



Laporan Akhir Projek Penyelidikan Jangka Pendek

Development of an Electronic Intelligent Screening System for Malaria Parasite

By

Dr. Nor Ashidi Mat Isa

Assoc. Prof. Dr. Umi Kalthum Ngah

Dr. Zeehaida Mohamed

Dr. Kamal Zuhairi Zamli

Noorhidayati Abu Seman

2008

LAMPIRAN A

ABSTRAK

PEMBINAAN SISTEM PENYARINGAN PINTAR ELEKTRONIK UNTUK PARASIT MALARIA

Abstrak

Penyelidikan ini mencadangkan pengaplikasian rangkaian neural buatan untuk mengkelas parasit malaria kepada tiga jenis iaitu *Plasmodium falciparum*, *Plasmodium vivax* dan *Plasmodium malariae*. Enam ciri-ciri parasit malaria (i.e. saiz sel darah merah (RBC) yang dijangkiti per saiz RBC normal, bentuk parasit, bilangan kromatin, bilangan parasit per RBC, tekstur RBC dan lokasi kromatin parasit) digunakan sebagai data masukan. Dalam usaha menentukan keupayan rangkaian neural sebagai pengkelas pintar, dua jenis rangkaian neural iaitu multilayered perceptron (MLP) dan hybrid multilayered perceptron (HMLP) digunakan.

Penyelidikan ini telah berjaya membina satu sistem pintar untuk pengkelasan parasit malaria. Sistem yang dibina mempunyai dua komponen. Komponen pertama ialah sistem pengekstrakan ciri pintar yang digunakan untuk mengekstrak enam jenis ciri parasit malaria. Ciri-ciri ini kemudiannya akan dimasukkan sebagai data masukan kepada komponen kedua yang dinamakan sistem pengkelasan pintar. Penyelidikan ini telah berjaya menggunakan rangkaian HMLP yang dilatih menggunakan MRPE untuk melaksanakan proses pengkelasan. Sistem yang dibina mampu menghasilkan sehingga 90% dan 89.50% kejituan pengkelasan masing-masing pada fasa latihan dan ujian. Maka, sistem yang dibina mempunyai potensi yang baik untuk diketengahkan sebagai alat penyaringan untuk pengenalpastian parasit malaria dalam darah manusia.

DEVELOPMENT OF AN ELECTRONIC INTELLIGENT SCREENING SYSTEM FOR MALARIA PARASITE


Abstract

This research proposes an application of artificial neural networks to classify the malaria parasite into three species, namely *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*. Six features (i.e. size of red blood cell (RBC) infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite) from thin blood smear are used as input data. In order to determine the suitability of the artificial neural networks as intelligent classifier, two types of neural networks, i.e. multilayered perceptron (MLP) and hybrid multilayered perceptron (HMLP) are used.

This research has successfully developed an intelligent system for classification of malaria parasite. The system consists of two main components. The first component, namely an intelligent feature extraction system is developed to extract aforementioned six features of malaria parasite from thin blood smear image. These features will then be fed into the second component of the system called an automatic classification system. This research has successfully employed the HMLP network trained with the MRPE training algorithm to perform the classification process. The system is capable to produce the accuracy of classification up to 90% and 89.50% accuracy in the training and testing phase respectively. Thus, the developed system has great potential to be used as mass-screening tool for malaria parasite determination.

LAMPIRAN B

LAPORAN TEKNIKAL



LAPORAN TEKNIKAL GERAN JANGKA PENDEK

PEMBINAAN SISTEM PENYARINGAN PINTAR ELEKTRONIK UNTUK PARASIT MALARIA (*DEVELOPMENT OF AN ELECTRONIC INTELLIGENT SCREENING SYSTEM FOR MALARIA PARASITE*)

KETUA PENYELIDIK:

Dr Nor Ashidi Mat Isa

PENYELIDIK-PENYELIDIK BERSAMA:

Prof. Madya Dr Umi Kalthum Ngah

Dr Zeehaida Mohamed

Dr Kamal Zuhairi Zamli

Noorhidayati Abu Seman

**School of Electrical & Electronic Engineering
and School of Biological Sciences,
Universiti Sains Malaysia**

KANDUNGAN

Muka Surat

KANDUNGAN		i
ABSTRAK		iv
ABSTRACT		v
BAB 1	PENGENALAN	
1.1	Pengenalan	1
1.2	Penggunaan Rangkaian Neural dalam Menentukan Jenis Parasit Malaria	1
1.3	Objektif dan Skop Penyelidikan	2
BAB 2	KAJIAN ILMIAH	
2.1	Pengenalan	4
2.2	Jenis Parasit Malaria	4
2.2.1	Parasit Plamodium Falciparum	5
2.2.2	Parasit Plamodium Vivax	6
2.2.3	Parasit Plamodium Ovale	8
2.2.4	Parasit Plamodium Malariae	9
2.3	Rangkaian Neural	10
2.3.1	Rangkaian Neuron Biologi	11
2.3.2	Rangkaian Neural Buatan	12
2.3.2.1	Pemodelan Neuron	13

2.3.2.2	Seni Bina	15
2.3.2.3	Proses Pembelajaran	20
2.3.3	Prestasi Rangkaian Neural Buatan	26
2.3.4	Aplikasi Rangkaian Neural Buatan	30
2.3.4.1	Aplikasi di Dalam Bidang Perubatan	32
2.4	Ringkasan	35

BAB 3 PENENTUAN JENIS PARASIT MALARIA MENGGUNAKAN RANGKAIAN NEURAL

3.1	Pengenalan	37
3.2	Sistem Penangkapan Imej Palitan Darah Secara Automatik	39
3.3	Rangkaian Perseptron Berbilang Lapisan Hibrid	39
3.3.1	Seni Bina dan Ciri-ciri Rangkaian	40
3.3.2	Pemberat Sambungan Rangkaian	43
3.4	Metodologi dan Sampel Data	48
3.5	Kesimpulan	49

BAB 4 KEPUTUSAN DAN PERBINCANGAN

4.1	Pengenalan	50
4.2	Keputusan	50
4.2.1	Sistem Penangkapan Imej Parasit Malaria Secara Automatik	50

4.2.2	Sistem Pengkelasan Parasit	
	Malaria Secara Automatik	52
4.3	Perbincangan	55
4.4	Kesimpulan	57
BAB 5	KESIMPULAN	
5.1	Kesimpulan	59
RUJUKAN		62

PEMBINAAN SISTEM PENYARINGAN PINTAR ELEKTRONIK UNTUK PARASIT MALARIA

Abstrak

Penyelidikan ini mencadangkan pengaplikasian rangkaian neural buatan untuk mengkelas parasit malaria kepada tiga jenis iaitu *Plasmodium falciparum*, *Plasmodium vivax* dan *Plasmodium malariae*. Enam ciri-ciri parasit malaria (i.e. saiz sel darah merah (RBC) yang dijangkiti per saiz RBC normal, bentuk parasit, bilangan kromatin, bilangan parasit per RBC, tekstur RBC dan lokasi kromatin parasit) digunakan sebagai data masukan. Dalam usaha menentukan keupayan rangkaian neural sebagai pengkelas pintar, dua jenis rangkaian neural iaitu multilayered perceptron (MLP) dan hybrid multilayered perceptron (HMLP) digunakan.

Penyelidikan ini telah berjaya membina satu sistem pintar untuk pengkelasan parasit malaria. Sistem yang dibina mempunyai dua komponen. Komponen pertama ialah sistem pengestrakan ciri pintar yang digunakan untuk mengekstrak enam jenis ciri parasit malaria. Ciri-ciri ini kemudiannya akan dimasukkan sebagai data masukan kepada komponen kedua yang dinamakan sistem pengkelasan pintar. Penyelidikan ini telah berjaya menggunakan rangkaian HMLP yang dilatih menggunakan MRPE untuk melaksanakan proses pengkelasan. Sistem yang dibina mampu menghasilkan sehingga 90% dan 89.50% kejituan pengkelasan masing-masing pada fasa latihan dan ujian. Maka, sistem yang dibina mempunyai potensi yang baik untuk diketengahkan sebagai alat penyaringan untuk pengenalpastian parasit malaria dalam darah manusia.

DEVELOPMENT OF AN ELECTRONIC INTELLIGENT SCREENING SYSTEM FOR MALARIA PARASITE

Abstract

This research proposes an application of artificial neural networks to classify the malaria parasite into three species, namely *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*. Six features (i.e. size of red blood cell (RBC) infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite) from thin blood smear are used as input data. In order to determine the suitability of the artificial neural networks as intelligent classifier, two types of neural networks, i.e. multilayered perceptron (MLP) and hybrid multilayered perceptron (HMLP) are used.

This research has successfully developed an intelligent system for classification of malaria parasite. The system consists of two main components. The first component, namely an intelligent feature extraction system is developed to extract aforementioned six features of malaria parasite from thin blood smear image. These features will then be fed into the second component of the system called an automatic classification system. This research has successfully employed the HMLP network trained with the MRPE training algorithm to perform the classification process. The system is capable to produce the accuracy of classification up to 90% and 89.50% accuracy in the training and testing phase respectively. Thus, the developed system has great potential to be used as mass-screening tool for malaria parasite determination.

BAB 1

PENGENALAN

1.1 Pengenalan kepada klasifikasi Parasit Malaria

Malaria merupakan penyakit berjangkit bawaan vektor yang disebabkan oleh parasit protozoa dari genus Plasmodium. Bentuk penyakit yang paling serius adalah disebabkan oleh parasit plasmodium falciparum dan parasit plasmodium vivax, tetapi spesies berkait yang lain seperti parasit plasmodium ovale dan parasit plasmodium malariae turut mampu menjangkiti manusia. Kumpulan pathogenic spesies plasmodium ini dirujuk sebagai parasit malaria. Pada masa kini, terdapat dua cara yang digunakan bagi mengenalpasti parasit malaria iaitu “thick blood smear” dan “thin blood smear”. “thick blood smear” digunakan untuk menentukan kadar ketumpatan parasit malaria per mikroliter sel darah merah manakala “thin blood smear” digunakan untuk mengenalpasti identiti spesies parasit malaria.

1.2 Penggunaan Rangkaian Neural dalam menentukan Jenis Parasit Malaria.

Kecerdikan buatan menjadi satu kaedah pemodelan yang sangat popular bagi menyelesaikan masalah-masalah yang kompleks. Salah satu cabang daripada kecerdikan buatan yang sering digunakan ialah rangkaian neural. Terdapat banyak aplikasi-aplikasi pemodelan rangkaian neural dalam bidang perubatan dan salah satunya adalah untuk mengesan parasit malaria. Penambahbaikan terhadap model rangkaian neural juga telah dilakukan dengan membangunkan satu rangkaian neural separa pengulangan (recurrent neural network) berdasarkan siri-siri masa (time series).

Jayavanth dan Singh [1] bekerjasama dalam menggunakan rangkaian neural untuk menganalisis kekuatan malaria melalui pengagregatan dan kebolehcanggaan erythrocytes. Keputusan daripada kajian menunjukkan malaria dengan kekuatan yang tinggi telah berjaya dikelaskan dengan 100% ketepatan dan bagi kes malaria yang mempunyai kekuatan yang kurang, julat antara 60% ke 80% telah berjaya dikelaskan. Gao et. al [2] telah membuktikan rangkaian neural sesuai untuk digunakan dalam meramal jenis parasit malaria. Hasil dari kajian juga mendapati rangkaian neural banyak memberikan kelebihan dan keupayaan untuk dianalisis, dapat mengurangkan data dan mudah untuk di aplikasi. Rangkaian neural juga digunakan untuk meramal kedudukan subsele protein di dalam sel prokaryotic atau eukaryotic daripada komposisi asid amino [3]. Antara kegunaan lain rangkaian neural adalah meramal mitochondrial transit peptides (mTPs) daripada Malaria yang disebabkan oleh kewujudan parasit plasmodium falciparum, Bender et. al [4].

1.3 Objektif dan skop Penyelidikan.

Objektif utama dalam penyelidikan ini adalah untuk membangunkan sistem pintar bagi mengklasifikasikan jenis parasit malaria. Sistem pintar ini akan melakukan ramalan berdasarkan sampel data yang diperolehi dari Jabatan Mikrobiologi, Hospital Universiti Sains Malaysia.

Penyelidikan ini mencadangkan penggunaan rangkaian perseptron berbilang lapisan (Multilayered Perceptron, MLP) dan perseptron berbilang lapisan hibrid (Hybrid Multilayered Perceptron, HMLP) dalam menentukan jenis parasit malaria. Rangkaian MLP ini akan dilatih oleh algoritma perambatan balik (back propagation, BP), algoritma

Lavenberg Marquardt (LM) dan algoritma Bayesian Regularization (BR). Rangkaian MLP terubahsuai yang mempunyai beberapa sambungan lurus tambahan yang dikenali sebagai rangkaian perseptron berbilang lapisan hibrid (Hybrid Multilayered Perceptron, HMLP) dicadangkan dalam kajian ini mampu memberikan kejutuan yang lebih tinggi berbanding rangkaian MLP. Disamping itu juga, rangkaian HMLP mampu mengurangkan saiz rangkaian yang dibentuk oleh rangkaian MLP, Mashor,2004 [5].

Secara umumnya , penyelidikan ini mempunyai beberapa objektif iaitu:

- (1) Membina satu sistem penangkapan imej automatik bagi parasit malaria daripada imej palitan darah.
- (2) Mengklasifikasikan jenis parasit malaria kepada tiga jenis spesis iaitu Parasit Plasmodium falciparum, parasit Plasmodium vivax dan parasit Plasmodium malariae.
- (3) Menganalisis 6 ciri (saiz darah merah yang dijangkiti per saiz darah merah normal, bentuk parasit, bilangan chromatin, bilangan parasit didalam sel darah merah, tekstur sel darah merah dan kedudukan chromatin bagi parasit) dari “thin blood smear” sebagai parameter masukan kepada rangkaian neural.
- (4) Melakukan analisis kepada 600 sel parasit malaria untuk mengklasifikasikan menggunakan rangkaian HMLP.
- (5) Membina satu sistem pintar yang dapat mengklasifikasikan jenis parasit malaria.

BAB 2

KAJIAN ILMIAH

2.1 Pengenalan

Malaria adalah antara penyakit yang disebabkan oleh parasit protozoa dan merupakan punca utama kematian di dunia. Dianggarkan lebih kurang 300 - 500 juta kes dilaporkan dan 1.5 hingga 2.7 juta kematian di seluruh dunia [6]. Malaria merupakan penyakit berjangkit bawaan vektor yang disebabkan oleh parasit protozoa dari genus *Plasmodium*. Terdapat empat spesis genus *Plasmodium* iaitu *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium ovale* dan *Plasmodium malariae* [7]. *Plasmodium* ini dirujuk sebagai parasit malaria di dalam tubuh manusia. Parasit Malaria ini disebar oleh nyamuk *Anopheles* [6]. Pada dasarnya malaria adalah infeksi pada sel-sel darah merah yang menyebabkan demam berulang dengan tiba-tiba. Malaria yang disebabkan oleh *Plasmodium falciparum* sangat berbahaya dan dapat menyebabkan kerosakan pelbagai organ tubuh, koma dan kematian.

2.2 Jenis Parasit Malaria

Plasmodium merupakan genus protozoa parasit. Jangkitan yang disebabkan oleh genus ini dikenali sebagai malaria. Parasit ini sentiasa mempunyai dua hos dalam kitaran hidupnya, vektor nyamuk dan hos vertebrata. Antara *Plasmodium* yang dirujuk sebagai parasit malaria di dalam tubuh manusia adalah *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium ovale* dan *Plasmodium malariae*.

2.2.1 Parasit Plasmodium falciparum

Penyakit malaria yang disebabkan oleh spesies ini juga disebut “Malaria Tertiana Maligna” dan merupakan penyakit malaria yang paling ganas yang menyerang manusia. Daerah penyebaran malaria ini adalah daerah tropika dan sub tropika dan kadang kala ke daerah yang lebih luas walaupun sudah mula dapat dibanteras di Amerika Syarikat dan sekitar Mediterranean. Malaria falciparum adalah pembunuh terbesar manusia di daerah tropika seluruh dunia dan sekitar 50% penderita malaria ini tidak dapat diubati.


Seperti malaria lainnya, schizont exoerythrocytic dari Plasmodium falciparum terjadi dalam sel hati. Schizont mula merebak pada hari ke 5 dan mengeluarkan 30000 merozoit. Disini tidak terjadi exoerythrocytic fasa ke 2 dan tidak terjadi relaps. Penyakit akan timbul sekitar 1 tahun, dan biasanya 2 – 3 tahun kemudian setelah infeksi pertama. Hal ini disebabkan oleh jumlah populasi parasit yang sedikit dalam sel darah merah.

Merozoit menyerang sel darah merah pada semua peringkat umur. Plasmodium falciparum juga dapat meningkatkan parasitemianya lebih tinggi jika dibandingkan dengan malaria lainnya. Sel darah merah mengandungi parasit seterusnya akan bertemu didalam jaringan yang paling dalam seperti limpa dan sum-sum tulang pada masa schizogony. Pada waktu gametocyt berkembang, sel darah merah tersebut akan bergerak menuju sirkulasi darah perifer dan biasanya kelihatan seperti bentuk cincin.

Trophozoit berbentuk cincin adalah yang paling kecil diantara parasit malaria lainnya yang menyerang manusia. Trophozoit membiak dan mulai bergerak dengan

pseudopodi dan pergerakannya tidak seaktif Plasmodium vivax. Erythrocyt yang terinfeksi berkembang menjadi tidak sekata dan lebih besar daripada Plasmodium vivax sehingga menyebabkan sel hospes.

Schizont yang matang berkembang menjadi 8-32 merozoit dan pada umumnya 16 merozoit. Pertemuan schizont ke darah periferer mengambil masa sekitar 48 jam dan dalam keadaan yang berat, saat terjadinya parasitemia, iaitu pada kepadatan 25% boleh menyebabkan kematian. Imej palitan darah yang mengandungi parasit Plasmodium falciparum dipaparkan seperti rajah 2.1.



Rajah 2.1: Palitan darah yang mengandungi Parasit Plasmodium falciparum

2.2.2 Parasit Plasmodium vivax


Spesis plasmodium ini menyebabkan penyakit "Malaria Tertiana Benigna" atau disebut malaria tertian. Nama tertian adalah berdasarkan fakta bahawa timbulnya gejala demam terjadi setiap 48 jam. Penyakit ini banyak terjadi di daerah tropika dan sub tropika, dan 43% penyakit malaria adalah disebabkan oleh Plasmodium vivax. Proses schizogony exoerythrocytic dapat terus terjadi sehingga 8 tahun dan disertai dengan kitaran relaps.

Plasmodium vivax hanya menyerang erythrocyt (reticulocyt) dan tidak berupaya menyerang erythrocyt yang matang. Setelah menyerang ke dalam erythrocyt, ia akan berbentuk cincin. Cytoplasma menjadi aktif seperti ameba dan membentuk pseudopodia yang bergerak ke semua arah yang disebut "vivax". Infeksi terhadap erythrocyt lebih dari satu trophozoit dapat terjadi, tetapi jarang. Pada saat trophozoit berkembang, erythrocyt membesar, pigmennya berkurang dan berkembang menjadi peculiar stipling yang disebut "Schuffners dot". Dot (titik) tersebut akan kelihatan apabila diwarnai dan akan kelihatan parasit didalamnya. Cincin yang menempatkan $1/3 - 1/2$ dari erythrocyt dan trophozoit akan menempatkan $2/3$ dari sel darah merah tersebut dalam masa 24 jam. Granula hemozin mulai terakumulasi sesuai dengan pembelahan nukleus dan berulang sehingga 4 kali, terdapat 16 nukleus pada schizont yang matang. Apabila terjadi immunisasi atau diobati secara chemotherapy, hanya sedikit sahaja nukleus yang dapat dihasilkan. Proses schizogony dimulai dengan granula pigmen yang terakumulasi didalam parasit. Merozoit seterusnya menyerang erythrocyt lainnya dan pembentukan Schizogony dalam erythrocyt memakan masa 48 jam.

Beberapa merozoit berkembang menjadi gametocyt, dan gametocyt yang matang akan mengisi sebahagian besar erythrocyt yang membesar. Gametocyt memerlukan 4 hari untuk matang. Perbandingan antara makro microgametocyt adalah 2:1, dan salah satu sel darah kadang-kala diisi oleh kedua-duanya (macro dan micro) dan schizont.

Dalam nyamuk terjadi proses pembentukan zigot, ookinete dan oocyt dengan ukuran 50 um dan menghasilkan 10000 sporozoit. Terlalu banyak oocyst dapat membunuh nyamuk itu sendiri sebelum oocyt berkembang menjadi sporozoit. Imej

palitan darah yang mengandungi parasit Plasmodium vivax dipaparkan seperti rajah 2.2.




Rajah 2.2: Palitan darah yang mengandungi Parasit Plasmodium vivax

2.2.3 Parasit Plasmodium ovale

Penyakit yang disebabkan infeksi parasit ini disebut “Malaria Tertiana Ringan” dan merupakan parasit malaria yang paling jarang pada manusia. Biasanya penyakit malaria ini tersebar di daerah tropika, tetapi telah dilaporkan merebak ke daerah Amerika Syarikat dan Eropah. Penyakit ini banyak dilaporkan di daerah pantai Barat Afrika yang merupakan lokasi asal kejadian, penyakit ini kemudiannya berkembang ke daerah Afrika Tengah dan sedikit di Afrika Timur. Plasmodium ovale sukar di diagnosis kerana mempunyai persamaan dengan Plasmodium. vivax.

Schizont yang matang berbentuk oval dan mengisi separuh dari sel darah hospes. Biasanya akan terbentuk 8 merozoit, dengan kitaran antara 4 hingga 16. Bentuk titik (dot) terlihat pada awal infeksi didalam sel darah merah. Bentuknya lebih besar daripada Plasmodium vivax dan apabila diwarnai, akan kelihatan warna merah terang.

Gametocyt dari Plasmodium ovale memerlukan masa yang lebih panjang untuk meresap kedalam darah perifer daripada malaria lainnya. Tetapi ia cepat dan dapat menginfeksi nyamuk secara teratur dalam waktu 3 minggu setelah infeksi. Imej palitan darah yang mengandung parasit Plasmodium ovale dipaparkan seperti rajah 2.3.



Rajah 2.3: Palitan darah yang mengandungi Parasit Plasmodium ovale


2.2.4 Parasit Plasmodium Malariae

Infeksi parasit Plasmodium Malariae juga disebut “Malaria Quartana” dengan terjadinya krisis penyakit setiap 72 jam. Plasmodium malariae adalah parasit kosmopolitan, tetapi penyebarannya tidak berulang di setiap lokasi. Parasit ini sering di temui di daerah tropika Afrika, Myanmar, India, SriLanka, Malaysia, Jawa dan Eropah. Juga tersebar di daerah baru seperti Jamaica, Guadalope, Brazil, Panama dan Amerika Syarikat.

Schizogony exoerythrocytic terjadi dalam masa 13 hingga 16 hari, dan relaps terjadi sehingga 53 tahun. Bentuk erythrocytic berkembang secara perlahan-lahan dan parasit dapat ditemui didalam sel darah. Bentuk cincin yang pipih dapat bertahan

sehingga 48 jam, yang akhirnya berubah bentuk memanjang menjadi bentuk “band” yang mengumpulkan pigmen disekitarnya. Nukleus akan terbelah menjadi 6 hingga 12 merozoit dalam masa 72 jam. Peningkatan parasitemianya rendah yaitu sekitar 1 parasit setiap 20000 sel darah.

Gametocyt berkemungkinan berkembang dalam organ dalaman, bentuk matangnya jarang ditemukan dalam darah perifer. Ia berkembang sangat perlahan untuk menjadi sporozoit infeksi. Imej palitan darah yang mengandungi parasit *Plasmodium malariae* dipaparkan seperti rajah 2.4.



Rajah 2.4:Palitan darah yang mengadungi Parasit *Plasmodium Malariae*

2.3Rangkaian Neural

Bidang kecerdikan buatan telah memainkan peranan yang penting di dalam meningkatkan taraf hidup manusia kini. Pelbagai teknik kecerdikan buatan telah dibina untuk membolehkan komputer menjalankan fungsi-fungsi manusia seperti pengecaman corak, peramalan data dan diagnosis penyakit. Kecerdikan buatan yang sering diaplikasikan bagi menggantikan fungsi pemikiran manusia ialah rangkaian neural

buatan. Konsep pengoperasian rangkaian neural buatan boleh dianalogikan kepada konsep pemikiran otak manusia. Pembinaan struktur atau seni bina, proses pembelajaran dan teknik pengoperasiannya adalah berdasarkan kepada rangkaian neural biologi tersebut.


2.3.1 Rangkaian Neuron Biologi

Neuron merupakan unit struktur dan fungsi asas sistem saraf manusia. Fungsi neuron adalah sebagai pemproses dan penerima informasi atau isyarat masukan dari penerima pancaindera atau neuron lain dan menghantar informasi tersebut kepada organ pengesan atau neuron yang lain pula. Neuron terdiri daripada nukleus, sel badan, dendrit, akson dan sinaps seperti yang ditunjukkan di dalam Rajah 2.5 (Crossman & Neary, 1995).

Setiap neuron mempunyai satu badan sel yang mempunyai banyak cabang yang wujud daripadanya. Cabang-cabang ini dinamakan dendrit. Dendrit ini berfungsi untuk menerima informasi dari neuron lain melalui akson. Akson pula berperanan untuk menghantar informasi daripada badan sel pada satu neuron kepada neuron yang lain.

Setiap neuron bersambung dengan neuron yang lain melalui satu ruang kecil yang wujud di antara dendrit dan akson yang dinamakan ruang sinaps. Perhubungan di antara dua neuron untuk proses penghantaran dan penerimaan informasi berlaku pada ruang sinaps ini. Setiap informasi dikodkan berdasarkan perubahan isyarat elektrik. Apabila isyarat elektrik ini melepasi had atau nilai ambang tertentu yang ditentukan pada setiap sinaps, sinaps tersebut akan dirangsangkan. Ini akan membenarkan penghantaran dan penerimaan informasi di antara dua neuron. Manakala isyarat

elektrik yang kurang daripada nilai ambang ini akan merencat sinaps tersebut dan menghalang perhubungan di antara dua neuron.



Rajah 2.5: Gambarajah neuron biologi.

2.3.2 Rangkaian Neural Buatan

Pada dasarnya, rangkaian neural atau juga dipanggil model bersambungan (*connectionist model*) mengandungi satu set unit pengiraan (juga dipanggil sel) dan satu set sambungan data satu arah yang menyambungkan unit-unit tersebut (Gallant, 1995). Norgaard *et al.* (2000) pula menakrifkan rangkaian neural sebagai satu sistem yang mengandungi elemen-elemen pemprosesan mudah dipanggil neuron yang disambungkan di antara satu sama lain di dalam satu rangkaian oleh satu set pemberat (sinaps). Haykin (1994) menakrifkan rangkaian neural sebagai pemproses teragih selari besar yang mempunyai satu kecenderungan semulajadi untuk penyimpanan pengetahuan berpengalaman dan menggunakannya. Ia menyerupai otak manusia berdasarkan dua perkara berikut:

1. Pengetahuan diperoleh oleh rangkaian melalui proses pembelajaran.
2. Kekuatan sambungan di antara neuron yang dikenali sebagai pemberat sinaps digunakan untuk menyimpan pengetahuan.

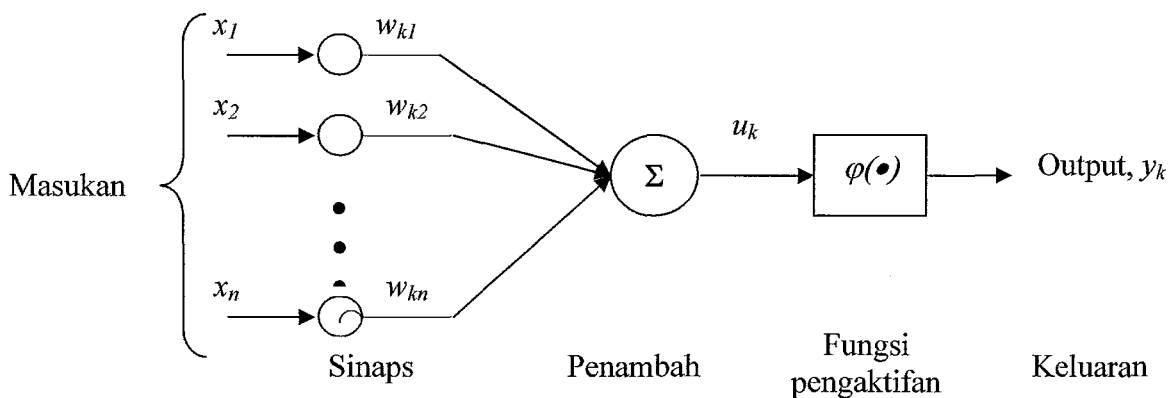
Amnya, seperti rangkaian neural biologi, rangkaian neural buatan merupakan satu sistem yang terdiri daripada neuron-neuron yang disambungkan di antara satu sama lain. Pada sistem ini, beberapa neuron akan bertindak sebagai neuron masukan yang akan menerima informasi atau data masukan. Data ini akan dihantar kepada neuron-neuron perantara untuk diproses. Neuron-neuron perantara ini akan menjadi perantaraan di antara neuron-neuron masukan dan keluaran. Setiap neuron tersebut akan disambungkan di antara satu sama lain melalui satu sambungan berpemberat. Sambungan ini diibaratkan sebagai sinaps yang membenar atau menghalang perhubungan di antara dua neuron. Kemudian, data yang telah diproses akan dihantar kepada neuron-neuron keluaran sebagai keluaran kepada rangkaian neural tersebut. Pada keseluruhannya, fungsi dan prestasi rangkaian neural buatan ini bergantung kepada pemodelan neuron, seni bina rangkaian dan proses pembelajaran rangkaian neural tersebut.

2.3.2.1 Pemodelan Neuron

Asas pemodelan neuron rangkaian neural buatan adalah berdasarkan pemodelan neuron McCulloch-Pitts (Luger & Stubblefield, 1998, Haykin, 1994, Chester, 1993). Neuron adalah unit pemrosesan informasi bagi satu rangkaian neural buatan. Sebagai satu elemen asas, operasi yang dilakukan di dalam neuron tersebut akan menentukan fungsi dan jenis pengoperasian sesuatu rangkaian neural. Pemodelan bagi

neuron ini adalah seperti yang ditunjukkan di dalam Rajah 2.5 (Gallant, 1995, Haykin, 1994, Winston, 1992).

Berdasarkan kepada Rajah 2.6, terdapat tiga komponen asas yang membentuk neuron iaitu satu set sinaps atau sambungan rangkaian, satu penambah dan satu fungsi pengaktifan. Setiap sinaps pada sesuatu neuron akan dicirikan dengan satu nilai pemberat. Andaikan neuron k yang dianalisa mempunyai n sinaps atau data masukan. Data atau signal x_j pada masukan sinaps ke- j yang disambungkan pada neuron k akan didarabkan dengan nilai pemberat sinaps ke- j tersebut, w_{kj} . Konsep pendaraban ini menunjukkan kepentingan dan pengaruh nilai pemberat sinaps kepada keluaran pemprosesan bagi sesuatu neuron. Penambah pula berfungsi untuk menambah semua signal atau data x_j yang telah diberatkan atau didarabkan dengan pemberat sinaps masing-masing. Operasi penambahan ini melibatkan penggabung linear atau lurus. Hasil tambah nilai-nilai tersebut akan dihantar kepada fungsi pengaktifan.



Rajah 2.6: Pemodelan neuron tak lurus

Pemodelan neuron secara matematik berdasarkan Rajah 2.6 boleh ditakrifkan berdasarkan dua persamaan berikut:

$$u_k = \sum_{j=1}^n w_{kj} x_j \tag{2.1}$$

dan

$$y_k = \varphi(u_k) \quad (2.2)$$


Berdasarkan Persamaan (2.1) dan (2.2), u_k adalah keluaran penambah, x_j adalah data atau signal masukan pada sinaps ke- j , w_{kj} adalah pemberat sinaps ke- j untuk neuron k dan $\varphi(\bullet)$ adalah fungsi pengaktifan. Manakala, y_k dan n masing-masing adalah keluaran bagi neuron k dan bilangan masukan atau sinaps. Terdapat beberapa jenis fungsi pengaktifan yang sering digunakan iaitu fungsi penghad tetap (*hard limiter*), fungsi lurus sesecebis (*piecewise linear function*), fungsi sigmoid dan fungsi lurus (Nauck *et al.*, 1997, Haykin, 1994).

2.3.2.2 Seni Bina

Terdapat pelbagai jenis rangkaian neural buatan yang dibina. Rangkaian neural buatan ini dibezakan di antara satu sama lain oleh seni bina dan teknik atau algoritma pembelajarannya (Welstead, 1994). Pemilihan seni bina rangkaian neural buatan yang sesuai untuk sesuatu aplikasi tertentu penting untuk menentukan kecekapan rangkaian neural tersebut. Kriteria utama bagi membezakan seni bina satu rangkaian neural dengan rangkaian neural yang lain ialah kaedah penyambungan neuron-neuron di antara lapisan di dalam rangkaian tersebut. Secara amnya, seni bina rangkaian neural dibahagikan kepada dua jenis yang utama iaitu rangkaian neural suap depan (*feedforward neural network*) dan rangkaian neural suap balik (*feedback neural network*) (Norgaard *et al.*, 2000, Gallant, 1995, Haykin, 1994).

Rangkaian Neural Suap Depan

Seni bina bagi rangkaian neural suap depan adalah seperti yang ditunjukkan di dalam Rajah 2.7. Kebiasaannya, asas pembinaan rangkaian neural suap depan konvensional adalah terdiri daripada tiga lapisan utama iaitu lapisan masukan, tersembunyi dan keluaran. Lapisan tersembunyi ini bertindak sebagai perantaraan di antara lapisan masukan dan lapisan keluaran. Terdapat seni bina rangkaian neural suap depan yang mempunyai lebih daripada satu lapisan tersembunyi. Penambahan lebih daripada satu lapisan tersembunyi akan menyebabkan rangkaian neural berupaya mengekstrak statistik sesuatu data pada peringkat yang lebih tinggi (Churchland & Sejnowski, 1992). Keupayaan mengekstrak statistik pada peringkat tinggi ini amat penting apabila saiz masukan adalah besar.




Rajah 2.7: Rangkaian neural suap depan.

Seni bina rangkaian neural suap depan hanya membenarkan setiap neuron menerima data masukan daripada neuron pada lapisan terdahulu sahaja. Terdapat dua kaedah penyambungan di antara neuron pada rangkaian neural suap depan iaitu rangkaian neural dengan sambungan penuh (*fully connected*) dan sambungan separa

(partially connected). Rajah 2.7 dan 2.8 masing-masing menunjukkan rangkaian neural dengan sambungan penuh dan separa. Pada rangkaian yang dibina secara sambungan penuh, setiap neuron pada setiap lapisan akan disambungkan kepada setiap neuron pada lapisan berikutnya seperti yang ditunjukkan di dalam Rajah 2.7. Kaedah penyambungan ini menyebabkan keluaran setiap neuron pada setiap lapisan akan dijadikan data masukan untuk setiap neuron pada lapisan berikutnya. Penyambungan ini mengandaikan semua neuron pada lapisan terdahulu mempengaruhi aktiviti setiap neuron pada lapisan berikutnya.

Walaupun bagaimanapun, terdapat neuron pada satu lapisan yang tidak atau terlalu sedikit memberikan pengaruh terhadap aktiviti neuron pada lapisan berikutnya. Pengekalan sambungan di antara dua neuron ini akan menambahkan kekompleksan rangkaian neural yang dibina. Maka, penyingkiran sambungan di antara dua neuron tersebut seharusnya dilakukan untuk mewujudkan rangkaian neural yang lebih ringkas. Fenomena ini akan mewujudkan satu rangkaian neural dengan kaedah sambungan separa seperti yang ditunjukkan di dalam Rajah 2.8. Berdasarkan kepada Rajah 2.8, terdapat neuron pada satu lapisan yang tidak disambungkan kepada neuron pada lapisan berikutnya.



Rajah 2.8: Rangkaian neural suap depan dengan sambungan separa


Salah satu ciri penting rangkaian neural buatan suap depan untuk diaplikasikan di dalam penyelidikan ini sebagai sistem diagnosis barah pangkal rahim ialah keupayaannya untuk mengenalpasti kenalaran (*regularity*) sesuatu data (Winston, 1992). Ini bermaksud rangkaian tersebut berupaya untuk mengenalpasti ciri-ciri statistik data masukan yang dipunyai oleh sesuatu data keluaran tertentu. Dua rangkaian suap depan yang sering diaplikasikan dewasa ini ialah rangkaian MLP dan RBF.

Rangkaian Neural Suap Balik

Seni bina rangkaian neural suap balik berbeza daripada rangkaian neural suap depan dari segi penambahan sekurang-kurangnya satu gelung suap balik seperti yang ditunjukkan di dalam Rajah 2.9 bagi rangkaian yang mempunyai tiga neuron masukan, dua neuron tersembunyi dan satu neuron keluaran. Berdasarkan kepada Rajah 2.9, keluaran pada neuron keluaran dan neuron tersembunyi disuap balik kepada neuron masukan sebagai data-data masukan yang baru. Selain itu, keluaran pada neuron keluaran juga boleh disuap balik kepada neuron tersembunyi. Terdapat satu lagi jenis suap balik yang boleh dilakukan iaitu suap balik sendiri seperti yang diwakili oleh garisan putus-putus di dalam Rajah 2.9. Keluaran pada setiap neuron akan disuap balik sebagai masukannya.

Berdasarkan kepada seni bina di antara kedua-dua jenis rangkaian neural ini, didapati rangkaian neural suap depan lebih pantas proses pembelajarannya berbanding rangkaian neural suap balik. Ini disebabkan oleh keupayaan rangkaian neural suap depan untuk memodelkan sesuatu sistem dengan satu laluan ke hadapan sahaja tanpa perlu menyuap-balik sebarang keluaran (Nelson & Illingworth, 1992). Selain itu,

rangkaian neural suap depan juga mempunyai kelebihan dari segi keupayaan mencapai kestabilan rangkaian yang lebih baik berbanding rangkaian neural suap balik. Rangkaian neural suap balik perlu melalui beberapa ulangan proses untuk mencapai kestabilan dan pengulangan proses ini tidak menjamin kestabilan rangkaian sepenuhnya. Rangkaian tersebut berkemungkinan untuk berosilasi di antara nilai-nilai parameter yang dikemaskini yang menghalangnya daripada mencapai kestabilan. Walaubagaimanapun, rangkaian ini mempunyai kelebihan dari segi keupayaannya untuk menyediakan keadaan tak lurus di dalam satu rangkaian lurus. Selain itu, rangkaian neural suap balik juga memberikan kebolehsuaian (*adaptability*) dan kebolehlatihan (*trainability*) yang lebih baik berbanding rangkaian neural suap depan. Kebolehsuaian adalah keupayaan keseluruhan rangkaian neural untuk mengemaskini rangkaiannya dengan sendiri manakala kebolehlatihan merujuk kepada keupayaan rangkaian tersebut dilatih untuk memenuhi sesuatu keluaran. Dua contoh rangkaian neural suap balik yang sering digunakan ialah rangkaian teori resonans adaptif (*adaptive resonance theory, ART*) dan Hopfield.



Rajah 2.9: Rangkaian neural suap balik.

2.3.2.3 Proses Pembelajaran

Proses pembelajaran memainkan peranan yang penting untuk memastikan rangkaian neural berkeupayaan untuk berfungsi seperti rangkaian neural biologi. Proses pembelajaran adalah sebagai satu prosedur yang diimplementasikan kepada rangkaian neural untuk mengubah nilai parameter-parameter rangkaian neural. Terdapat dua fasa yang perlu dilalui oleh setiap rangkaian neural iaitu fasa pembelajaran (*learning phase*) atau fasa latihan (*training phase*) dan fasa dapat-kembali (*retrieving phase*) atau fasa ujian (*testing phase*) (Kung, 1993).

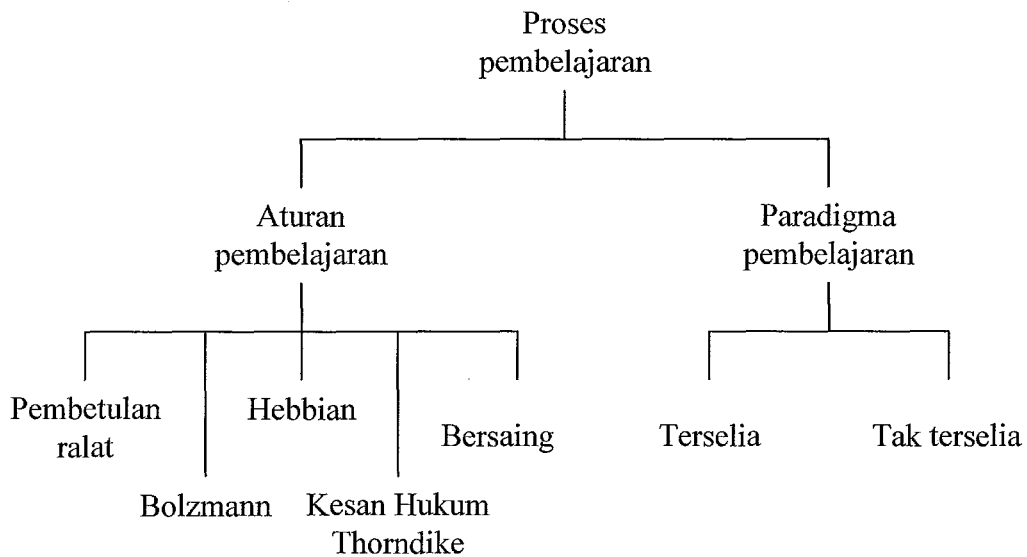
Pada fasa latihan, rangkaian neural akan dimasukkan dengan satu set data latihan yang digunakan oleh rangkaian neural tersebut untuk belajar ciri-ciri statistik data masukan dan mewakili keseluruhan data tersebut. Ciri-ciri statistik ini adalah seperti corak perubahan data keseluruhan, corak pengelompokan data dan sebagainya. Proses pembelajaran ini akan menentukan nilai optimum parameter-parameter bagi rangkaian neural tersebut. Pada fasa ujian pula, satu set data ujian yang baru akan dimasukkan kepada rangkaian neural yang telah dilatih tersebut bagi menentukan keupayaan rangkaian neural tersebut untuk mewakili keseluruhan data.

Menurut Haykin (1994), pembelajaran ditakrifkan seperti berikut:

Pembelajaran adalah satu proses yang mana parameter-parameter bebas rangkaian neural dipadankan melalui proses stimulasi yang berterusan oleh persekitaran yang mana rangkaian neural itu berada. Jenis pembelajaran adalah berdasarkan kaedah yang digunakan oleh parameter untuk berubah.

Proses pembelajaran rangkaian neural terbahagi kepada dua bahagian iaitu algoritma atau aturan pembelajaran dan paradigma pembelajaran. Terdapat lima jenis

aturan pembelajaran iaitu pembedulan ralat (*error-correction*), Hebbian, bersaing (*competitive*), Boltzmann dan kesan hukum Thorndike (*Thorndike's law of effect*). Paradigma pembelajaran pula terbahagi kepada pembelajaran terselia dan tak terselia. Pembahagian proses pembelajaran ini boleh digambarkan seperti Rajah 2.10.



Rajah 2.10: Pembahagian proses pembelajaran rangkaian neural

Paradigma Pembelajaran

Terdapat dua paradigma pembelajaran bagi rangkaian neural iaitu pembelajaran terselia (*supervised learning*) dan pembelajaran tak terselia (*unsupervised learning*) (Kung, 1993, Schyns, 1991). Pembelajaran terselia pula terbahagi kepada pembelajaran mudah dan sukar. Pembelajaran sukar terbahagi kepada dua bahagian iaitu algoritma rangkaian bebas dan tetap (Gallant, 1995).

Bagi pembelajaran secara terselia, data latihan yang dimasukkan kepada rangkaian neural mempunyai pasangan set data masukan dan data keluaran sasaran. Data keluaran sasaran ini bertindak sebagai 'guru' yang menyediakan rangkaian neural

tersebut dengan data keluaran yang disasarkan bagi setiap data masukan yang diberikan. Proses pengemaskinian parameter-parameter rangkaian neural adalah dipengaruhi oleh data masukan dan ralat keluaran bagi rangkaian neural tersebut. Ralat keluaran ini merujuk kepada perbezaan di antara keluaran rangkaian neural dengan keluaran sasaran. Parameter-parameter rangkaian neural akan dikemaskini supaya keluaran rangkaian neural yang diperolehi menyamai atau mempunyai perbezaan yang kecil dan munasabah dengan keluaran sasaran. Nilai optimum bagi parameter-parameter rangkaian neural diperolehi jika rangkaian neural tersebut dapat mewakili keseluruhan data masukan dan meminimumkan ralat keluaran yang diperolehi.

Bagi pembelajaran tak terselia, data latihan yang disediakan untuk rangkaian neural hanya mengandungi data masukan sahaja. Rangkaian neural tidak mempunyai data keluaran sasaran yang boleh dijadikan panduan pengoptimuman nilai-nilai parameternya. Pembelajaran hanya berdasarkan kepada pengalaman rangkaian neural tersebut mengcam corak statistik seperti kenalaran data latihan yang dimasukkan. Oleh itu, teknik pembelajaran ini juga dikenali sebagai pembelajaran terselia-sendiri (*self-supervised learning*).

Pada pembelajaran tak terselia ini terdapat dua kaedah utama yang digunakan oleh rangkaian neural untuk mengemaskini parameter-parameternya iaitu pembelajaran bekerjasama dan pembelajaran bersaing (Nelson & Illingworth, 1992). Pada pembelajaran bekerjasama, setiap neuron akan bertindakbalas dengan data yang dimasukkan secara bersama-sama. Setiap neuron akan cuba menguja di antara satu sama lain. Jika data masukan menguja salah satu neuron pada rangkaian neural tersebut, neuron-neuron lain akan turut teruja dan bertindakbalas dengan data tersebut.

Parameter-parameter semua neuron ini akan dikemaskinikan nilainya. Tetapi jika data yang dimasukkan merencat aktiviti sesuatu neuron, maka neuron yang lain juga akan terencat aktiviti mereka. Ini menyebabkan tiada tindakbalas yang berlaku terhadap data tersebut dan data tersebut tidak akan dihantar ke lapisan seterusnya.

Teknik pembelajaran bersaing pula hanya membenarkan neuron tertentu teruja dan bertindakbalas dengan data masukan pada satu-satu masa. Oleh itu, semua neuron akan bersaing di antara satu sama lain untuk bertindakbalas dengan data masukan tersebut. Hanya neuron yang teruja sahaja yang akan dikemaskinikan nilai parameternya, manakala neuron lain akan direncatkan dan tidak akan dikemaskinikan parameter mereka.

Aturan Pembelajaran

Berdasarkan kepada Rajah 2.10, aturan pembelajaran terbahagi kepada lima aturan iaitu aturan pembedahan ralat, Hebbian, bersaing, Boltzmann dan kesan hukum Thorndike (Haykin, 1994). Penerangan bagi kelima-lima aturan adalah seperti di bawah:

(a) Aturan pembelajaran pembedahan ralat

Pada aturan ini, pengemaskinian parameter-parameter rangkaian adalah berdasarkan kepada matlamat untuk meminimumkan fungsi kos ralat keluaran. Ralat keluaran adalah nilai perbezaan di antara keluaran sasaran dengan keluaran rangkaian dan diwakili oleh Persamaan (2.3):

$$e_k(n) = d_k(n) - y_k(n) \quad (2.3)$$

Berdasarkan Persamaan (2.3), $d_k(n)$ ialah keluaran sasaran dan $y_k(n)$ ialah keluaran sebenar rangkaian.

Kriteria fungsi kos yang sering digunakan adalah kriteria ralat kuasa dua min (*mean square error, MSE*) dan didefinisikan sebagai nilai kuasa dua min bagi perjumlahan ralat kuasa dua. Kriteria fungsi kos ini diwakili oleh persamaan:

$$J = E \left[\frac{1}{2} \sum_k e_k^2(n) \right] \quad (2.4)$$

Berdasarkan Persamaan (2.4), E ialah operator statistik jangkaan (*statistical expectation operator*).

(b) Aturan Hebbian

Aturan pembelajaran ini diperkenalkan oleh Donald Hebb pada tahun 1949. Dua keadaan bagi menggambarkan aturan ini adalah seperti berikut:

- i. Jika satu neuron mendapat data atau signal masukan dari neuron yang lain dan jika kedua-dua belah pada sambungan yang menghubungkan neuron-neuron tersebut aktif atau teruja secara serentak, maka pemberat sambungan tersebut akan dikuatkan.
- ii. Jika semasa penghantaran data tersebut hanya satu neuron yang teruja pada satu masa, maka pemberat sambungan dua neuron tersebut akan dilemahkan.

(c) Aturan bersaing

Pembelajaran bersaing hanya membenarkan satu neuron aktif atau teruja pada satu masa. Neuron-neuron pada satu lapisan akan bersaing di antara satu sama lain untuk mendapatkan peluang bagi bertindakbalas dengan data yang dimasukkan pada lapisan tersebut. Strategi yang digunakan ialah 'menang-ambil-semua' (*winner-takes-all*). Neuron yang mempunyai tindakbalas yang paling tinggi akan menang, diuja dan

dikemaskini nilai parameternya manakala neuron-neuron lain akan direncatkan dan tidak dikemaskini nilai parameter-parameter mereka.

(d) Aturan Boltzmann

Berdasarkan aturan ini, setiap neuron akan dicirikan dengan fungsi tenaga, E yang ditakrifkan oleh persamaan berikut:

$$E = -\frac{1}{2} \sum_i \sum_j w_{ji} s_j s_i, \quad i \neq j \quad (2.5)$$

Berdasarkan Persamaan (2.5), s_i adalah keadaan neuron i dan w_{ji} adalah pemberat sambungan di antara neuron i dan j .

Aturan ini beroperasi dengan cara memilih satu neuron secara rawak (katakan neuron j) pada satu langkah pemprosesan tertentu dan mengalihkan keadaan neuron j tersebut daripada keadaan s_j kepada keadaan $-s_j$ pada suhu T dengan kebarangkalian

$$W(s_j \rightarrow -s_j) = \frac{1}{1 + \exp(-\Delta E_j / T)} \quad (2.6)$$

Berdasarkan Persamaan (2.6), ΔE_j adalah perubahan tenaga yang terhasil daripada pengalihan keadaan dan T adalah suhu pseudo (*pseudo-temperature*). Aturan ini akan diulangi sehingga rangkaian mencapai keseimbangan haba.

(e) Aturan kesan hukum Thorndike

Berdasarkan kepada kesan hukum Thorndike klasik, Haykin (1994) menakrifkan semula aturan ini sebagai:

Jika sesuatu tindakan yang diambil oleh satu sistem pembelajaran memenuhi satu keadaan penerimaan tertentu, maka kecenderungan sistem untuk mewujudkan tindakan tersebut akan ditinggikan. Jika sebaliknya, maka kecenderungan sistem untuk mewujudkan tindakan itu adalah rendah.

Aturan ini digunakan di dalam pembelajaran pengukuhan (*reinforcement learning*) iaitu sama ada pembelajaran pengukuhan sekutuan (*associative reinforcement learning*) dan pembelajaran pengukuhan tak sekutuan (*nonassociative reinforcement learning*).

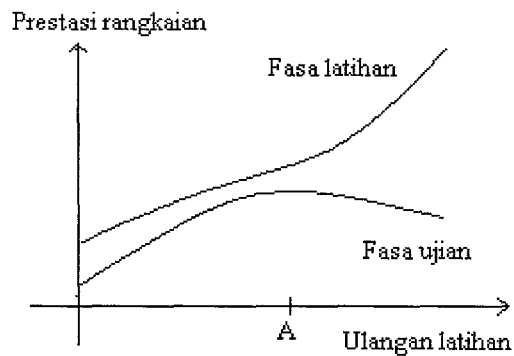
2.3.3 Prestasi Rangkaian Neural Buatan

Bagi mengaplikasikan rangkaian neural seperti rangkaian neural biologi, rangkaian neural tersebut perlu melalui dua fasa utama iaitu fasa latihan dan fasa ujian. Fasa latihan berfungsi sebagai fasa pembelajaran bagi rangkaian neural tersebut untuk mengemaskini struktur dan nilai parameter rangkaiannya. Proses pengoptimuman parameter dilakukan untuk memastikan rangkaian neural tersebut mempunyai kemampuan pengitlakan (*generalization*). Pengitlakan bermaksud keupayaan rangkaian neural untuk belajar, mengesan dan mewakili ciri-ciri statistik data latihan dan berkemampuan untuk menentu luar (*extrapolate*) data baru yang dimasukkan pada fasa ujian (Principe *et al.*, 2000).

Keupayaan pengitlakan dan prestasi rangkaian neural ditentukan oleh beberapa faktor iaitu saiz data latihan, bilangan lelaran data latihan, bilangan neuron-neuron atau nod-nod dan bilangan pemberat rangkaian. Sebagai contoh, penyelidikan oleh Principe *et al.* (2000) mendapati secara am, rangkaian MLP biasanya memerlukan bilangan set data latihan sekurang-kurangnya 10 kali ganda pemberat rangkaiannya bagi menghasilkan kejituan rangkaian 90 peratus. Data latihan yang dimasukkan semasa proses pembelajaran mestilah merangkumi keseluruhan ciri-ciri statistik keseluruhan data yang dimodelkan. Jika data latihan tidak mempunyai data yang mewakili ciri-ciri

statistik tertentu, rangkaian neural akan gagal untuk mengesan dan menentu luar data baru yang mempunyai ciri-ciri tersebut.

Prestasi rangkaian neural secara am pada kedua-dua fasa boleh digambarkan seperti Rajah 2.11. Rajah tersebut menunjukkan prestasi rangkaian neural pada fasa latihan dan ujian melawan bilangan lelaran latihan (Rich & Knight, 1991). Pada bahagian permulaan, penambahan bilangan lelaran latihan akan meningkatkan prestasi rangkaian neural pada kedua-dua fasa. Rangkaian neural mengemaskini parameter-parameter untuk meningkatkan keupayaan pengitlakannya. Rangkaian neural ini mencapai keupayaan pengitlakan yang optimum pada titik A dan memberikan prestasi maksimum pada fasa ujian. Walaubagaimanapun, selepas titik tersebut, prestasi rangkaian neural pada fasa ujian menurun walaupun prestasi fasa latihan terus meningkat. Ini kerana fenomena penghafalan data (*data memorization*) mula terjadi. Rangkaian neural mula menghafal ciri-ciri spesifik data latihan yang dimasukkan. Rangkaian neural mengemaskini parameter-parameter rangkaian berdasarkan ciri-ciri spesifik data latihan ini dan bukan berdasarkan ciri-ciri statistiknya. Semakin meningkat bilangan lelaran latihan, rangkaian neural akan menghafal ciri-ciri spesifik data latihan dengan lebih baik. Fenomena ini menyebabkan rangkaian neural gagal untuk menentu luar data ujian yang baru kerana ciri-ciri spesifik di antara data latihan dan ujian adalah berbeza.



Rajah 2.11: Prestasi rangkaian neural terhadap bilangan lelaran latihan

Bagi mendapatkan prestasi rangkaian neural yang optimum pada kedua-dua fasa tersebut, proses pembelajaran rangkaian perlu diberhentikan sebelum fenomena penghafalan data berlaku. Terdapat tiga kaedah atau kriteria pemberhentian (*stop criteria*) yang digunakan iaitu pemberhentian berdasarkan pra-tentu bilangan lelaran latihan, pemberhentian berdasarkan ralat set latihan (*training-set error*) dan pemberhentian berdasarkan pengitlakan (Principe *et. al.*, 2000). Pada kaedah pemberhentian berdasarkan pra-tentu bilangan lelaran latihan, nilai bilangan lelaran latihan telah ditentukan nilainya terlebih dahulu sebelum proses pembelajaran rangkaian dilakukan. Pada kaedah pemberhentian berdasarkan ralat set latihan pula, pemilihan julat ralat yang dibenarkan untuk sesuatu rangkaian neural ditentukan. Rangkaian neural akan mengulangi proses pembelajaran sehingga nilai MSE rangkaian neural berada di dalam julat tersebut. Ini bertujuan untuk meminimumkan ralat keluarannya. Kaedah pemberhentian berdasarkan pengitlakan akan memberhentikan proses pembelajaran rangkaian sebaik sahaja rangkaian mencapai kemampuan pengitlakan yang maksimum.

Selain itu, bilangan nod dan pemberat rangkaian juga akan memberikan kesan yang sama seperti lelaran data latihan terhadap prestasi rangkaian neural.

Penambahan bilangan nod pada mulanya akan meningkatkan prestasi rangkaian neural. Namun, apabila penambahan bilangan nod yang berlebihan terutama sekali jika bilangan nod sama atau melebihi bilangan data masukan, fenomena pemetaan secara terus (*direct mapping*) akan terjadi. Setiap data masukan akan dipetakan secara terus kepada sesuatu nod. Ini menyebabkan nod tersebut mampu menghafal setiap data yang dimasukkan. Fenomena ini dinamakan penghafalan data (Radhakrisnan & Mohamed, 2000, Principe *et al.*, 2000). Penghafalan data ini menyebabkan rangkaian neural tersebut hanya belajar berkenaan dengan ciri spesifik data latihan berbanding ciri statistiknya. Fenomena ini akan memberikan prestasi rangkaian neural yang tinggi pada fasa latihan namun prestasi rangkaian neural tersebut adalah rendah pada fasa ujian.

Kebiasaannya, sebelum rangkaian neural melalui proses pembelajaran, struktur optimum rangkaian neural tersebut perlu ditentukan terlebih dahulu oleh pengguna. Struktur yang ditentukan ini merangkumi bilangan nod tersembunyi, bilangan nod masukan, bilangan nod keluaran dan bilangan pemberat rangkaian. Kaedah ini bersifat subjektif iaitu pengguna hanya berpandukan kepada andaian bahawa semakin banyak nod dan pemberat rangkaian, maka semakin tinggi prestasi rangkaian. Oleh itu, terdapat dua kaedah untuk mendapatkan bilangan nod-nod dan pemberat rangkaian yang optimum bagi sesuatu rangkaian neural iaitu kaedah pertumbuhan (*growing method*) dan penyingkiran (*prunning method*) (Hertz *et al.*, 1991). Di dalam kaedah pertumbuhan, rangkaian neural tersebut akan diberikan dengan bilangan nod tersembunyi, nod masukan atau pemberat rangkaian yang minimum (Ramamurti & Ghosh, 1999, Hertz *et al.*, 1991). Rangkaian neural akan menambah bilangan

parameter-parameter tersebut sehingga rangkaian tersebut mencapai prestasi yang optimum. Di dalam kaedah penyingkiran pula, rangkaian neural akan diberikan dengan bilangan maksimum parameter-parameter tersebut (Ramamurti & Ghosh, 1999, Sum *et al.*, 1999, Hertz *et al.*, 1991). Proses penyingkiran bertanggungjawab untuk menyingkirkan bilangan parameter-parameter tersebut sehingga prestasi rangkaian yang optimum diperolehi.

Kedua-dua kaedah yang dicadangkan itu pada dasarnya adalah bertujuan untuk menghindarkan masalah terkurang padanan (*underfitting*) dan terlebih padanan (*overfitting*) (Mashor, 1999a). Terkurang padanan wujud apabila rangkaian neural mempunyai bilangan nod tersembunyi atau masukan dan bilangan pemberat rangkaian kurang daripada nilai optimum. Ini menyebabkan rangkaian neural mempunyai keupayaan pengitlakan yang rendah. Terlebih padanan pula merujuk kepada rangkaian neural mempunyai nilai parameter-parameter rangkaian yang melebihi nilai optimumnya. Fenomena ini biasanya akan menghasilkan padan lengkungan berdimensi tinggi kepada data latihan. Ini menyebabkan rangkaian akan memberikan prestasi yang sangat baik pada fasa latihan dan prestasi yang teruk pada fasa ujian.

2.3.4 Aplikasi Rangkaian Neural Buatan

Rangkaian neural telah digunakan di dalam pelbagai bidang seperti pengenalpastian sistem (*system identification*), pengcaman corak (*pattern recognition*), pengelasan corak (*pattern classification*), peramalan (*prediction*) dan sebagainya. Berdasarkan kepada penerangan-penerangan berkenaan rangkaian neural buatan pada bahagian terdahulu, beberapa perkara perlu diberi perhatian sebelum sesuatu

rangkaian neural diaplikasikan sebagai satu fungsi tertentu. Perkara-perkara yang perlu diberi perhatian adalah seperti berikut:

1. *Jenis seni bina rangkaian neural.*

Pemilihan seni bina rangkaian neural seharusnya berlandaskan kepada jenis dan kriteria pengaplikasian yang hendak dilakukan. Jika pengaplikasian mementingkan kadar masa pemprosesan seperti aplikasi di dalam talian, maka seni bina suap depan lebih sesuai digunakan. Selain itu, faktor-faktor seperti kestabilan, kebolehlatihan, kebolehsuaian dan sebagainya terhadap sesuatu set data juga perlu dipertimbangkan di dalam pemilihan seni bina rangkaian neural yang sesuai.

2. *Jenis teknik dan algoritma pembelajaran.*

Dua teknik pembelajaran yang boleh digunakan ialah pembelajaran terselia atau pembelajaran tak terselia. Teknik pembelajaran ini bertanggungjawab untuk menentukan nilai-nilai parameter sesuatu rangkaian seperti pemberat rangkaian dan penempatan pusat rangkaian. Pembelajaran terselia lebih praktikal untuk digunakan kepada rangkaian neural yang memodelkan sesuatu sistem yang mana data latihan dan ujian sistem tersebut mempunyai ciri-ciri statistik yang sama. Jika sebaliknya, maka pembelajaran tak terselia lebih praktikal untuk digunakan.

3. *Penyediaan data latihan dan data ujian.*

Data latihan yang akan dimasukkan kepada rangkaian neural untuk proses pembelajaran perlu mencukupi dan mempunyai segala maklumat dan ciri statistik sesuatu masalah yang hendak dimodelkan dengan rangkaian neural tersebut. Ini bertujuan untuk menyediakan rangkaian neural tersebut dengan keupayaan pengitlakan yang tinggi (Radhakrishnan & Mohamed, 2000).

4. *Pemilihan nilai-nilai parameter dan saiz rangkaian.*

Pemilihan nilai-nilai parameter dan saiz rangkaian neural yang optimum penting untuk membekalkan rangkaian neural dengan keupayaan pengitlakan yang baik dan menghindarkan rangkaian neural tersebut daripada masalah-masalah penghafalan data, terlebih padanan, terkurang padanan dan sebagainya. Sebagai contoh, Mashor (1999a) membuktikan bahawa prestasi salah satu rangkaian neural iaitu rangkaian RBF bergantung kepada bilangan nod masukan, bilangan nod tersembunyi dan pemilihan fungsi asasnya. Oleh itu, nilai-nilai parameter-parameter sesuatu rangkaian adalah penting untuk ditentukan nilai optimumnya.

5. *Analisa akhir prestasi rangkaian neural.*

Analisa akhir prestasi rangkaian neural seperti ketepatan rangkaian membuat ramalan, analisa ralat keluaran dan sebagainya perlu dilakukan. Ini bertujuan untuk membuktikan bahawa rangkaian neural tersebut sesuai untuk diaplikasikan sebagai satu fungsi tertentu. Sebagai contoh, bagi pengaplikasian rangkaian neural sebagai pengenalpastian sistem, sistem yang telah dimodelkan menggunakan rangkaian neural akan melalui beberapa ujian pengesahan model seperti ramalan satu langkah ke hadapan (*one step ahead predictions, OSA*), keluaran ramalan model (*model predicted outputs, MPO*), MSE, ujian korelasi (*correlation test*) dan ujian kuasa dua chi (*chi-squares test*) (Mashor, 1999a).

2.3.4.1 Aplikasi Di Dalam Bidang Perubatan

Sejajar dengan kejayaan pengaplikasian rangkaian neural di dalam pelbagai bidang dan kepesatan dunia perubatan dewasa ini, banyak penyelidikan telah

dijalankan untuk mengaplikasikan rangkaian neural di dalam dunia perubatan. Penyelidikan-penyelidikan tersebut telah berjaya membuktikan keupayaan rangkaian neural untuk membantu meningkatkan taraf dunia perubatan. Penyelidikan rangkaian neural di dalam bidang perubatan ini banyak tertumpu kepada pembinaan sistem diagnosis, peningkatan kualiti imej perubatan dan pengekstrakan ciri-ciri imej perubatan. Beberapa jenis rangkaian neural telah berjaya diaplikasikan di dalam bidang perubatan di dalam penyelidikan-penyelidikan terdahulu. Salah satu rangkaian neural yang sering digunakan ialah rangkaian MLP. Pengaplikasian rangkaian MLP sebagai sistem pengesanan awal lemah jantung dengan menggunakan 348 kes telah memberikan kejituan, sensitiviti dan spesifisiti masing-masing sebanyak 90.2%, 89.3% dan 90.5% (Kennedy *et al.*, 1994). Rangkaian MLP juga diaplikasikan untuk mendiagnosis barah buah dada pada peringkat awal (Ng *et al.*, 2002). Menggunakan data termografi buah dada sebagai masukan, rangkaian MLP mampu memberikan kejituan prestasi diagnosis sebanyak 61.54%.

Rangkaian RBF juga telah digunakan di dalam bidang perubatan. Rangkaian ini berupaya mengenalpasti kawasan jisim (*mass*) tertentu pada imej mammogram (Zong *et al.*, 1997). Dengan menggunakan 25 sampel imej mammogram, rangkaian memberikan purata dan sisihan piawai kadar pengenalpastian masing-masing sebanyak 92.2% dan 3.12%. Harrison *et al.* (1994) pula membuktikan rangkaian RBF mampu memberikan kejituan sebanyak 89.5% dengan sensitiviti dan spesifisiti masing-masing sebanyak 87.3% dan 90.7% apabila diaplikasi sebagai sistem diagnosis lemah jantung.

Chang & Chung (1999) menggunakan rangkaian Hopfield sebagai teknik peruasan tiga jenis imej perubatan iaitu imej salunan magnet (*magnetic resonance, MR*)

dan tomografi komputer (*computer tomography, CT*). Keputusan menunjukkan rangkaian memberikan prestasi peruasan yang baik untuk mengesan ciri-ciri atau kawasan tertentu pada imej perubatan tersebut. Cheng *et al.* (1996) pula mencadangkan rangkaian neural Hopfield bersaing sebagai teknik peruasan imej MR dan CT. Peruasan yang dibuat adalah berdasarkan kepada taburan paras kelabu imej. Rangkaian tersebut telah dibuktikan mempunyai prestasi peruasan yang lebih baik berbanding teknik purata-c kabur dan purata-c keras (*hard c mean, HCM*).

Selain itu, beberapa rangkaian neural yang lain juga telah digunakan di dalam bidang perubatan. Rangkaian ARTMAP telah dibuktikan berkeupayaan sebagai model peramalan untuk prognosis komplikasi pesakit yang dimasukkan ke dalam unit rawatan rapi (*intensive care units, ICU*) (Lim *et al.*, 1999a). Liang *et al.* (1994) mencadangkan pengkaskadan di antara rangkaian Kohonen dengan rangkaian penandaan santai (*relaxation labeling*) untuk meruas imej perubatan. Rangkaian neural yang dibina itu mampu meruas imej perubatan dengan lebih baik berbanding kaedah ambang dengan pengawetan momen. Rangkaian ARTMAP kabur (*fuzzy ARTMAP*) pula telah digunakan untuk mengesan sindrom koronari tenat (*acute coronary syndrome, ACS*) (Kuan *et al.*, 2002). Menggunakan data sejarah pesakit, gejala dan tanda yang diperolehi daripada pemeriksaan klinikal, rangkaian ARTMAP kabur yang digunakan di dalam penyelidikan itu mampu menjalankan diagnosis dengan memberikan kejituan, sensitiviti dan spesifisiti masing-masing sebanyak 81.02%, 84.47% dan 57.33%.

Rangkaian pemetaan penganjuran diri (*self organizing map, SOM*) juga telah dibuktikan berkeupayaan mengesan dan meruas imej arteri dengan baik. Rangkaian SOM ini mempunyai tiga kelebihan iaitu rangkaian tidak memerlukan informasi awalan,

rangkaian hanya mempunyai satu parameter kawalan dan prestasi peruasan adalah baik serta tidak memerlukan proses peningkatan kualiti imej (Kong & Guan, 1994).

2.4 Ringkasan

Penerangan di dalam bahagian 2.2, menerangkan jenis parasit malaria. Kebanyakan kes yang dilaporkan melibatkan negara dari daerah tropika dan sub tropika. Terdapat 4 jenis parasit malaria yang menyerang manusia iaitu Plasmodium falciparum, Plasmodium vivax, Plasmodium ovale dan Plasmodium malariae. Diantara keempat-empat parasit malaria tersebut, Plasmodium falciparum adalah yang paling bahaya. Di negara ini, plasmodium ovale tidak dikesan dan hanya 3 jenis malaria lainnya dikesan.

Rangkaian neural pula diterangkan dalam bahagian 2.3. Analogi konsep pengoperasian kepada pemikiran otak manusia telah berjaya diaplikasikan menggunakan rangkaian neural. Kesesuaian sesuatu rangkaian neural untuk digunakan sebagai fungsi tertentu bergantung kepada pemilihan jenis seni bina, pemilihan teknik pembelajaran, penyediaan data masukan, pemilihan nilai-nilai parameter awalan dan saiz rangkaian, dan analisa akhir prestasinya.

Penyelidikan terdahulu telah berjaya menggunakan rangkaian neural seperti rangkaian perseptron berbilang lapisan (Multilayered Perceptron, MLP) dalam menentukan jenis parasti malaria. Kajian penentuan jenis parasit malaria menggunakan rangkaian neural berdasarkan parameter-parameter kimia telah dijalankan dengan meluas namun kajian jenis parasit malaria menggunakan rangkaian neural pada masa kini masih belum diterokai. Oleh itu, kajian yang sedang dijalankan ini akan menentukan

jenis parasit malaria menggunakan rangkaian neural dengan menggunakan parameter-parameter biologi sebagai parameter masukan.

BAB 3

PENENTUAN JENIS PARASIT MALARIA MENGGUNAKAN RANGKAIAN NEURAL

3.1 Pengenalan

Rangkaian neural merupakan salah satu daripada kecerdikan buatan yang sering digunakan di dalam bidang perubatan. Terdapat dua jenis penggunaan rangkaian neural di dalam bidang perubatan iaitu penggunaannya sebagai teknik pemprosesan imej perubatan dan sebagai sistem diagnosis sesuatu penyakit. Penggunaannya sebagai teknik pemprosesan imej perubatan telah berjaya meningkatkan kualiti imej perubatan tersebut untuk memudahkan diagnosis sesuatu penyakit oleh doktor (Chang & Chung, 1999, Kovacevic & Loncaric, 1997, Chen *et al.*, 1991b). Manakala, penggunaan rangkaian neural sebagai sistem diagnosis sesuatu penyakit pula berupaya untuk meningkatkan kejituan, sensitiviti dan spesifisiti, dan mengurangkan kes salah negatif dan salah positif (Kuan *et al.*, 2002, Ng *et al.*, 2002, Li & Najarian, 2001, Lo *et al.*, 1999, Lim *et al.*, 1999a, Christoyianni *et al.*, 1999). Salah satu jenis penyakit yang dikesan menggunakan rangkaian neural ialah barah pangkal rahim (Li & Najarian, 2001, Mitra *et al.*, 2000, Tumer *et al.*, 1998).

Penggunaan rangkaian neural sebagai teknik pengklasifikasian malaria memerlukan beberapa ciri penting yang dapat membezakan sepsis-spesis parasit malaria tersebut. Secara umumnya, parasit malaria, 'Plasmodial' terbahagi kepada 4 spesis utama iaitu 'Plasmodium falciparum', 'Plasmodium vivax', 'Plasmodium malariae' dan 'Plasmodium ovale'. Bagaimanapun, hanya 3 daripada spesis tersebut yang hadir di Malaysia iaitu 'Plasmodium falciparum', 'Plasmodium vivax' dan 'Plasmodium

malariae'. 'Plasmodium vivax' merupakan spesis parasit yang menyebabkan kesan penyakit yang kuat kepada mangsa namun jarang menyebabkan kematian. 'Plasmodium falciparum' adalah spesis parasit malaria yang sangat bahaya kerana ia menyebabkan kematian kepada mangsanya. Kajian bagi projek hanya tertumpu kepada proses pengklasifikasian 3 spesis parasit malaria. Penyelidikan ini mencadangkan rangkaian neural HMLP dengan menggunakan algoritma MRPE sebagai sistem pengesanan imej palitan parasit malaria tersebut.

Bagi kajian ini, 600 sampel data digunakan bagi proses mengklasifikasikan parasit malaria ke dalam rangkaian neural HMLP. 186 sampel adalah daripada jenis 'Plasmodium falciparum', 210 sampel adalah 'Plasmodium vivax', dan 204 sampel adalah 'Plasmodium malariae'. Sampel data tersebut diperolehi daripada Jabatan Microbiologi, Hospital Universiti Sains Malaysia (HUSM). Sebagai data masukan kepada rangkaian neural tersebut, penyelidikan ini mencadangkan penggunaan 6 ciri yang terdapat pada sel iaitu saiz sel darah merah yang telah dijangkiti per saiz normal sel darah merah, bentuk parasit, bilangan kromatin, bilangan parasit per sel darah merah, tekstur sel darah merah dan kedudukan kromatin bagi parasit. 300 sampel sel parasit malaria (100 sel 'Plasmodium falciparum', 100 sel 'Plasmodium vivax', dan 100 sel 'Plasmodium malariae') digunakan sebagai data latihan bagi rangkaian neural. Bagi data ujian, 300 sel juga digunakan iaitu 86 daripada sel tersebut adalah 'Plasmodium falciparum', 110 sel 'Plasmodium vivax', dan 104 sel 'Plasmodium malariae'.

Bagi memastikan kesesuaian sesuatu rangkaian neural sebagai sistem diagnosis sel parasit malaria, analisa kejituan pengkelasan dilakukan.

3.2 Sistem Penangkapan Imej Palitan Darah Secara Automatik

Setiap imej palitan darah yang dianalisa diambil secara automatik dengan menggunakan mikroskop digital. Perkakasan Leica CTR mikroskop diintegrasikan bersama program yang dibangunkan bagi membolehkan mikroskop tersebut menangkap imej secara automatik. Imej palitan darah yang telah diambil kemudiannya diproses bagi menentukan kehadiran parasit malaria seterusnya mengklasifikasikannya kepada spesis-spesis tersebut. Kemudian, kanta mikroskop akan berganjak ke kanan bagi membolehkannya menangkap imej palitan darah yang berikutnya iaitu yang bersebelahan dengan imej palitan yang telah dianalisa. Proses penangkapan dan analisa imej ini berterusan sehingga selesai semua kawasan imej palitan dijumpai.

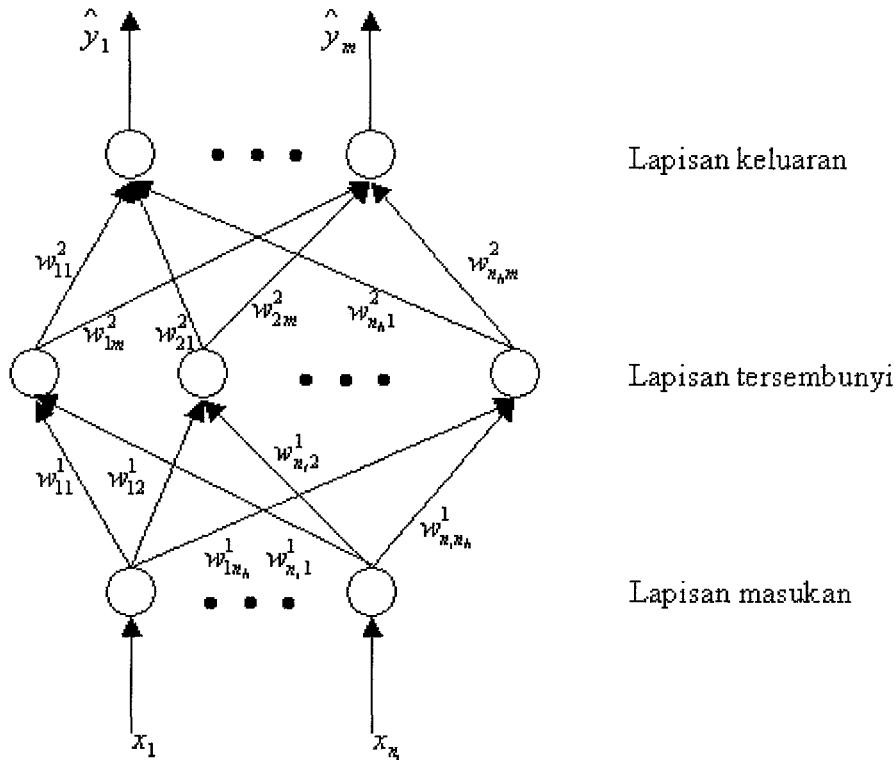
3.3 Rangkaian Perseptron Berbilang Lapisan Hibrid

Rangkaian Perseptron berbilang lapisan (MLP) mempunyai keupayaan untuk digunakan sebagai tiga fungsi utama iaitu keupayaan untuk mengimplemen fungsi logik Boolean, keupayaan untuk mengklasifikasikan data dan keupayaan untuk mengimplemen transformasi tak lurus untuk proses penganggaran (Haykin, 1994, Hush & Horne, 1993). Rangkaian MLP ini telah digunakan di dalam pelbagai bidang seperti pengelasan data (Pardo *et al.*, 2000, Schmitz & Aldrich, 1999, Roychowdhury *et al.*, 1999, Peterson *et al.*, 1998), pengenalpastian sistem (Jayasuriya *et al.*, 2002, Anders & Korn, 1999, Belli *et al.*, 1999) dan pemprosesan imej (Mamat & Mashor, 2001, Long *et al.*, 1999, Blacknell & White, 1993). Rangkaian MLP juga telah dibuktikan mempunyai keupayaan yang tinggi untuk digunakan di dalam bidang perubatan terutamanya sebagai sistem diagnosis barah buah dada (Ng *et al.*, 2002, Christoyianni

et al., 1999, Yao & Liu, 1999, Cheng *et al.*, 1995) dan diagnosis barah pangkal rahim (Li & Najarian, 2001, Mitra *et al.*, 2000, Tumer *et al.*, 1998, Ricketts *et al.*, 1992a, Lee *et al.*, 1991). Oleh itu, penyelidikan ini mencadangkan penggunaan rangkaian MLP dan rangkaian perseptron berbilang lapisan hibrid (HMLP) sebagai sistem mengkelaskan spesies parasit malaria. Rangkaian MLP dipilih berdasarkan penggunaannya yang banyak di dalam bidang perubatan khususnya diagnosis barah pangkal rahim manakala rangkaian HMLP dipilih berdasarkan keupayaan rangkaian HMLP ini memberikan prestasi yang lebih baik berbanding rangkaian MLP konvensional (Mashor 2000b, 1999b). Rangkaian MLP akan dilatih menggunakan algoritma 'Back Propagation' (BP), 'Lavenberg-Marquardt' (LM) dan 'Bayesian Regularization' (BR) dan rangkaian HMLP akan dilatih menggunakan algoritma ralat ramalan jadi semula ubahsuai (*modified recursive prediction error, MRPE*) yang diperkenalkan oleh Mashor (2000b, 1999b). Kajian tersebut membuktikan bahawa rangkaian MLP dan HMLP yang dilatih menggunakan algoritma tersebut berupaya menumpu dengan kadar yang lebih baik dan mempunyai nilai akhir MSE yang lebih kecil berbanding dengan rangkaian yang dilatih menggunakan algoritma ralat ramalan jadi semula (*recursive prediction error, RPE*) dan perambatan balik.

3.3.1 Seni Bina dan Ciri-ciri Rangkaian

Pada tahun 1958, Rosenblatt telah memperkenalkan model perseptron (Hush & Horne, 1993). Pengkaskadan beberapa perseptron di dalam satu lapisan akan membentuk satu rangkaian yang dinamakan rangkaian MLP. Perseptron di dalam rangkaian MLP ini dirujuk sebagai neuron atau nod. Rajah 3.1 menunjukkan rangkaian MLP dengan n_i nod masukan, n_h nod tersembunyi dan m nod keluaran.



Rajah 3.1: Seni bina rangkaian MLP

Berdasarkan kepada Rajah 3.1, data masukan, x_i akan dirambat ke nod tersembunyi melalui sambungan berpemberat, w_{ij}^1 yang menyambungkan nod masukan dengan nod tersembunyi. Setiap nod ini beroperasi seperti model perseptron dengan fungsi sigmoid sebagai fungsi pengaktifannya. Keluaran bagi nod tersembunyi ke- j , u_j diberi oleh persamaan:

$$u_j(t) = \varphi \left(\sum_{i=1}^{n_i} w_{ij}^1 x_i(t) + b_j^1 \right); \quad \text{untuk } 1 \leq j \leq n_h \quad (3.1)$$

Berdasarkan Persamaan (3.1), $\varphi(\bullet)$ ialah fungsi pengaktifan, b_j^1 ialah pincang pada nod tersembunyi ke- j .

Keluaran untuk setiap nod tersembunyi pula akan dirambat ke setiap nod keluaran melalui sambungan berpemberat, w_{jk}^2 yang menyambungkan nod tersembunyi

dengan nod keluaran. Keluaran bagi neuron keluaran ke- k , \hat{y}_k diberikan oleh persamaan:

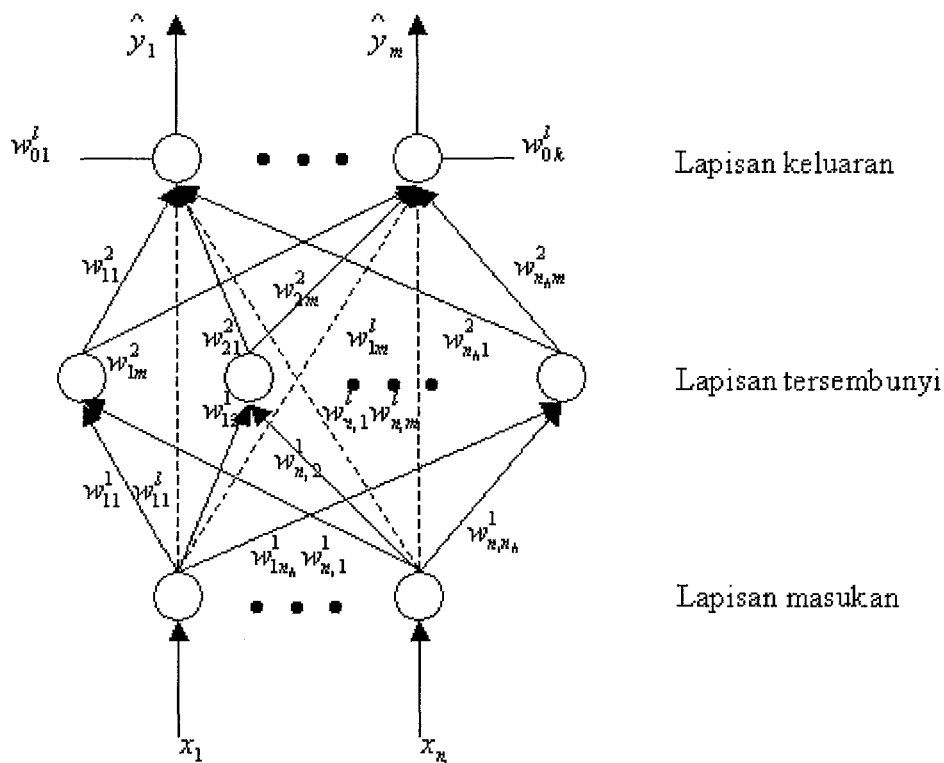
$$\hat{y}_k(t) = \sum_{j=1}^{n_h} w_{jk}^2 u_j(t); \quad \text{untuk } 1 \leq k \leq m \quad (3.2)$$

Rangkaian MLP mempunyai sifat tak lurus yang tinggi yang menyebabkan sistem lurus terpaksa dimodelkan dengan model tak lurus. Maka sambungan lurus ditambahkan kepada rangkaian MLP konvensional untuk mewujudkan satu rangkaian HMLP yang mampu memodelkan sistem lurus tersebut dengan lebih baik seperti yang ditunjukkan di dalam Rajah 3.1 (Mashor, 2000b).

Berdasarkan Rajah 3.1, sambungan lurus terbentuk daripada sambungan yang menghubungkan nod masukan terus kepada nod keluaran. Keluaran bagi rangkaian HMLP, \hat{y}_k diberikan oleh persamaan:

$$\hat{y}_k(t) = \sum_{j=1}^{n_h} w_{jk}^2 u_j(t) + \sum_{i=0}^{n_i} w'_{ik} x_i(t) \quad \text{untuk } 1 \leq k \leq m \quad (3.3)$$

Berdasarkan Persamaan (3.3), sebutan kedua pada bahagian kanan persamaan mewakili sambungan lurus di antara nod masukan dengan nod keluaran dan w'_{ik} ialah pemberat sambungan lurus tersebut. Berdasarkan Persamaan (3.3), apabila nilai $i = 0$, w'_{ik} dan x_i di dalam sebutan kedua masing-masing akan mewakili pemberat sambungan dan masukan untuk masukan pincang rangkaian.



Rajah 3.2: Seni bina rangkaian HMLP.

Rangkaian HMLP ini telah dibuktikan mempunyai prestasi yang lebih baik berbanding rangkaian MLP konvensional (Mashor, 2000b, 1999b). Penyelidikan yang terperinci telah dilakukan di dalam kedua-dua penyelidikan oleh Mashor tersebut untuk membuktikan keupayaan rangkaian HMLP tersebut. Rangkaian HMLP tersebut telah digunakan untuk memodelkan tiga sistem dan ujian korelasi yang diperolehi berada di dalam selang keyakinan 95%. Analisa MSE pula menunjukkan bahawa rangkaian HMLP yang dicadangkan mempunyai nilai yang lebih kecil dan menumpu dengan lebih baik dan cepat berbanding rangkaian MLP, RBF dan HRBF.

3.3.2 Pemberat Sambungan Rangkaian

Algoritma pembelajaran untuk mencari nilai pemberat rangkaian MLP yang sering digunakan pada peringkat awal adalah algoritma penurunan cerun (Hush &

Horne, 1993). Walaubagaimanapun, algoritma ini kurang sesuai digunakan pada rangkaian MLP yang menggunakan fungsi pengaktifan penghad tetap kerana algoritma tersebut memberikan nilai sifar pada kebanyakan tempat. Selepas itu, algoritma yang paling popular digunakan pada rangkaian MLP adalah algoritma parambatan balik (Ng *et al.*, 2002, Wahap *et al.*, 2002, Janahiraman *et al.*, 2002, Harun *et al.*, 2002, Principe *et al.*, 2000). Algoritma ini berasaskan aturan pembelajaran pembetulan ralat. Algoritma ini mudah diimplemenkan dan memberikan prestasi yang baik, namun algoritma ini mempunyai kadar penumpuan yang lambat (Rughooputh & Rughooputh, 1999b). Selain itu, algoritma ini juga merupakan teknik pengoptimuman tak lurus, maka ia kurang sesuai digunakan untuk pemodelan sistem lurus (Mashor, 2000b). Penggunaan algoritma tersebut ke atas rangkaian HMLP tidak mampu untuk meningkatkan prestasi rangkaian tersebut.

Kelemahan algoritma perambatan balik ini telah mendorong penggunaan satu algoritma yang dinamakan ralat ramalan jadi semula (*recursive prediction error, RPE*) ke atas rangkaian MLP (Chen *et al.*, 1990a). Algoritma ini mempunyai prestasi yang lebih baik berbanding algoritma perambatan balik. Malah, algoritma RPE juga berkemampuan untuk menyediakan kadar penumpuan rangkaian MLP yang lebih cepat dan nilai penumpuan akhir bagi ambang dan pemberat sambungan yang diperolehi adalah lebih baik (Billings & Chen, 1995, Billings *et al.*, 1990).

Mashor (2000b, 1999b) telah mengubahsuai algoritma RPE. Pengubahsuaian yang dilakukan ialah mengoptimum cara momentum dan kadar pembelajaran yang diumpukkan kepada algoritma RPE. Algoritma terubahsuai itu dinamakan ralat ramalan jadi semula ubahsuai (*modified recursive prediction error, MRPE*). Ujian MSE telah

membuktikan rangkaian HMLP dengan algoritma MRPE menumpu kepada nilai yang lebih kecil dan mempunyai kadar penumpuan yang lebih cepat berbanding rangkaian MLP dengan algoritma RPE. Selain itu, rangkaian HMLP dengan algoritma MRPE ini juga menghindarkan pengelajaran data latihan semasa proses pembelajaran. Maka, penyelidikan ini akan menggunakan algoritma MRPE untuk menentukan nilai pemberat sambungan rangkaian HMLP dan MLP.

Penerangan mengenai algoritma MRPE di bawah adalah berdasarkan penerangan oleh Mashor (2000b, 1999b). Asalnya, algoritma RPE yang diimplemenkan oleh Chen *et al.* (1990a) meminimumkan fungsi kos di bawah:

$$J(\hat{\Theta}) = \frac{1}{2N} \sum \varepsilon^T(t, \hat{\Theta}) \Lambda^{-1} \varepsilon(t, \hat{\Theta}) \quad (3.4)$$

dengan mengemaskini vektor parameter teranggar, $\hat{\Theta}$ (mengandungi w dan b), menggunakan algoritma Gauss-Newton di bawah:

$$\hat{\Theta}(t) = \hat{\Theta}(t-1) + P(t)\Delta(t) \quad (3.5)$$

dan

$$\Delta(t) = \alpha_m(t)\Delta(t-1) + \alpha_g(t)\psi(t)\varepsilon(t) \quad (3.6)$$

Berdasarkan Persamaan (3.5) dan (3.6), $\varepsilon(t)$ ialah ralat rangkaian, Λ ialah matriks tentu positif simetri berdimensi $m \times m$, m ialah bilangan nod keluaran, $\alpha_m(t)$ ialah momentum dan $\alpha_g(t)$ ialah kadar pembelajaran. $\alpha_m(t)$ dan $\alpha_g(t)$ mempunyai nilai di antara 0 dan 1 dan secara tipikal, kedua-dua pemboleh ubah tersebut masing-masing mempunyai nilai menghampiri 1 dan 0. Di dalam algoritma MRPE, kedua-dua pemboleh

ubah tersebut diubah untuk meningkatkan kadar penumpuan algoritma tersebut berdasarkan persamaan:

$$\alpha_m(t) = \alpha_m(t-1) + a \quad (3.7)$$

dan

$$\alpha_g(t) = \alpha_m(t)(1 - \alpha_m(t)) \quad (3.8)$$

Berdasarkan Persamaan (3.7) dan (3.8), a ialah satu pemalar dengan nilai tipikal 0.01.

$\psi(t)$ mewakili kecerunan keluaran ramalan satu langkah ke hadapan, \hat{y} terhadap parameter rangkaian:

$$\psi(t, \Theta) = \left[\frac{d \hat{y}(t, \Theta)}{d \Theta} \right] \quad (3.9)$$

$P(t)$ di dalam Persamaan (3.5), dikemaskinikan nilainya berdasarkan:

$$P(t) = \frac{1}{\lambda(t)} \left[P(t-1) - P(t-1) \psi(t) (\lambda(t) I + \psi^T(t) P(t-1) \psi(t))^{-1} \psi^T(t) P(t-1) \right] \quad (3.10)$$

Berdasarkan Persamaan (3.10), $\lambda(t)$ ialah faktor pelupa (*forgetting factor*). $\lambda(t)$ mempunyai nilai di antara 0 hingga 1, dan dikemaskinikan nilainya berdasarkan persamaan:

$$\lambda(t) = \lambda_0 \lambda(t-1) + (1 - \lambda_0) \quad (3.11)$$

Berdasarkan Persamaan (3.11), λ_0 ialah nilai awalan faktor pelupa. Nilai awalan matriks $P(t)$, $P(0)$ kebiasaannya diumpukkan dengan nilai αI . I ialah matriks identiti dan α ialah pemalar dengan nilai tipikal di antara 100 hingga 10000. Biasanya, nilai α yang dipilih ialah 1000.

Matriks kecerunan, $\psi(t)$ dikira nilainya berdasarkan persamaan:

$$\psi_k(k) = \frac{dy_k(t)}{d\theta_c} = \begin{cases} u_j & \text{jika } \theta_c = w_{jk}^2 \quad 1 \leq j \leq n_h \\ x_i & \text{jika } \theta_c = w_{ik}^l \quad 0 \leq i \leq n_i \\ u_j(1-u_j)w_{jk}^2 & \text{jika } \theta_c = b_j^1 \quad 1 \leq j \leq n_h \\ u_j(1-u_j)w_{jk}^2 x_i & \text{jika } \theta_c = w_{ij}^1 \quad 1 \leq j \leq n_h, 1 \leq i \leq n_i \\ 0 & \text{lain-lain} \end{cases} \quad (3.12)$$

Berdasarkan penerangan di atas, langkah pengimplementasian algoritma MRPE ialah:

1. Beri nilai awalan kepada semua pemberat rangkaian, ambang, $P(0)$, a , b , $\alpha_m(0)$, λ_0 dan $\lambda(0)$. (b adalah parameter rekabentuk dan mempunyai nilai tipikal di antara 0.8 dan 0.9).
2. Masukkan data masukan kepada rangkaian dan cari keluaran rangkaian berdasarkan Persamaan (3.3).
3. Kira ralat ramalan menggunakan persamaan:

$$\varepsilon_k(t) = y_k(t) - \hat{y}_k(t) \quad (3.13)$$

Berdasarkan Persamaan (3.13), $y_k(t)$ ialah keluaran sasaran rangkaian.

4. Cari nilai matriks $\psi(t)$ menggunakan Persamaan (3.12). (Elemen $\psi(t)$ mesti dikira bermula dari lapisan keluaran turun ke lapisan tersembunyi).
5. Cari nilai matriks $P(t)$ dan $\lambda(t)$ masing-masing menggunakan Persamaan (3.10) dan (3.11).
6. Jika $\alpha_m(t) < b$, kemaskini nilai $\alpha_m(t)$ menggunakan Persamaan (3.7).
7. Kemaskini nilai $\alpha_g(t)$ dan $\Delta(t)$ masing-masing menggunakan Persamaan (3.8) dan (3.6).
8. Kemaskini nilai $\hat{\Theta}(t)$ menggunakan Persamaan (3.5).

9. Ulang Langkah (2) hingga (8) untuk setiap sampel data.

3.4 Metodologi dan Sampel Data

Seperti yang telah dibincangkan, kajian projek hanya tertumpu kepada pengklasifikasian spesies-spesies parasit malaria kepada 3 jenis iaitu 'Plasmodium falciparum', 'Plasmodium vivax' dan 'Plasmodium malariae'. Penyelidikan akan membangunkan dua rangkaian bagi melihat perbandingan antara rangkaian dan mengenalpasti rangkaian yang terbaik. Rangkaian yang dicadangkan ialah rangkaian MLP dengan menggunakan algoritma BP, LM dan BR dan rangkaian HMLP dengan menggunakan algoritma MRPE.

Bagi mengenalpasti keberkesanan rangkaian MLP dan HMLP sebagai teknik mendiagnosis parasit malaria, rangkaian-rangkaian tersebut perlu melalui 2 fasa iaitu fasa pembelajaran dan fasa ujian. Setiap rangkaian memerlukan bilangan nod tersembunyi dan bilangan data lalaran sebagai parameter masukan selain daripada masukan ciri-ciri parasit malaria. Bilangan nod tersembunyi dan lalaran data diperolehi daripada fasa latihan yang memberikan hasil yang optimum. Keputusan prestasi bagi setiap rangkaian berdasarkan kepada kejituan. Kejituan didefinisikan sebagai peratusan klasifikasi yang betul terhadap spesies malaria.

Dalam kajian ini, 600 sampel parasit malaria digunakan bagi proses pengklasifikasian parasit malaria. 186 sampel daripada keseluruhan adalah spesies 'Plasmodium falciparum', 210 sampel adalah spesies 'Plasmodium vivax' dan 204 sampel adalah spesies 'Plasmodium malariae'. Sampel data diperolehi daripada Hospital Universiti Sains Malaysia (HUSM).

3.5 Kesimpulan

Secara amnya, bab ini menerangkan tentang keseluruhan proses yang telah dijalankan di dalam penyelidikan ini. Proses kajian dimulakan dengan memilih spesis-spesis parasit malaria yang akan diklasifikasikan. Ciri-ciri parasit malaria bagi setiap spesis dikenalpasti dan dibandingkan bagi melihat perbezaan antara ciri dan akan dijadikan sebagai masukan kepada sistem yang dibangunkan. Rangkaian neural yang dibangunkan ialah rangkaian MLP dan HMLP. Rangkaian MLP telah terbukti berupaya dalam proses mengklasifikasikan data dengan tepat terutama dalam bidang perubatan. Rangkaian HMLP yang dicadangkan diramalkan mempunyai keupayaan yang lebih berbanding rangkaian MLP terutama daripada sudut kejituan. Keputusan kejituan bagi setiap rangkaian akan diperhatikan dan rangkaian yang memberikan kejituan ramalan yang lebih tinggi akan dipilih untuk diimplemenkan ke dalam sistem pengklasifikasian parasit malaria. Pembangunan sistem akan dilakukan menggunakan rangkaian neural terbaik bagi memperolehi satu pengkelasan yang mempunyai kadar ketepatan yang tinggi.

BAB 4

KEPUTUSAN DAN PERBINCANGAN

4.1 Pengenalan

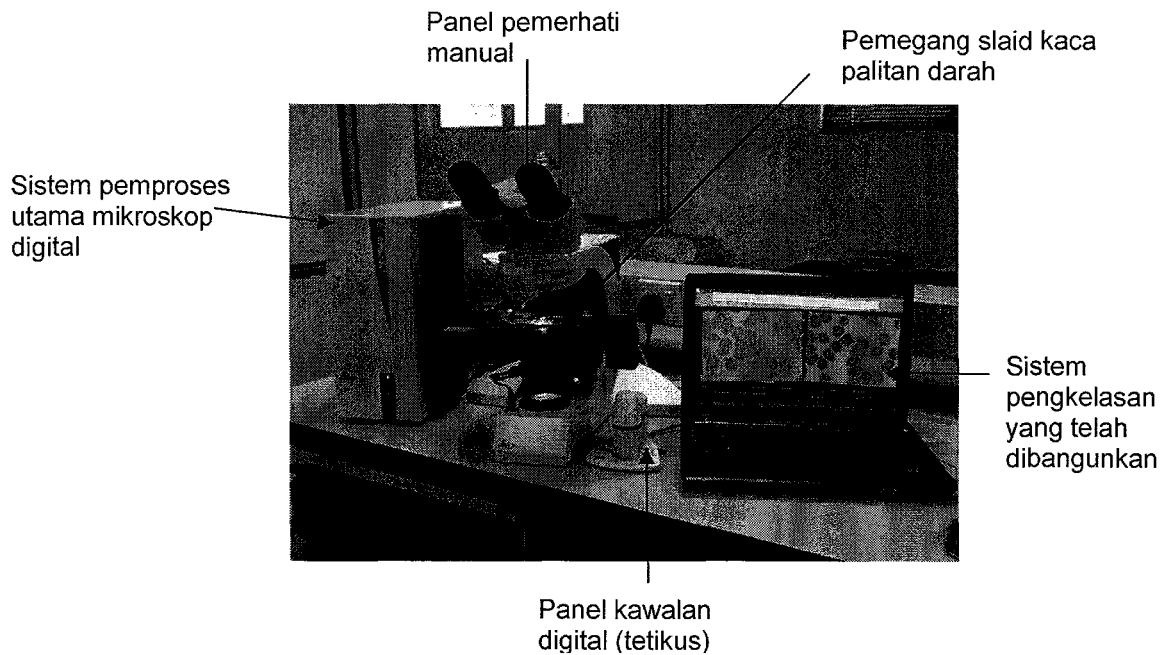
Di dalam bab ini, keputusan pembinaan sistem penangkapan imej parasit malaria dan pengklasifikasian jenis parasit malaria akan dibincangkan.

4.2 Keputusan

Penyelidikan bertumpu kepada dua sistem iaitu sistem penangkapan imej parasit malaria secara automatik dan sistem pengkelasan jenis parasit malaria. Kedua-dua sistem digabungkan bagi membentuk sebuah sistem lengkap yang beroperasi sepenuhnya, menangkap imej palitan darah dan seterusnya mengelaskannya kepada jenis-jenis parasit malaria.

4.2.1 Sistem penangkapan imej parasit malaria secara automatik

Sistem memerlukan perkakasan mikroskop digital bagi membolehkan integrasi antara aturaca dan alat penangkapan imej. Perkakasan mikroskop digital disambung kepada sistem yang dibangunkan seperti rajah 4.1.



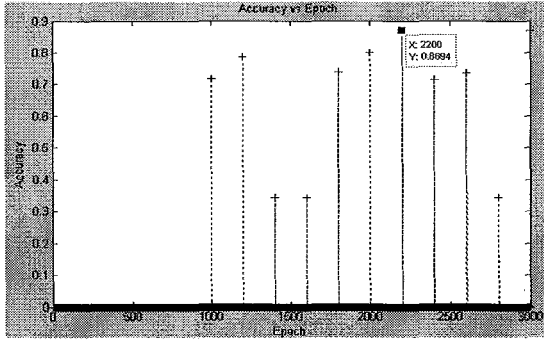
Rajah 4.1: Perkakasan mikroskop digital yang diintegrasikan bersama sistem penyelidikan

Rajah 4.1 menunjukkan gabungan sistem penangkapan imej secara automatik dan sistem pengkelasan parasit malaria. Mikroskop digital secara umumnya mempunyai sistem pemproses utama yang membolehkan mikroskop dikawal secara digital menggunakan komputer. Panel kawalan digital (tetikus) bertindak sebagai masukan kepada mikroskop digital. Tetikus ini beroperasi menggerakkan pemegang slaid kaca ke arah yang diinginkan pengguna. Panel pemerhati manual bertindak sebagai paparan imej selain daripada paparan imej di skrin komputer. Sistem penangkapan imej secara automatik iaitu dikawal sepenuhnya oleh sistem tanpa menggunakan tetikus sebagai masukan. Setelah slaid kaca imej palitan diletakkan di atas pemegang slaid, sistem dihidupkan dan imej pertama ditangkap. Imej ini akan disimpan di dalam sistem kedua iaitu sistem pengkelasan jenis malaria parasite di mana proses pengkelasan jenis-jenis parasit malaria akan dilakukan. Setelah proses ini

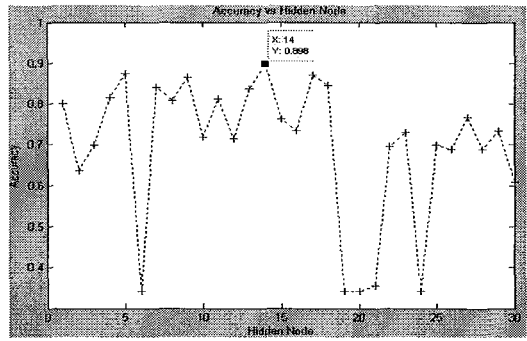
selesai, pemegang slaid kaca bergerak ke kiri bagi membolehkan penangkapan imej yang kedua dilakukan bersebelahan dengan imej yang telah ditangkap sebelum ini dan seterusnya dikelaskan kepada jenis-jenis parasit malaria. Proses ini berterusan sehingga sistem penangkapan imej secara automatik tersebut selesai menangkap dan mengelaskan semua imej daripada slaid kaca imej palitan tersebut. Setiap sel darah tidak akan terlepas daripada proses ini sehingga semua sel yang hadir pada imej palitan tersebut diproses.

4.2.2 Sistem Pengkelasan Parasit Malaria Secara Automatik

Dalam system pengkelasan, semua rangkaian neural ditetapkan bilangan lelaran data latihan dan bilangan nod tersembunyi optimum bagi memberikan kejitian pengkelasan yang maksimum. Analisis bagi mendapatkan bilangan lelaran data latihan yang optimum ditentukan terlebih dahulu dengan menetapkan bilangan nod tersembunyi sebanyak 10. Bilangan lelaran data latihan yang optimum ditentukan dengan menambah lelaran data latihan satu persatu sehingga prestasi kejitian yang maksimum diperolehi. Setelah ditetapkan lelaran data latihan, bilangan nod tersembunyi akan ditambah satu persatu sehingga prestasi kejitian yang optimum diperolehi. Analisis ini dilakukan kepada rangkaian MLP dan HMLP. Bagi analisis menggunakan rangkaian MLP, keputusan bilangan data lelaran dan bilangan nod tersembunyi ditentukan daripada Rajah 4.2, Rajah 4.3 dan Rajah 4.4.




(a) Data lelaran

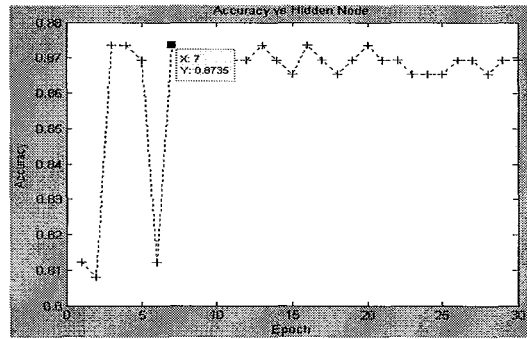


(b) Nod tersembunyi

Rajah 4.2 : Prestasi rangkaian MLP menggunakan algoritma 'Back Propagation' (BP)




(a) Data lelaran

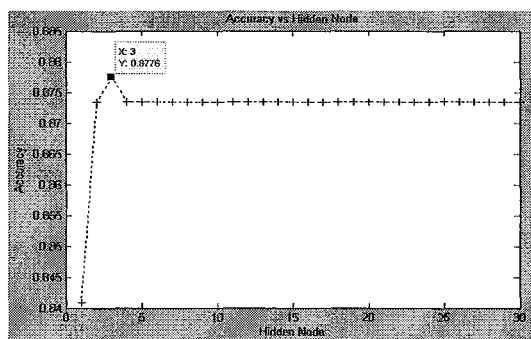


(b) Nod tersembunyi

Rajah 4.3 : Prestasi rangkaian MLP menggunakan algoritma 'Levenberg-Marquardt' (LM).



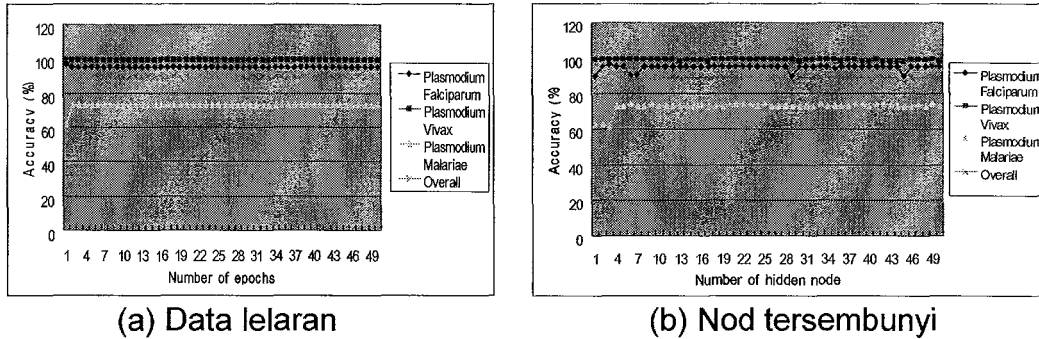
(a) Data lelaran



(b) Nod tersembunyi

Rajah 4.4 : Prestasi rangkaian MLP menggunakan algoritma 'Bayesian rule' (BR).

Bagi analisis menggunakan rangkaian HMLP, keputusan bilangan data lelaran dan bilangan nod tersembunyi ditentukan daripada Rajah 4.5.



Rajah 4.5 : Prestasi rangkaian HMLP menggunakan algoritma MRPE.

Daripada rajah 4.2, rangkaian MLP menggunakan algoritma BP menunjukkan prestasi optimum pada data lelaran 14 dan bilangan nod tersembunyi sebanyak 2200. Rangkaian MLP menggunakan algoritma LM menunjukkan prestasi optimum pada data lelaran 100 dan bilangan nod tersembunyi sebanyak 7 dan rangkaian MLP menggunakan algoritma BR menunjukkan prestasi optimum pada data lelaran 1000 dan bilangan nod tersembunyi sebanyak 3. Rangkaian HMLP yang menggunakan algoritma MRPE memberikan prestasi yang optimum pada data lelaran 2 dan bilangan nod tersembunyi sebanyak 10. Ringkasan bagi data lelaran dan bilangan nod tersembunyi bagi setiap algoritma MLP dan HMLP dipaparkan seperti Jadual 4.1.

Jadual 4.1: Bilangan nod tersembunyi dan data lelaran bagi MLP dan HMLP

Rangkaian	Bilangan nod tersembunyi	Bilangan data lelaran
MLP dengan BP	2200	14
MLP dengan LM	7	100
MLP dengan BR	3	1000
HMLP dengan MRPE	10	2

Keputusan kejitian rangkaian MLP yang dilatih menggunakan algoritma BP, LM dan BR dan rangkaian HMLP yang dilatih menggunakan algoritma MRPE keatas imej palitan darah ditunjukkan seperti Jadual 4.2.

Jadual 4.2: Keputusan kejitian rangkaian MLP dan HMLP

Rangkaian	Kejitian
MLP dengan BP	89.80%
MLP dengan LM	87.35%
MLP dengan BR	87.76%
HMLP dengan MRPE	89.50%

4.3 Perbincangan

Berdasarkan kepada Jadual 4.1, rangkaian MLP menggunakan algoritma BP hanya memerlukan 14 lelaran data sahaja untuk mencapai prestasi optimum tetapi memerlukan bilangan nod tersembunyi yang tinggi iaitu sebanyak 2200. Namun begitu, Jadual 4.2 menunjukkan bahawa rangkaian MLP menggunakan BP berupaya mengelaskan data-data ujian setinggi 89.80%. Walaupun kejituan rangkaian ini tinggi dan kadar penumpuan yang pantas, ia mempunyai keupayaan pengitlakan yang rendah kerana rangkaian memerlukan bilangan nod tersembunyi yang tinggi. Secara tidak langsung, data ujian yang boleh diaplikasikan menggunakan rangkaian MLP jenis ini tidak menyeluruh terutama bagi data yang mempunyai bilangan nod tersembunyi yang sedikit.

Bagi rangkaian MLP menggunakan LM dan BR, keputusan menunjukkan peratusan kejituan yang hampir sama bagi kedua-duanya iaitu 87.35% dan 87.76%. Kedua-dua algoritma memerlukan bilangan nod tersembunyi sebanyak 7 dan 3 dan bilangan lelaran data sebanyak 100 dan 1000 bagi mencapai prestasi optimum. Secara umumnya, walaupun rangkaian MLP menggunakan BR mempunyai kejituan yang lebih tinggi berbanding MLP menggunakan LM dan memerlukan bilangan nod tersembunyi yang lebih sedikit, namun kadar penumpuannya sangat perlahan kerana ia memerlukan data lelaran sebanyak 1000 untuk mencapai prestasi optimum.

Bagi rangkaian HMLP menggunakan MRPE, peratusan kejituan yang tinggi iaitu sebanyak 89.50% memberikan prestasi pengitlakan yang kedua terbaik selepas rangkaian MLP menggunakan BP. Walaupun rangkaian HMLP memberikan peratusan kedua terbaik namun rangkaian tersebut hanya memerlukan bilangan nod tersembunyi

sebanyak 10 dan bilangan data lelaran sebanyak 2 untuk mencapai prestasi optimum berbanding rangkaian MLP menggunakan BP yang memerlukan bilangan nod tersembunyi sebanyak 2200 dan bilangan data lelaran sebanyak 14. Secara umumnya, rangkaian HMLP boleh melakukan pengkelasan tanpa memerlukan kriteria yang terlalu banyak berbanding rangkaian MLP yang menggunakan BP. Rangkaian HMLP menunjukkan kadar penumpuan yang tertinggi berbanding kesemua rangkaian MLP. Ini menunjukkan bahawa rangkaian HMLP beroperasi dengan masa yang singkat dan memberikan keputusan pengkelasan yang paling jitu berbanding rangkaian-rangkaian MLP.

Secara keseluruhan, didapati bahawa rangkaian HMLP mencapai prestasi kejituan optimum sebanyak 89.50%, iaitu prestasi kejituan yang terbaik di antara kesemua rangkaian neural yang digunakan. Begitu juga dengan struktur rangkaian yang dibangunkan, rangkaian HMLP mampu menumpu dengan pantas pada 2 lelaran data sahaja. Berdasarkan prestasi kejituan pengkelasan yang dilakukan, rangkaian HMLP mempunyai kemampuan untuk melakukan pengkelasan yang tepat dengan kejituan pengkelasan yang tinggi. Oleh itu, rangkaian HMLP dipilih untuk digunakan ke dalam sistem penentuan jenis parasit malaria yang dibina.

4.4 Kesimpulan

Keputusan bagi sistem penangkapan imej palitan darah secara automatik memberikan kesan yang sangat mendalam dalam memudahkan sistem pengkelasan jenis parasit malaria beroperasi dengan cepat tanpa memerlukan pantauan yang kerap daripada pengguna. Sistem penangkapan imej secara automatik hanya boleh

dibangunkan daripada perkakasan yang sesuai seperti mikroskop dan komputer. Sistem mikroskop digital juga boleh dan sesuai diintegrasikan bersama sistem lain yang dibangunkan tanpa memberikan masalah kepada sistem dan perkakasan.

Keputusan yang diperolehi juga menunjukkan, antara rangkaian MLP, penggunaan 'Back Propagation' memberikan prestasi yang terbaik berbanding 'Levenberg-Marquardt' dan 'Bayesian Rule'. Berdasarkan kepada keputusan tersebut, MLP terbukti sesuai diimplementasikan untuk mengkelaskan parasit malaria kepada 3 spesis (*Plasmodium Vivax*, *Plasmodium Falciparum* dan *Plasmodium Malariae*). Walaubagaimanapun, rangkaian HMLP terbukti lebih berkesan dan memberikan prestasi yang lebih baik berbanding semua jenis rangkaian MLP. HMLP dan MLP terbukti dapat mengkelaskan parasit-parasit malaria berasaskan 6 ciri iaitu saiz sel darah merah yang telah dijangkiti per saiz normal sel darah merah, bentuk parasit, bilangan kromatin, bilangan parasit per sel darah merah, tekstur sel darah merah dan kedudukan kromatin bagi parasit.

Secara keseluruhannya, penggunaan spesis parasit malaria ke dalam rangkaian neural jelas menunjukkan bahawa ciri-ciri spesis parasit malaria sesuai dijadikan sebagai parameter masukan. Berdasarkan kepada keputusan yang diperolehi, penggunaan rangkaian neural ke dalam sistem pintar telah berjaya memberikan kejituan pengkelasan yang baik.

BAB 5

KESIMPULAN

5.1 Kesimpulan

Di dalam penyelidikan ini, sistem penangkapan imej palitan darah secara automatik dan sistem pengkelasan jenis parasit malaria berdasarkan ciri-ciri sel parasit malaria menggunakan rangkaian neural telah berjaya dibangunkan. Kedua-dua sistem ini kemudiannya digabungkan menjadi sistem utama dalam proses pengkelasan jenis-jenis parasit malaria. Sistem penangkapan imej secara automatik yang terdiri daripada perkakasan mikroskop digital sebagai perkakas utama berjaya dibangunkan dan digabungkan bersama sistem pengkelasan jenis parasit malaria. Terdapat 6 ciri sel seperti yang dibincangkan di dalam bab 3 (saiz sel darah merah yang telah dijangkiti per saiz normal sel darah merah, bentuk parasit, bilangan kromatin, bilangan parasit per sel darah merah, tekstur sel darah merah dan kedudukan kromatin bagi parasit) berjaya dijadikan sebagai masukan kepada sistem rangkaian neural. Sistem ini berkemampuan untuk melakukan pengkelasan parasit malaria kepada 3 spesis dengan kejituan yang tinggi. Pembangunan sistem ini dapat membantu memudahkan bidang perubatan dalam menentukan dan mengklasifikasikan spesis parasit malaria.

Kajian ini telah menggunakan rangkaian perseptron berbilang lapisan (MLP) yang dilatih oleh tiga jenis algoritma iaitu algoritma perambatan belakang (BP), Lavenberg Marquardt (LM) dan Bayesian Regularization (BR) tetapi keseluruhan keputusan yang diperolehi adalah kurang baik berbanding rangkaian perseptron

berbilang lapisan hibrid (HMLP). Rangkaian HMLP yang dibangunkan berjaya memberi keupayaan pengkelasan yang lebih baik berbanding MLP.

Penyelidikan ini mencadangkan penggunaan analisis rangkaian HMLP dengan menggunakan algoritma MRPE bagi mengkelaskan spesis-spesis parasit malaria. Sebelum rangkaian HMLP boleh diaplikasikan, bilangan nod tersembunyi dan bilangan data lelaran perlu dikenalpasti dan ditentukan apabila ujian rangkaian latihan HMLP mencapai prestasi yang optimum. Proses ini perlu bagi rangkaian HMLP memberikan kejituan yang tinggi dan cepat. Keputusan yang diperolehi di dalam bahagian 4.2 telah membuktikan bahawa rangkaian HMLP hanya memerlukan data lelaran sebanyak 2 bagi dan bilangan nod tersembunyi sebanyak 10 bagi menghasilkan kejituan yang lebih tinggi berbanding rangkaian MLP. Walaupun rangkaian MLP memberikan kejituan yang tinggi, namun ada di antara rangkaian yang memerlukan data lelaran yang terlalu banyak dan bilangan nod yang terlalu tinggi. Oleh itu, rangkaian MLP yang digunakan boleh diklasifikasikan sebagai kurang upaya berbanding dengan rangkaian HMLP secara keseluruhannya. Secara umumnya, keputusan yang diperolehi telah berjaya mencapai objektif-objektif penyelidikan iaitu:

1. Membina satu sistem penangkapan imej automatik bagi parasit malaria dan digabungkan bersama sistem pengkelasan jenis parasit malaria.
2. Mengklasifikasikan jenis parasit malaria kepada tiga jenis spesis iaitu Parasit Plasmodium falciparum, parasit Plasmodium vivax dan parasit Plasmodium malariae.
3. Membuktikan bahawa enam ciri parasite malaria (saiz darah merah yang dijangkiti per saiz darah merah normal, bentuk parasit, bilangan

chromatin, bilangan parasit didalam sel darah merah, tekstur sel darah merah dan kedudukan chromatin bagi parasit) dari “thin blood smear” sesuai dan boleh dijadikan sebagai parameter masukan kepada rangkaian neural.

4. Membina satu sistem pengkelasan jenis parasite malaria menggunakan rangkaian HMLP dengan peratus kejituan mencapai 88.50%.

RUJUKAN

- [1] S, Jayavanth & M. Singh, "Artificial Neural Network Analysis of malaria Severity Through Aggregation and Deformability Parameters of Erythrocytes", *Clinical Hemorheology and Microcirculation*, 29(3-4), 2003, pp. 457-468.
- [2] C. Y. Gao, H. Y. Xiong, D. Yi, G. J. Chai, X. W. Yang, L. Liu, "Study on Meteorology Factor-based Neural Network Model of Malaria", *Zhonghua liuxingbingxue zazhi*, 24(9), 2003, pp. 831-834.
- [3] A. Reinhardt and T. Hubbard, "Using Neural Network for Prediction of the Subcellular Location of Proteins", *Nucleic Acids Research*, 26(9), 1998, pp. 2230-2236.
- [4] A. Bender, G. G. Van Dooren, S. A. Ralph, G. I. McFadden, G. Schneider, "Properties and Prediction of Mitochondrial Transits Peptides from Plasmodium Falciparum", *Molecular and Biochemical Parasitology*, 132(2), 2003, pp. 59-66.
- [5] M. Y. Mashor, M. K. Osman and M. R. Arshad, "3D Object Recognition Using 2D Moment and HMLP Networks", *Proceeding of the International Conference on Computer Graphics, Imaging and Visualization*, 2004, pp. 126-130.
- [6] Citing internet sources URL:
http://www.netdoctor.co.uk/travel/disease/malaria_disease.htm
- [7] Citing internet sources URL:<http://www.emedicine.com/med/byname/malaria.htm>
- [8] Chang, C. Y. & Chung, P. C. (1999). A Contextual-Constraint Based Hopfield Neural Cube for Medical Image Segmentation. *Proc. of The IEEE Region 10 Conf. on TENCN*. 2. 1170-1173.
- [9] Li, Z. & Najarian, K. (2001). Automated Classification of Pap Smear Tests Using Neural Networks. *Proc. of Int. Joint Conf. on Neural Networks*. 4. 2899-2901.
- [10] Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. New Jersey: Prentice Hall.
- [11] Pardo, M., Sberveglieri, G., Gardini, S. & Dalcanale, E. (2000) A Hierarchical Classification Scheme for An Electronic Nose. *Sensor and Actuators B*. 69. 359-365.
- [12] Jayasuriya, T. D., Yaacob, S. & Nagarajan, R. (2002). An Intelligent Control System Employing Neural Adaptive Feedback Linearization. *Proc. of Int. Conf. on Artificial Intelligence in Engineering and Technology*. 140-145.

- [13] Mamat, M. & Mashor, M. Y. (2001). Image Compression Using Multilayered Perceptron Network. *Proc. of Student Conf. on Research and Development (SCOReD)*. 151.
- [14] Christoyianni, I., Dermatas, E. & Kokkinakis, G. (1999). Neural Classification of Abnormal Tissue in Digital Mammography Using Statistical Features of The Texture. *Proc. of The 6th IEEE Int. Conf. on Electronics, Circuits and Systems*. 1. 117-120.
- [15] Mashor, M. Y. (2000b). Hybrid Multilayered Perceptron Networks. *Int. J. of System Science*. 31(6). 771-785.
- [16] Hush, D. R. & Horne, B. G. (1993). Progress in Supervised Neural Networks. *IEEE Signal Processing Magazine*. 8-39.
- [17] Ng, E. Y. K., Peh, Y. C., Fok, S. C., Ng, F. C. & Sim, L. S. J. (2002). Early Diagnosis of Breast Cancer Using Artificial Neural Network with Thermal Images. *Proc. of Kuala Lumpur Int. Conf. on Biomedical Engineering*. 62-65.
- [18] Wahap, A. R., Khalid, M., Ahmad, A. R. & Yusof, R. (2002). A Neural Network Based Bank Cheque Recognition System for Malaysian Cheques. *Proc. of Int. Conf. on Artificial Intelligence in Engineering and Technology*. 273-279.
- [19] Janahiraman, T., Tay, Y. H., Khalid, M. & Yusof, R. (2002). Classification of Handwritten Digits Using Geometrical and Topological Feature Extraction Technique and Neural Network. *Proc. of Int. Conf. on Artificial Intelligence in Engineering and Technology*. 291-297.
- [20] Harun, S., Kassim, A. H. M. & Nor, N. I. A. (2002). Application of Neural Network Method for Rainfall-Runoff Modeling. *Proc. of Int. Conf. on Artificial Intelligence in Engineering and Technology*. 333-337.
- [21] Principe, J. C., Euliano, N. R & Lefebvre, W. C. (2000). *Neural and Adaptive Systems: Fundamentals Through Simulations*. New York: John Wiley & Sons.
- [22] Rughooputh, H. C. S. & Rughooputh, S. D. D. V. (1999b). EKF Learning Algorithm For The Quaternion-Valued Multi-Layered Perceptron Neural Network. *Proc. of The Int. Conf. on Robotics, Vision and Parallel Processing for Automation*. 1. 117-122.
- [23] Chen, S., Cowan, C. F. N., Billings, S. A., & Grant, P. M. (1990a). A Parallel Recursive Prediction Error Algorithm for Training Layered Neural Networks. *Int. J. of Control*. 51(6). 1215-1228.

- [24] Billings, S. A. & Chen, S. (1995) Neural Networks and System Identification. Dalam *Neural Network Application in Control* (Irwin, G. W., Warwick, K. & Hunt, K. J. ed.). 229-251. London: The Institution of Electrical Engineers.

LAMPIRAN C

PENERBITAN

International Society for Advanced Research

**Emerging Technologies,
Robotics and Control Systems
Volume 2**



Editor: Salvatore Pennacchio

www.internationalsar.org

Table of Contents

Microrobotic Technologies for Biological Micro-Nanohandling Jordi Brufau Penella, Jorge Otero Díaz, Manel Puig Vidal	9
Mechanical Design of Joint Braking and Underactuated Mechanism of “Tri-Star3”; Horizontal Polyarticular Arm Equipped 3-Wheeled Expandable Mobile Robot Kenjiro Tadakuma, Masatsugu Matsumoto, Shigeo Hirose	17
Smart Sensor Based Vision System for Automated Processes Antonis Argyros, Gusztáv Bártfai, Christian Eitzinger, Zsolt Kemény, Balázs Csanád Csáji, László Kék, Manolis Lourakis, Werner Reisner, Wolfgang Sandrisser, Thomas Sarmis, Gerald Umgeher, Zsolt János Viharos	24
Transport Network Feasible Solutions in Market-based Allocation of Flow Resources Koen Kok, Hans Akkermans	30
Neuro-quantum networks: classical basics Tigran Ambaryan	38
Control of a 6 DOF Parallel Manipulator using Rapid Prototyping J. M. Rosario, M. Moretti, D. Dumur	42
Experimental Environment for Teaching Integrated Systems using low-cost Mobile Robots H. F. Filho, R. Pegoraro, M. A. C. Caldeira, J. M. Rosario	50
Fuzzy and Neuronal Control to Flexible Manipulator Efren Gorrostieta, Juan Manuel Ramos, J. Carlos Pedraza	56
An Implementation of a Fault Detection and Isolation System on Foundation Fieldbus Environment Diego R. C. Silva, Raphaela G. Fernandes, Luiz A. H. G. de Oliveira, Adrião D. D. Neto	62
Hammerstein system identification by means of orthonormal basis functions and radial basis functions Rafał Stanisławski	69

Robust Stability and Performance in a Non-conventional Observer-Compensator Scheme R. Galindo	74	Classification of Malaria Parasite Species Based on Thin Blood Smears Using Hybrid Multilayered Perceptron Network (HMLP) Noorhidayati Abu Seman, Nor Ashidi Mat Isa, Zeehaida Mohamed, Umi Kalthum Ngah, Kamal Zuhairi Zamli	168
Yaw-based Control of a X4-bidirectional Flyer Planar Motion Rhouma Mlayeh, Lotfi Beji, Azgal Abichou	83	Swarm-Based Cooperative Control for a Group of Mobile Robots Q. P. Ha, N. M. Kwok	174
Efficient Electromagnetic Field Level Prediction using Neural Models Bratislav Milovanović, Zoran Stanković, Marija Milijić	89	A Topological Path Layout for Autonomous Navigation of Multi-sensor Robots F. Ferreira, V. Santos, J. Dias	191
A neuro-fuzzy control of a three levels inverter fed induction motor M. Bendjebbar, M. Zerikat, A. Bendiabdellah	96	Intelligent Control of the Perceptual System for Partner Robots Naoyuki Kubota, Kenichiro Nishida	204
Robust Vision Landmark Acquisition and Data Association for an Autonomous Mobile Robot R. Vázquez-Martín, P. Núñez, R. Marfil, A. Bandiera, F. Sandoval	102	The use of Improved Root-MUSIC Frequency estimation method for three phase induction motor incipient rotor's faults detection A. H. Boudinar, N. Benouzza, A. Bendiabdellah, N. Boughanmi	210
Managing Data Association in visual SLAM using SIFT features Arturo Gil, Óscar Reinoso, Luis Payá, Mónica Ballesta, José M. Pedrero	108	Mobile Robot Local Predictive Control Using a Visual Perception Horizon Lluis Pacheco, Ningsu Luo	217
A Numerical Study on Stabilization of Distributed Parameter Overhead Crane Models Masashi Otanaka, Hideki Sano	114		
Bearing Fault Diagnosis in Asynchronous Machine Based on Current Analysis Using High-Resolution Technique Mounir Djeddi, Pierre Granjon, Benoit Leprettre, Boukhemis Chetate	120		
Bio-inspired Navigation of Autonomous Robots in Heterogenous Environments Schmickl Thomas, Möslinger Christoph, Thenius Ronald, Crailsheim Karl	126		
A Robust Approach to the Minimum Variance Control of LTI MIMO Systems Wojciech P. Hunek	133		
Visual Perception Theory Underlying Perceptual Navigation Özer Ciftcioglu, Michael S. Bittermann, I. Sevil Sariyildiz	139		
Automatic Theorem Proving: Situation Management and Decision Making Jaroslav E. Poliscuk	154		

Classification of Malaria Parasite Species Based on Thin Blood Smears

Using Hybrid Multilayered Perceptron Network (HMLP)

NOORHIDAYATI ABU SEMAN¹, NOR ASHIDI MAT ISA², ZEEHAIDA MOHAMED^{**},
UMI KALTHUM NGAH³, KAMAL ZUHAI RI ZAMLI⁴

¹School of Electrical & Electronic Engineering,
Universiti Sains Malaysia, Engineering Campus,
14300, Nibong Tebal, Pulau Pinang,
MALAYSIA.

¹Email: noorhidayati82@yahoo.com

²Tel: +6045996051, Fax: +6045941023, Email: ashidi@eng.usm.my

³Tel: +6045996022, Fax: +6045941023, Email: umi@eng.usm.my

⁴Tel: +6045996079, Fax: +6045941023, Email: eekamal@eng.usm.my

^{**}School of Medical Sciences,
Universiti Sains Malaysia, Health Campus,
16150 Kubang Kerian, Kelantan,
MALAYSIA.

Email: zeehaida@kck.usm.my

Abstract: This study proposes an application of the HMLP network to classify the malaria parasite into three species, namely *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*. Six features (i.e. size of RBC infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite) from thin blood smear are used as input data. In order to determine the suitability of the HMLP network, the MRPE training algorithm is employed to train the HMLP network. In this study, the HMLP network trained using the MRPE algorithm produced a good performance with 90% and 89.50% accuracy in the training and testing phase respectively. The HMLP network with the MRPE training algorithm produced the highest accuracy to classify *Plasmodium vivax* species compared to the

Plasmodium falciparum and *Plasmodium malariae*. The accuracy the training and testing phase for *Plasmodium vivax* is 99% and 99.10% respectively. The results show the promising use of the HMLP network for malaria parasite classification.

Key- Words:- Neural network, MRPE algorithm, malaria parasite, HMLP network, pattern recognition.

1.0 INTRODUCTION

Malaria is one of the leading causes of death in the world. It is estimated that there are 300-500 million new cases every year, with 1.5 to 2.7 million deaths worldwide [1]. Malaria is a common and serious infection caused by four species of the genus *Plasmodium*, namely *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium ovale* and

Plasmodium malariae [2]. The malarial parasite, *Plasmodium*, is a small, single-cell blood organism or protozoan which lives as a parasite in the human body, often carried by a species of mosquito named *Anopheles* [1]. Currently, there are two commonly used tests to detect the malaria parasite which are the thick and thin blood smears. The thin blood smear permits the identification of the malaria parasite species, while the thick blood smear enables the density determination of the malaria parasite per microliter of red blood cells (RBC).

Artificial neural networks are studied and applied in various disciplines such as neurobiology, psychology, computer science, cognitive science, engineering, economics, medicine, etc. One of the applications of neural networks in medical field is the detection of malaria parasites. Jayavanth and Singh [3] employed artificial neural network to analyze malaria severity through aggregation and deformability parameters of erythrocytes. The research demonstrated that malaria with high severity was successfully classified with 100% accuracy. In the case of non-severe and mildly-severe malaria, successful classification was found to be in the range of 60% to 80%. Gao et. al [4] claimed that neural network was effective for forecasting malaria. In their study, the neural network produced promising results with efficiency of 84.85%. The study also demonstrated that neural networks provided several advantages such as having strong ability for analysis, lower claim for data, convenient and easy to apply. Neural networks have also been used to predict the subcellular location of proteins in prokaryotic or eukaryotic cells from their amino acid composition [5]. Another application for the neural network approach was for the prediction of mitochondrial transit peptides (mTPs) from the malaria-causing parasite *Plasmodium falciparum* was presented in the work by Bender et. al [6].

As neural network supports generalization, robustness and parallel implementation paradigm properties, it becomes a popular choice in object or

pattern recognition [7][8]. One of the popular neural networks is multilayered perceptron (MLP) network. However, in the year 2000, Mashor has introduced the hybrid multilayered perceptron (HMLP) network that can significantly improve the performance of the MLP network [9].

The HMLP network has been applied in pattern recognition as the classification system. Mashor et al. employed the HMLP network to classify 3D object using 2D moment [7]. The proposed system achieved the recognition accuracy of up to 100%. For the cervical cancer application with image processing, Mat-Isa et al. used the HMLP network in cervical cancer classification [8]. The HMLP had successfully classified the type of cervical cells with high percentage in both training and testing phase. In the current study, the HMLP network was considered and used to classify the type of malaria parasite into three categories, (i.e. *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*). The HMLP network was trained using modified recursive prediction error (MRPE) algorithm.

2.0 HYBRID MULTILAYERED PERCEPTRON

The MLP network is a highly nonlinear neural network. Thus, modeling a linear system using a nonlinear model (i.e. the MLP network) can never be better than using a linear model. Therefore, Mashor proposed additional linear input connections to the MLP network, which forms a modified version of MLP called hybrid multilayered perceptron (HMLP) network. The HMLP network allows the network inputs to be connected directly to the output nodes via weighted connections to form a linear model, which is in parallel with the non-linear MLP model [9]. Further explanation on the HMLP network is taken from Mashor [9]. Figure 1 shows an example of a HMLP network with one hidden layer, six inputs, v1, v2, v3, v4, v5, v6 and three outputs, y1, y2, y3

which represent the three types of malaria parasite.

As shown in Figure 1, for the HMLP network with m output nodes, n_h hidden nodes and n_i input nodes, the output of the k -th neuron, y_k , in the output layer is given by:

$$\hat{y}_k(t) = \sum_{j=1}^{n_h} w_{jk}^2 F\left(\sum_{i=1}^{n_i} w_{ij}^1 v_i(t) + b_j\right) + \sum_{i=0}^{n_i} w_{ik}^0 v_i^0(t) \quad (2.1)$$

for $1 \leq k \leq m$

where w_{ij}^1 , w_{jk}^2 and w_{ik}^0 denote the weights of the connection between input and hidden layer, weights of the connection between hidden and output layer, and weights of the linear connection between input and output layer respectively. b_j and v_i^0 denote the

thresholds in hidden nodes and inputs that are supplied to the input layer respectively. $F(\bullet)$ is an activation function and is normally be selected as sigmoid function, which is given by:

$$F(v(t)) = \frac{1}{1 + e^{-v(t)}} \quad (2.2)$$

The weights w_{ij}^1 , w_{jk}^2 , w_{ik}^0 and threshold b_j are unknown and should be selected to minimize the prediction errors, defined as:

$$\mathcal{E}_k(t) = y_k(t) - \hat{y}_k(t) \quad (2.3)$$

where $y_k(t)$ is the actual output and $\hat{y}_k(t)$ is the network output.

In the current study the weights and threshold is determined using the MRPE algorithm [10]. The MRPE is a modified version of recursive prediction error (RPE) algorithm. The RPE and MRPE are based on Gaussian-Newton type algorithm that generally provides better performance than a steepest type algorithm such as back propagation [10],[11],[12]. The complete explanation on the MRPE algorithm can be found in [9].

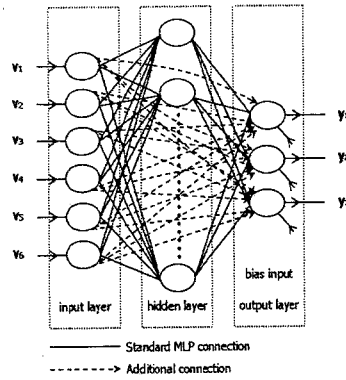


Figure 1: Hybrid multilayered perceptron network.

3.0 METHODOLOGY AND DATA SAMPLES

The malaria parasites, Plasmodium are classified into 4 species namely *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium ovale* and *Plasmodium malariae*. However, only three species of malaria parasite are encountered in Malaysia, i.e. *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*. *Plasmodium vivax* causes severe morbidity but is rarely fatal, while *Plasmodium falciparum* is the most virulent species of malaria since it can result in death to the host. As discussed earlier, there are two tests to detect the malaria parasite; i.e. thick and thin blood smears. This study focuses on classification of three species of malaria parasite; i.e. *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae* from the thin blood smears.

To determine the suitability of the HMLP network as part of malaria parasite diagnosis technique, the HMLP network needs to go through training and testing phase. During both phases, the optimum structure and diagnosis performance of the HMLP networks is determined. The analysis of diagnosis performance of the HMLP network is based on accuracy. Accuracy is defined as the probability


that the type of malaria parasite is determined correctly.

In the current study, 600 cells of malaria parasite (186 cells of *Plasmodium falciparum*, 210 cells of *Plasmodium vivax* and 204 cells of *Plasmodium malariae*) are used in classifying malaria parasite using the HMLP network. The data are taken from Microbiology Department, Hospital Universiti Sains Malaysia (HUSM). For each cell, six extracted features will be used as input data to the HMLP network. The features are the size of RBC infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite. 300 cells of malaria parasite (100 cells of *Plasmodium falciparum*, 100 cells of *Plasmodium vivax* and 100 cells of *Plasmodium malariae*) are used as training data while another 300 cells of malaria parasite (86 cells of *Plasmodium falciparum*, 110 cells of *Plasmodium vivax* and 104 cells of *Plasmodium malariae*) are used as testing data.


4.0 RESULT AND DISCUSSION

The optimum number of hidden node and number of training epochs are obtained when the HMLP network achieves the highest performance. Figures 2(a) and (b) show the diagnosis performance of the HMLP network versus different number of epochs in the training and testing phase respectively. From the graph, the HMLP network produced the highest performance when it was trained with 2 epochs.

Determination of the optimum hidden nodes of the HMLP network is done based on the results shown in Figures 3(a) and (b). Figures 3(a) and (b) show the diagnosis performance of the HMLP network during training and testing phase respectively. The HMLP network using the MRPE algorithm achieves the highest performance at 10 hidden nodes.




(a) Training phase




(b) Testing phase

Figure 2: Diagnosis performance of the HMLP network for different number of epochs.



(a) Training phase



(b) Testing phase

Figure 3: Diagnosis performance of the HMLP network for different number of hidden nodes.

After the HMLP network has been trained using the MRPE algorithm, the results in Figures 2 and 3 show that the HMLP network needed 10 hidden nodes and 2 training epochs to produce optimum diagnosis performance. After obtaining the optimum structure for the network, the performance of the HMLP network is determined. Table 1 shows the

performance of the HMLP network during training and testing phase to classify the three types of malaria parasite. The result shows that HMLP network with the MRPE training algorithm produces the overall accuracy of 90% and 89.50% to classify the malaria parasite into the three types in the training and testing phase respectively. Accuracy for each type of malaria parasite (*Plasmodium Vivax*, *Plasmodium Falciparum* and *Plasmodium Malariae*) in both training and testing phase are 98%, 99%, 73%, 95.3488%, 99.10% and 74.04%. *Plasmodium Vivax* produced the highest accuracy as compared to *Plasmodium Falciparum* and *Plasmodium Malariae*.

Table 1: Diagnosis performance of the HMLP network.

Parasite Type	Accuracy	
	Training	Testing
<i>Plasmodium Falciparum</i>	98.00%	95.35%
<i>Plasmodium Vivax</i>	99.00%	99.10%
<i>Plasmodium Malariae</i>	73.00%	74.04%
Overall	90.00%	89.50%

5.0 CONCLUSION

The HMLP network trained using the MRPE algorithm has been proposed to classify malaria parasite into the three types namely the *Plasmodium Falciparum*, *Plasmodium Vivax* and *Plasmodium Malariae*. Six features extracted from thin blood smear samples, which are the size of RBC infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite have been used as the HMLP network input data. The HMLP network trained by the MRPE training algorithm produced the overall accuracy 90% in the training phase and 89.50% in the testing phase. These results show that the HMLP network is able to classify the malaria parasite into the three types.

ACKNOWLEDGEMENT

This work is supported by the Universiti Sains Malaysia under short term grant entitled 'Development of Electronic Intelligent Screening System for Malaria Parasite'.

REFERENCES

- [1] Citing internet sources URL: http://www.netdoctor.co.uk/travel/diseases/malaria_disease.htm
- [2] Citing internet sources URL: <http://www.emedicine.com/med/byname/malaria.htm>
- [3] S. Jayavanth, & M. Singh, "Artificial Neural Network Analysis of malaria Severity Through Aggregation and Deformability Parameters of Erythrocytes", *Clinical Hemorheology and Microcirculation*, 29(3-4), 2003, pp. 457 – 468.
- [4] C. Y. Gao, H. Y. Xiong, D. Yi, G. J. Chai, X. W. Yang, L. Liu, "Study on Meteorological Factors-based Neural Network Model of Malaria", *Zhonghua liuxingbingxue zazhi*, 24(9), 2003, pp. 831-834.
- [5] A. Reinhardt and T. Hubbard, "Using Neural Networks for Prediction of the Subcellular Location of Proteins", *Nucleic Acids Research*, 26(9), 1998, pp. 2230-2236.
- [6] A. Bender, G. G. Van Dooren, S. A. Ralph, G. I. McFadden, G. Schneider, "Properties and Prediction of Mitochondrial Transit Peptides from *Plasmodium Falciparum*" *Molecular and Biochemical Parasitology*, 132(2), 2003, pp. 59-66.
- [7] M. Y. Mashor, M. K. Osman and M. R. Arshad, "3D Object Recognition Using 2D Moments and HMLP Networks", *Proceeding of the International Conference on Computer Graphics, Imaging and Visualization*, 2004, pp. 126-130.
- [8] N. A. Mat-Isa, M. Y. Mashor and N. H. Othman, "Classification of Cervical Cancer Cells using

HMLP Network with Confidence Percentage and Confidence Level Analysis", *International Journal of the Computer, the Internet and Management*, 11(1), 2003, pp. 17-29.

- [9] M. Y. Mashor, "Hybrid Multilayered Perceptron Networks", *International Journal of System Science*, Vol. 31. No. 6., 2000, pp. 771-785.
- [10] M. Y. Mashor, "Modified Recursive Prediction Error Algorithm for Training Layered Neural Network", *International Journal of the Computer, the Internet and Management*, 11(2),

2003, pp. 24-36.

- [11] M. Y. Mashor, "Performance Comparison Between Back Propagation, RPE and MRPE Algorithms For Training MLP Networks", *International Journal of the Computer, the Internet and Management*, 8(3), 2000.
- [12] M. Y. Mashor, "Performance Comparison Between HMLP, MLP and RBF Networks with Application to On-line System Identification", *Conference on Cybernetics and Intelligent Systems*, 2004.

Classification of Malaria Parasite Species Based on Thin Blood Smears Using Multilayer Perceptron Network

**Noorhidayati Abu Seman, *Nor Ashidi Mat Isa, Lim Chia Li, Zeehaida Mohamed, Umi
Kalthum Ngah, Kamal Zuhairi Zamli**

School of Electrical & Electronic Engineering,
Universiti Sains Malaysia, Engineering Campus,
14300, Nibong Tebal, Pulau Pinang, Malaysia.

*Tel: +604-5995999 ext 6051. Fax: +604-5941023. Email: ashidi@eng.usm.my

Anstract. This paper discusses the application of the MLP network to classify the malaria parasite into three species, namely *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*. Six features (i.e. size of RBC infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite) from thin blood smear were used as input data. In order to determine the applicability of the MLP network, three different training algorithms were employed to train the MLP networks. In this study, the MLP network trained using back propagation algorithm produced the best performance with 89.80% accuracy as compared to Levenberg-Marquardt and Bayesian Rule algorithms. The result significantly demonstrates the suitability of the MLP network for classifying the malaria parasite.

Keywords

Malaria parasite, intelligent system, multilayered perceptron network, thin blood smear

1. Introduction

Malaria is one of the leading causes of death in the world. It is estimated that there are 300-500 million new cases every year, with 1.5 to 2.7 million deaths worldwide [1]. Research has shown that malaria is caused by four species of the genus malarial parasite *Plasmodium* (i.e. *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium ovale* and *Plasmodium malariae*) [2]. *Plasmodium* is actually a small, single-cell blood organism or protozoan which originated from a species of mosquito called *Anopheles* [1]. It is the *Anopheles* mosquito bites that can spread the *Plasmodium* into the human blood stream.

Currently, there are two tests to detect the malaria parasite; i.e. thick and thin blood smears. The thin blood smear is used to determine the species of malaria parasite, while thick blood smear is used to find the density of malaria parasite per microliter of red blood cells (RBC).

A number of useful researches into analyzing and classifying malaria parasite using neural network do exist. For instance, Jayavanth and Singh [3] have used an artificial neural network to analyze malaria severity through aggregation and deformability parameters of erythrocytes. The research successfully classifies high severity malaria with 100% accuracy. Nevertheless, the success rate for the classification of non-severe and mildly-severe malaria spans the range from 60% to 80%. Gao et. al [4] advocates that neural network was effective for forecasting malaria. In their study, the neural network yield promising result with the efficiency of 84.85%. The study also concludes that neural networks are useful for malaria forecasting particularly due to flexible analysis possibility, lower claim for data, convenient and easy to apply. Bender et. al [5] describes the application of neural mitochondrial transit peptides (mTPs) from the malaria-causing parasite *Plasmodium falciparum*

Multilayered perceptron (MLP) network trained using back propagation (BP) algorithm is the most popular choice in neural network applications. The current study proposes the MLP network to classify the malaria parasite and compare the performance of various available training algorithms namely back propagation, Levenberg-Marquardt and Bayesian rule.

This paper is organized as follows. Section 2.0 discusses the basic concept of the MLP network. Section 3.0 outlines the training algorithms employed in this research. Section 4.0 gives our methodology. Section 5.0 gives our result and discussion. Finally, section 6.0 outlines our conclusion.

2. Multilayered Perceptron Network

A MLP network is a feed forward neural network with one or more hidden layers. Cybenko [6] and Funahashi [7] have proved that the MLP network is a general function approximator and the MLP network with one hidden layer (as shown in Figure 1) is sufficient to approximate any continuous function. Based on Figure 1, the input layer acts as an input data buffer that distributes the input to the hidden layer. The outputs from the hidden layer then become the inputs to the output layer, which provides the network output.

A hidden neuron performs two functions, i.e. the combining function and the activation function. Consider a MLP network with n_i input nodes, the output of the j -th neuron of the hidden layer is given by:

$$v_j(t) = F\left(\sum_{i=1}^{n_i} w_{ji}^1 x_i(t) + b_j\right); \text{ for } 1 \leq j \leq n_h \quad (1)$$

where the w_{ji}^1 denotes the weights that connect the input and the hidden layer; x_i and b_j denote the input that are supplied to the input layer and thresholds in hidden nodes respectively; n_i and n_h are number of input nodes and hidden nodes respectively.




Figure 1: Multilayered perceptron networks

The output of the k -th output neuron, y_k in the output layer is given by:

$$\hat{y}_k(t) = \sum_{j=1}^{n_h} w_{kj}^2 v_j(t); \text{ for } 1 \leq k \leq n_o \quad (2)$$

where n_o is the number of output nodes; w_{kj}^2 denotes the weights of the connections between the hidden and output layer. It can be derived from equations (1) and (2) that the MLP network with one hidden layer can be expressed by following equation:

$$\hat{y}_k(t) = \sum_{j=1}^{n_h} w_{kj}^2 F \left(\sum_{i=1}^{n_i} w_{ji}^1 x_i(t) + b_j \right); \text{ for } 1 \leq k \leq n_o \quad (3)$$

$F(\cdot)$ is an activation function that is normally selected as a sigmoid function, which is given by:

$$F(v(t)) = \frac{1}{1 + e^{-v(t)}} \quad (4)$$

The weights w_{ji}^1 , w_{kj}^2 and threshold b_j are unknown and should be selected to minimize the prediction errors, defined as:

$$\rho_k(t) = y_k(t) - \hat{y}_k(t) \quad (5)$$

where $y_k(t)$ is the actual output and $\hat{y}_k(t)$ is the network output.

3. Training Algorithms

As described earlier, three training algorithms for the MLP network will be employed and compared their performance. This section briefly presents the back propagation, Levenberg-Marquardt and Bayesian Rule algorithms.

3.1 Back Propagation Algorithm

Back-propagation, the most commonly used to train The MLP network, is a gradient descent procedure that computes the derivatives' values in a very efficient way, and modifies the weights according to a parameter known as learning rate [8]. Back propagation is a steepest decent type algorithm where the weight connection between the j -th neuron of the hidden layer and the i -th neuron of the input layer are respectively updated according to:

$$\begin{aligned}
w_{ji}(t) &= w_{ji}(t-1) + \Delta w_{ji}(t) \\
b_j(t) &= b_j(t-1) + \Delta b_j(t)
\end{aligned} \tag{6}$$

with the increment $\Delta w_{ji}(t)$ and $\Delta b_j(t)$ given by:

$$\begin{aligned}
\Delta w_{ij}(t) &= \eta_w \rho_j(t) x_i(t) + \alpha_w \Delta w_{ij}(t-1) \\
\Delta b_j(t) &= \eta_b \rho_j(t) + \alpha_b \Delta b_j(t-1)
\end{aligned} \tag{7}$$

where the subscripts w and b represent the weight and threshold respectively, α_w and α_b are momentum constants which determine the influence of the past parameter changes on the current direction of movement in the parameter space, η_w and η_b represent the learning rates and $\rho_j(t)$ is the error signal of the j -th neuron of the hidden layer which is back propagated in the network. Since the activation function of the output neuron is linear, the error signal at the output node is

$$\rho_k(t) = y_k(t) - \hat{y}_k(t) \tag{8}$$

and for the neurons in the hidden layer

$$\rho_j(t) = F'(x_i(t)) \sum_j \rho_j^k(t) w_{ji}^2(t-1) \tag{9}$$

where $F'(x_i(t))$ is the first derivative of $F(x_i(t))$ with respect to $x_i(t)$.

Since back propagation algorithm is a steepest decent type algorithm, the algorithm suffers from a slow convergence rate. The search for the global minima may be trapped at local minima and the algorithm can be sensitive to the user selectable parameters [9].

3.2 Levenberg-Marquardt Algorithm

Levenberg-Marquardt algorithm is a gradient-based, deterministic local optimization algorithm. The Levenberg-Marquardt algorithm has an advantage over the traditional Back

Propagation algorithm, where it can provide faster (second-order) convergence rate and keep relative stability [10][11].

Like the quasi-Newton methods, the Levenberg-Marquardt algorithm was designed to approach second-order training speed without having to compute the Hessian matrix. When the performance function has the form of a sum of squares (as is typical in training feed forward networks), then the Hessian matrix can be approximated as:

$$H = J^T J \quad (10)$$

and the gradient can be computed as:

$$g = J^T e \quad (11)$$

where J is the Jacobian matrix that contains first derivatives of the network errors with respect to the weights and biases, and e is a vector of network errors. The Jacobian matrix can be computed through a standard back propagation technique that is much less complex than computing the Hessian matrix [12]. The Levenberg-Marquardt algorithm uses this approximation to the Hessian matrix in the following Newton-like update:

$$\Delta w = -[J^T J + \mu I]^{-1} J^T e \quad (12)$$

where Δw is a differential weights and μ is a control parameter.

When the scalar μ is zero, it is similar to Newton's method, using the approximate Hessian matrix. When μ is large, it becomes gradient descent with a small step size. Newton's method is faster and more accurate near an error minimum, so the aim is to shift towards

Newton's method as quickly as possible. Thus, μ is decreased after each successful step (reduction in performance function) and is increased only when a tentative step would increase the performance function. In this way, the performance function will always be reduced at each iteration of the algorithm [12].

3.3 Bayesian Rule Algorithm

Given the Baye's Rule as [13]

$$p(\theta | D) = \frac{p(D | \theta)}{p(D)} \quad (13)$$

where $p(\theta)$ is the prior probability of a parameter θ before having seen the data and

$p(\theta | D)$ called the likelihood were the probability of the data D.

Bayes' Rule is used to determine the posterior probability of θ given the data D [13]. In general this will provide an entire distribution over possible values of θ . This process was apply to neural networks and come up with the probability distribution over the network weights, w , given the training data $p(w | D)$. When finding a posterior distribution over weights,

$$\begin{aligned} p(w | D) &= \frac{p(D | w)p(w)}{p(D)} \\ &= \frac{p(D | w)}{\int p(D | w)p(w)dw} \end{aligned} \quad (14)$$

In the Bayesian formalism, learning the weights means changing our belief about the weights from the prior, $p(w)$, to the posterior, $p(w | D)$ as a consequence of seeing the data as illustrated by Figure 2.




Figure 2 : Changing prior weights to posterior weights

4 Methodology and Data Samples

As discussed earlier, this study focuses on classification of three species of malaria parasite; i.e. *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae* from the thin blood smears. To determine the applicability of the MLP network as malaria parasite diagnosis technique, the MLP network needs to go through training and testing phases. During both phases, the optimum structure and diagnosis performance of the MLP networks are determined. The performance analysis of the MLP network is based on accuracy. Accuracy is defined as the percentage of overall correct determination of malaria species.

In this study, 562 data of malaria parasite (172 *Plasmodium falciparum*, 194 *Plasmodium vivax* and 196 *Plasmodium malariae*) are used in classifying malaria parasite using the MLP network. The data are taken from Hospital Universiti Sains Malaysia (HUSM). Six features of the thin blood images will be used as input data to the MLP network. The features are size of RBC infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite. 350 data (110 *Plasmodium falciparum*, 120 *Plasmodium vivax* and 120 *Plasmodium malariae*) are used as training data while the remaining 212 data (62 *Plasmodium falciparum*,

74 *Plasmodium vivax* and 76 *Plasmodium malariae*) are used as testing data. The data are fed randomly into the MLP network.

5 Result and Discussion

The optimum number of hidden node and number of training epochs are obtained when the MLP network achieves the highest performance. Figure 3 (a) and (b) show the result of obtaining the optimum training epochs and number of hidden node for back propagation algorithm respectively. The MLP network using back propagation algorithm achieves the highest performance at the number of hidden nodes equal to 2200 and 14 training epochs.

Results for Levenberg-Marquardt training algorithm are shown in Figure 4. This training algorithm produced the best performance at 100 training epochs and 7 hidden nodes. Figure 5 shows the result for the Bayesian Rule training algorithm. This training algorithm achieved an optimal result at 1000 training epochs and 3 hidden nodes.

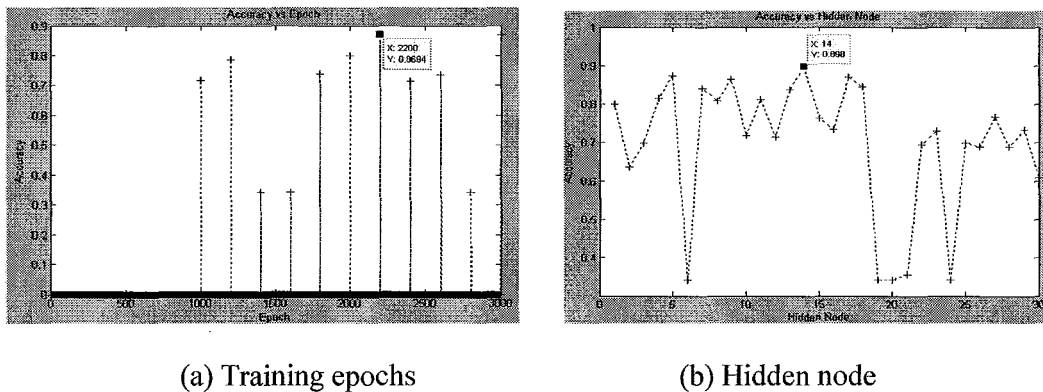




Figure 3 : Performance of the MLP network with back propagation algorithm.




(a) Training epoch

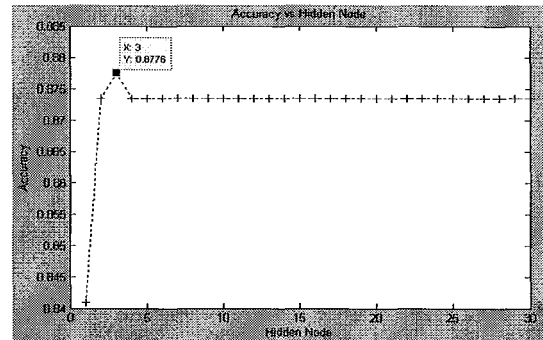


(b) Hidden node

Figure 4 : Performance of the MLP network with Levenberg-Marquardt algorithm.



(a) Training epoch



(b) Hidden node

Figure 5 : Performance of the MLP network with Bayesian rule algorithm.

After obtaining the optimum structure for the network, the performance of the MLP network was determined. Table 1 shows the performance comparison of the MLP network using those three training algorithms. The result shows that back propagation training algorithm produces the highest accuracy, 89.80% as compared to Levenberg-Marquardt and Bayesian Rule training algorithm, which produce 87.35% and 87.76% of accuracy respectively.

Table 1: The performance comparison of the MLP network with three different training algorithms.

Training algorithm	Accuracy
Back propagation	89.80%
Levenberg-Marquardt	87.35%
Bayesian Rule	87.76%

6 Conclusion

The results obtained indicate that, the MLP network which has been trained with the back propagation algorithm produced the highest performance compared to the Levenberg-Marquardt and Bayesian Rule algorithms. The result also proved that the MLP network can be implemented to classify malaria parasite into three classes (i.e. *Plasmodium falciparum*, *Plasmodium vivax* and *Plasmodium malariae*) based on six features (i.e. size of RBC infected per size of normal RBC, shape of parasite, number of chromatin, number of parasite per RBC, texture of RBC and location chromatin of parasite) extracted from thin blood smears. Further study by applying the different types of neural network architectures combining with the other learning algorithms can be done in order to find the most appropriate network for classification malaria parasite.

References

- [1] Citing internet sources URL: http://www.netdoctor.co.uk/travel/diseases/malaria_disease.htm

- [2] Citing internet sources URL: <http://www.emedicine.com/med/byname/malaria.htm>
- [3] Jayavanth, S., Singh, M., “Artificial neural network analysis of malaria severity through aggregation and deformability parameters of erythrocytes”, *Clinical Hemorheology and Microcirculation*, (2003) 29(3-4), 457-468.
- [4] Gao, C.Y., Xiong, H.Y., Yi, D., Chai, G.J., Yang, X.W., Liu, L., “Study on meteorological factors-based neural network model of malaria”, *Zhonghua liuxingbingxue zazhi*, (2003) 24(9), 831-834.
- [5] Bender, A.a , Van Dooren, G.G.b , Ralph, S.A.b , McFadden, G.I.b , Schneider, G. A. “Properties and prediction of mitochondrial transit peptides from Plasmodium falciparum” *Molecular and Biochemical Parasitology*, (2003). 132(2), 59-66.
- [6] Cybenko, G., “Approximations by superposition of a sigmoidal function”, *Mathematics of Control, Signal and Systems*, (1989) 2, 303-314.
- [7] Funahashi, K., “On the approximate realisation of continuous mappings by neural networks”, *Neural Networks*, (1989). 2, 183-192.
- [8] El-Fallahi, A.A., Martí, R.A. , Lasdon, L.B., “Path relinking and GRG for artificial neural networks”, *European Journal of Operational Research*, (2006). 169(2), 508-519.
- [9] Mashor, M.Y., “Modified Recursive Prediction Error Algorithm For Training Layered Neural Network ”, *International Journal of the Computer, the Internet and Management*, (2003). 11(2), 24-36.
- [10] Battiti, R., “First and second-order methods for learning between steepest descent and Newton’s method”, *Neural Computation*, (1992). 4, 141–166.
- [11] Dong Wang, Wei-Zhen Lu, “Forecasting of ozone level in time series using MLP model with a novel hybrid training algorithm”, *Atmospheric Environment*, (2006). 40(5), 913-924.

- [12] Citing internet sources URL: <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet>
- [13] Bishop, C.M., Neural Network For Pattern Recognition, Oxford University Press. (2004).