B. 2004. *Development of Composite Leading Indicators (CLIs) in Indonesia*. <http://www.oecd.org/dataoecd/54/59/34898123.pdf>
- Zhang, Wenda dan Zhuang, Juzhong. 2002. *Leading Indicators of Business Cycles in Malaysia and The Philippines*. Asian Development Bank. http://www.adb.org/documents/erd/working_papers/wp032.pdf