



Metode Jaringan Syaraf Tiruan Untuk Prediksi Performa Mahasiswa Pada Pembelajaran Berbasis *Problem Based Learning* (PBL)

Badieah^{a,*}, Rachmat Gernowo^b, Bayu Surarso^c

^aProgram Studi Teknik Informatika Universitas Islam Sultan Agung Semarang

^bProgram Studi Fisika Universitas Diponegoro Semarang

^cProgram Studi Matematika Universitas Diponegoro Semarang

Naskah Diterima : 27 April 2016; Diterima Publikasi : 16 Mei 2016

DOI: 10.21456/vol6iss1pp46-58

Abstract

In order to improve academic quality in higher education, students' performance evaluation is becoming important. To prevent increasing failure rate in the course, we need a system that is capable of predicting student's performance in the end of the course. The research used several factors that are considered to affect students' performance on Problem Based Learning (PBL), such as students' demography, students' prior knowledge and group heterogeneity. The method used in the study was Artificial Neural Network (ANN) with backpropagation training algorithm. Total 8 neurons were used as inputs for ANN which were obtained from gender variable (2 neurons), age variable (1 neuron), students' average knowledge variable (1 neuron), students' average skill variable (1 neuron) and group heterogeneity variable (3 neurons). Several different ANN architecture were tested in the study using 2, 7 and 12 hidden neurons respectively. Each architecture was trained using various different training parameters in order to find the best ANN architecture. Dataset used in the research were obtained from Academic Information System in Faculty of Dentistry Unissula which contained Adult and Elderly Diseases Course's participants from year 2009 to 2013. The ANN output were numeric values which represented students' performance in Adult and Elderly Diseases Course. The output of this study is a system that is able to predict the student performance in block course. The result shows that using 7 hidden neurons in the network combining with 0.5, 0.1 and 9000 for learning rate, momentum and epoch respectively, were the best ANN architecture and parameters in the study. The MSE obtained from validation test was 0,011926 with correlation coefficient (R) 0,796879. The prediction system are expected to help faculty and academic evaluation team to conduct actions to improve student's academic performance and prevent them from failure in the course.

Keywords: Artificial Neural Network; Problem Based Learning; Prediction

Abstrak

Untuk meningkatkan mutu akademik perguruan tinggi, evaluasi akademik sangatlah penting dilakukan. Untuk mencegah meningkatnya kegagalan mahasiswa pada matakuliah, dibutuhkan sebuah sistem yang mampu memprediksi nilai akhir matakuliah agar dapat dilakukan upaya preventif untuk mencegahnya. Pada penelitian ini diidentifikasi beberapa faktor yang diperkirakan dapat mempengaruhi performa belajar mahasiswa pada sistem pembelajaran *Problem Based Learning* (PBL), seperti faktor demografi, faktor *Prior Knowledge* serta faktor heterogenitas kelompok. Metode yang digunakan pada penelitian ini adalah Jaringan Syaraf Tiruan (JST) dengan algoritma pelatihan *backpropagation*. Sebanyak 8 neuron digunakan sebagai input untuk JST yang diambil dari variabel gender (2 neuron), usia (1 neuron), rata-rata nilai *knowledge* (1 neuron), rata-rata nilai *skill* (1 neuron) dan level heterogenitas kelompok (3 neuron). Pada *hidden neuron* diujicobakan beberapa nilai yakni 2, 7 dan 12 *hidden neuron*. Tiap arsitektur diujicobakan dengan variasi parameter pelatihan yang berbeda-beda untuk mencari arsitektur JST yang terbaik. Data yang diujicobakan pada penelitian diambil dari sistem informasi akademik Fakultas Kedokteran Gigi Unissula pada mata kuliah *Adult and Elderly Diseases* dan rentang tahun 2009-2013. Output yang dihasilkan adalah nilai numerik yang merepresentasikan nilai performa mahasiswa pada mata kuliah blok *Adult and Elderly Diseases*. Hasil penelitian adalah sebuah perangkat lunak yang mampu memprediksi nilai akhir matakuliah blok. Dari hasil pengujian didapatkan arsitektur JST terbaik diantara arsitektur lainnya adalah JST dengan jumlah *hidden neuron* sebanyak 7 buah dengan menggunakan parameter pelatihan *learning rate* sebesar 0,5, *momentum* sebesar 0,1 dan *epoch* sebanyak 9000. Dari target MSE sebesar 0,01 didapatkan nilai MSE pada validasi sebesar 0,011926 dan koefisien korelasi sebesar 0,796879. Hasil penelitian diharapkan dapat membantu dosen dan tim evaluasi akademik untuk meningkatkan performa mahasiswa serta melakukan upaya preventif terhadap kegagalan mahasiswa pada matakuliah blok.

Keywords : Jaringan Syaraf Tiruan; *Problem Based Learning*; Prediksi

*) Penulis korespondensi: badieah.assegaf@unissula.ac.id

1. Pendahuluan

Sistem pembelajaran berbasis permasalahan atau disebut dengan *Problem Based Learning* (PBL), saat ini telah diadopsi oleh banyak fakultas kedokteran di seluruh dunia (Wood, 2003). Salah satu tujuan utama dari implementasi PBL adalah untuk membantu mahasiswa mengembangkan kemampuan belajar secara mandiri (*self-learning skill*). Secara umum, sistem pembelajaran ini menerapkan metode *student-centered learning* dimana mahasiswa dibagi menjadi beberapa kelompok kecil dan diberikan sebuah skenario kasus klinis riil untuk didiskusikan.

Pada metode pembelajaran ini mahasiswa dituntut untuk berpikir secara kritis untuk mengidentifikasi sumber-sumber keilmuan yang diperlukan untuk diketahui dan dimana mencarinya dalam rangka menginterpretasikan berbagai informasi untuk menyelesaikan permasalahan tersebut. Peran tutor (dosen) pada proses belajar tersebut adalah memfasilitasi agar tiap-tiap mahasiswa pada kelompok belajar mampu berperan aktif dalam mengidentifikasi permasalahan secara kritis dan tidak keluar dari lingkup tujuan pembelajaran (*learning objective*) yang seharusnya. Tutor akan memberikan pertanyaan dan pernyataan yang sifatnya dapat memicu (*trigger*) pengetahuan yang dimiliki mahasiswa (*prior knowledge*) dan menjamin proses diskusi tetap berfokus pada isu-isu klinis yang relevan (Alajmi, 2014).

Berdasarkan mekanisme belajar mengajar pada PBL, keefektifan dari implementasi PBL tergantung dari tiga hal utama yakni kasus klinis (*case*) yang sedang dibahas, performa dari tutor pengampu serta performa dari mahasiswa itu sendiri (Alajmi, 2014). Sehingga dengan model pembelajaran ini, jika performa mahasiswa merupakan *output* yang mengindikasikan keefektifan proses pembelajaran, maka kolaborasi dari ketiga faktor tersebut yang akan menjadi penentu utama keberhasilan proses pembelajaran PBL. Proses evaluasi akademik pun akan difokuskan pada ketiga faktor tersebut.

Evaluasi akademik merupakan hal penting dilakukan untuk meningkatkan mutu akademik di perguruan tinggi. Pada Fakultas Kedokteran Gigi (FKG) Unissula, evaluasi mata kuliah blok dilakukan ketika modul mata kuliah tersebut sudah selesai berjalan. Proses evaluasi diawali dengan pemaparan rangkuman hasil pembelajaran mahasiswa pada mata kuliah blok tersebut oleh tim modul mata kuliah blok. Diantara bahan evaluasi yang dibahas diantaranya adalah detail prosentase perolehan nilai mahasiswa (nilai huruf), prosentase kelulusan mahasiswa pada mata kuliah blok tersebut serta prosentase nilai *knowledge* dan nilai *skill*. Beberapa item lainnya kaitannya dengan jumlah *retaker* dan *first-time taker*, jumlah kehadiran tutor dan mahasiswa (*attendance*), jumlah kehadiran *expert* pada kuliah pakar, serta

ketercapaian sasaran belajar juga menjadi bahan pada evaluasi tersebut. Evaluasi tersebut dilakukan dengan tujuan untuk memperbaiki rangkaian sistem belajar yang telah berjalan agar ada peningkatan ke arah yang lebih baik ke depannya. Sehingga evaluasi yang dilakukan adalah bersifat kuratif.

Upaya preventif kemudian perlu dilakukan sebagai langkah strategis yang dapat dilakukan oleh fakultas dalam rangka meningkatkan mutu akademik di fakultas tersebut. Salah satu langkah strategis yang dapat dilakukan adalah dengan cara meningkatkan performa mahasiswa dalam rangkaian kegiatan pembelajaran pada mata kuliah blok. Dengan lebih memahami kesulitan-kesulitan yang dihadapi mahasiswa dan pendekatan yang tepat kepada mahasiswa diharapkan dapat membantu meningkatkan performa mereka pada proses pembelajaran. Selain itu, fakultas juga perlu mengetahui potensi performa mahasiswa pada tiap-tiap matakuliah. Sehingga kegagalan mahasiswa pada matakuliah blok akan cepat diidentifikasi untuk dicarikan solusinya sebelum perkuliahan berlangsung.

Informasi perkiraan performa mahasiswa yang digunakan pada evaluasi tersebut kemudian dapat diteruskan dan digunakan untuk membantu tutor memberikan pendekatan yang tepat pada tiap-tiap mahasiswa. Hal ini dilatarbelakangi oleh pentingnya peran seorang tutor untuk dapat mengetahui karakteristik dari masing-masing mahasiswa yang berada pada kelompok belajar yang diampunya terutama pada level akademiknya. Dengannya, akan memudahkan tutor untuk dapat menghidupkan suasana diskusi serta memberikan pendekatan yang tepat kepada masing-masing mahasiswa yang sesuai dengan sasaran-sasaran belajar. Hal ini didukung oleh penelitian yang dilakukan oleh Das *et al.* (2002) yang menyimpulkan bahwa dibutuhkan strategi yang berbeda pada mahasiswa dengan latar belakang yang berbeda.

Namun pada kenyataannya, karena berbagai kondisi yang tidak memungkinkan dan banyaknya mata kuliah serta mahasiswa yang diampunya, tutor tidak memiliki cukup waktu untuk mendapatkan informasi-informasi yang dibutuhkan untuk mengetahui karakteristik, latar belakang dan potensi yang dimiliki oleh masing-masing mahasiswa yang diampunya. Sehingga meskipun tiap-tiap mahasiswa memiliki latar belakang dan kondisi akademik yang berbeda, tak jarang tutor memberikan perlakuan dan ekspektasi yang sama untuk seluruh anggota kelompok belajarnya. Hal ini terkadang akan menimbulkan kondisi yang tidak menguntungkan bagi mahasiswa-mahasiswa dengan kondisi tertentu.

Pada awal penelitian diidentifikasi faktor-faktor yang sekiranya dapat mempengaruhi performa mahasiswa pada proses belajar mengajar. Pada pembelajaran yang sifatnya melibatkan siswanya bekerja secara kooperatif seperti PBL (*cooperative*

learning), diketahui pada beberapa penelitian bahwa faktor-faktor seperti pembentukan kelompok belajar dapat mempengaruhi performa belajar mahasiswa. Menanggapi hal tersebut, jika yang dipelajari adalah tugas yang sifatnya pemecahan permasalahan, melatih bagaimana berkomunikasi dengan baik kepada orang-orang yang memiliki kemampuan yang berbeda-beda, serta jawaban benar yang diharapkan bisa lebih dari satu, maka pembentukan kelompok yang heterogen diperlukan (Samsudin dan Sunarti, 2006). Sehingga, sesuai dengan sifat dari pembelajaran PBL, maka pengaruh heterogenitas dari kelompok belajar diperkirakan dapat mempengaruhi performa belajar mahasiswa.

Pada beberapa penelitian lainnya disebutkan bahwa tingkat *prior knowledge* yang dimiliki mahasiswa mempunyai pengaruh yang besar pada proses pembelajaran (Hailikari *et al.* (2008); Beskeni *et al.* (2011); Liu *et al.* (2014)). Selain itu, faktor demografi seperti usia, jenis kelamin, status pernikahan dan lain-lain juga terbukti memiliki pengaruh pada performa belajar mahasiswa (Oladokun *et al.* (2008); Ogor (2007); Kovacic (2010); Laokietkul *et al.* (2009)).

Penelitian sebelumnya menunjukkan sejumlah teknik *data mining* dengan menggunakan metode *Artificial Intelligence* sudah banyak dilakukan sebagai upaya untuk meningkatkan performa mahasiswa dalam pembelajaran (Laokietkul, dkk (2009); Ogor (2007)). Sehingga sejalan dengan tujuan tersebut, pada penelitian ini akan dibangun sebuah sistem dengan teknik *data mining* menggunakan metode Jaringan Syaraf Tiruan (JST) sebagai solusi untuk memperkirakan performa mahasiswa pada akhir blok. Variabel yang digunakan untuk menghasilkan perkiraan performa mahasiswa tersebut dikelompokkan menjadi tiga kelompok besar, yakni variabel demografi (usia dan jenis kelamin), variabel *prior knowledge* (nilai *knowledge*, nilai *skill* dan IPK) dan level heterogenitas kelompok.

Sistem yang dibangun dapat dijadikan solusi untuk memberikan informasi perkiraan performa mahasiswa yang kemudiandimanfaatkan sebagai bahan evaluasi yang bersifat preventif untuk mencegah kegagalan mahasiswa pada akhir mata kuliah blok, serta sebagai bahan bagi tutor mata kuliah untuk membantu memberikan pendekatan dan *encouragement* yang tepat kepada tiap-tiap mahasiswa yang diampunya sesuai dengan karakteristik dan latar belakang akademiknya. Sehingga dengan informasi yang diberikan pada sistem ini, diharapkan dapat membantu Fakultas Kedokteran Gigi untuk meningkatkan mutu pendidikannya. Karena sifatnya adalah *prototype*, sistem yang dibangun hanya akan mengedepankan fungsinya untuk memperkirakan (memprediksi) performa mahasiswa pada mata kuliah blok. Penelitian ini tidak akan terlalu berfokus pada

keamanan sistem beserta integrasinya dengan Sistem Informasi Akademik (SIA) yang ada, meskipun hasil penelitian pada akhirnya diharapkan dapat terintegrasi dengan baik pada SIA yang digunakan pada Fakultas Kedokteran Gigi Unissula. Penelitian juga hanya diujicobakan pada satu mata kuliah saja, yakni mata kuliah *Adult and Elderly Diseases* yang diajarkan pada perkuliahan semester 4 (empat).

2. Kerangka Teori

2.1. Problem Based Learning (PBL)

Problem Based Learning (PBL) merupakan metodologi pembelajaran yang mendorong mahasiswa untuk lebih memahami subjek yang sedang dipelajari. Sistem pembelajaran ini mengkombinasikan antara pengetahuan dasar (*knowledge*) dan *skill* dengan memposisikan mahasiswa sebagai *problem solver* terhadap permasalahan yang akan dihadapi mahasiswa tersebut dimasa yang akan datang (Bidokht, 2011). Pada sistem PBL, mahasiswa diarahkan untuk berpikir menyelesaikan permasalahan berdasarkan skenario problem yang kemudian didiskusikan secara bersama-sama pada suatu kelompok diskusi. Kelompok diskusi ini tidak hanya dapat menstimulasi pemahaman dari mahasiswa, namun juga melatih kemampuan berkomunikasi, kerjasama, penyelesaian masalah, bertanggungjawab, berbagi informasi serta menghormati sesama sejawat (Wood, 2003).

2.2. Demografi

Demografi merupakan cabang ilmu sosiologi yang mempelajari tentang karakteristik dari populasi manusia seperti kelahiran, kematian, perkawinan, penyakit, pertumbuhan dan lain sebagainya. Penelitian pada bidang ini dibagi menjadi dua yakni aspek kuantitatif dan aspek kualitatif. Aspek kuantitatif diarahkan pada komposisi, jumlah kepadatan, distribusi, pertumbuhan, ukuran dan struktur dari populasi. Sedangkan aspek kualitatif berhubungan dengan faktor-faktor sosiologi seperti seperti kualitas pendidikan, kriminalitas, ras, kelas sosial, tingkat kekayaan dan lain sebagainya.

Saat ini banyak sekali penelitian yang menggunakan data demografi sebagai variabel penelitiannya. Pada perkembangannya, data demografi kemudian digunakan sebagai variabel penelitian pada berbagai penelitian berbasis *data mining*. Laokietkul *et al.* (2009) dan Ogor (2007) membuktikan pada penelitiannya bahwa data demografi mahasiswa dapat digunakan untuk memprediksi perfoma mahasiswa menggunakan teknik data mining.

Sehingga, merujuk pada penelitian sebelumnya (Laokietkul *et al.*, 2009 dan Ogor, 2007), data demografi merupakan salah satu faktor yang dapat mempengaruhi performa belajar siswa. Sehingga teori inilah yang mendasari bahwa data demografi

dapat digunakan untuk memprediksi performa belajar mahasiswa.

2.3. Prior Knowledge

Secara definisi, *prior knowledge* merupakan pengetahuan atau informasi yang dimiliki oleh seseorang yang didapatkan dari pengalamannya terdahulu. Untuk melihat seberapa efektif seseorang mempelajari sesuatu yang baru, diperlukan integrasi yang sinergis antara latar belakang pengetahuan yang dimilikinya, mengkonstruksi pengetahuan yang baru serta beradaptasi dengan konsep dan keyakinan yang ada saat ini sesuai dengan yang dibutuhkan. Sehingga, seorang pelajar yang tidak memiliki latar belakang pengetahuan yang cukup akan mengalami kesulitan untuk memahami informasi baru.

Berlandaskan pada definisi sebelumnya, *prior knowledge* juga dapat dikonsepsikan sebagai entitas multidimensional dan hierarkis yang terdiri dari seluruh pengetahuan (*knowledge*) dan keterampilan (*skill*) yang didapatkan sebelumnya. *Prior knowledge* pada dunia pendidikan telah dipertimbangkan sebagai salah satu faktor paling penting yang dapat mempengaruhi performa seorang pelajar dalam mempelajari sesuatu (Hailikari *et al.*, 2008; Beskeni *et al.*, 2011).

2.4. Heterogenitas Kelompok

Menurut Samsudin dan Sunarti (2006), kelompok belajar yang heterogen mampu memaksimalkan proses pembelajaran. Heterogenitas yang dimaksud adalah termasuk diantaranya adalah kemampuan akademik siswa, etnis, latar belakang (demografi), tingkat sosial ekonomi dan jenis kelamin.

Namun saat ini masih banyak perdebatan diantara metode pengelompokan siswa secara heterogen atau homogen yang secara efektif mampu meningkatkan performa siswa dalam belajar. Ada pendapat yang menyatakan bahwa jika proses pembelajaran yang diambil melibatkan keterampilan yang spesifik dan prosedural, maka pembentukan kelompok yang homogen akan baik untuk diterapkan. Namun jika proses pembelajaran dilakukan untuk memecahkan suatu permasalahan dan belajar bagaimana cara berkomunikasi yang baik, maka pembentukan kelompok yang heterogen akan baik untuk diterapkan (Samsudin dan Sunarti, 2006).

2.5. Cross-Industry Standard Data Mining (CRISP-DM)

Tahapan penelitian yang dilakukan pada penelitian ini adalah menerapkan metodologi *Cross-Industry Standard Process Data Mining* atau yang biasa disebut CRISP-DM sebagai standar model proses penggunaan data mining untuk penyelesaian permasalahan (Larose, 2005).

Model standarisasi tahapan data mining CRISP-DM terdiri dari 6 tahapan, yakni (Chapman *et al.*, 2000) :

- a. Tahap Pemahaman Permasalahan (*Business Understanding*)
- b. Tahap Pemahaman Data (*Data Understanding*)
- c. Tahap Persiapan Data (*Data Preparation*)
- d. Tahap Pemodelan (*Modeling*)
- e. Tahap Evaluasi (*Evaluation*)
- f. Tahap Penggunaan/Pemanfaatan (*Deployment*)

2.2. Pustaka Rujukan

Dalam rangka untuk memprediksi performa mahasiswa pada akhir blok, maka sebuah teknik data mining menggunakan metode Jaringan Syaraf Tiruan (JST) diimplementasikan pada sistem yang dibangun pada penelitian ini. Sebelumnya beberapa peneliti telah melakukan penelitian kaitannya dengan peningkatan performa mahasiswa pada perguruan tinggi menggunakan teknik data mining.

Moucary *et al.* (2006) menggunakan Jaringan Syaraf Tiruan dan teknik clustering untuk mengklasifikasi kemampuan kognitif mahasiswa sebagai *slow*, *moderate* dan *fast learner*. Ogor (2007) membangun sistem monitoring dan evaluasi performa mahasiswa menggunakan algoritma C.50. Kovacic (2010) membandingkan beberapa teknik data mining untuk memprediksi performa mahasiswa pada sebuah mata kuliah. Pada penelitiannya Kovacic menggunakan beberapa variabel sosio-demografi sebagai variabel independennya. Kemudian Laokietkul *et al.* (2009) menggunakan teknik Particular full-scaled class association rules (PFSCARs) dan variabel demografi untuk memprediksi performa belajar mahasiswa pada tahun pertama perkuliahan.

Dari beberapa penelitian tersebut tampak bahwa teknik data mining dapat digunakan untuk memprediksi performa mahasiswa pada perguruan tinggi yang melandasi penelitian ini.

2.3. Singkatan dan Akronim

Pada penelitian ini digunakan beberapa singkatan diantaranya adalah PBL yang merupakan singkatan dari *Problem Based Learning*. CRISP-DM adalah singkatan dari *Cross Industry Standard Procedure for Data Mining* yang merupakan langkah-langkah standar penelitian berbasis data mining. Kemudian JST adalah kependekan dari Jaringan Syaraf Tiruan yang istilah ini akan terus digunakan pada seluruh penelitian.

3. Metodologi

3.1. Tahap Pemahaman Permasalahan (*Business Understanding*)

Tahapan ini merupakan tahapan awal penelitian dimana tujuan dan arah penelitian yang akan dilakukan diidentifikasi. Pada tahap ini, dilakukan observasi secara langsung ke Fakultas Kedokteran Gigi (FKG) Unissula dan dilakukan wawancara ke beberapa pihak yang berhubungan dengan kegiatan

akademik. Wawancara dilakukan untuk lebih memahami proses bisnis dari kegiatan akademik pada fakultas tersebut yang menggunakan sistem *Problem Based Learning* (PBL).

Pada tahap ini, identifikasi lebih lanjut tentang faktor-faktor yang berpengaruh terhadap performa belajar mahasiswa dilakukan. Identifikasi faktor-faktor berpengaruh tersebut dilakukan melalui studi literatur yang diambil dari berbagai sumber yang relevan seperti jurnal ilmiah, prosiding penelitian, artikel ilmiah, buku dan sumber penunjang lainnya.

3.2. Tahap Pemahaman Data (Data Understanding)

Pada tahap ini dilakukan pengumpulan data nilai akademik mahasiswa yang didapatkan dari database akademik Fakultas Kedokteran Gigi Unissula. Dari database akademik, didapatkan data demografi dan nilai akademik yang terkumpul mulai tahun 2009 hingga tahun 2013. Pada tahap ini, eksplorasi data dilakukan untuk kemudian digunakan untuk penentuan variabel-variabel *input*.

3.3. Tahap Persiapan Data (Data Preparation)

Pada tahap persiapan data dilakukan dua tahapan untuk melakukannya, diantaranya adalah :

a. Data Preprocessing

Pada tahap ini semua variabel dipersiapkan untuk digunakan pada penelitian. Adapun variabel-variabel yang terpilih adalah sebagai berikut :

Tabel 1. Daftar Variabel Penelitian

Nama Variabel	Keterangan
Jenis Kelamin	Jenis kelamin mahasiswa
Usia	Usia mahasiswa ketika mengambil matakuliah. Dihitung dari tahun ketika mengambil mata kuliah dikurangi tahun lahir.
Rata-rata Nilai Knowledge	Perolehan rata-rata nilai <i>knowledge</i> dari mata kuliah yang telah diikuti.
Rata-rata Nilai Skill	Perolehan rata-rata nilai <i>skill</i> dari mata kuliah yang telah diikuti.
IPK	Indeks Prestasi Kumulatif mahasiswa
Level heterogenitas	Merupakan level heterogenitas kemampuan akademis kelompok.
Nilai akhir blok	Nilai akhir blok mata kuliah

Pada variabel penelitian, level heterogenitas dihitung dengan menggunakan teori matematika yang dipaparkan oleh Graf dan Bekele (2006) menggunakan persamaan sebagai berikut :

$$ADI = \frac{SkorMaks(S1, \dots, Sn) + SkorMin(S1, \dots, Sn)}{2} \quad (1)$$

$$GHI = \frac{SkorMaks(S1, \dots, Sn) - SkorMin(S1, \dots, Sn)}{1 + \sum_j |ADI - skordari(Sj(i))|} \quad (2)$$

Secara teori, kelompok dikatakan memiliki level heterogenitas yang memuaskan ketika kombinasi pada kelompok terdiri dari anggota dengan skor rendah, sedang dan tinggi (Graf dan Bekele, 2006).

Skor disini merujuk pada total skor yang didapatkan dari seluruh atribut. Tabel 2 menunjukkan aturan pemberian skor untuk atribut rata-rata nilai *knowledge* kelompok dan atribut rata-rata nilai *skill* kelompok.

Tabel 2. Aturan *scoring* pada atribut rata-rata *knowledge* dan rata-rata *skill*

Kategori	Interval	Skor
Baik	> 64,99	3
Cukup	60 - 64,99	2
Kurang	< 60	1

Sedangkan Tabel 3 menunjukkan aturan pemberian skor untuk atribut rata-rata IPK.

Tabel 3. Aturan *scoring* pada atribut IPK

Kategori	Interval	Skor
Baik	> 2,75	3
Cukup	2,20 - 2,75	2
Kurang	< 2,20	1

Dari total skor yang didapatkan oleh masing-masing anggota kelompok, kemudian dihitung level heterogenitas kelompoknya dengan menggunakan rumus *Goodness of Heterogeneity* (GH) pada rumus (2) setelah sebelumnya dihitung nilai *Average Difference* (AD) menggunakan rumus (1). Jika hasil GH bernilai nol (GH=0), menandakan kelompok yang dibentuk adalah homogen (sama). Kemudian jika nilai GH < 1 menandakan kelompok yang dibentuk kurang heterogen dan jika nilai GH > 1 menandakan kelompok yang dibentuk sudah baik tingkat heterogenitasnya. Semakin besar nilai GH, semakin baik heterogenitas kelompok tersebut.

Dari *dataset* yang ada, kemudian dilakukan pembersihan data (*data cleaning*) untuk menghindari adanya *outlier*, *missing value*, redundansi data, serta *misclassification*. Setelah melalui proses pembersihan data (*data cleaning*), data yang terkumpul kemudian ditransformasikan ke dalam bentuk numerik agar dapat diproses oleh *Machine Learning Neural Network*. Untuk variabel numerik, digunakan rumus *min-max normalization* (Larose, 2005).

$$X^* = \frac{X - \min(X)}{\text{range}(X)} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (3)$$

Adapun aturan pengkategorian nilai prediksi mengacu pada Buku Pedoman Pendidikan Kedokteran Gigi Unissula yang ditampilkan pada Tabel 4.

Tabel 4. Standar Nilai Mata Kuliah di FKG Unissula

Angka	Huruf	Bobot	Predikat	Status
75-100	A	4	Baik sekali	Lulus
70-74,99	AB	3,5	Baik	Lulus
65-69,99	B	3	Baik	Lulus
60-64,99	BC	2,5	Cukup	Lulus
55-59,99	C	2	Kurang	Tidak lulus
50-54,99	CD	1,5	Kurang	Tidak lulus
45-49,99	D	1	Kurang sekali	Tidak lulus
0-44,99	E	0	Kurang sekali	Tidak lulus

b. Pemisahan *Dataset*

Setelah *dataset* melalui tahap *data preprocessing*, didapatkan sebanyak 303 data yang dapat digunakan pada penelitian. Pada *dataset* yang didapatkan, *dataset* kemudian dipisahkan berdasarkan rentang tahun yakni *dataset* pada rentang tahun 2009-2012 digunakan untuk *dataset training*, sedangkan sisanya yakni tahun 2013 digunakan sebagai validasi. Pembagian *dataset* tersebut dijelaskan pada Tabel 5.


Tabel 5. Pembagian *Dataset* Penelitian

Rentang Tahun	<i>Dataset</i>	Jumlah Data
2009-2012	Training	236
2013	Validasi	67

3.3. Tahap *Pemodelan (Modeling)*

3.3.1. *Jaringan Syaraf Tiruan*

Jaringan syaraf tiruan (JST) merupakan sebuah sistem kecerdasan buatan yang berfungsi sebagai sistem pengolah informasi yang memiliki sifat seperti kecerdasan saraf otak manusia. JST merupakan generalisasi model matematis dari pemahaman manusia Berbeda dengan metode lain, algoritma untuk JST beroperasi langsung dengan angka sehingga data yang tidak numerik harus diubah menjadi data numerik (Hermawan, 2006).



Gambar 1. Struktur Unit Jaringan Syaraf Tiruan (Hermawan, 2006)

Secara teori JST minimal memiliki 3 unit pengolah, diantaranya adalah :

1. *Input layer*

Lapisan unit ini menyatakan nilai sebuah pola yang digunakan untuk masukan pada jaringan.

2. *Hidden layer*

Lapisan ini merupakan lapisan penghubung antara *input layer* dan *output layer* dimana *output* yang dikeluarkan tidak secara langsung diamati. Pada kasus-kasus tertentu, pada jaringan memungkinkan memiliki *hidden layer* lebih dari satu.

3. *Output layer*

Merupakan lapisan terakhir pada JST yang berfungsi untuk tempat keluaran. Pada beberapa penerapan, unit keluaran digunakan untuk merepresentasikan sebuah pola.

Pada metode JST, terdapat beberapa fungsi aktifasi yang dapat diterapkan, diantaranya adalah fungsi aktivasi Sigmoid Biner, Sigmoid Bipolar dan Tangen Hiperbolik. Karakteristik yang harus dimiliki oleh fungsi aktivasi tersebut adalah kontinu,


diferensiabel dan tidak menurun secara monoton (Puspitaningrum, 2006). Pada penelitian ini, digunakan fungsi aktivasi sigmoid biner. Fungsi aktivasi ini merupakan fungsi aktivasi yang paling banyak digunakan karena yang paling mudah diferensiasinya. Range dari fungsi aktivasi ini adalah (0,1) dan didefinisikan dengan rumus :

$$f_i(x) = \frac{1}{1+e^{-x}} \tag{4}$$

fungsi turunannya adalah :

$$f_i'(x) = f_i(x)(1-f_i(x)) \tag{5}$$

Fungsi aktivasi ini dapat diilustrasikan pada Gambar 2, sebagai berikut :



Gambar 2. Fungsi Sigmoid Biner dengan range (0,1)

Algoritma pelatihan yang populer digunakan pada Jaringan Syaraf Tiruan untuk memperbaiki bobot adalah algoritma Perambatan Mundur (*backpropagation*). Algoritma ini terdiri dari dua tahapan utama, yakni tahapan perambatan maju (*feedforward*) dan tahapan perambatan mundur (*backpropagation*). Pada tahapan perambatan mundur, bobot-bobot yang ada pada jaringan diperbaiki. Perbaikan dimulai dari bobot yang berada diantara lapisan *output* ke *hidden layer* kemudian bergerak mundur untuk memperbaiki bobot yang berada diantara *hidden layer* dan *input layer*. Setiap perubahan bobot yang didapatkan ditujukan untuk mengurangi besarnya kesalahan (*error*). Setelah bobot diperbaiki, maka bobot-bobot tersebut dialirkan kembali ke jaringan melalui tahapan perambatan maju (*feedforward*). Iterasi dari kedua proses tersebut terus menerus dilakukan pada semua *dataset* pelatihan sampai kondisi berhenti terpenuhi.

Fase *feedforward* merupakan fase dimana *input* dialirkan ke dalam jaringan untuk kemudian diproses dan menghasilkan *output* (*input-proses-output*). Proses ini berjalan searah dimulai dari *inputlayer* kemudian melalui *hidden layer* untuk kemudian diproses selanjutnya dan masuk ke *outputlayer* untuk dihitung hasil keluaran dari jaringan serta dihitung selisih *error*nya.

Pada awal fase ini, dilakukan penjumlahan bobot pada *hidden layer* dengan menggunakan rumus :

$$Z_{netj} = w_{0j} + \sum_{i=1}^n w_{ij} x_{ij} \tag{6}$$

Dimana *i* merupakan *neuron* ke-*i* (*i*=1,2,...,*n*) pada lapisan *input* dan *j* merupakan *neuron* ke-*j* (*j*=1,2,...,*p*) pada *hidden layer*. *x_{ij}* merupakan nilai

input pada input neuron i ke hidden neuron j . w_{0j} merupakan bias pada lapisan input, sedangkan w_{ij} merupakan bobot pada input neuron i yang menuju ke hidden neuron j .

Setelah penjumlahan bobot pada hidden layer dilakukan, kemudian diterapkan fungsi aktivasi pada bobot tersebut menggunakan fungsi aktivasi Sigmoid. Hasil dari penerapan fungsi aktivasi ini menjadi nilai yang akan digunakan oleh neuron pada hidden layer untuk proses selanjutnya. Rumus yang digunakan pada tahap penerapan fungsi aktivasi ini adalah sebagai berikut :

$$Z_j = f(Z_{net_j}) = \frac{1}{1 + e^{-Z_{net_j}}} \quad (7)$$

Dimana e merupakan bilangan natural yang memiliki nilai sama dengan 2.718281828. Hasil perhitungan dari $f(Z_{net_j})$ ini merupakan nilai aktivasi pada hidden neuron j untuk kemudian dikirimkan ke seluruh output neuron.

Tahap selanjutnya setelah didapatkan nilai numerik tiap neuron pada hidden layer adalah mengalirkan sinyal numerik tersebut ke layer selanjutnya, yakni output layer. Untuk melakukannya, tahapan yang digunakan identik dengan tahap ketika nilai pada input layer dialirkan pada hidden layer, yaitu menjumlahkan tiap bobot pada hidden layer dengan menggunakan rumus :

$$y_{net_k} = v_{0k} + \sum_{j=1}^k z_j v_{jk} \quad (8)$$

Nilai v_{0k} merupakan nilai bias pada hidden layer, z_j merupakan hasil nilai fungsi aktivasi yang keluar dari hidden layer dan v_{jk} merupakan bobot pada hidden neuron j menuju ke output neuron k ($k=1,2,\dots,m$).

$$y_k = f(Y_{net_k}) = \frac{1}{1 + e^{-y_{net_k}}} \quad (9)$$

Sedangkan $f(Y_{net_k})$ merupakan hasil fungsi aktivasi akibat penjumlahan bobot antara hidden neuron dan output neuron. Hasil fungsi aktivasi pada output neuron ini merupakan nilai keluaran aktual yang kemudian dihitung selisihnya dengan nilai target output-nya. Pada tiap iterasi, kemudian dihitung error keseluruhan dengan menggunakan rumus Mean Squared Error (MSE) (Kardan et al., 2013):

$$MSE = \frac{1}{N} \sum_{m=1}^N (T_m - O_m)^2 \quad (10)$$

Pada rumus di atas, O_m merupakan nilai output dari jaringan syaraf sedangkan T_m merupakan nilai target yang diinginkan untuk setiap keluaran dari N yang merupakan banyaknya dataset training. Jika nilai MSE yang dihasilkan masih belum sesuai dengan yang ditargetkan, maka proses akan dilanjutkan ke fase selanjutnya, yakni fase backpropagation dimana bobot-bobot pada jaringan

diperbaiki untuk kemudian dialirkan kembali ke jaringan menggunakan proses feedforward. Proses ini akan berulang hingga nilai error mencapai threshold yang diharapkan atau sudah mencapai batas maksimal iterasi yang ditentukan.

Untuk melakukan fase backpropagation, setelah semua unit output y_k menerima pola target t_k , lalu informasi kesalahan (δ_k) output dihitung yang kemudian dikirimkan ke lapisan berikutnya dan digunakan untuk menghitung besar koreksi bobot dan bias antara input layer dan hidden layer. Untuk menghitung galat antara hidden layer dan lapisan output, maka digunakan rumus:

$$\delta_k = (t_k - y_k) f'(y_{net_k}) \quad (11)$$

Dimana :

$$f'(y_{net_k}) = (1 - f(y_{net_k})) f(y_{net_k}) \quad (12)$$

Kemudian setelah galat yang terdapat pada hidden layer dan output layer ditemukan, langkah selanjutnya adalah menghitung galat yang terdapat diantara input layer dan hidden layer menggunakan rumus :

$$\delta_j = \delta_{net_j} f'(Z_{net_j}) \quad (13)$$

Dimana :

$$\delta_{net_j} = \sum_{k=1}^m \delta_k v_{jk} \quad (14)$$

$$f'(Z_{net_k}) = (1 - f(Z_{net_k})) f(Z_{net_k}) \quad (15)$$

Setelah galat pada masing-masing layer diketahui, besarnya perubahan yang akan ditambahkan pada bobot lama dihitung dengan menggunakan rumus :

$$\Delta w_{ij} = \eta \delta_j x_i \quad (16)$$

$$\Delta v_{jk} = \eta \delta_k z_j \quad (17)$$

Δw_{ij} dan Δv_{jk} masing-masing merupakan besarnya perubahan yang akan ditambahkan pada bobot lama yang akan diperbaharui. Dimana η adalah laju pembelajaran, δ_j galat yang dibawa antara lapisan input dan hidden layer, dan δ_k adalah galat yang dibawa antara hidden layer dan output layer. x_i merupakan nilai masukan yang berasal dari neuron i ke neuron j sedangkan z_j merupakan hasil fungsi aktivasi yang keluar dari hidden layer.

Setelah didapatkan Δw_{ij} dan Δv_{jk} , maka langkah selanjutnya adalah memperbaiki bobot lama menjadi bobot yang baru. Aturan perubahan bobot pada metode backpropagation dapat dirumuskan sebagai berikut :

$$w_{ij}(\text{baru}) = w_{ij}(\text{lama}) + \Delta w_{ij} \quad (18)$$

$$v_{jk}(\text{baru}) = v_{jk}(\text{lama}) + \Delta v_{jk} \quad (19)$$

$w_{ij}(\text{baru})$ merupakan bobot baru antara input layer dan hidden layer yang akan dicari, sedangkan $w_{ij}(\text{lama})$ merupakan bobot lama yang diperbaharui. $v_{jk}(\text{baru})$ merupakan bobot baru antara

hidden layer dan output layer yang akan dicari sedangkan $V_{jk}(lama)$ merupakan bobot lama yang akan diperbaharui.

Prosedur pembaharuan bobot pada JST dapat dimodifikasi dengan menggunakan momentum (μ). Manfaat menambahkan momentum ke dalam rumus perubahan bobot adalah untuk mempercepat konvergensi bobot pada jaringan yang berakibat pula pada percepatan waktu pelatihan jaringan. Hal ini dikarenakan momentum memaksa proses perubahan bobot terus bergerak sehingga tidak terperangkap dalam minimum lokal. Untuk melakukannya, langkah pertama yang diperlukan adalah memodifikasi rumus (16) dan rumus (17). Pada kedua rumus tersebut, jika error tidak terjadi (output aktual sama dengan output target) maka nilai $\delta_k = 0$ dan hal ini akan menyebabkan koreksi bobot $\Delta W_{jk} = 0$, atau dengan kata lain pembaharuan bobot akan berlanjut dalam arah yang sama dengan sebelumnya. Inilah yang akan menyebabkan lamanya proses konvergensi bobot pada jaringan. Pada keadaan seperti inilah parameter momentum digunakan untuk memodifikasi perubahan bobot sebagai berikut :

$$\Delta w_{ij}(t + 1) = \alpha \delta_j x_i + \mu \Delta w_{ij}(t) \tag{20}$$

$$\Delta v_{jk}(t + 1) = \alpha \delta_k z_j + \mu \Delta v_{jk}(t) \tag{21}$$

Cara lain untuk memodifikasi bobot menggunakan momentum adalah dengan cara memodifikasi rumus (18) dan (19) sebagai berikut :

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j x_i + \mu [w_{ij}(t) - w_{ij}(t - 1)] \tag{22}$$

$$v_{jk}(t+1) = v_{jk}(t) + \alpha \delta_k z_j + \mu [v_{jk}(t) - v_{jk}(t - 1)] \tag{23}$$

Bobot yang sudah diperbaiki kemudian dialirkan lagi ke jaringan dan dihitung nilai kesalahannya kembali (error). Jika besar error yang dihasilkan lebih kecil dari toleransi yang ditentukan atau jumlah iterasi (epoch) pada proses pelatihan sudah mencapai iterasi maksimum, maka proses pelatihan dihentikan.

3.3.2. Penentuan Arsitektur JST

Secara teori, pada metode JST tidak ada aturan baku untuk menentukan arsitektur JST yang optimal untuk diterapkan ke dalam sistem (Kardan et al., 2013). Sehingga pencarian arsitektur dan parameter pelatihan JST harus dilakukan secara trial dan error. Berdasarkan rules of thumbs untuk menentukan jumlah neuron pada hidden layer, maka jumlah hidden neuron yang diujicobakan pada penelitian ini ditampilkan pada Tabel 6.

Tabel 6 Arsitektur JST yang diujicobakan

Nama JST	Jumlah InputNeuron	Jumlah HiddenNeuron	Jumlah OutputNeuron
JST 1	8	2	1
JST 2	8	7	1
JST 3	8	12	1

Untuk melakukan ujicoba pelatihan JST langkah selanjutnya adalah menentukan parameter pelatihan JST. Penentuan parameter ini juga dilakukan secara trial dan error. Pada penelitian ini, parameter learning rate dan momentum yang diujicobakan ditampilkan pada Tabel 7.

Tabel 7 Learning rate dan momentum yang diujicobakan

Parameter	Nilai Parameter Yang Diujicobakan				
Learning Rate	0,1	0,2	0,3	0,4	0,5
Momentum	0,1	0,2	0,3	0,4	0,5

Parameter-parameter tersebut diujicobakan pada tiap arsitektur JST (JST 1, JST 2 dan JST 3) dengan ketentuan kombinasi maksimum epoch seperti yang ditampilkan pada Tabel 8. Sehingga jika seluruhnya dikombinasikan, maka akan ada sebanyak 250 percobaan pelatihan JST pada masing-masing arsitektur JST dan total 750 percobaan untuk keseluruhan arsitektur. Seluruh percobaan ini diujicobakan dengan tujuan untuk mencari arsitektur JST yang paling optimal untuk diimplementasikan ke dalam sistem.

Tabel 8 Epoch yang diujicobakan

Parameter	Nilai Parameter Yang Diujicobakan				
Epoch	1000	2000	3000	4000	5000
	6000	7000	8000	9000	10000

Selanjutnya setelah arsitektur dan parameter JST ditentukan, proses pelatihan JST dilakukan. Proses yang terjadi selama proses pelatihan JST berlangsung adalah fase feedforward, fase backpropagation, dan fase perubahan bobot. Pada fase feedforward, pola masukan dihitung mulai dari input layer hingga output layer menggunakan fungsi aktivasi. Kemudian pada fase backpropagation selisih antara output jaringan dengan target yang diinginkan merupakan besar kesalahan yang terjadi. Kesalahan tersebut dialirkan mundur dimulai dari garis yang berhubungan langsung dengan output neuron. Fase terakhir adalah fase dimana bobot-bobot yang ada pada jaringan dimodifikasi untuk menurunkan nilai error yang terjadi (Siang, 2009).

3.4. Tahap Evaluasi (Evaluation)

Untuk melihat apakah JST yang sudah melalui proses pelatihan mampu mengenali pola data baru (unseen data), maka proses validasi dilakukan. Pada tahap ini, proses yang berjalan hanyalah proses feedforward saja. Seperti pada proses pembelajaran, hasil dari proses feedforward ini kemudian diukur keakuratannya untuk mengontrol apakah jaringan sudah dapat mengenali pola dengan baik.

Pengukuran keakuratan hasil prediksi pada penelitian ini dilihat dari nilai MSE yang dihitung dengan menggunakan rumus (10). Jika hasil validasi menunjukkan nilai MSE mendekati 0 (nol), maka sistem yang dibangun dianggap sudah dapat diimplementasikan ke dalam sistem.

Selain itu, salah satu indikator yang digunakan untuk mengukur kualitas dari JST, digunakan rumus koefisien korelasi (R) (Kardan *et al.*, 2013). Nilai R akan menunjukkan hubungan antara nilai target dan nilai *output* yang dihasilkan oleh JST.

$$R = \frac{\sum_{m=1}^N (T_m - \mu_T)(O_m - \mu_o)}{\sqrt{\sum_{m=1}^N (T_m - \mu_T)^2} \sqrt{\sum_{m=1}^N (O_m - \mu_o)^2}} \quad (24)$$

Variabel μ_T pada rumus menunjukkan rata-rata dari target dan μ_o adalah nilai rata-rata dari *output* yang dikeluarkan oleh JST. Baik atau tidaknya nilai R dilihat dari range antara -1 dan 1. Jika hasil prediksi sempurna, maka nilai target dan nilai output akan memiliki nilai yang sama persis (R=1). Dengan nilai tersebut artinya antara nilai target dan output memiliki korelasi yang sempurna. Namun korelasi semacam ini sangat jarang terjadi. Sebaliknya jika nilai R pada hasil prediksi mendekati -1, artinya nilai target dan output sama tidak berkorelasi (Kardan *et al.*, 2013).

3.5. Tahap Pemanfaatan (Deployment)

Ketika model JST yang dihasilkan telah dianggap menghasilkan *output* yang diharapkan, maka pada tahap ini antarmuka pengguna sistem dibangun untuk memudahkan user mengakses sistem. Untuk menguji sistem yang dibangun, digunakan data pengujian yang diambil seluruhnya dari data pada tahun 2013.

4. Hasil dan Pembahasan

4.1. Hasil Penelitian


Setelah semua percobaan dilakukan, kemudian semua hasil terbaik pada masing-masing arsitektur JST dibandingkan. Tabel 9 merupakan tabel perbandingan performa JST pada masing-masing arsitektur. Performa yang dibandingkan adalah nilai MSE dan R yang didapatkan baik pada proses pelatihan JST maupun pada saat validasi.

Pada Tabel 9 tampak bahwa pada JST 1 nilai MSE yang diperoleh pada proses pelatihan lebih kecil dibandingkan dengan pada saat validasi. Hal ini menunjukkan kondisi *overfitting* dimana performa MSE pada proses pelatihan lebih baik dibandingkan dengan performa MSE pada saat validasi. Pada arsitektur JST 2 kondisi ini tidak terjadi karena nilai MSE yang didapatkan pada validasi lebih kecil dibandingkan pada saat pelatihan. Kemudian pada

JST 3 kondisi *overfitting* kembali terjadi dimana nilai MSE pada validasi lebih besar dibandingkan pada saat pelatihan.

Untuk memilih arsitektur JST yang paling optimal dari keseluruhan 750 percobaan yang dilakukan pada penelitian ini, diambil dari arsitektur dengan nilai MSE yang kecil dan tidak mengalami kondisi *overfitting*. Berdasarkan kriteria tersebut, maka arsitektur JST 2 Session 299 terpilih sebagai arsitektur JST yang paling optimal dari 750 percobaan yang dilakukan. Sehingga, bobot-bobot antar *neuron* yang dihasilkan dari arsitektur ini digunakan untuk diimplementasikan pada sistem untuk memprediksi nilai mahasiswa.

Arsitektur JST Session 299 menggunakan jumlah *hidden neuron* sebanyak 7 buah dan parameter *learning rate* sebesar 0,5 serta *momentum* sebesar 0,1. Iterasi yang digunakan adalah sebanyak 9000. Arsitektur JST yang paling optimum pada penelitian ini hanyalah sebatas pada 750 percobaan yang dilakukan. Artinya, penelitian dapat dikembangkan dengan mengoptimalkan beberapa aspek yang diduga dapat meningkatkan performa JST. Sebagai contoh, percobaan dengan kombinasi parameter pelatihan yang berbeda dari yang digunakan pada penelitian ini dan lain sebagainya.



Gambar 3. Grafik perbandingan target dan output hasil prediksi

UID	Nama	Gender	Usia	Rata-Rata Knowledge	Rata-Rata Skill	SPK	Target Nilai	Prediksi Nilai
311010001	EMELIA DWI ASTARI	P	20	73.38	82.06	3.67	78.351204	74.96149308
311010002	INAS MAYDA EL ZAHWA	P	18	44.79	67.42	1.82	57.188660	52.27040454
311010003	ANINDA PRADAGARI	P	19	66.78	82.60	3.26	69.400134	69.78308802
311010004	MALITA MANDELLASARI	P	20	67.51	82.27	3.39	76.509194	70.09090909
311010005	DOENNA KARANA INTANGGAS	P	19	67.42	82.02	3.30	70.581288	70.14561478
311010006	DEVY DWI FAJARHANI	P	21	67.63	84.97	3.29	69.438056	76.20065608
311010007	DWINDA REDY BATHAZ	P	19	63.46	78.02	2.75	62.450488	66.08244420
311010008	DWI RATNA UTAMI	P	20	70.55	86.53	3.62	72.940958	72.71778872
311010009	QIS ANDHA MAULANA	L	19	46.38	78.90	3.01	67.820732	68.02440100
311010010	AUGIA MIFTAHUL JANAH	P	18	65.24	83.71	3.21	69.420460	68.83491000
311010011	TITO RANDA	L	20	63.36	81.50	2.90	74.541070	69.33044420

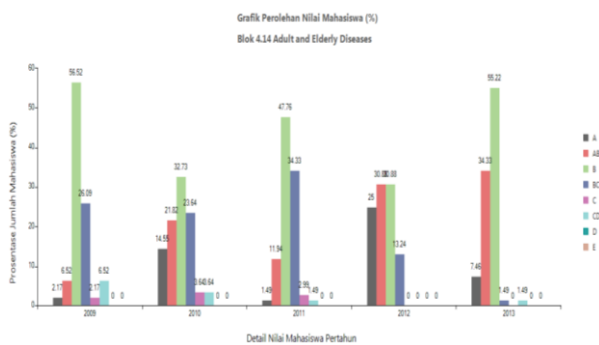
Gambar 4. Laporan prediksi nilai akhir blok mahasiswa

Tabel 9. Hasil Prediksi dan Validasi JST

JST	Session	LR*	M**	Epoch	Training		Validasi	
					MSE	R	MSE	R
JST 1	98	0,5	0,2	8000	0,013306	0,696135	0,014635	0,779855
JST 2	299	0,5	0,1	9000	0,012597	0,739863	0,011926	0,796879
JST 3	745	0,5	0,5	5000	0,011485	0,777175	0,013369	0,761367

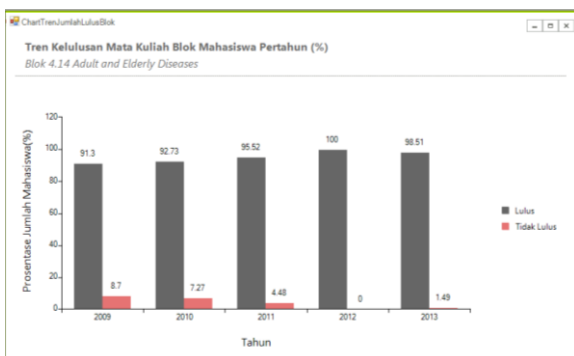
*LR (Learning Rate) **M (Momentum)

Laporan prediksi nilai akhir blok yang ditampilkan pada Gambar 4 digunakan untuk melihat prediksi nilai mahasiswa pada tiap matakuliah per kelompok. Laporan ini dapat digunakan baik oleh tim evaluasi akademik maupun tutor mata kuliah tersebut. *Combobox* matakuliah berfungsi untuk memilih daftar mata kuliah blok yang ditawarkan pada semester mendatang sedangkan *combobox* kelompok adalah daftar kelompok-kelompok kecil mahasiswa pada mata kuliah tersebut. Pada laporan akan tampil prediksi nilai pada kuliah yang dipilih. Pada penelitian ini, nilai yang keluar adalah nilai dari matakuliah Blok *Adult and Elderly Diseases*.



Gambar 5 Grafik tren perolehan nilai akhir blok mahasiswa pertahun

Grafik tren perolehan nilai (Gambar 5) digunakan sebagai *tools* untuk membantu tim evaluasi akademik mengevaluasi nilai mahasiswa pada matakuliah tertentu pertahunnya. Sehingga ketika ada indikasi penurunan prosentase perolehan nilai pada sebuah matakuliah blok, misalnya, akan dapat diupayakan langkah-langkah strategis untuk mencegahnya.



Gambar 6 Grafik tren perolehan nilai akhir blok mahasiswa pertahun

Gambar 6 menunjukkan grafik tren kelulusan mata kuliah blok mahasiswa pertahun. Melalui grafik ini, *user* dapat melihat tren prosentase kelulusan mahasiswa pada mata kuliah blok tertentu. Sehingga, jika ada indikasi penurunan prosentase kelulusan mahasiswa pada matakuliah tertentu (diindikasikan dari prediksi nilai), maka dapat dicarikan solusi dan pendekatan yang terbaik sebagai upaya preventif terhadap kegagalan mahasiswa pada akhir blok.

4.2. Pembahasan


Penelitian ini bertujuan untuk membangun sebuah sistem yang mampu memprediksi nilai akhir blok mahasiswa pada metode pembelajaran problem based learning. Sistem yang dibangun diharapkan dapat membantu pihak tim evaluasi akademik dan tutor mata kuliah untuk memberikan gambaran perkiraan performa mahasiswa pada mata kuliah yang akan dilaksanakan. Sehingga melalui hasil prediksi tersebut, dapat dilakukan upaya preventif dan strategi untuk mencegah kegagalan mahasiswa pada mata kuliah blok. Melalui studi literatur, didapatkan beberapa faktor yang sekiranya dapat mempengaruhi performa belajar mahasiswa. Faktor-faktor tersebut diantaranya adalah faktor demografi (usia dan jenis kelamin), faktor *prior knowledge* (rata-rata nilai *knowledge*, rata-rata nilai *skill* dan Indeks Prestasi Kumulatif) serta tingkat heterogenitas kelompok. Total dataset yang didapatkan untuk diujicobakan pada penelitian adalah sebanyak 303 data diambil pada rentang tahun 2009 hingga 2013. Data kemudian dipecah menjadi dua bagian, yakni data pada rentang tahun 2009-2012 digunakan untuk dataset training (236 data) dan sisanya data pada tahun 2013 (67 data) digunakan untuk validasi.

Pada penelitian digunakan topologi jaringan dengan 3 buah layer yakni input layer, *hidden layer* dan output layer. Permasalahan yang sedikit sulit pada implementasi JST adalah, pada metode ini tidak ada teori yang pasti untuk menentukan banyaknya jumlah *hidden neuron* dan parameter-parameter yang akan diujikan. Sehingga pada penelitian ini diujicobakan beberapa arsitektur JST dengan jumlah *hidden neuron* yang berbeda sebagai proses *trial* dan *error*. Berdasarkan *rules of thumb* untuk memperkirakan Jumlah *hidden neuron* (Heaton, 2008), maka pada penelitian ini jumlah *hidden neuron* yang diujicobakan diantaranya adalah 2, 7 dan 12 *neuron*. Masing-masing dari arsitektur tersebut kemudian dilatih dengan kombinasi parameter pelatihan yang bervariasi. Parameter pelatihan yang digunakan untuk proses pelatihan diantaranya adalah *learning rate*, *momentum* dan jumlah maksimum *epoch*. Untuk parameter *learning rate* dan *momentum*, rentang nilai yang diujicobakan adalah antara 0,1-0,5. Kemudian *epoch* yang diujicobakan adalah antara 1.000-10.000.

Dari parameter-parameter tersebut didapatkan 750 kombinasi parameter yang diujicobakan pada ketiga arsitektur JST. Dari ketiganya kemudian dibandingkan performa hasil *training* dan validasinya. Performa JST dihitung menggunakan *Mean Squared Error* dan koefisien korelasi (R). Nilai MSE akan menunjukkan seberapa jauh nilai error yang dikeluarkan oleh jaringan dan koefisien korelasi digunakan untuk mengukur seberapa dekat nilai output yang dikeluarkan jaringan terhadap target nilai yang diharapkan. Hasil validasi yang didapatkan adalah nilai MSE terkecil terletak pada arsitektur JST

2 yang menghasilkan nilai MSE sebesar 0,011926 dan koefisien korelasi sebesar 0,796879. Nilai yang didapatkan memang tidak terlalu tinggi, namun jika dilihat dari hasil penelitian, tampak bahwa JST sudah mampu mengenali pola data dengan baik. Artinya, karena nilai MSE yang dihasilkan pada validasi tidak lebih tinggi dibandingkan dengan hasil pelatihan, maka bisa dipastikan bahwa kondisi *overfitting* tidak terjadi pada arsitektur tersebut dan jaringan tidak sekedar menghafalkan pola data yang ada di dataset training saja namun mampu menggeneralisasi pola data yang baru. Dibandingkan dengan arsitektur JST 2, pada arsitektur JST 1 dan JST 3 mengalami kondisi *overfitting*. Menurut Khasei dan Bijari (2010), jaringan dengan struktur yang sederhana akan menghasilkan *output* yang baik pada saat validasi jika menggunakan jumlah *hidden neuron* yang tidak terlalu banyak. Sehingga kasus *overfitting* pada JST 1 kemungkinan besar bukan disebabkan oleh pengaruh jumlah *hidden neuron* namun lebih disebabkan oleh peristiwa *overtraining*, dimana pada *epoch* yang tinggi jaringan belum mampu mencapai *minimum error* dan menyebabkan iterasi terus dilakukan. Peristiwa *overfitting* ini ditandai dengan kecilnya nilai MSE yang dihasilkan pada proses *training* sedang pada proses validasi nilai MSE lebih besar dibandingkan dengan hasil *training*. Hal ini menandakan jaringan terlalu menghafal pola data pada *dataset training* dan tidak bisa menggeneralisasi data yang baru.

Secara sekilas jumlah *hidden neuron* pada JST 1 tampak terlalu kecil dibandingkan dengan JST 2 dan JST 3 dan akan memberikan asumsi bahwa hasil yang didapatkan pada JST 1 diakibatkan oleh peristiwa *underfitting*. Namun berdasarkan grafik yang ditunjukkan pada Gambar 4.8 tidak menunjukkan tanda-tanda bahwa JST 1 mengalami peristiwa *underfitting*. Kondisi *underfitting* biasanya ditandai dengan tidakampunya jaringan untuk melakukan generalisasi. Sehingga berapapun nilai input yang diberikan, jaringan akan terus menerus memberikan nilai yang sama. Jika digambarkan pada diagram kartesian, nilai MSE yang didapatkan dari seluruh iterasi akan tampak membentuk garis lurus seperti yang digambarkan pada Gambar 7.




Gambar 7 Contoh kondisi *underfitting*

Selanjutnya pada arsitektur JST 3 juga menunjukkan kondisi *overfitting*. Karena JST 2 dengan 7 *hidden neuron* tidak mengalami peristiwa

overfitting, maka peristiwa *overfitting* yang terjadi pada JST 3 menandakan bahwa 12 *hidden neuron* sudah termasuk jumlah yang banyak untuk digunakan pada jaringan. Hal ini sesuai dengan beberapa teori yang menyebutkan bahwa penggunaan *hidden neuron* yang terlalu besar akan memicu munculnya kondisi *overfitting* (Karsoliya, 2012; Kardan *et al.*, 2013). Sehingga pada JST 3 jumlah *hidden neuron* cukup mempengaruhi munculnya peristiwa *overfitting* meskipun kemungkinan peristiwa *overtraining* juga masih ada.

Pada dasarnya *underfitting* dan *overfitting* merupakan permasalahan yang umum terjadi ketika menggunakan JST. Permasalahan tersebut muncul karena tidak adanya teori yang bisa memastikan berapa jumlah *hidden neuron* sebenarnya hingga dikatakan “terlalu sedikit” atau “terlalu banyak”. Meskipun ada peneliti yang mencoba membuat metode untuk memperkirakan jumlah *hidden neuron* pada JST (Karsoliya, 2012), namun pada sebagian besar kasus perlu dilakukan *trial* dan *error* untuk mencari *hidden neuron* yang optimal. Teori dasarnya adalah *hidden neuron* ditambahkan jika performa JST berjalan lambat untuk konvergen atau jika MSE semakin besar nilainya. Sebaliknya, *neuron* sebaiknya dikurangi jika jaringan terus menerus memberikan nilai keluaran yang sama meskipun telah menggunakan *epoch* yang besar (Khasei dan Bijari, 2010).

Namun tentu saja, jumlah *hidden neuron* tidak satu-satunya faktor yang mempengaruhi performa dari JST. Parameter lainnya seperti *learning rate* dan *momentum* juga berperan aktif dalam membantu JST untuk menggeneralisasi pola data. Penggunaan nilai *learning rate* yang terlalu kecil, akan membuat jaringan akan lama untuk mencapai *global minimum*. Sebaliknya penggunaan nilai *learning rate* yang besar akan menyebabkan jaringan akan *overshoot* melewati *global minimum* dan nilai *error*-nya akan meningkat lagi.



Gambar 8 Pengaruh *Learning Rate* untuk Mencapai Kondisi Optimum (Sugiono *et al.*, 2012)

Dengan menggunakan *momentum* pada pelatihan JST, perubahan bobot yang pada iterasi ke-*n* akan ditambahkan delta perubahan bobot pada iterasi *n-1* yang nilainya dilipatkan sebesar nilai *momentum*. Nilai *momentum* yang terlalu kecil akan

menyebabkan perubahan bobot akan kecil dan nilai bobot yang sekarang tidak akan jauh berbeda dengan nilai bobot pada iterasi sebelumnya. Sehingga untuk mencapai konvergensi, jaringan membutuhkan iterasi yang banyak.

Namun seperti halnya *hidden neuron*, pada metode JST tidak ada yang bisa memastikan berapa nilai *learning rate* dan *momentum* yang seharusnya digunakan untuk proses pelatihan JST. Sehingga proses *trial* dan *error* harus terus dilakukan hingga jaringan mencapai nilai MSE yang lebih mendekati 0 (nol). Pada penelitian ini, arsitektur mencapai nilai optimum ketika menggunakan *learning rate* sebesar 0,5 dan *momentum* 0,1 serta *epoch* sebanyak 9000. Nilai optimum yang didapatkan pada penelitian ini hanyalah sebatas pada lingkup 750 percobaan yang dilakukan. Karena bisa jadi penggunaan kombinasi parameter yang berbeda akan memberikan performa JST yang lebih baik. Diharapkan pada pengembangan selanjutnya, sistem prediksi nilai yang dibangun pada penelitian ini dapat dimodifikasi agar secara adaptif dapat menaikkan atau menurunkan nilai *learning rate* dan *momentum* sesuai dengan kondisi performa MSE yang dihasilkan oleh jaringan seperti yang ada pada perangkat lunak MATLAB. Sehingga dengan modifikasi tersebut akan mempermudah untuk mencari nilai dari kedua parameter tersebut tanpa harus secara manual diinisialisasikan ke dalam sistem.

5. Kesimpulan

Pada penelitian ini, diujicobakan dengan menggunakan metode Jaringan Syaraf Tiruan (JST) dengan menggunakan algoritma pelatihan *backpropagation*. Pada metode ini, penentuan kombinasi antara jumlah *hidden neuron* dengan parameter pelatihan yakni *learning rate*, *momentum* dan *epoch* memiliki peran penting dalam mencapai nilai yang optimum. Namun karena tidak ada aturan baku untuk menentukan parameter-parameter tersebut, maka proses *trial* dan *error* harus dilakukan.

Berdasarkan hasil *trial* dan *error* yang dilakukan pada penelitian ini, arsitektur JST yang paling optimum adalah menggunakan jumlah *hidden neuron* sebanyak 7 buah, parameter *learning rate* 0,5, parameter *momentum* 0,1 dan *epoch* sebanyak 9000. Nilai MSE yang didapatkan pada arsitektur tersebut adalah sebesar 0,011926 dan R sebesar 0,796879. Dari hasil tersebut dapat disimpulkan bahwa metode ini dapat digunakan untuk memprediksi nilai akhir matakuliah blok mahasiswa pada sistem pembelajaran *Problem Based Learning*. Sehingga dapat menyediakan informasi yang diharapkan bermanfaat kepada pengguna tentang prediksi performa mahasiswa serta sebagai bahan evaluasi akademik sebelum mata kuliah blok dilaksanakan.

Namun demikian, hasil penelitian masih dapat dikembangkan lebih lanjut dengan lebih menekankan pada aspek optimalisasi pemilihan jumlah *hidden neuron* dan parameter pelatihan JST. Akan lebih baik jika sistem yang dikembangkan secara adaptif mampu merubah nilai *learning rate* dan *momentum* secara adaptif sesuai dengan kondisi jaringan saat proses pelatihan JST.

Untuk pengembangan pada penelitian selanjutnya, diharapkan FKG Unissula mampu melakukan perbaikan struktur *database* serta secara aktif melengkapi ketersediaan data untuk kebutuhan penelitian. Fitur-fitur data yang sekiranya dapat dijadikan parameter yang berpengaruh terhadap performa mahasiswa seperti absensi, status pernikahan, sumber dana pendidikan, pekerjaan dan elemen-elemen nilai tutorial maupun *skill lab* secara detail dapat dilengkapi. Sehingga dengan struktur *database* yang baik dan ketersediaan data yang lengkap diharapkan dapat dibangun sistem prediksi yang mampu menghasilkan *output* yang lebih baik lagi.

Ucapan Terima Kasih

Penulis mengucapkan rasa terima kasih kepada drg Musri Amurwaningsih selaku Ketua Tim Kurikulum Fakultas Kedokteran Gigi Unissula, drg. R.Rama Putranto, M.Kes., Ph.D selaku Kepala Unit Penjaminan Mutu Fakultas Kedokteran Gigi Unissula dan seluruh staff tata usaha Fakultas Kedokteran Gigi Unissula yang secara kooperatif bersedia membantu memberikan berbagai data dan informasi yang dibutuhkan pada penelitian ini.

Daftar Pustaka

- Alajmi, N., 2014. Factors that influence performance in problem-based learning tutorial. *Ph.D dissertation*, Bond University Faculty of Health Science and Medicine
- Beskeni, R.D., Yousuf, M.I., Awang, M.M., Ranjha, A.N., 2011. The effect of prior knowledge in understanding chemistry concepts by senior secondary school students. *International Journal of Academic Research*, 3(2), 607-611.
- Bidokht, M.H., 2011. Life-long Learners Through Problem-Based and Self Directed Learning. *Procedia Computer Science* 3, 1446-1453
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C. and Wirth, R., 2000. *CRISP-DM 1.0 : Step-by-Step Data Mining Guide*, SPSS.
- Das, M., Mpofu, D.F.S., Hasan, M.Y., Stewart, T.S., 2002. Student perceptions of tutor skill in problem-based learning tutorials. *Medical Education*, (36), 272-278
- Graf, S., Bekele, R., 2006. Forming Heterogeneous Groups for Intelligent Collaborative Learning

- Systems with Ant Colony Optimization, *In Proceedings of the 8th International Conference on Intelligent Tutoring Systems (ITS 2006)*, 217-226
- Hailikari, T., Katajavouri, N., Ylane, S.L., 2008. The Relevance of Prior Knowledge in Learning and Instructional Design, *American Journal of Pharmaceutical*, 72(5), 1-8
- Heaton, J., 2008. *Introduction to Neural Networks for C*, Second Edition, Heaton Research, St Louis
- Hermawan, 2006, *Jaringan Syaraf Tiruan Teori dan Aplikasi*, Penerbit Andi Yogyakarta
- Kardan, A.A., Sadeghi, H., Ghidary, S.S., Sani, M.R.F., 2013. Prediction of Student Course Selection in Online Higher Education Institutes Using Neural Network, *Computer & Education* 65(2013), 1-11
- Karsoliya, S., 2012. Approximating Number of Hidden Layer Neurons in Multiple Hidden Layer BPNN Architecture, *International Journal of Engineering Trends and Technology* Vol.3 Issue.6, 714-717
- Khasei, M., Bijari, M., 2010. An Artificial Neural Network (p,d,q) Model for Timeseries Forecasting, *Expert Systems with Applications* 37(2010), 479-489
- Kovacic, Z.J., 2010. Early Prediction of Student Success : Mining Students Enrollment Data, *Proceedings of Informing Science & IT Education Conference (InSITE) 2010*, 647-665
- Laokietkul, J., Utakrit, N., Meesad, P., 2009. A Forecasting Model to Evaluate a Freshman's Ability to Succeed by Using Particular Full-Scaled Class Association Rules (PFSCARs), *International Conference of Computer Science and Information Technology-Spring Conference*, 40-44
- Larose, D.T., 2005. *Discovering Knowledge in Data : An Introduction to Data Mining*, Wiley-Interscience, Canada
- Liu, T.C., Lin, Y.C., Paas, F., 2014. Effects of Prior Knowledge on Learning from Different Compositions of Representations in a Mobile Learning Environment, *Computer & Education*, Vol.72, 328-338
- Moucary, C.E., Khair, M., Zakhem, W., 2006, Improving Student Performance Using Data Clustering and Neural Networks in Foreign-Language Based Higher Education, *The Research Bulletin of Jordan ACM Vol II(III)*, 27-34
- Ogor, E.N., 2007. Student Academic Performance Monitoring and Evaluation Using Data Mining Techniques, *Forth Congress of Electronics, Robotics and Automotive Mechanics*, 354-359
- Oladokun, V.O., Adebajo, A.T., Owaba, O.E.C., 2008. Predicting Students Academic Performance using Artificial Neural Networks : A Case Study of an Engineering Course, *The Pacific Journal of Science and Technology* Vol.9, 72-79
- Puspitaningrum, 2006, *Pengantar Jaringan Saraf Tiruan*, Penerbit Andi, Yogyakarta
- Samsudin dan Sunarti, 2006. Cooperative Learning : Heterogenous vs Homogenous Grouping, *Apera Conference 2006*, 1-6
- Siang, J.J., 2009. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan MATLAB*, Penerbit Andi, Yogyakarta
- Sugiono, Wu, M.H., Oraifige, I., 2012. Employ the Taguchi Method to Optimize BPNN's Architectures in Car Body Design System, *American Journal of Computational and Applied Mathematics* 2012 2(4), 140-151
- Wood, D.F., 2003. ABC of Learning and Teaching in medicine : Problem based learning, *BMJ*, Volume 326, 328-330