

Web-Based Decision Support System dengan Jaringan Syaraf **Tiruan untuk Deposan Bank Syariah: Sebuah Proposal**

Saiful Anwar¹ dan Eko Budhi Suprasetiawan²

Abstract.

Previous studies have convincingly shown the evidence that depositor's motive in patronizing Islamic bank is simply to seek return so-called saving-investment motive. This paper proposes a decision support system for depositors, supporting their motives in dealing with Islamic bank's investment based deposit product namely *mudharabah* time deposit. Initially, the paper investigates many types of algorithm to be utilized as an expert system to predict future rate of return of *mudharabah* time deposit. We found that artificial neural networks (ANNs) algorithm is the best suited one to carry a prediction task in the system. By using this system, it is believed that depositor's fund will stay longer in the Islamic bank industry. Additionally, Islamic bank will gain more attraction from conventional bank's depositor by starting to compare their interest rate currently received with one month ahead predicted rate of return. At the end, the system will benefit the industry by increasing competitiveness in pooling fund system against its counter part. According to the best author's knowledge, this is the first decision support system ever built for depositors of Islamic bank.

Keywords: Islamic bank, *mudharabah* time deposit, decision support system, artificial neural networks

I. Pendahuluan

Dalam dunia perbankan, dana pihak ketiga (DPK) memainkan peran yang sangat penting dimana jumlahnya, dari sisi deposan, ditentukan oleh dua hal, yaitu: kemampuan keuangan deposan yang dipengaruhi oleh tingkat pendapatan dan kekayaannya, dan tingkat kesadaran seseorang untuk menabung yang dipengaruhi oleh *saving motive*. Ahli ekonomi pertama yang berbicara tentang *saving motive* adalah Adam Smith pada tahun 1776 yang mengatakan bahwa: "*The principle which prompts to save is the desire of bettering our condition, a desire which is generally calm and dispassionate, comes with us from the womb, and never leaves us still we go into the grave*" (Kasilingam & Jayabal, 2008). Pernyataan diatas menunjukkan bahwa motivasi dasar seseorang dalam menabung adalah untuk membuat hidupnya menjadi lebih baik di masa depan.

Kemudian, Keynes (1936) melengkapi tinjauan diatas dengan memperkenalkan delapan motivasi yang dimiliki seorang deposan antara lain: (1) *Precautionary motive* atau motivasi berjaga-jaga. (2) *Foresight* atau *life-cycle motive* yang bertujuan agar tidak terjadi perubahan pendapatan yang terlalu besar di masa depan, terutama setelah memasuki masa pensiun. (3) *Profit motive* yaitu motivasi untuk mendapatkan *reward* atau keuntungan dari dana yang disimpan. (4) *Improvement motive* yaitu sebuah keinginan untuk memperbaiki kondisi

¹ Mahasiswa S3 tahun terakhir, Nagaoka University of Technology, Jepang.

² Mahasiswa S2, PSKTTI, Universitas Indonesia

kehidupan di masa depan. (5) *Independence motive* yaitu motivasi untuk memiliki rasa independensi atau kemampuan berkehendak karena memiliki uang. (6) *Enterprise motive*; bertujuan untuk melakukan investasi pada saat keuangannya memungkinkan. (7) *Bequest* atau *Pride motive* yaitu membangun kebanggaan diri dengan mempersiapkan masa depan dari keturunannya, dan (8) *Avarice* atau *pure miserliness motive*, yaitu sebuah motivasi yang didasarkan keinginan murni seseorang untuk memiliki sesuatu lebih banyak (*greedy*).

Khusus untuk memfasilitasi *profit motive*, para ahli sistem informasi manajemen telah membuat sebuah *decision support sistem (DSS)* yang membantu deposan membandingkan informasi suku bunga yang ditawarkan seluruh bank pada suatu wilayah atau negara tertentu. Contoh DSS yang ditujukan untuk para deposan ini dapat dilihat di www.bankrate.com, www.best-bankrates.com, www.monitorbankrates.com, dan lain sebagainya. Sistem ini bertujuan membantu deposan dalam memonitor suku bunga berlaku pada bank-bank yang beroperasi di wilayah atau negara tertentu dan kemudian menjadikannya sebagai panduan untuk menentukan dimana dia akan menyimpan dananya dengan harapan dapat menikmati pendapatan bunga maksimum.

Selaras dengan penjelasan sebelumnya, ternyata motif utama para penabung di bank syariah juga tidak berbeda dengan para penabung di bank konvensional. Mereka lebih mengutamakan tujuan mendapatkan bagi hasil daripada motivasi keber-**agama**-an, sebagaimana dijelaskan pada riset-riset sebelumnya yang dilakukan oleh, Kasri et.al, (2009), Mangkuto, (2004) dan, Haron dan Ahmad, (2000). Terkait hal ini, penulis berpendapat bahwa motif penabung di bank syariah lebih cocok disebut sebagai *investment-saving motive* daripada istilah *profit motive* yang digunakan oleh Keynes. Karena secara teori, deposan bank syariah harus berhadapan dengan risiko kehilangan dana yang ditabung mengingat bank syariah menggunakan kontrak bagi hasil pada produk tabungannya. Hal ini berbeda dengan deposan bank konvensional yang tidak berhadapan dengan risiko yang sama. Sebab, *profit motive* yang menjadi dasar menabung di bank konvensional diartikan sebagai harapan mendapatkan imbalan atas dana yang tersimpan karena menahan konsumsi saat ini dimana jumlahnya

tidak akan berubah selama masa penyimpanan (*pre-determined rate*) sebagai pengejawantahan dari filosofi *time value of money* yang diharamkan dalam Islam.

Untuk kasus Indonesia, *Investment-saving motive* secara empirik ditemukan oleh Kasri et.al (2009) yang menjelaskan bahwa ketertarikan utama para deposan menabung di bank syariah dilatarbelakangi oleh Rate Bagi Hasil (RBH)-nya yang kompetitif. Selanjutnya, ditemukan pula adanya tendensi dimana deposan akan menarik dananya dari bank syariah jika bank konvensional menawarkan tingkat suku bunga yang lebih tinggi daripada RBH bank syariah yang saat itu diterima. RBH atau sering juga disebut *rate of return* ini dihitung dengan cara membagi jumlah uang yang diterima seorang dengan jumlah uang yang disimpannya secara pro-rata selama satu tahun. Dengan RBH yang dipublikasikan setiap bulan ini, deposan hanya dapat membandingkan bagi hasil yang diterima dengan suku bunga berjalan yang ditawarkan bank konvensional tanpa mampu memprediksi secara ilmiah berapa RBH yang akan diterima bulan depan; apakah akan lebih tinggi atau sebaliknya.

Dilatarbelakangi permasalahan diatas, riset ini difokuskan untuk menjadi fasilitator terhadap *saving-investment motive* para deposan, agar tidak cepat berubah menjadi *profit motive* yang diharamkan dalam Islam. Lebih jelasnya, tulisan ini bertujuan men-*support* motif deposan bank syariah dengan membuat sebuah DSS, yang fiturnya berbeda dengan DSS berbasis suku bunga, yaitu DSS yang memiliki kemampuan prediksi atas tingkat bagi hasil satu bulan ke depan. Untuk itu, DSS yang diberi nama DSS-Deposan Bank Syariah (DSS-DBS) ini akan memiliki sebuah algoritma khusus dan spesifik untuk melakukan tugas prediksi yang tidak dijumpai pada DSS bank konvensional. DSS-DBS ini menggunakan sebuah algoritma yang disebut *artificial neural networks* atau Jaringan Syaraf Tiruan (JST) yang akan bertugas membantu deposan memprediksi tingkat bagi hasil yang akan diberikan bank syariah satu bulan ke depan berdasarkan kinerja keuangannya. Dengan demikian, sistem ini akan memberikan informasi yang berguna bagi para deposan untuk mengoptimalkan pendapatan bagi hasil yang akan diperoleh dengan menyimpan dananya pada bank syariah yang paling tepat; daripada langsung memindahkannya ke sebuah

bank konvensional yang menawarkan suku bunga berjalan yang belum tentu lebih tinggi dari pada bagi hasil yang akan diterima dari bank syariah tempatnya menyimpan dana saat ini atau bank syariah lain.

Hasil dari penelitian ini adalah sebuah proposal berupa purwarupa (*prototype*) dari sistem yang dimaksud dengan kemampuan yang masih terbatas yaitu melakukan prediksi bagi hasil produk deposito *mudharabah* satu bulan dari Bank Syariah Mandiri sebagai studi kasus. Penulis berkeyakinan bahwa riset mengenai DSS-DBS ini sangat penting dengan alasan sebagai berikut. **Pertama**, dana deposito di bank syariah cukup dominan dimana jumlahnya per Mei 2011 adalah sekitar 60.17% dari total DPK (Bank Indonesia). **Kedua**, porsi dana depositan yang mengendap pada produk deposito berjangka periode satu bulan sangat dominan dimana jumlahnya per-April 2011 adalah sebesar 70.23% dari total deposito berjangka *mudharabah* (Bank Indonesia) walaupun deposito jenis ini memberikan RBH paling rendah. Hal ini menandakan bahwa sebagian besar dana depositan bank syariah bersifat sangat cair dan bertendensi untuk berpindah dengan cepat dari satu bank ke bank yang lain. **Ketiga**, kelebihan utama produk deposito berjangka bank syariah adalah dimungkinkannya melakukan *break rekening* tidak pada masa jatuh tempo tanpa adanya *breakage fee* yang pada bank konvensional biasanya dikenakan sebesar 0.5% hingga 1% dari nominal dana yang disimpan. Dengan fitur ini, depositan bank syariah dimungkinkan berperilaku seperti seorang investor yang bisa memindahkan dananya kapan saja dan kemana saja selama para depositan memiliki akses informasi yang cepat dan akurat terkait dengan prediksi pergerakan tingkat bagi hasil produk deposito seluruh bank syariah.

Sejauh yang penulis ketahui, riset ini adalah riset pertama yang pernah dilakukan di bank syariah terutama dalam hal pengembangan perangkat DSS untuk para depositannya dimana tulisan ini dibuat sebagai implementasi dari riset-riset sebelumnya (tabel 1). Selanjutnya, tulisan ini disusun dengan struktur sebagai berikut: bab 2 akan menggambarkan lebih rinci tentang *saving model* pada bank konvensional dan membandingkannya dengan sudut pandang Islam serta bagaimana bank syariah memberikan solusi atas hal tersebut. Selanjutnya

pada bab 3 akan dibahas tentang studi literatur yang menjelaskan secara singkat mengenai *decision support sistem* dan beberapa teknik *machine learning* yang dapat digunakan sebagai pilihan algoritma prediksi. Pada bab 4 akan dibahas tentang data dan metodologi riset. Kemudian pada bab 5 akan dipresentasikan purwarupa dari DSS-DBS dan tingkat akurasi dalam melakukan prediksi. Terakhir, seluruh tulisan ini akan ditutup pada bab 6 sebagai kesimpulan.

II. Saving Model dan Produk Tabungan Berbasis Syariah

II.1 Saving model berbasis bunga.

Kim (2001) menjelaskan beberapa model formal terkait dengan motif menabung seseorang sebagaimana berikut. (1) *Life-cycle model*; (2) *Precautionary model*; (3) *Buffer-stock model*; (4) *Permanent-income model*. Model *life-cycle* yang diperkenalkan oleh Ando and Modigliani pada tahun 1963 menjelaskan bahwa para deposan menyimpan dananya dengan tujuan untuk menyelaraskan jumlah pendapatan dan konsumsi sepanjang hidupnya. Pada dasarnya model ini bersandarkan pada motif untuk menjaga kemampuan finansialnya setelah memasuki masa pensiun. Selanjutnya, *Precautionary model* adalah sebuah model formal yang menggambarkan perilaku menabung individu berdasarkan pada keinginan untuk berjaga-jaga pada saat “musim paceklik” atau kondisi *emergency* (Canova et.al, 2005). Sedangkan *buffer-stock model* adalah sebuah model yang menggambarkan bahwa perilaku menabung seseorang dipengaruhi oleh tujuannya untuk melindungi tingkat konsumsinya terhadap adanya kemungkinan penurunan pendapatan di masa depan (Kim, 2001). Sedangkan yang terakhir, *permanent-income model* adalah sebuah model berdasarkan hipotesa *permanent-income*, diperkenalkan oleh Friedman pada tahun 1957, yang menyebutkan bahwa pola konsumsi seseorang tidak ditentukan oleh tingkat konsumsi saat ini melainkan atas ekspektasi tingkat pendapatan di masa depan. Hal ini berimplikasi pada tingkat keinginan menabung seseorang dimana jika ekspektasi pendapatan masa depan adalah tinggi, maka jumlah dana yang disisihkan untuk ditabung saat ini menjadi lebih rendah atau sebaliknya.

II.2 Kegiatan menabung dari sudut pandang Islam

Pentingnya aktifitas dan perilaku menabung disebutkan secara jelas dalam Al-Quran sebagai berikut: ***“Dan janganlah kamu jadikan tanganmu terbelenggu pada lehermu dan janganlah kamu terlalu mengulurkannya karena itu kamu menjadi tercela dan menyesal”*** (QS. 17:29). Lebih spesifik Jalaludin (1992) menerangkan bahwa motif menabung dalam sudut pandang Islam adalah tidak ditujukan hanya untuk kepentingan diri sendiri dan keluarga, sebagaimana dimaksud Keynes, akan tetapi Islam mewajibkan pemeluknya untuk memperhatikan nilai dan tanggung jawab sosial. Allah SWT menggambarkan keharusan adanya titik keseimbangan antara kepentingan pribadi dengan kepentingan sosial pada dua ayat Al-quran dibawah ini.

1. ***“Dan hendaklah takut kepada Allah orang-orang yang seandainya meninggalkan di belakang mereka anak-anak yang lemah, yang mereka khawatir terhadap [kesejahteraan] mereka. Oleh sebab itu hendaklah mereka bertakwa kepada Allah dan hendaklah mereka mengucapkan perkataan yang benar.”*** (QS. 4:9)
2. ***“.....supaya harta itu jangan hanya beredar di antara orang-orang kaya saja di antara kamu. Apa yang diberikan Rasul kepadamu maka terimalah dia. Dan apa yang dilarangnya bagimu maka tinggalkanlah; dan bertakwalah kepada Allah. Sesungguhnya Allah sangat keras hukuman-Nya.*** (QS. 59:7)

Jelas terlihat disini bahwa tujuan menabung dalam Islam bukan sekedar menyimpan uang saja, akan tetapi uang yang tersimpan itu harus diinvestasikan agar tidak berputar hanya pada kelompok tertentu yang kemudian harus digunakan untuk meningkatkan tingkat kesejahteraan umat. Selain itu, investasi yang dimaksud dalam Islam adalah investasi yang berkeadilan yang mendukung tingkat kehidupan yang baik dan meliputi dimensi spiritual dan moral serta tidak berbasiskan riba atau suku bunga. Sebagaimana Allah SWT sebutkan dalam Al-Quran: ***“Hai orang-orang yang beriman, janganlah kamu memakan riba dengan berlipat ganda dan bertakwalah kamu kepada Allah supaya kamu mendapat keberuntungan.”*** (QS. 3:130).

II.3 Produk tabungan Islami

Secara umum, bank syariah memiliki dua jenis sumber dana. Yang pertama adalah DPK yang berasal dari individu dan disimpan dalam bentuk tabungan *wadiah*, tabungan *mudharabah* dan deposito berjangka *mudharabah*. Sedangkan yang kedua adalah dana dalam bentuk non deposit seperti hutang antar bank, sekuritas yang dikeluarkan perbankan, kewajiban antar bank, kewajiban bank pada bank sentral dan kewajiban lainnya (Ismal, 2009).

Untuk produk tabungan berbasis *wadiah*, bank syariah memiliki otoritas untuk menggunakan dana tersimpan tanpa berkewajiban untuk berbagi hasil kepada deposan. Sedangkan pada tabungan atau deposito berbasis kontrak *mudharabah*, bank dan deposan sepakat untuk berbagi keuntungan dan kerugian. Deposito berjangka yang menggunakan kontrak jenis ini memiliki dua tipe, yang pertama disebut *mudharabah muqayyadah* dan yang kedua adalah *mudharabah mutlaqah*. Pada tipe pertama, bank syariah berfungsi hanya sebagai *fund manager*, agen atau disebut juga sebagai *non-participating Mudharib* (El-Din, 2004). Dengan demikian, bank tidak memiliki otoritas untuk mencampur dana deposan dengan dana bank kecuali dengan seizin deposan. Dalam perlakuan akuntansinya, transaksi jenis ini tidak digolongkan sebagai sumber dana bank melainkan dicatat secara *off balance sheet*. Sebaliknya, untuk tipe yang kedua, bank syariah diperkenankan untuk menggunakan dana tersebut sebeb-bebanya tanpa ada batasan dari deposan dalam hal penyaluran pembiayaan, dan kemudian berbagi risiko antara bank dengan deposan (Grais and Pellegrini, 2006).

Pada prakteknya, ketika seorang penabung membuka rekening, khususnya rekening deposito berjangka *mudharabah*, maka antara bank dan deposan terlebih dahulu menyepakati persentase bagi hasil yang akan diberikan setiap akhir bulan selama periode deposit. Kemudian, deposan akan memperoleh bagi hasil yang jumlahnya berbeda-beda setiap bulan mengingat jumlah imbal bagi hasil yang diterima tergantung pada tingkat kinerja bank syariah (Zoubi and Olson, 2008).

III. Kajian Literatur

III.1 Decision support system

Pembuatan keputusan adalah hasil dari proses yang sangat kompleks yang bertujuan untuk mengantisipasi kondisi yang akan terjadi di masa depan baik yang bersifat positif dan menguntungkan atau sebaliknya dengan berdasarkan data, informasi dan pengetahuan masa kini dan pengalaman masa lampau. Proses pengambilan keputusan ini bermula dari kesadaran seseorang bahwa ia tinggal dalam sebuah sistem yang kompleks, dan kemudian dilanjutkan dengan melakukan klasifikasi atas faktor-faktor luar yang terkait dengan permasalahan dimana faktor-faktor yang paling mempengaruhi hasil dari proses klasifikasi itu akan dijadikan dasar seseorang dalam pengambilan keputusan. Faktor-faktor paling penting itu kemudian diolah dengan menggunakan *additive factor* yang berfungsi sebagai mesin prediksi yang akan digunakan sebagai penunjuk arah dalam pengambilan keputusan. Mesin prediksi ini akan mempermudah seseorang dalam mensimplifikasi seluruh informasi yang sudah berhasil diklasifikasi sebelumnya dan kemudian memberikan pilihan berupa prediksi-prediksi yang masing-masing prediksi tersebut sudah diberi bobot untuk kemudian dipilih mana yang akan menjadi sebuah keputusan yang paling tepat. Ringkasnya, proses diatas dapat dilihat pada gambar 1.

Dalam beberapa dekade terakhir ini, manusia disuguhkan oleh perkembangan teknologi informasi yang sangat pesat. Hal ini memungkinkan tersedianya peranti lunak terkini dan canggih yang berguna dalam pengambilan sebuah keputusan baik untuk level perusahaan maupun individu. Khusus dalam dunia keuangan, Wen et.al (2008) mengajukan proposal berupa *knowledge-based decision support system* yang menggunakan JST sebagai algoritma prediksi yang berguna sebagai mesin untuk mengukur dan memprediksi kinerja keuangan sebuah perusahaan. Selanjutnya, Tsang et.al (2003) juga mengajukan proposal mengenai sebuah perangkat pendukung pembuatan keputusan dengan memprediksi kinerja investasi perusahaan, sistem ini diberi nama Evolutionary Dynamic Data Investment Evaluator (EDDIE) berbasis pada *genetic programming* sebagai algoritma prediksinya.

Matheson dan Howard (1968) lebih lanjut menjelaskan secara teoritis bahwa *decision support system* adalah sebuah sistem yang menerapkan prosedur ilmiah dalam sebuah situasi yang teramat kompleks tempat dimana dibutuhkan sebuah pengambilan keputusan. Sistem ini menggunakan model komputasi yang akan melakukan evaluasi secara kuantitatif atas setiap opsi yang dimiliki dan kemudian memberikan perbandingan dengan cara menghitung bobot masing-masing opsi tersebut, yang pada akhirnya menyodorkan usulan kepada pengguna atas keputusan yang akan diambil. Dalam tulisannya Wen et.al (2008) menjelaskan secara lebih detail bagian-bagian sub-sistem yang menyusun sebuah DSS sebagaimana berikut: (1) *Data management sub-system*. (2) *Knowledge management sub-system*. (3). *Model management sub-yistem*. (4) *Dialogue sub-system*.

Sebagai sebuah sistem, masing-masing sub-sistem tidak bekerja sendiri melainkan saling terangkai dan terkait untuk menjalankan tugasnya dalam memberikan masukan atau usulan kepada penggunanya (gambar 2). DSS ini bekerja mulai dari memproses data pada sub-sistem *data management*, kemudian melakukan analisa atas setiap hubungan yang terjadi pada seluruh data yang berhasil dikumpulkan yang prosesnya dilakukan oleh sub-sistem *knowledge management*. Selanjutnya sub-sistem *model management* akan melakukan permodelan data yang hasil akhirnya digunakan untuk membandingkan pilihan-pilihan yang bisa diambil dengan terlebih dahulu melakukan pembobotan. Usulan yang dihasilkan akan diberikan kepada pengguna sistem yang ditampilkan pada sub-sistem *dialogue*.

III.2 Sub-sistem *model management* (SMM)

Bagian ini membahas secara khusus tentang SMM mengingat sub-sistem ini berfungsi sebagai mesin prediksi atas pilihan-pilihan yang bisa diambil oleh pengguna DSS. Wen et.al (2008) menjelaskan bahwa sub-sistem *model management* adalah bagian dari DSS yang bertanggung jawab membangun model prediksi. Sub-sistem ini membutuhkan model komputasi khusus yang disebut algoritma prediksi untuk melakukan tugas evaluasi secara kuantitatif yang selanjutnya akan menghasilkan perbandingan dan usulan atas opsi yang bisa

diambil seorang pembuat keputusan (gambar 3). Dalam hal pemilihan algoritma prediksi yang akan digunakan pada sub-sistem ini, Nisbet et.al (2009) merinci perkembangan metode statistika dan *data mining* yang bisa dipilih sebagai mesin prediksi dari masa paling awal hingga masa depan sebagaimana berikut:

Generasi pertama. Generasi ini berlangsung kira-kira abad ke-18 dimana saat itu terdapat dua cabang ilmu analisa statistika yaitu teorema Bayesian dan statistika klasik. Khusus untuk statistika klasik, kondisinya saat itu masih sangat sederhana yang disebut dengan nama regresi linear. Metode ini membutuhkan syarat-syarat berupa asumsi awal yang sangat ketat atas data yang akan dianalisa dimana data harus berupa distribusi yang jamak diketahui seperti distribusi normal, distribusi logit, dan distribusi poisson. Berikutnya, data yang akan dianalisa harus memiliki faktor independen, memiliki varian yang konstan (*homoscedastic*) dan terakhir variabel haruslah numerik dan bersifat kontinyu.

Generasi kedua. Sebagai perkembangan dari generasi pertama, pada tahun 80-an para peneliti sudah memiliki data yang sangat banyak dan bersifat non linear. Data-data tersebut tidak bisa dianalisa dengan menggunakan teknik regresi linear. Sehingga, pada masa ini dikembangkan model yang menggunakan pendekatan baru seperti; model logit, model probit, dan model generalisasi linear seperti Generalized Autoregressive Conditional Heteroscedastics (GARCH).

Generasi ketiga. Generasi ini dimulai ketika para peneliti berhadapan dengan data yang jauh lebih banyak dari generasi kedua dengan sifat data yang sangat tidak linear. Pada saat ini, para peneliti menggunakan pendekatan baru yang sangat berbeda dengan sebelumnya yaitu dengan mengikuti bagaimana neuron pada otak manusia bekerja. Metode baru ini disebut sebagai metode *machine learning* yang terdiri dari model JST dan decision tree.

Generasi keempat. Generasi ini dikembangkan untuk menutupi kekurangan yang ada pada metode *machine learning* dengan menggunakan sebuah pendekatan yang disebut *hypothesis space*. *Hypothesis space* adalah pendekatan yang menggunakan konstruksi matematis pada setiap permasalahan yang dihadapi (Nisbet et.al, 2009). Sebuah metode *machine learning* yang

menggunakan pendekatan *hypothesis space* dan fungsi “Kernel” diberi nama Support Vector Machines (SVMs).

Generasi kelima. Sebenarnya generasi ini belumlah muncul karena para peneliti masih berupaya keras untuk mensimulasikan bagaimana kerja sebuah mesin berfikir (*learning machine*) yang paling kompleks di dunia, yaitu otak manusia.

III.3 Algoritma prediksi

Upaya mencari algoritma prediksi yang paling sesuai, yang akan digunakan dalam sebuah DSS adalah pekerjaan yang tidak mudah. Hal ini disebabkan karena metode yang dipilih bukan berdasarkan atas tingkat kerumitan dan kecanggihan sebuah algoritma, melainkan tergantung dari karakteristik data yang digunakan. Nisbet et.al (2009) menjelaskan hal tersebut dengan mengatakan bahwa: “*Some data sets can be analyzed better with statistical analysis techniques, and other data sets can be analyzed better with data mining techniques*”. Dengan demikian, seorang peneliti perlu mencoba satu persatu, mana metode yang paling cocok untuk digunakan dalam DSS yang akan dibangunnya. Berikut pilihan-pilihan metode yang paling sering digunakan untuk melakukan prediksi.

a. Model Generalized Autoregressive Conditional Heteroscedastics (GARCH)

Heteroskedastik adalah sebuah definisi yang digunakan untuk sebuah ukuran ekspektasi error yang tidak konstan pada sebuah serial data dimana error tersebut tergantung pada variabel independennya. Kondisi ini sebenarnya menyalahi asumsi yang disyaratkan keberadaannya pada model regresi linear berupa kondisi homoskedastik dimana nilai ekspektasi error harus selalu sama pada seluruh titik variabel independen dan tidak dipengaruhi perubahannya oleh ukuran variabel independennya (Engle, 2001).

Engle pada tahun 1982 memperkenalkan kemungkinan menggunakan sifat heteroskedastik dari rata-rata error dan varian error pada sebuah data *time series* secara simultan yang kemudian diberi nama dengan sebutan Auto Regressive Conditional Heteroscedasticity (ARCH). Ringkasnya, model ini menjelaskan bahwa sebuah proses stokastik dari ukuran rata-rata tingkat erornya

dapat digunakan untuk memprediksi nilai aktual eror pada saat model tersebut mampu menyerupai data empiris yang dimiliki.

Selanjutnya, Bollerslev pada tahun 1986 memodifikasi model ARCH karena model ini memerlukan terlalu banyak parameter untuk cukup menggambarkan volatilitas dari sebuah data pada keseluruhan data time series. Model tersebut diberi nama Generalized Autoregressive Conditional Heteroscedasticity (GARCH). Model ini hanya membutuhkan tiga buah parameter yang memberikan kemampuan terhadap akar (*squared root*) dari angka-angka yang tak terbatas jumlahnya untuk mempengaruhi kondisi varian pada waktu berjalan (Matei, 2001). Bollerslev menjelaskan secara matematis model GARCH(p,q) yang dikembangkannya sebagai berikut:

$$Y_t = \sigma_t \epsilon_t; \quad \sigma_t^2 = \alpha + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (1)$$

Dimana: Y_t = Variabel dependent pada periode berjalan-t; σ_t = Standar deviasi pada periode berjalan-t; $\{\epsilon_t\}$ = Sebuah sekuen yang independen dan identik dari distribusi data dengan nilai rata-rata 0 dan varian sebesar 1.0; α = Nilai rata-rata; e_{t-1}^2 = Volatilitas eror data dari periode sebelumnya (t-1) (ARCH); σ_{t-j}^2 = varian dari periode sebelumnya (t-1) (GARCH)

b. Model Jaringan Syaraf Tiruan (JST)

JST adalah salah satu cabang pembahasan dari metode *machine learning* yang mensimulasi cara kerja jaringan syaraf. Model ini bekerja dalam bentuk kelompok dan berstruktur yang terdiri dari sel-sel yang disebut neuron yang membentuk jaringan syaraf seperti halnya pada otak manusia (gambar 4). Elemen-elemen yang mendukung beroperasinya sebuah neuron, sebagaimana terlihat pada gambar 5, yang terdiri dari; input, *weight* atau bobot yang berfungsi sebagai metode pembelajaran, fungsi transformasi yang akan menentukan apakah informasi yang datang cukup penting untuk diteruskan ke neuron lain dengan cara membandingkan bobot informasi dengan ambang batasnya. Kemudian yang terakhir adalah output. Layaknya otak manusia, neuron pada JST memerlukan proses training sebagai berlangsungnya proses pemahaman seperti mengenal

pola, menggeneralisasi sebuah permasalahan, dan melakukan pembelajaran mandiri untuk meningkatkan kemampuannya dalam melakukan analisa dan membuat sebuah kesimpulan.

Secara teknis JST bekerja sebagai berikut. Dimulai dari sebuah neuron bernama j (gambar 5) yang memiliki beberapa sumber input seperti $(x_1, x_2, x_3, \dots, x_j)$ dan sebuah output (y_j) . Masing-masing input yang akan masuk ke dalam neuron j memiliki bobot berupa $(w_{1j}, w_{2j}, w_{3j}, \dots, w_{ij})$ yang diartikan sebagai tingkat urgensi dari masing-masing input tersebut. Kemudian, informasi yang masuk ke dalam neuron j adalah berupa penjumlahan seluruh nilai informasi yang masuk dikalikan dengan masing-masing bobotnya yang disebut nilai bersih (u_j) . Selanjutnya, u_j akan dikomparasi dengan nilai ambang batas (t_j) yang dimiliki neuron j dan ditentukan apakah informasi yang masuk akan disampaikan ke neuron berikutnya dimana masing-masing neuron memiliki nilai t_j yang berbeda-beda. Jika u_j lebih besar dari t_j maka neuron j akan mengolah dan kemudian menyampaikannya ke neuron lain dalam bentuk output (y_j) . Untuk melakukan hal ini, neuron memerlukan sebuah fungsi yang disebut fungsi aktivasi bertugas untuk mengaktifkan u_j dan mentransformasinya menjadi y_j . Fungsi aktivasi tersebut yang paling sering digunakan adalah fungsi logistik dan sigmoid.

Tipologi atau arsitektur dari kebanyakan JST yang digunakan dalam sebuah penelitian berbentuk multilayer (West et.al, 1997). Oleh karena itu, penelitian ini akan mengkombinasikan beberapa neuron dalam bentuk multilayer untuk digunakan dalam pengenalan pola seperti melakukan klasifikasi, dan melakukan prediksi. Bentuk multilayer ini berupa *feed-forward network* yang terdiri dari layer input, layer tersembunyi (*hidden layer*) dan layer output. Secara matematis, model JST dituliskan sebagai berikut:

$$y = f(x, \theta) + \varepsilon \quad (2)$$

Dimana: x adalah vector dari variabel-variabel dependen yang akan menjadi sumber informasi, θ adalah bobot dari variabel-variabel independen dan ε adalah komponen *random error*. Selanjutnya, persamaan (3) adalah persamaan dari sebuah fungsi yang akan digunakan untuk melakukan tugas estimasi dan prediksi dari sejumlah data yang tersedia. Persamaan ini dapat dituliskan sebagai berikut:

$$Y = f \left[v_0 + \sum_{j=1}^m h \left(\lambda_j + \sum_{i=1}^n x_i w_{ij} \right) v_j \right] \quad (3)$$

Dimana: Y=Output; f=Fungsi aktivasi pada output layer; v_0 =Bias pada output; m= Jumlah unit neuron yang tersembunyi; h=Fungsi aktivasi pada hidden layer; λ_j =Bias yang terjadi pada unit-unit yang tersembunyi ($j = 1, \dots, m$); n=Jumlah unit yang berfungsi sebagai input; x_i = Vektor input ($i = 1, \dots, n$); w_{ij} = Bobot dari unit input i ke unit tersembunyi j; v_j = Bobot dari unit tersembunyi j ke output ($j = 1, \dots, m$)

c. Model Support Vector Machines (SVMs)

Support vector machine adalah model *machine learning* yang diperkenalkan oleh Vladimir Vapnik and Carolina Cortes pada tahun 1995. Model ini diperkenalkan untuk mengatasi kelemahan yang ditemui pada JST mengingat dalam proses pembelajarannya sering ditemui terjadinya *over training* yang mengurangi kemampuan belajarnya. Selain itu, JST terkadang gagal mencapai nilai global optima ketika berusaha melakukan optimisasi tingkat eror dari fungsi galatnya. Karena itulah, SVMs tidak melakukan hal yang sama seperti dilakukan JST yang berupaya meminimalisasi terjadinya eror pada saat training, melainkan dengan meminimalisasi batas atas dari *generalization error* guna mencapai performa terbaik dalam melakukan generalisasi informasi. Hal tersebut dilakukan dengan menggunakan prinsip *structural risk minimization*. Adapun batas atas dari *generalization error* yang dimaksud adalah sebuah nilai kombinasi antara *training error* dengan sebuah perlakuan regularisasi yang mengontrol kompleksitas sebuah ruang hipotesa (*hypothesis space*).

Pada awalnya model SVMs ini hanya digunakan untuk melakukan tugas pengenalan pola saja dengan melakukan pemetaan secara non-linier atas sebuah set data yang kompleks dengan menggunakan pendekatan dimensi ruang yang lebih tinggi (gambar 6). Akan tetapi, setelah diperkenalkannya fungsi Vapnik's ϵ -insensitive loss, model ini mengalami perkembangan dan digunakan lebih lanjut untuk melakukan prediksi yang dikenal juga dengan sebutan *support vector regression*. Sebagai pendatang baru, para peneliti sudah mulai banyak menggunakan model ini dan mendapatkan hasil prediksi yang sangat memuaskan

terutama di area keuangan dan ekonomi. Sebagai contoh Li et.al (2008) menggunakan SVMs untuk memprediksi nilai tukar dolar Amerika terhadap yen Jepang. Selanjutnya, Gu et.al (2011) juga menggunakan model ini dan mengkombinasikannya dengan algoritma genetik untuk memprediksi harga properti di China. Pai et.al (2006) secara matematis menggambarkan bagaimana model ini dikembangkan dari model yang awalnya digunakan untuk klasifikasi menjadi sebuah model prediksi Y_i dengan menggunakan sebuah data set; $G = \{(x_i, a_i)\}_{i=1}^N$ dimana x_i adalah vektor dari model input, a_i adalah nilai aktual dari input dan N adalah jumlah pola yang dimiliki sebuah data set. Formula tersebut adalah: $Y_i = f(x) = w_i \phi_i(x) + b$ (4)

Dimana: $Y_i =$ Output dalam bentuk scalar; $\phi_i(x) =$ ruang kerja dari input x ; w_i and $b =$ koefisien estimasi dengan menggunakan prinsip *structural risk minimization*, dimana, prinsip *structural risk minimization* dinyatakan sebagai berikut: $R(C) = C \frac{1}{N} \sum_{i=1}^N L_\varepsilon(d_i, Y_i) + \frac{1}{2} \|w\|^2$ (5)

dimana:

$$L_\varepsilon(d_i, Y_i) = \begin{cases} |d_i - Y_i| - \varepsilon, & |d_i - Y_i| \geq \varepsilon, \\ 0, & \text{others,} \end{cases}$$

$C =$ Konstanta regularisasi; $\varepsilon =$ Parameter presisi yang mempresentasikan jarak antara pipa yang berlokasi disekitar fungsi regresi; $d =$ Nilai actual pada saat periode I ; $Y =$ Nilai estimasi pada saat periode i ; $L_\varepsilon(d_i, Y_i) =$ Fungsi Vapnik's ε -insensitive loss yang akan memiliki nilai nol pada saat Y_i berada didalam pipa- ε . Selanjutnya, $\frac{1}{2} \|w\|^2$ adalah norma dari bobot vektor yang akan digunakan untuk menghitung tingkat kerataan (*flatness*) dari sebuah fungsi. Hal ini merupakan sebuah istilah regularisasi yang biasa digunakan untuk mengatur hubungan timbal balik antara kompleksitas dan aproksimasi dari sebuah ukuran keakuratan pada sebuah model regresi (Gu et.al, 2011). Sementara itu C pada persamaan 5 digunakan untuk menetapkan hubungan timbal balik antara varian dengan

kerataan (flatness) model. Kemudian, persamaan 5 diatas dirubah menjadi persamaan bersyarat sebagaimana berikut:

$$\text{Minimisasi: } R(w, \zeta, \zeta^*) = \frac{1}{2} \|w\|^2 + C \frac{1}{N} \sum_{i=1}^N (\zeta + \zeta^*) \quad (6)$$

Dengan syarat: $w_i \phi_i(x_i) + b - d_i \leq \varepsilon + \zeta_i^*$, dengan $i=1,2,..N$; $d_i - w_i \phi_i(x_i) - b_i \leq \varepsilon + \zeta_i$, dengan $i=1,2,..N$, dan $\zeta_i, \zeta_i^* \geq 0$, dengan $i=1,2,..N$. Selanjutnya variabel ζ dan ζ^* , keduanya akan digunakan untuk merepresentasikan jarak antar titik dari nilai aktual ke nilai batasnya yang terletak pada pipa ε .

Permasalahan optimisasi bersyarat ini kemudian diselesaikan dengan menggunakan format Langrangian (α_i, α_i^*) sebagaimana terlihat pada formula 7 yang memenuhi syarat kesamaan (*equality*) dari $\alpha_i \times \alpha_i^* = 0$ dimana $\alpha_i \geq 0$ and $\alpha_i^* \geq 0$

$$\begin{aligned} L(w_i, \zeta, \zeta^*, \alpha_i, \alpha_i^*, \beta_i, \beta_i^*) &= \frac{1}{2} \|w\|^2 + C \left(\frac{1}{N} \sum_{i=1}^N (\zeta + \zeta^*) \right) \\ &- \sum_{i=1}^N \alpha_i \left[w_i \phi(x_i) + b - d_i + \varepsilon + \zeta_i^* \right] - \sum_{i=1}^N \alpha_i^* \left[d_i - w_i \phi(x_i) - b + \varepsilon + \zeta_i \right] - \sum_{i=1}^N (\beta_i \zeta_i + \beta_i^* \zeta_i^*) \end{aligned} \quad (7)$$

Kemudian, agar dapat melakukan regresi, kondisi Karush-Kuhn-Tucker (K) dipergunakan untuk menghasilkan dual Langrangian sebagaimana berikut:

$$J(\alpha_i, \alpha_i^*) = \sum_{i=1}^N d_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^N d_i (\alpha_i - \alpha_i^*) - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) - (\alpha_j - \alpha_j^*) K(x_i, x_j)$$

$$\text{Dengan syarat: } \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0, \quad 0 \leq (\alpha_i, \alpha_i^*) \leq C, \quad i=1,2,3...N \quad (8)$$

Pada persamaan ini, perlakuan multiplikasi terhadap Langrangian yang mempresentasikan α_i and α_i^* telah memenuhi syarat dimana $\alpha_i \times \alpha_i^* = 0$. Selanjutnya, nilai ekspektasi optimum vektor *regression hyper plane* (w^*)

$$\text{ditentukan oleh: } w^* = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x_j) \quad (9)$$

Fungsi Kernel pada formula 9 direpresentasikan oleh $K(x_i, x_j) = \phi(x_i) \times \phi(x_j)$ dimana nilainya sama dengan output yang dihasilkan dalam vektor x_i dan x_j dalam ruang kerja $\phi(x_i)$ and $\phi(x_j)$. Kemudian, dengan

mengikuti kondisi Karush-Kuhn-Tucker conditions, hanya beberapa dari $(\alpha_i - \alpha_i^*)$ yang akan bernilai 0.

Penelitian ini menggunakan jenis Kernel berupa radial basis function (RBF) yang paling banyak digunakan oleh para peneliti karena sifatnya yang mampu melokalisasi dan merespon secara terbatas terhadap seluruh nilai riil yang ada pada sumbu x (*Statistica user guide*). Fungsi RBF dinyatakan sebagai

$$\text{berikut: } K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (10)$$

Dimana; σ adalah luas bidang RBF yang telah ditentukan sebelumnya seperti C dan ε . Akhirnya, model SVMs yang telah siap digunakan untuk melakukan regresi diformulasikan sebagai berikut:

$$f(x, \alpha, \alpha^*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (11)$$

IV. Data dan Metode Penelitian

Dalam pengumpulan data, penelitian ini menggunakan teori “Bank’s Failure”, yaitu sebuah teori kegagalan bank dengan menggunakan pendekatan makroekonomi yang diperkenalkan oleh Gambbs (1977) yang mengatakan bahwa: “*Extremely bad management may not prove fatal to a bank until economic condition leads to unexpected capital outflows or loan losses*”. Teori ini berkeyakinan bahwa kegagalan sebuah bank yang ditandai dengan kebankrutannya, tidak akan terjadi sampai datang sebuah kondisi ekonomi tertentu yang berakibat pada terjadinya arus modal keluar atau kegagalan bayar para kreditur secara masif. Dengan alasan tersebut, penelitian ini hanya menggunakan variabel makroekonomi untuk menginvestigasi volatilitas RBH.

Sebagaimana dijelaskan pada gambar 7, penelitian ini diinvestigasi dengan tiga langkah sebagai berikut. Langkah pertama menggunakan delapan macam variabel makroekonomi yang akan diseleksi berdasarkan tingkat signifikansinya dalam mempengaruhi volatilitas RBH. Delapan variabel yang digunakan adalah jumlah variable makro maksimum yang bisa dikumpulkan penulis yang terdiri dari: nilai tukar dolar Amerika terhadap rupiah (EXCH), indeks saham dari

Jakarta Stock Index (JST), uang beredar yang diukur dengan M1, tingkat inflasi (INFR), suku bunga rata-rata deposito berjangka satu bulan (INTR), suku bunga BI (BIRT), harga emas internasional berdasarkan London fix price (GOLD), dan harga rata-rata minyak per barel untuk tipe *Brent crude oil* dan *West Texas intermediate crude oil* dalam dolar (OIL). Variabel-variabel makro tersebut kecuali untuk GOLD dan OIL diperoleh dari laman Bank Indonesia. Sementara, data GOLD dan OIL diperoleh dari website World Gold Council dan US Energy Information and Administration. Kemudian, data yang digunakan sebagai variabel terikatnya adalah data rate bagi hasil deposito berjangka satu bulan dari industry perbankan syariah Indonesia (RBH-ALL). Seluruh data variabel bebas dan variabel terikat yang dikumpulkan sejak Januari 2000 sampai Desember 2008 akan digunakan untuk proses training. Pada investigasi tahap pertama ini, JST digunakan sebagai *selector machine* karena kelebihan-kelebihan yang dimilikinya berdasarkan kajian *literature review* yang dilaporkan oleh Zhang (2000).

Investigasi tahap kedua adalah melakukan penseleksian algoritma prediksi yang akan digunakan dalam sub-sistem *model management* (SMM). Proses penseleksian ini ditujukan untuk mencari algoritma terbaik dengan berdasarkan dua hal, yaitu yang memiliki tingkat akurasi terbaik dan memiliki kemampuan belajar terbaik yang ditandai dengan tingkat variasi eror yang kecil atau stabil.

Terakhir, pada investigasi tahap ketiga, model prediksi terpilih yang sebelumnya telah diberikan proses training dengan menggunakan data periode Januari 2000 sampai Desember 2008, akan diuji untuk melakukan prediksi RBH Bank Syariah Mandiri (RBH-BSM) berdasarkan variabel makro terpilih pada investigasi tahap pertama. Proses prediksi ini akan dievaluasi dengan menggunakan dua metode; pertama dengan ukuran statistik dan yang kedua dengan metode *in sample prediction* yaitu dengan cara membandingkan hasil prediksi dengan data aktual selama periode data sample. Akhirnya, *prototype* dari DSS ini akan diuji untuk melakukan *out-of sample prediction*, yaitu melakukan prediksi RBH deposito mudharabah berjangka waktu satu bulan diluar periode sampel berdasarkan pengetahuan yang diperoleh pada proses training .

V. Analisa dan Diskusi

V.1. Investigasi tahap pertama-Menseleksi variabel makroekonomi

Tahap ini terdiri dari beberapa langkah, antara lain: (1) Mendesain arsitektur JST. (2) Memberikan training pada JST. (3) Mengevaluasi kehandalan JST. Pada proses pertama, penelitian ini menggunakan “*exhaustive search method*” untuk menentukan arsitektur terbaik JST yang akan digunakan selanjutnya. Metode ini cukup memakan waktu karena bertujuan untuk menseleksi seluruh bentuk JST yang mungkin digunakan, dibatasi dengan menggunakan batasan r-squared sebesar 0.000001 sebagai kriteria *fitness* dan jumlah iterasi sebanyak 20.000 iterasi. Akhirnya, arsitektur JST yang terpilih adalah berupa $N^{(10-3-1)}$ (gambar 8). Arsitektur ini terdiri dari 1 layer input dengan 10 neuron, 1 layer tersembunyi yang memiliki 3 neuron, dan 1 layer output yang terdiri dari 1 neuron.

Selanjutnya, proses training pada JST dilakukan dengan terlebih dahulu men-*set* tiga buah konfigurasi. Konfigurasi pertama adalah menentukan fungsi logistik sebagai fungsi aktivasi pada layer tersembunyi. Kedua, metode *sum-of-squared errors* dipilih untuk meminimisasi eror pada output. Terakhir, output yang diharapkan di-*set* antara 0 dan 1 karena menggunakan fungsi logistik pada layer tersembunyi. Setelah ketiga konfigurasi diatas selesai dilakukan, JST ditraining dengan menggunakan batasan-batasan tertentu untuk menghindari terjadinya kondisi *over training* yang akan memberikan hasil yang tidak maksimal berupa: (1) algoritma pembelajaran ditentukan dengan menggunakan metode *back propagation*. (2) Rate momentum dibatasi hingga 0.1. (3) Proses training akan dihentikan ketika *mean squared error* berkurang hingga 0.000001 atau pada saat proses ini berjalan hingga 20.000 iterasi, kondisi mana yang tercapai lebih dahulu.

Kemudian, proses terakhir dilakukan untuk memastikan kalau $N^{(10-3-1)}$ cukup handal dalam melakukan tugasnya sebagai *selector*. Hal itu akan diinvestigasi dengan menggunakan pendekatan statistik berupa nilai korelasi (r), R^2 , rerata nilai eror absolut (AE) dan rerata nilai eror relative absolute (ARE). Sebagaimana diperlihatkan dalam tabel 2, tampak bahwa JST dengan arsitektur

$N^{(10-3-1)}$ cukup bisa diandalkan untuk menjalankan tugasnya. Metode lain yang digunakan dalam pengujian ini adalah dengan menggunakan model visual yaitu dengan memperhatikan grafik yang membandingkan nilai aktual dari RBH dengan nilai prediksinya sepanjang periode *in-sample data*. Berdasarkan gambar 9, terlihat bahwa hasil yang diberikan sangat baik dimana garis yang dibentuk oleh data hasil prediksi sangat dekat dengan data aktualnya.

Sebagai hasil dari invetigasi tahap pertama ini, INTR, BIRT dan M1 menempati ranking pertama, kedua dan ketiga sebagai variabel makroekonomi yang sangat dominan mempengaruhi pergerakan rate bagi hasil. Selanjutnya disusul oleh M1, STIN dan EXCH dan INFR (gambar 10). Sedangkan variabel OIL dan GOLD hamper-hampir tidak memiliki kontribusi sama sekali dengan nilai 0.22% dan 0.19% (table 3). Dengan demikian, variabel makro yang akan digunakan pada DSS-DBS adalah EXCH, STIN, M1, INFR, INTR, dan BIRT.

V.2 Investigasi tahap kedua-pemilihan algoritma prediksi

Tahap kedua ini dilakukan melalui dua tahapan. Pertama, melakukan prosedur permodelan untuk masing-masing algoritma prediksi. Kedua, melakukan komparasi tingkat akurasi yang dihasilkan oleh masing-masing model. Proses ini menggunakan enam variabel bebas terpilih dan RBH dari Bank Syariah Mandiri untuk produk deposito *mudharabah periode* satu bulan sebagai variable terikat (RBH-BSM).

V.2.1 Prosedur permodelan

a. Model GARCH.

Model terpilih dalam penelitian ini adalah AR(1)-GARCH(1,1) yang terdiri dari ARCH (1) dan GARCH (1) dengan kombinasi proses AR(1). Model ini dipilih berdasarkan kriteria R^2 , AIC sebagaimana terlihat pada tabel 4 dan uji normalitas menggunakan statistic Jarque-Bera statistic (gambar 11). Tabel 5 memperlihatkan keberadaan korelasi antara volatilitas data sekarang dengan data sebelumnya yang menandakan bahwa variabel yang dijadikan sampel adalah tepat untuk dianalisa dan diprediksi dengan menggunakan model GARCH. Selanjutnya model AR(1)-GARCH(1,1) diformulasikan sebagai berikut:

$$RR = 6.77 + 0.016INFR - 8.28e-005EXCH + 0.66INTR - 1.47e-004STIN - 1.87e-$$

$$006M1 - 0.35BIRT + 0.62 \quad (12)$$

$$\sigma_t^2 = 0.0055 - 0.099 e_{t-1}^2 + 1.02113512 \sigma_{t-j}^2$$

b. *Model JST.*

Pada tahapan ini, arsitektur terpilih dari model JST yang akan digunakan untuk proses *learning* dan *testing* adalah $N^{(8-6-1)}$. Selanjutnya JST diberikan proses *training* dengan kondisi khusus guna mencegah terjadinya *over fitting* diantaranya dengan menggunakan *back propagation* sebagai algoritma *learning* dimana *learning rate* dan *momentum rates* diatur sebesar 0.1. Selanjutnya, proses ini akan dipaksa berhenti ketika nilai *mean squared error* mencapai 0.000001 atau jumlah iterasi mencapai 20,000 dimana kondisi yang tercapai lebih cepat. Model ini dinyatakan handal dengan kriteria sebagaimana disajikan pada tabel 6 dimana nilai dari koefisien korelasi (r) dan R^2 cukup signifikan.

c. *Model SVMs*

Sama halnya dengan perlakuan yang diberikan kepada model JST, model SVMs juga mengalami proses *training*. Proses ini dibatasi dengan menggunakan batasan-batasan sebagai berikut: (1). Jumlah maksimum iterasi yang boleh dilakukan adalah sebanyak 1000 iterasi. (2). Jumlah maksimum training eror yang dapat diperoleh adalah sebesar 0.001. (3). Ukuran memori yang diperkenankan sebesar 40 *megabyte*. Sebelumnya telah diatur tipe Kernel yang akan digunakan adalah tipe RBF dengan nilai σ sebesar 0.143. Sebagai hasilnya, nilai C, ϵ , jumlah *support vectors* dan *cross-validation error* yang akan digunakan adalah 10, 0.1, 72, dan 0.059. Sementara itu, uji kualitas terhadap model SVMs menunjukkan nilai *mean error squared* sebesar 0.697, rasio standar deviasi sebesar 0.538 dan R^2 sebesar 0.848. Hal ini mengindikasikan bahwa model SVMs yang dibangun cukup mampu menjalankan tugasnya melakukan prediksi RBH.

V.2.2 Perbandingan tingkat akurasi masing-masing model

Dalam rangka pemilihan algoritma prediksi, penelitian ini menguji ketiga model yang sudah diterangkan sebelumnya dengan tiga cara: (1) Membandingkan kualitas pembelajaran masing-masing model dengan menggunakan tiga

parameter statistik berupa R^2 , *mean absolute error* (MAE) dan *normalized means squared error* (NMSE). NMSE dan MAE pada dasarnya adalah parameter yang digunakan untuk mengevaluasi seberapa akurat hasil prediksi yang dihasilkan oleh sebuah algoritma prediksi, semakin kecil nilainya maka kualitas model akan semakin baik. (2) Menginvestigasi seberapa baik sebuah model melakukan prediksi dengan menggunakan *out of sample data* untuk periode satu tahun dengan menggunakan formula sebagai berikut:

$$\text{Accuracy power} = 100\% - \% \text{ Error of prediction} \quad (13)$$

(3) Membandingkan grafik prediksi dengan grafik data actual yang dihasilkan saat melakukan proses training.

Sebagaimana telah diringkaskan pada tabel 7, secara statistik JST menunjukkan performa yang lebih baik dibandingkan model GARCH dan model SVMs. Nilai r-squared dari JST yang menunjukkan kemampuan model dalam menjelaskan volatilitas RBH sangat tinggi, yaitu sebesar 0.88 melebihi model GARCH dan SMVs. Selanjutnya, walaupun nilai MAE dari JST sedikit lebih tinggi daripada GARCH, tetapi nilai NMSE-nya sangat rendah yaitu sebesar 0.19. Hal ini menunjukkan bahwa kemampuan pembelajaran dan prediksi JST lebih unggul dibandingkan algoritma prediksi lainnya. Selanjutnya, kemampuan prediksi yang diukur dengan menggunakan *in-sample data* menguatkan kelebihan JST sebelumnya. Walaupun kemampuan prediksi JST berdasarkan *out-of sample data* menurun, tetapi kemampuan prediksi satu bulan ke depannya sedikit lebih rendah dari SVM tetapi jauh lebih akurat dari GARCH. Selanjutnya, dengan menggunakan grafik pada gambar 12 terlihat bahwa kemampuan belajar dan prediksi JST sangat stabil dibandingkan dengan algoritma lainnya dimana garis prediksi dibandingkan dengan garis dari data aktualnya berjarak lebih dekat dan konsisten dibandingkan dengan yang lain. Dengan melihat hasil evaluasi diatas, penelitian ini memastikan untuk menggunakan JST sebagai algoritma prediksi pada DSS-DBS.

V.3 Implementasi sistem dalam melakukan prediksi.

Pada gambar 13 dapat dilihat tampilan DSS berbasis web yang dapat diakses darimana saja. Pada tampilan depan, pengguna akan disuguhkan tiga

macam menu, berupa: pertama, informasi *prime cost* dari bank syariah dan konvensional. Menu ini lebih diutamakan untuk stake holder seluruh bank, baik bank konvensional maupun bank syariah. Kedua, informasi bagi hasil bank syariah periode berjalan yang dapat dibandingkan dengan suku bunga simpanan yang sedang berlaku pada bank konvensional. Selanjutnya yang terakhir adalah menu prediksi bagi hasil sebagai bahasan utama dalam penelitian ini yang diberi nama DSS-DBS. Untuk mengakses menu DSS-DBS, pengguna harus mengklik menu “time deposit rate forecast” yang akan membawanya ke halaman prediksi. Selanjutnya, pada halaman tersebut, pengguna akan diminta untuk memilih RBH sebuah bank syariah yang akan diprediksi dan hasilnya akan dibandingkan dengan bank syariah lain oleh sistem. Selanjutnya, disediakan pula menu untuk membandingkan hasil prediksi RBH bank syariah dengan suku bunga berlaku bank konvensional tertentu untuk produk yang sama. Hal ini dimaksudkan guna memancing perhatian deposan bank konvensional untuk mulai membandingkan pendapatan bunga yang saat ini diterima, dengan bagi hasil yang akan diterima bulan depan jika dananya dipindahkan ke bank syariah. DSS-DBS berbasis JST ini akan menjalankan proses prediksinya dengan menggunakan algoritma sebagaimana dapat dilihat pada catatan tambahan dari laporan penelitian ini. Sebagai hasilnya akan ditampilkan prediksi bagi hasil satu bulan ke depan dari bank yang dipilih.

Pada tahap beta ini, DSS-DBS akan digunakan untuk menjalankan perintah prediksi RBH dari simpanan deposito *mudharabah* periode satu bulan, produk Bank Syariah Mandiri, untuk penempatan dana bulan April 2011. Misalkan, pengguna pada tanggal 10 April 2011 adalah seorang deposan Bank Syariah Mandiri yang akan menerima bagi hasil pada tanggal 11 April untuk penempatan dana bulan Maret pada deposito *mudharabah* berjangka waktu satu bulan. Menurut Bank Syariah Mandiri, deposan akan menerima bagi hasilnya sebesar 5.56%. Kemudian, yang bersangkutan ingin mengetahui bagi hasil yang akan diterima pada tanggal 11 Mei 2011 dari bank yang sama untuk memutuskan apakah akan tetap menyimpan uangnya di Bank Syariah Mandiri dengan nisbah 55% atau memilih memindahkannya ke deposito berjangka Bank syariah lain

atau bahkan dipindahkan ke bank konvensional seperti Bank Permata yang pada saat menggunakan sistem telah menawarkan suku bunga deposito satu bulan sebesar 5.75% (Harian Bisnis Indonesia, 7 April 2011).

Pada saat menggunakan, tampilan antar muka DSS-DBS menginformasikan terlebih dahulu bahwa sistem ini berhasil memprediksi RBH dari penempatan dana bulan Maret yang diterima pada bulan April dengan tingkat akurasi sebesar 95.002%. Selanjutnya, pengguna akan memerintahkan sistem untuk memprediksi RBH yang akan diterima pada bulan Mei dengan mengklik tombol “**Predict**”. Beberapa saat kemudian sistem menginformasikan bahwa Bank Syariah Mandiri akan memberikan RBH sebesar 5.98%. Berdasarkan informasi ini, deposan dapat mengambil keputusan untuk meneruskan simpanannya atau tidak.

Sebulan kemudian, untuk mengevaluasi keputusan yang diambil deposan dan ketepatan sistem dalam memberikan informasi maka hasil prediksi akan dibandingkan dengan informasi RBH aktualnya. Menurut informasi yang disampaikan Bank Syariah Mandiri lewat websitenya, produk simpanan *mudharabah* periode satu bulan untuk periode simpanan April yang dibagikan bulan Mei 2011, akan mendapatkan bagi hasil sebesar 5.99%. Dengan kata lain, sistem berhasil memprediksi kenaikan RBH dengan tingkat akurasi sebesar 99.99%. Dengan demikian, jika pada saat menerima bagi hasil di bulan April, deposan memutuskan untuk tetap menyimpan dananya di Bank Syariah Mandiri, maka keputusan yang diambil adalah tepat. Karena, jika dipindahkan ke Bank Permata pada saat itu, deposan hanya mendapatkan bunga sebesar 5.75% pada bulan Mei.

VI. Kesimpulan

Motivasi menabung deposan bank syariah, khususnya di Indonesia, secara empirik sangat dipengaruhi oleh seberapa besar bagi hasil yang akan diperoleh. Selanjutnya, didukung dengan fitur yang menguntungkan dari produk simpanan *mudharabah* seperti tidak adanya *breakage fee*, memungkinkan deposan dapat melakukan pemindahan dananya kapan saja untuk mendapatkan *return* yang terbaik dari bank tempatnya menyimpan dana. Untuk itulah, diperlukan sebuah

sistem yang mampu memberikan informasi secara cepat dan akurat dalam memprediksi dan kemudian membandingkan tingkat bagi hasil antar bank-bank syariah guna memperlambat terjadinya perpindahan dana deposan dari industri bank syariah ke bank konvensional.

Berdasarkan hasil eksperimen, penulis dapat menyimpulkan bahwa *expert system* berbasis JST yang diajukan ini dapat digunakan untuk membantu deposan memprediksi tingkat bagi hasil yang akan diperoleh satu bulan ke depan dengan tingkat akurasi yang sangat tinggi. Sistem ini diyakini bukan hanya akan menguntungkan deposan secara individu tetapi juga untuk industri bank syariah secara umum. Sebab, penggunaan system ini akan memperlambat seorang deposan untuk memindahkan dananya dari bank syariah ke bank konvensional, mengingat deposan akan membandingkan terlebih dahulu keuntungan yang akan diperoleh periode satu bulan ke depan yang akan diberikan bank syariah tempatnya menyimpan dana dengan bank syariah lain. Sehingga, pilihan memindahkan dana ke bank konvensional menjadi pilihan terakhir jika seluruh bank syariah yang telah diprediksi akan memberikan tingkat bagi hasil yang kurang memuaskan. Dampak positif lain dari penggunaan sistem ini adalah deposan bank konvensional akan tertarik untuk mulai membandingkan pendapatan bunga yang diterima dengan bagi hasil yang diberikan bank syariah pada bulan berjalan, dan kemudian mencoba memprediksi bagi hasil yang akan diberikan bank syariah pada bulan depan.

Sistem yang masih dalam versi beta ini masih memiliki keterbatasan untuk diimplementasikan dimana DSS-DBS ini hanya mampu memprediksi RBH deposito mudharabah periode satu bulan dari Bank Syariah Mandiri saja. Hal ini dikarenakan keterbatasan penulis dalam mengumpulkan data bagi hasil dari seluruh bank syariah. Melalui kerja sama secara formal antara tim penulis dan seluruh bank syariah di Indonesia, diharapkan di masa datang, DSS-DBS ini dapat diimplementasikan secara sempurna sehingga bisa dijadikan sebagai salah satu indikator daya saing antara bank syariah dengan bank konvensional di mata deposan bank syariah dan menjadi media promosi untuk menarik deposan bank konvensional menempatkan dananya di bank syariah.

TINJAUAN PUSTAKA

- Canova, Luigina., Manganelli, Anna Maria., dan Webley, Paul. "The Hierarchical Structure of Saving Motives". *Journal of Economic Psychology*. No. 26, p.21-34. 2005.
- El-Din, Seif Tag. "Issues in Accounting Standard for Islamic Financial Institutions". Markfield Institute of Higher Education, September 2004.
- Engle, R. "Garch 101: The Use of ARCH/GARCH Models in Applied Econometrics", *Journal of Economic Perspectives*. Vol.15, No.4, p.157-168, 2001.
- Gambos, C.M. "Bank failures – an historical perspective", *Federal Reserve Bank of Kansas City, Monthly Review*. Vol. 62, June, p. 10-20, 1977.
- Grais, Wafik., dan Pellegrini, Matteo. "Corporate Governance and Stakeholders Financial Interest in Institutions Offering Financial Services", *World Bank Policy Research Working Paper*, Series number 4053, Washington DC, 1 November, 2006.
- Gu, Jirong., Zhu, Mingcang., dan Jiang., Liuguangyan, "Housing Price Forecasting Based on Genetic Algorithm and Support Vector Machine". *Expert System with Application*, Vol.38, p.3383-3386, 2011.
- Haron, S., dan Ahmad, N. "The effects of conventional interest rates and rate of profit on funds deposited with Islamic banking system in Malaysia". *International Journal of Islamic Financial Services*, Vol. 1, No. 4, p.1-6, 2000.
- Ismal, Rifki. "Industrial Analysis of Liquidity Risk Management in Islamic Bank", *Journal of Islamic Banking and Finance*, Vol 26, No. 2, 2009.
- Jalaluddin, A.K.M. "Savings Behaviour in Islamic Framework". *Economic Bulletin (Persatuan Ekonomi, Kajian Perniagaan dan Pengurusan. Shah Alam)*. Vol 2, No. 3, p.71-85. 1992.
- Kasilingam.R , dan Jayabal. G. "Segmentation of Investors Based on Saving Motives". *Indian Journal of Economics and Business*. Vol 7, No 2, pp 241-254, 2008.
- Kasri, Rahmatina. A., dan Kassim ,Salina Hj. "Empirical Determinants of Saving in The Islamic Banks: Evidence From Indonesia". *J.KAU: Islamic Econ*. Vol. 22, No.2, p.3-23. 2009.
- Keynes, J.M. "The General Theory of Employment, Interest, and Money". Japan. Maruzen Co., Ltd. 1936.
- Kim, Yun-Hwan. "The Asian Crisis, Private Sector Saving, and Policy Implications". *Journal of Asian Economics*. No.12, p.331-351, 2001.
- Li, Boyang., Hu, Jinglu., dan Hirasawa, K. "Financial Time Series Prediction Using a Support Vector Regression Network". International Joint Conference on Neural Networks (IJCNN). 2008.
- Mangkuto, I.J. "Pengaruh tingkat suku bunga deposito konvensional dan tingkat pendapatan deposito Mudharaba terhadap pertumbuhan deposito di bank Muamalat Indonesia", Tesis Master, Universitas Indonesia, Jakarta. 2004.

- Matei, M. "Assessing Volatility Forecasting Models: Why GARCH Models Take The Lead". *Romanian Journal of Economic Forecasting*. Vol.4, p.42-65, 2009.
- Matheson. J.E., dan Howard. R.A.. "An Introduction to Decision Analysis". Stanford Research Institute, Stanford, CA. 1968.
- Nisbet, Robert., Elder, Jhon., dan Miner. Gary. "Handbook of Statistical Analysis and Data Mining Applications". Elsevier. 2009.
- Pai, ing-Feng., Lin, Chih-Shen., Hong, Wei-Chiang., dan Chen, Chen-Tung. "A Hybrid Support Vector Machine Regression for Exchange Rate Prediction". *Information and Management Sciences*. Vol.17, No.2, p.19-32, 2006.
- Tsang, E. P. K., Yung, P. dan Li, J. "EDDIE-Automation, a decision support tool for financial forecasting". *Journal of Decision Support Systems*, Special Issue on Data Mining for Financial Decision Making, Vol. 37, 559-565, 2004.
- Wen, W., Chen, Y.H., dan Chen, I.C. "A knowledge-based decision support system for measuring enterprise performance". *Knowledge-Based Systems*. Vol 21, p.148-163, 2008.
- West, P.M., Brockett, P.L., dan Golden, L.L.. "A Comparative Analysis of Neural Networks and Statistical Methods for Predicting Consumer Choice", *Marketing Science*, Vol.16, No.4, pp.370-391, 1997.
- Zhang, G., Patuwo, B., dan Hu, M. "Forecasting with artificial neural network: the state of the art", *International Journal of Forecasting*. Vol. 14, No. 1, pp. 35-62, 1998.
- Zoubi, T.A., dan Olson, D "Financial Characteristics of Banking Industry in the GCC Region: Islamic vs. Conventional banks", 2007. available at: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.116.5171>. [20 December 2009].

TABEL DAN GAMBAR

No	Nama penulis	Judul	Publikasi
1	Anwar. S, Watanabe. K, Romansyah. D & Pramono. S	Treating Return of Mudharabah Time Deposit as Investment Instrument	Humanomics, vol.26, no.4, pp.296-309 (2010)
2	Anwar. S & Mikami. Y	Comparing Accuracy Performance of ANN, MLR, and GARCH Model in Predicting Time Deposit Return of Islamic Bank	International Journal of Trade, Economics and Finance, vol.2, no.1, pp.44-50. (2011)
3	Anwar. S & Ismal. R	Robustness Analysis of Artificial Neural Networks and support Vector Machine in Making Prediction	Ninth IEEE International Symposium on Parallel and Distributed Processing with Application. pp.256-260. (2011)

Tabel 1. Publikasi riset penulis dengan topic DSS

Data Set	Correlation (r)	R ²	Mean of AE	Mean of ARE
Training data set	0.9364	0.8566	0.361526	0.044
Validation data set	0.9091	0.5608	0.612538	0.072
Testing data set	0.8874	0.5828	0.6667	0.083
All data set	0.9162	0.7729	0.449074	0.055

Tabel 2. Parameter pengujian penggunaan arsitektur jaringan N⁽¹⁰⁻³⁻¹⁾

Input column name	Importance, %
INTR	49.713013
BIRT	17.499574
M1	15.681459
STIN	9.735225
EXCH	5.747679
INFR	1.206882
OIL	0.221001
GOLD	0.195167

Tabel 3. Tingkat urgensi variabel independen

Dependent Variable: RR
Method: ML - ARCH (Marquardt) - Normal distribution
Date: 01/18/11 Time: 22:35
Sample (adjusted): 2000M02 2008M12
Included observations: 107 after adjustments
Convergence achieved after 30 iterations
Bollerslev-Wooldrige robust standard errors & covariance
Variance backcast: ON
GARCH = C(9) + C(10)*RESID(-1)^2 + C(11)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	6.777023	0.505320	13.41135	0.0000
INFR	0.016803	0.051280	0.327665	0.7432
EXCH	-8.28E-05	3.93E-07	-210.6816	0.0000
INTR	0.669570	0.114668	5.839202	0.0000
STIN	-0.000147	0.000129	-1.147186	0.2513
M1	-1.87E-06	2.32E-07	-8.054470	0.0000
BIRT	-0.359507	0.116705	-3.080475	0.0021
AR(1)	0.626533	0.042496	14.74329	0.0000

Variance Equation				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.005507	0.001937	2.843158	0.0045
RESID(-1)^2	-0.099398	0.062139	-1.599616	0.1097
GARCH(-1)	1.021135	0.043218	23.62762	0.0000

R-squared	0.845974	Mean dependent var	7.918993
Adjusted R-squared	0.829930	S.D. dependent var	1.520192
S.E. of regression	0.626921	Akaike info criterion	1.481429
Sum squared resid	37.73089	Schwarz criterion	1.756206
Log likelihood	-68.25646	F-statistic	52.72712
Durbin-Watson stat	1.924690	Prob(F-statistic)	0.000000

Inverted AR Roots	.63
-------------------	-----

Table 4. Hasil regresi least squares

Included observations: 107
Q-statistic probabilities adjusted for 1 ARMA term(s)

Auto correlation	Partial Correlation	AC	PAC	Q-Stat	Prob
.1*	.1*	1	0.069	0.069	0.5310
.1.	.1.	2	0.040	0.035	0.7096
.1*	.1*	3	0.136	0.131	2.7721
.1*	.1.	4	0.073	0.056	3.3783
.1.	.1*	5	-0.068	-0.087	3.9099
.1*	.1*	6	0.114	0.105	5.4170
.1.	.1.	7	-0.009	-0.036	5.4262
.1.	.1*	8	0.064	0.080	5.9117
.1.	.1.	9	0.053	0.028	6.2402
.1*	.1*	10	0.157	0.140	9.1968
.1.	.1*	11	-0.050	-0.075	9.5051
.1.	.1*	12	-0.039	-0.076	9.6925
.1.	.1.	13	0.062	0.052	10.171
.1.	.1*	14	-0.094	-0.120	11.271
.1.	.1*	15	-0.115	-0.064	12.941
.1.	.1*	16	-0.078	-0.122	13.728
.1.	.1.	17	-0.065	-0.022	14.274
.1.	.1.	18	-0.063	-0.031	14.800
.1.	.1.	19	-0.014	-0.009	14.826
.1.	.1.	20	-0.068	-0.043	15.439
.1.	.1.	21	-0.034	-0.005	15.600
.1.	.1.	22	-0.077	-0.037	16.407
.1.	.1*	23	0.046	0.069	16.698
.1.	.1.	24	-0.035	0.035	16.874
.1.	.1*	25	-0.118	-0.086	18.852
.1.	.1.	26	-0.065	-0.037	19.455
.1.	.1*	27	0.058	0.072	19.950
.1.	.1*	28	-0.137	-0.103	22.739
.1.	.1.	29	-0.009	0.005	22.752
.1.	.1.	30	-0.023	-0.043	22.830
.1.	.1.	31	-0.015	-0.006	22.866
.1.	.1*	32	-0.083	-0.085	23.930
.1.	.1.	33	-0.012	-0.055	23.952
.1.	.1*	34	-0.173	-0.159	28.715
.1*	.1*	35	0.069	0.130	29.486
.1.	.1.	36	0.001	-0.009	29.486

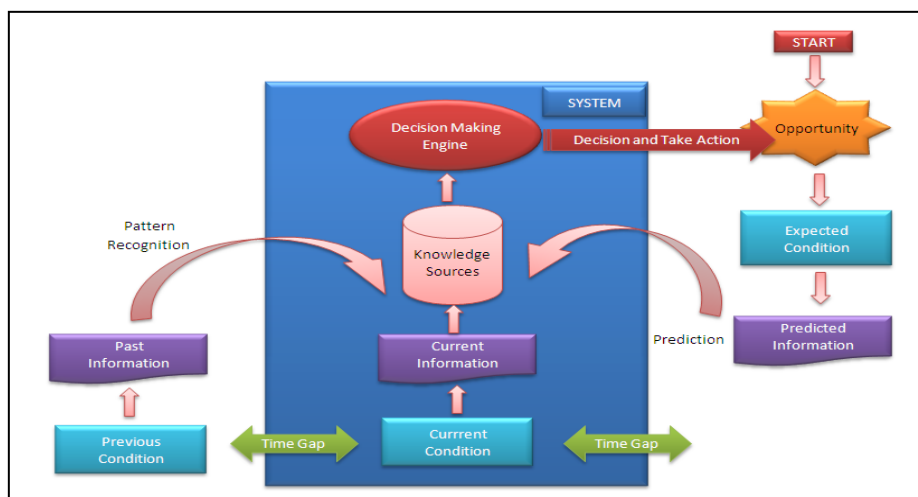
Tabel 5. Uji keberadaan proses GARCH

Data set	Correlation (r) in %	R ² in %	Mean of ARE
Training data set	93.89	86.94	0.067
Validation data set	92.94	79.64	0.087
Testing data set	90.32	78.29	0.079
All data set	0.06	84.51	0.071

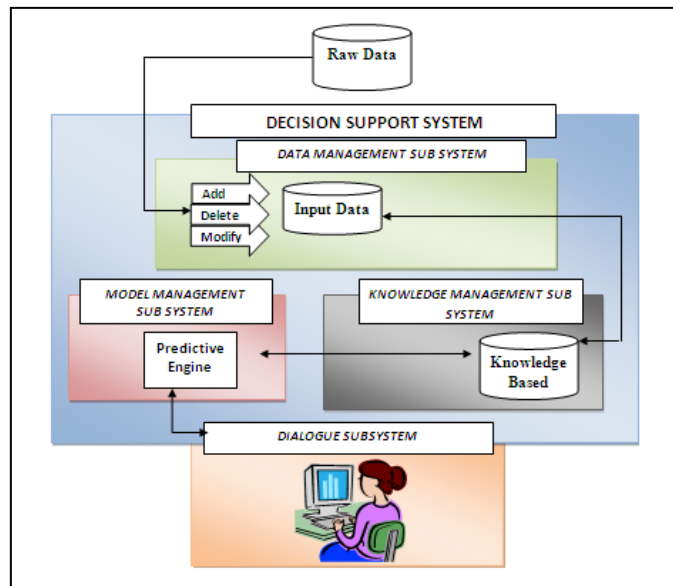
Tabel 6. Kriteria statistic kehandalan model JST

Parameter	ANNs	GARCH	SVM
Statistik			
1. R-squared	0.88	0.84	0.85
2. Mean Absolute Error (MAE)	0.56	0.41	0.63
3. Normalized Mean Standard Error (NMSE)	0.19	0.22	0.40
Tingkat akurasi			
1. In sample data	97.2%	80.2%	91.8%
2. Out of sample data (12 bulan)	78.6%	87.94%	83.50%
3. 1 bulan ke depan	94.1%	84.34%	98.13%
4. Rata-rata (in dan out of sample data)	92.87%	84.07%	91.84%

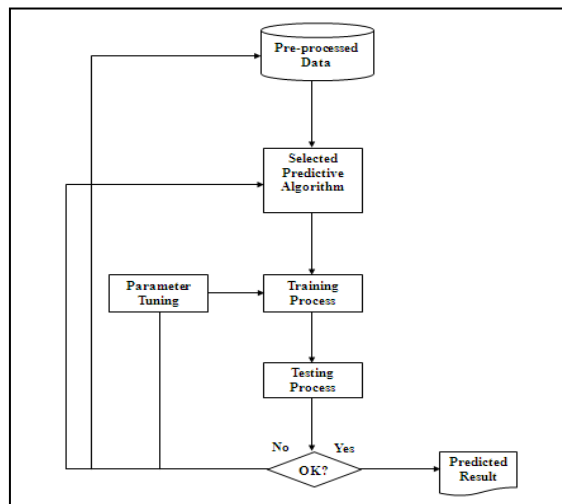
Tabel 7. Perbandingan secara statistic kualitas prediksi masing-masing model



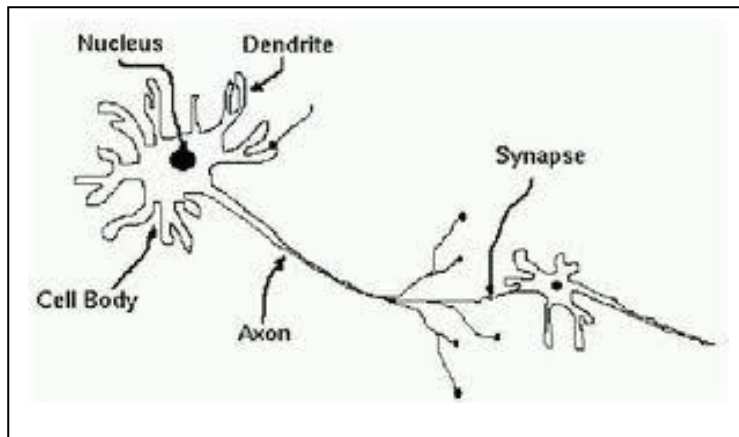
Gambar 1. Proses pembuatan keputusan



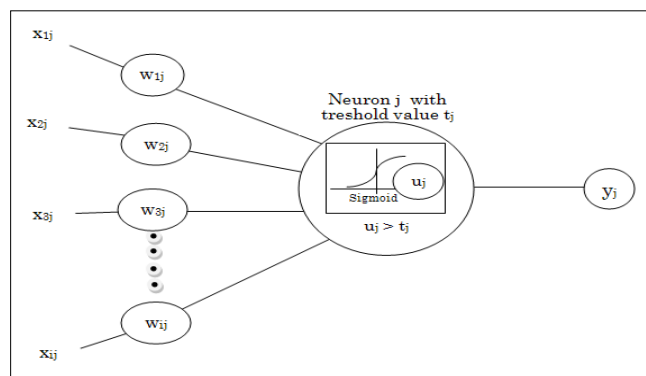
Gambar 2. Framework sebuah *decision support system*



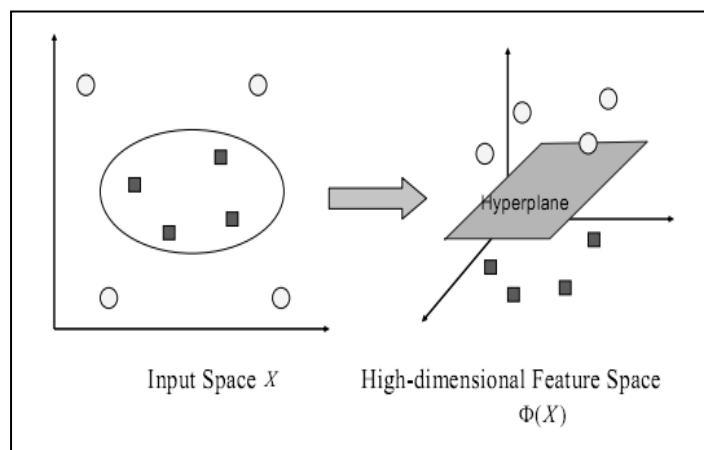
Gambar 3. Proses sebuah model prediksi



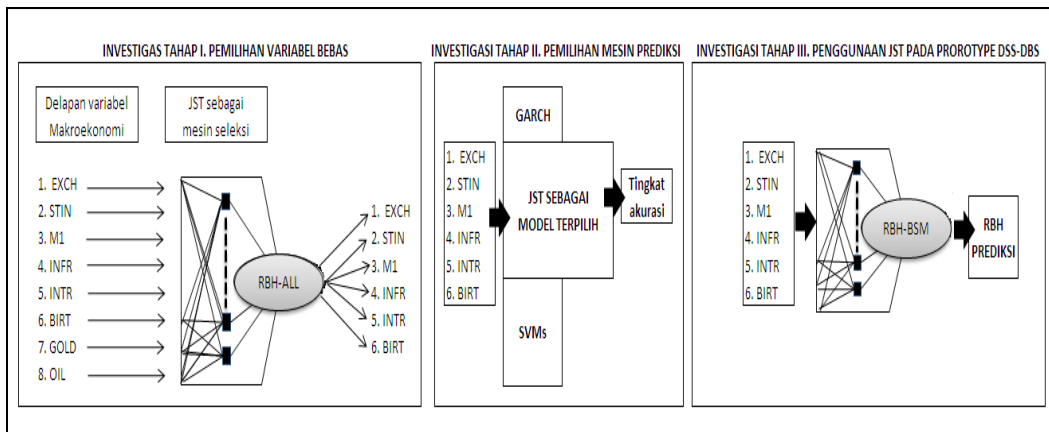
Gambar 4. Gambar syaraf otak manusia



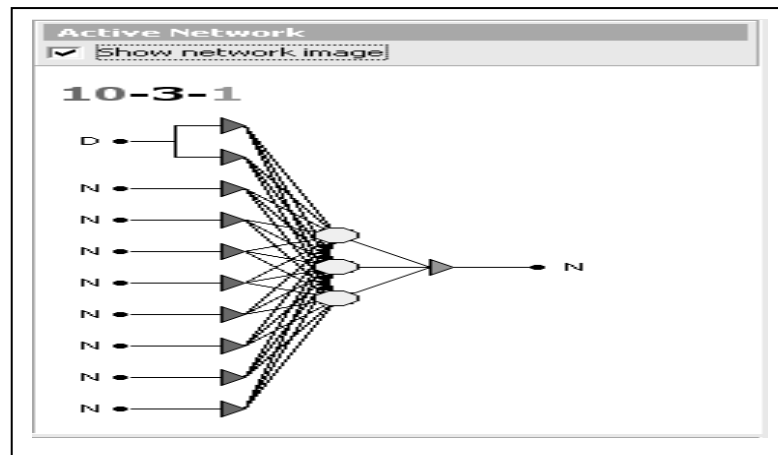
Gambar 5. Model sebuah neuron



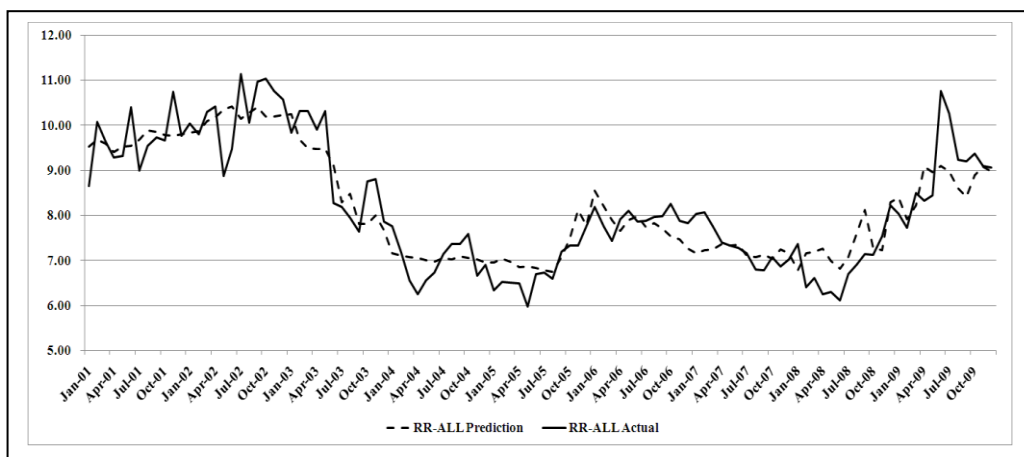
Gambar 6. Fungsi sebuah $\Phi(x)$ yang memetakan input menjadi sebuah ruang kerja berdimensi lebih tinggi
(Sumber (free): Kuliah Umum InfoKomputer.com)




Gambar 7. Framework Penelitian



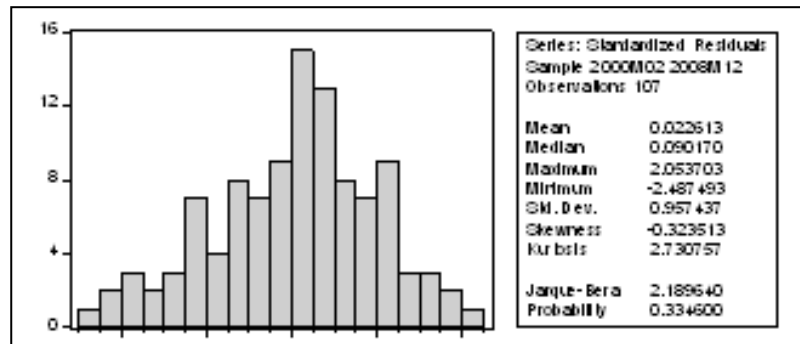
Gambar 8. Arsitektur jaringan $N^{(10-3-1)}$



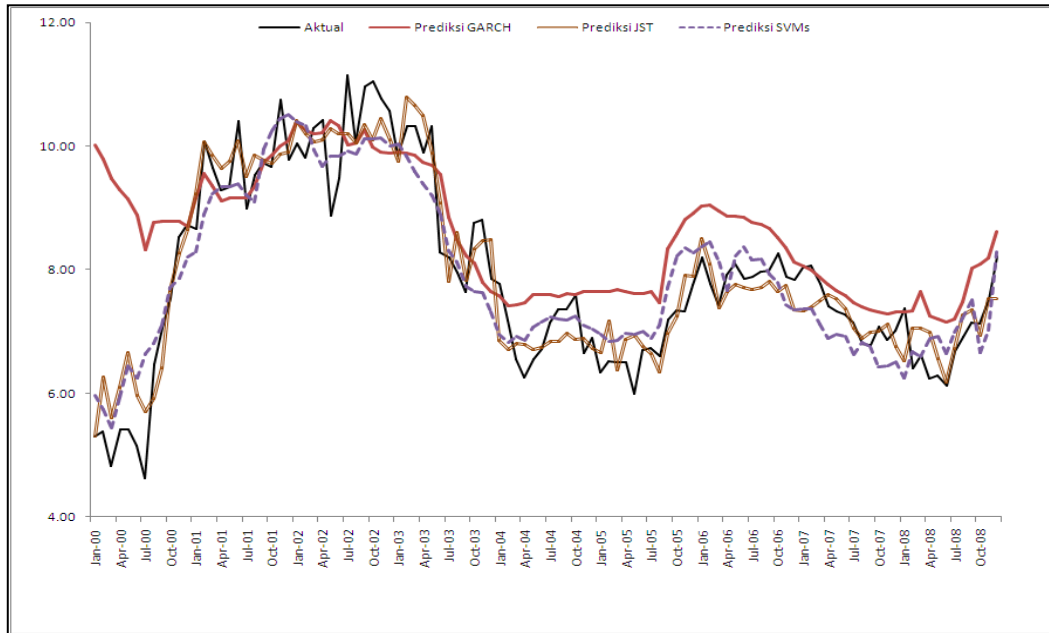
Gambar 9. Grafik prediksi versus aktual dari RR-ALL berdasarkan *in-sample data*



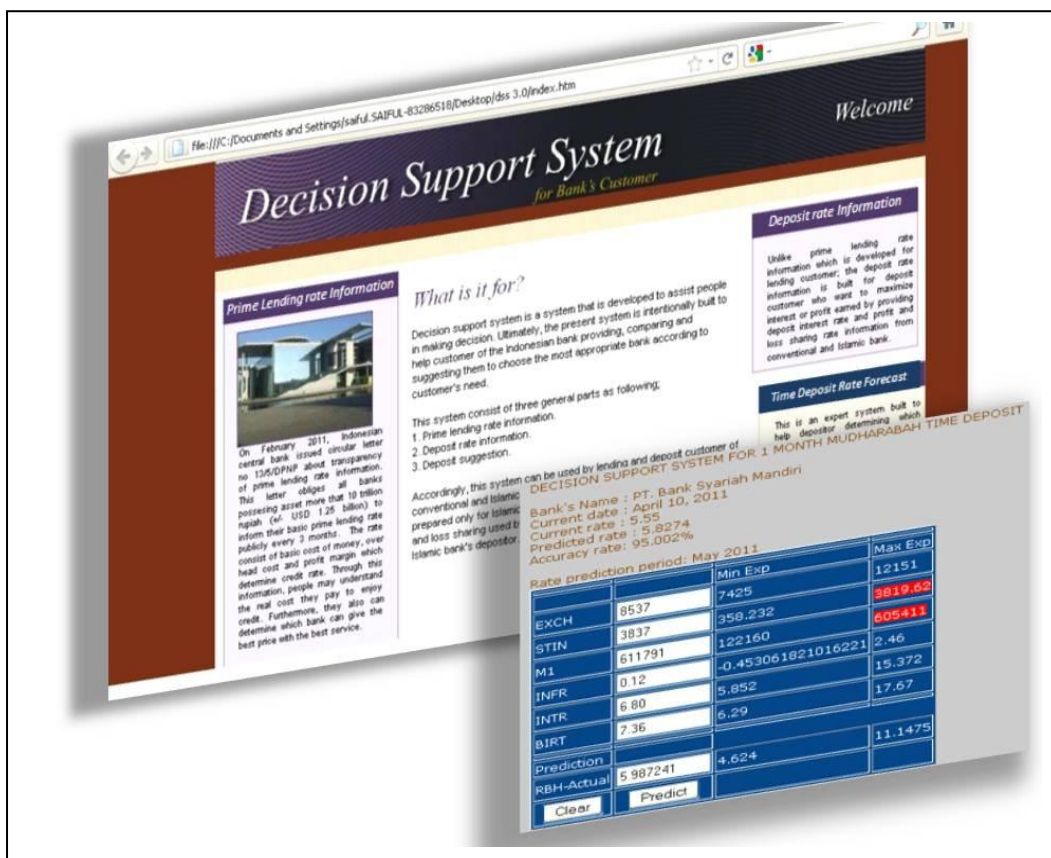
Gambar 10. Grafik tingkat urgensi masing-masing variable bebas



Gambar 11. Statistik Jarque-Bera



Gambar 12. Grafik RBH prediksi versus RBH aktual



Gambar 13. Tampilan antar muka (Interface) DSS-DBS

Catatan tambahan:

Algoritma JST menggunakan bahasa pemrograman JAVA.

WARNING - this code assumes all input variables have valid values within the 'value ranges' range (ie not missing or null)

/*

No description has been given to this model

The neural network model is:

inputs:6

hidden neurons: 2

linear neurons: 1

training data source: C:\dokumenku\KOMPETISI BINDATA.xls

training data view: Sheet1\$

Tiberius weights file: C:\Program Files\Tiberius\nstemp.twf

model created: Tue, Apr 26 2011, 2:34 PM

this file created: Mon, Aug 1 2011, 3:02 PM

Warning, the following field names from the original source data have been modified:

Also the suggested output name has been modified:

Tiberius_RBH-Actual = Tiberius_RBH_Actual

*/

```
import java.lang.Math;
import java.io.*;
```

```
public class Tiberius
{
```

```
public static double EXCH;
public static double STIN;
public static double M1;
public static double INFR;
public static double INTR;
public static double BIRT;
public static double Tiberius_RBH_Actual;
```

```
public static void main(String[] args)
{
    initData();
    calcNet();
    System.out.println(Tiberius_RBH_Actual);
}
```

```
public static void initData()
```

```
{
```

```
/*
```

```
data is set here
```

```
*/
```

```
EXCH = 10;
```

```
STIN = 10;
```

```
M1 = 10;
```

```
INFR = 10;
```

```
INTR = 10;
```

```
BIRT = 10;
```

```
}
```

```
public static void calcNet()
```

```
{
```

```
Tiberius_RBH_Actual = (((
+0.219708084060921 * (((EXCH * (5.03470859969238E-06)) - 0.049279727773789)
```

```

+ ((STIN * (-2.07622430748924E-03)) + 4.33707893774628)
+ ((M1 * (1.13821346047154E-05)) - 4.14065552824371)
+ ((INFR * (8.52338428542294E-02)) - 8.55295266828284E-02)
+ ((INTR * (0.489482621570382)) - 5.1943895801049)
+ ((BIRT * (-0.534746107224541)) + 6.40625836455)
+ 1.97370798427922)
+0.502125587258733 * (
myTanh(
((EXCH * (1.17102129870687E-04)) - 1.14619564717429)
+ ((STIN * (-7.41181245436865E-04)) + 1.54827277430545)
+ ((M1 * (2.33483621737146E-06)) - 0.849379560754584)
+ ((INFR * (-0.25716797938326)) + 0.258060118118188)
+ ((INTR * (1.19250723686726)) - 12.6548867976354)
+ ((BIRT * (0.257362818233754)) - 3.08320656244037)
- 1.92003266000254
))
-0.451269902757879)/2.0) + 0.5) * 6.5235) + 4.624;
}


```

```

public static double myTanh(double x)
{
    if (x > 20)
        return 1;
    else if (x < -20)
        return -1;
    else
    {
        double a = Math.exp(x);
        double b = Math.exp(-x);
        return (a-b)/(a+b);
    }
}
}

```

CURRICULUM VITAE



Name : **SAIFUL ANWAR, SE.Akt, M.Si**
 Status : Ph.D Candidate
 Sex : Male
 Address : 957-0847 Niigata Shi, Akihaku, Furutsu 165-7
 Pure house 102, JAPAN
 Phone : +81-080- 3738-1904
 E-mail : olieanwar@gmail.com

Educational Background

Formal Education

- 2009 – Now Ph.D Student, Risk Management Laboratory. Information Science and Control Engineering Dept, Nagaoka University of Technology, Japan.
 Research Topic: “*Designing an Intelligent Decision Support System for Islamic Bank's Depositor*”. GPA: 4.0
- 2008 – 2009 Ph.D Research Student, Global Information Infrastructure Laboratory, Management & Information System Science Dept, Nagaoka University of Technology, Japan.
- 2006 – 2008 Post graduate in Islamic Banking and Finance, University of Indonesia
 Research Topic: “*Analisis Pengaruh Perubahan Variabel Sasaran Kebijakan Moneter Terhadap Penentuan Cost of Fund Bank Syariah*”. (Studi Kasus di PT Bank Syariah Mandiri). GPA: 3.55
- 1996 – 2001 Economics Faculty, University of Indonesia (FEUI)
Bachelor of Accounting. GPA: 2.60

Research and Publication

1. "Predicting Future Depositor`s Rate of Return Applying Neural Network: A Case-study of Indonesian Islamic Bank". **Published in International Journal of Economic and Finance**, Canada, (Vol 2, No 3, 2010)
2. "Treating return of mudharabah time deposit as investment instrument: A utilization of artificial neural networks (ANNs)". **Published in Humanomics** (Vol 26, Issue 4, 2010). Emerald Publisher.
3. "Comparing Accuracy Performance of ANN, MLR, and GARCH Model in Predicting Time Deposit Return of Islamic Bank". **Published in International Journal of Trade, Economics and Finance**, Vol.2, No.1, February, 2011.
4. "Investigating Depositor Return Behavior of Indonesian Islamic Bank Using Neural Networks Model". **Accepted for publication in International Journal of Accounting and Information Management**, Emerald Publisher.
5. "Selecting Predictive Algorithm for Decision Support System in Islamic Banking: Empirical Investigation of ANNs and SVMs". **Under communication in IEEE Transaction on Services Computing Journal**.
6. "Determinants of Pricing Individual Depositor`s Rate of Return in Indonesian Islamic Bank: A Case-study of PT Bank Syariah Mandiri". **Presented and published in proceeding of Asia Pacific Industrial Engineering and Management Society (APIEMS)**, Kitakyushu, JAPAN 2009.
7. "Performance Comparison of Multiple Linear Regression and Artificial Neural Networks in Predicting Depositor Return of Islamic Bank". **Presented in International Conference on Information and Finance (ICIF)**, Kuala Lumpur, MALAYSIA 2010.
8. "Performance Comparison of Multiple Linear Regression and Artificial Neural Networks in Predicting Depositor Return of Islamic Bank". **Accepted for publication in proceeding of**

	<p>International Conference on E-business, Management and Economics (ICEME). Hong Kong - CHINA 2010. indexed by IEEE.</p> <p>9. <i>"Robustness Analysis of Artificial Neural Networks and Support Vector Machine in Making Prediction"</i>. Presented in The 9th IEEE International Symposium on Parallel and Distributed Processing with Applications, South Korea 2011. Published in proceeding and indexed by IEEE.</p> <p>Informal Education</p> <p>2008 Niigata Airline Course <i>Intensive Japanese Course</i></p> <p>2000 English Course <i>Intermediate Level</i></p> <p>1999 Islamic Accounting & Management Course <i>Held by Forum of Islamic Studies (FSI) FEUI</i></p> <p>1997 Islamic Economics Course (for 1 semester) <i>Held by Forum of Islamic Studies (FSI) FEUI</i></p>
Working Experience	<p>2005 - 2008 PT. BANK SYARIAH MANDIRI Operational and Accounting Div. as <i>Section Head of Quality Assurance</i></p> <p>2000 - 2008 SHARI'AH ECONOMICS & BANKING INSTITUTE as <i>Lecturer</i></p> <p>2003 - 2005 ERNST & YOUNG INDONESIA – Audit Services as <i>Junior Assistant</i></p> <p>PT Bank Mandiri Tbk; Audit engagement period: Interim and year end. (Dec 2004, June 2005, Sept 2005 and Dec 2005).</p> <p>PT Bank Muamalat Indonesia Tbk; Audit engagement period: Interim and year end. (Dec 2004 and March 2005)</p> <p>2002 - 2003 PT. TELEVISI TRANSFORMASI INDONESIA – Accounting Dept as <i>Financial Analyst & Cost Controller</i></p> <p>Jan 2002 to July 2002 PT. BANK MUAMALAT INDONESIA Tbk Muamalat Officer Development Program.</p> <p>Oct 2000 to Dec 2001 INDONESIAN BANK RESTRUCTURING AGENCY Accounting Div - as <i>Junior Accounting and Administration Staff</i></p>

I, the undersigned, certify that to the best of my knowledge and belief, this curriculum vitae correctly describes myself, my qualifications and experiences. I understand that any willful misstatement described herein may lead to my disqualification or dismissal, if employed.

Saiful Anwar, SE.Akt, M.Si (Ph.D Cand.)

PROFESSIONAL PROFILE

netcompetency@gmail.com



Name	Eko Budhi Suprasetiawan
Birth	Jakarta, 22 July 1975
Address	Komplek Griya Madani 1 No 8, Jatirasa, Jatiasih, Bekasi
Phone	0813 1151 7558
Email	netcompetency@gmail.com

Professional Objective

- ❑ Drive business development by incorporating IT strategy as strategic enabler which open opportunities for company growth.
- ❑ Apply and improve knowledge, skill and experience in IT, mainly software engineering, to design information system, which targeted as strategic-enabler in corporate business engagement.
- ❑ Design, develop and implement IT strategy which enable effective and productive collaboration between investors, employees, suppliers, partners and customers.

Higher Education

S1	
University	Institut Teknologi Bandung
Departement	Electrical Engineering
Graduation	April 1998
Final Project	Design and Implementation of Expert System Shell which Employee Artificial Neural Network for Its Production Rule
S2	
University	Universitas Indonesia
Departement	Program Pascasarjana, KTTI, Bidang Perbankan Islam
Start	2010

Work Experience

❑ PT EBConnection Indonesia	Project Delivery and Operation Support Manager	2009 ...
❑ Software Development Manager, VivaNews.Com	Software Development Manager	2008-2009
❑ Professional Service Department, Sun Microsystems Indonesia	Professional Service	2004 - 2008
❑ Professional Service Division, iGine Pte Ltd, Singapore	Software Engineer	2001 - 2003
❑ eCommerce Department, Sun Product Division, PT Metrodata Electronics Tbk	Technical Consultant	1999 - 2001
❑ Software Development Centre, Fujitsu Systems Indonesia	Programmer	1999
❑ CV Citra Inovasi 21, Bandung	Software Engineer	1996 - 1999
❑ Pusat Ilmu Komputer dan Sistem Informasi ITB	Asisten Dosen	1995 - 1996

Organizational Development Experience

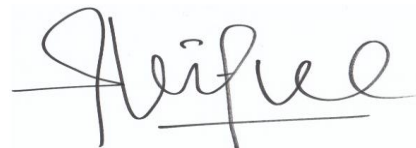
❑ Java on Linux Community eGroup	Owner and moderator	2001 - ...
❑ Pusat Teknologi Tepat Guna - Masjid Salman ITB	Head of R&D Division	1994 – 1998
❑ Himpunan Mahasiswa Elektroteknik	Member	1994 - 1998
❑ Keluarga Asrama Mahasiswa Bumi Ganesha - ITB	Staff of R&D Division	1995 - 1996

SURAT PERNYATAAN

Dengan ini saya menyatakan bahwa:

1. Karya tulis ini merupakan hasil karya asli saya yang diajukan untuk mengikuti *call for papers* Forum Riset Perbankan Syariah 2011.
2. Memahami dan bersedia mematuhi segala ketentuan yang telah ditetapkan oleh Panitia Forum Riset Perbankan Syariah 2011.
3. Semua sumber yang saya gunakan dalam penulisan ini telah saya cantumkan sesuai dengan ketentuan yang ditetapkan panitia Forum Riset Perbankan Syariah 2011.
4. Jika di kemudian hari terbukti bahwa saya tidak memenuhi segala ketentuan panitia dan hal-hal yang tercantum dalam surat pernyataan ini, maka saya bersedia menerima sanksi yang ditetapkan panitia Forum Riset Perbankan Syariah 2011.

(Niigata, 07 Agustus 2011)



(Saiful Anwar)
Mewakili Kedua Penulis