

RANGKAIAN NEURAL PERSEPTRON BERBILANG LAPISAN HIBRID
BERKELOMPOK UNTUK PENGELASAN CORAK YANG LEBIH BAIK

oleh

WAN MOHD FAHMI BIN WAN MAMAT

Tesis yang diserahkan untuk
Memenuhi keperluan bagi
Ijazah Sarjana Sains

November 2009

PENGHARGAAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Segala puji bagi Allah s.w.t yang Maha Pemurah dan Maha Mengasihani kerana dengan izin-NYA, penyelidikan ini dapat disempurnakan dengan jayanya.

Pertama sekali, ucapan terima kasih ditujukan kepada penyelia saya iaitu Prof. Madya Dr. Nor Ashidi Mat Isa di atas dorongan, sokongan dan tunjuk ajar yang telah diberikan. Selain sebagai mentor akademik dan “guru bahasa”, pendekatan terbuka dan kebebasan eksplorasi yang diberikan oleh beliau telah menjadikan perjalanan penyelidikan ini sebagai suatu pengalaman yang sangat bermakna dan menyeronokkan.

Penghargaan turut diberikan kepada Prof. Madya Dr. Habibah Wahab kerana sudi menjadikan projek ini sebagai sebahagian daripada “ahli keluarga” penyelidikan beliau di Pusat Pengajian Farmasi, USM. Kepada Prof. Madya Dr. Mahfoozur Rehman, segala inspirasi dan nasihat-nasihat yang telah diberikan akan sentiasa diigati. Penghargaan juga kepada Tenaga Nasional Research Department kerana sudi membekalkan data untuk kegunaan penyelidikan ini.

Tidak dilupakan, ucapan terima kasih kepada kroni-kroni Lab Celis; Fauzi, Subhi, Zailani dan Zamani. Sahabat-sahabat se-Batch USM EE 2003/2007, rakan-rakan dan seluruh warga USM kerana dengan kehadiran anda semua telah menjadikan perjalanan Master ini lebih mudah dan indah.

Terima kasih kepada Fellowship USM kerana sumbangan kewangan dan peluang yang diberikan kepada saya untuk berkongsi ilmu sebagai tutor kepada pelajar-pelajar

siswa. Juga kepada MOSTI kerana dana ScienceFund yang bertajuk Development of a New Architecture and Learning Algorithm of Artificial Neural Network for Determination of Potential Drug in Herbal Medicine.

Penghargaan terakhir ini diperuntukkan khas kepada seluruh ahli keluarga saya, terutamanya kepada kedua ibu bapa saya iaitu Wan Mamat dan Wan Rohayah. Tanpa restu, doa dan sokongan daripada mereka, penyelidikan ini tidak mungkin dapat disempurnakan. Oleh itu, saya tujukan tesis ini kepada mereka.

ISI KANDUNGAN

Muka Surat

PENGHARGAAN	ii
ISI KANDUNGAN	iv
SENARAI JADUAL	x
SENARAI RAJAH	xv
TERJEMAHAN ISTILAH	xvi
SINGKATAN ISTILAH	xxix
ABSTRAK	xxxiii
ABSTRACT	<u>xxxv</u>

BAB 1 – PENGENALAN

1.1 Pengenalan	1
1.2 Perkembangan Rangkaian Neural	2
1.3 Penyataan Masalah dan Motivasi	6
1.4 Objektif dan Skop Kajian	8
1.5 Garis Panduan Tesis	11

BAB 2 - EVOLUSI SENI BINA DAN ALGORITMA PEMBELAJARAN

RANGKAIAN NEURAL DAN APLIKASI SEBAGAI PENGELOAS

CORAK

2.1 Pengenalan	14
2.2 Rangkaian Neural Buatan	15
2.2.1 Seni Bina dan Algoritma Pembelajaran	17
2.2.2 Evolusi Rangkaian Neural	21
2.2.2.1 Evolusi Rangkaian Neural Perseptron	23
2.2.2.1.1 Rangkaian Perseptron Lapisan Tunggal	24
2.2.2.1.2 Rangkaian Perseptron Berbilang Lapisan	27
2.2.2.1.3 Rangkaian Perseptron Berbilang Lapisan Hibrid	29
2.2.2.1.4 Evolusi Algoritma Pembelajaran	32
2.2.2.2 Evolusi Rangkaian Fungsi Asas Jejarian	39
2.2.3 Aplikasi Rangkaian Neural Sebagai Pengelas Corak	46
2.2.3.1 Aplikasi Rangkaian Perseptron Berbilang Lapisan	47
2.2.3.2 Aplikasi Rangkaian Fungsi Asas Jejarian	50
2.2.3.3 Aplikasi Rangkaian Perseptron Berbilang Lapisan Hibrid	54
2.2.4 Ulasan	56

2.3	Penyelenggaraan Transformer Kuasa	57
2.3.1	Analisis Gas Terlarut	59
2.3.2	Kaedah-kaedah Sistem Diagnosis Awal Kerosakan Transformer Menggunakan Teknik DGA	59
2.3.2.1	Kaedah Kekunci Gas	60
2.3.2.2	Kaedah Nisbah	61
2.3.2.3	Kelemahan Kaedah Kekunci Gas dan Kaedah Nisbah	62
2.3.2.4	Aplikasi Rangkaian Neural Sebagai Sistem Diagnosis Transformer Menggunakan Teknik DGA	63
2.3.3	Ulasan	66
2.4	Penemuan Ubat	67
2.4.1	Cabaran Proses Penemuan Ubat	68
2.4.2	Konsep Seakan-ubat dan Tak Seakan-ubat	70
2.4.3	Kaedah Pengelasan Corak Seakan-ubat dan tak Seakan-ubat	71
2.4.3.1	Kaedah Pengiraan Mudah	71
2.4.3.2	Kaedah Penganalisis Topologi Ubat	74
2.4.3.3	Kaedah Mesin Pembelajaran Jenis Rangkaian Neural dan Pepohon Keputusan	75
2.4.5	Ulasan	79

BAB 3 - RANGKAIAN NEURAL PERSEPTRON BERBILANG LAPISAN**HIBRID BERKELOMPOK SEBAGAI PENGETAHUAN CORAK**

3.1 Pengenalan	83
3.2 Seni Bina Rangkaian Clustered-HMLP	84
3.3 Algoritma Pembelajaran Clustered-MRPE	88
3.3.1 Penentuan Kedudukan Pusat Rangkaian Clustered-HMLP	89
3.3.2 Pencarian Pemberat Rangkaian Clustered-HMLP	91
3.4 Pengujian Prestasi Rangkaian Clustered-HMLP	92
3.4.1 Penilaian Prestasi Rangkaian Clustered-HMLP	95
Menggunakan Kaedah Pengulangan 10 Kali	
3.4.1.1 Parameter Pengukuran Prestasi Menggunakan	96
Kaedah Kecekapan dan Sisihan Piawai	
3.4.1.2 Parameter Pengukuran Prestasi Menggunakan	97
Kaedah Hipotesis Bootstrap	
3.4.1.3 Keputusan Penilaian Prestasi	99
3.4.1.3.1 Iris	100
3.4.1.3.2 Glass	101
3.4.1.3.3 Lung Cancer	103

3.4.1.3.4 Pima Indian Diabetes	105
3.4.1.3.5 Wine	107
3.4.1.3.6 Hayes-Roth	108
3.4.1.3.7 Ionosphere	110
3.4.1.3.8 Image Segmentation	112
3.4.1.3.9 BUPA Liver Disorders	114
3.4.1.3.10 Balance Scale	115
3.4.1.3.11 Lymphography	117
3.4.1.3.12 Zoo	119
3.4.1.3.13 Tic-Tac-Toe	121
3.4.2 Penilaian Prestasi Rangkaian Clustered-HMLP	123
Menggunakan Kaedah Keesahan Silang Lipatan ke-10	
3.4.2.1 Wisconsin Breast Cancer	124
3.4.2.2 Pima Indian Diabetes	126
3.4.2.3 Wine	128
3.5 Ringkasan	129

BAB 4 - PENGAPLIKASIAN RANGKAIAN PERSEPTRON BERBILANG

LAPISAN HIBRID BERKELOMPOK SEBAGAI SISTEM DIAGNOSIS KEROSAKAN TRANSFORMER DAN SISTEM PENGELASAN SEBATIAN SEAKAN UBAT

4.1 Pengenalan	131
4.2 Aplikasi Rangkaian Clustered-HMLP Sebagai Sistem Diagnosis Kerosakan Transformer Menggunakan Teknik DGA	133
4.3 Aplikasi Rangkaian Clustered-HMLP Sebagai Sistem Pengelas Sebatian Seakan Ubat dan Bukan Seakan Ubat Menggunakan Pemerihal Aturan Lima Lipinski dan Aturan Veber	137
4.4 Ringkasan	147

BAB 5 – KESIMPULAN

5.1 Kesimpulan	149
5.2 Cadangan	153

RUJUKAN	156
LAMPIRAN	178
SENARAI PENERBITAN	179

SENARAI JADUAL

Muka Surat

Jadual 2.1:	Diagnosis kriteria kekunci gas	61
Jadual 2.2:	Ciri-ciri Jadual IEC 599	62
Jadual 2.3:	Aturan Lima Lipinski	72
Jadual 2.4:	Aturan Veber	73
Jadual 2.5:	Julat maksimum dan minimum untuk parameter-parameter yang digunakan di dalam kaedah pengiraan mudah	76
Jadual 2.6:	Empat sistem pengelas pintar sebatian DL yang menggunakan aplikasi rangkaian neural	80
Jadual 3.1:	Ciri-ciri Set Data UCI	93
Jadual 3.2:	Ciri-ciri set data Iris	100
Jadual 3.3:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Iris	101
Jadual 3.4:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Iris	101
Jadual 3.5:	Ciri-ciri set data Glass	102
Jadual 3.6:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Glass	103
Jadual 3.7:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Glass	103
Jadual 3.8:	Ciri-ciri set data Lung Cancer	104
Jadual 3.9:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Lung Cancer	104

Jadual 3.10:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Lung Cancer	105
Jadual 3.11:	Ciri-ciri set data Pima Indian Diabetes	105
Jadual 3.12:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Pima Indian Diabetes	106
Jadual 3.13:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Pima Indian Diabetes	107
Jadual 3.14:	Ciri-ciri set data Wine	107
Jadual 3.15:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Wine	108
Jadual 3.16:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Wine	108
Jadual 3.17:	Ciri-ciri set data Hayes-Roth	109
Jadual 3.18:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Hayes-Roth	109
Jadual 3.19:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Hayes-Roth	110
Jadual 3.20:	Ciri-ciri set data Ionosphere	110
Jadual 3.21:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Ionosphere	111
Jadual 3.22:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Ionosphere	111
Jadual 3.23:	Ciri-ciri set data Image Segmentation	112

Jadual 3.24:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Image Segmentation	113
Jadual 3.25:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Image Segmentation	113
Jadual 3.26:	Ciri-ciri set data BUPA Liver Disorders	114
Jadual 3.27:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data BUPA Livers Disorders	115
Jadual 3.28:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data BUPA Liver Disorders	115
Jadual 3.29:	Ciri-ciri set data Balance Scale	116
Jadual 3.30:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Balance Scale	116
Jadual 3.31:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Balance Scale	117
Jadual 3.32:	Ciri-ciri set data Lymphography	117
Jadual 3.33:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Lymphography	118
Jadual 3.34:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Lymphography	119
Jadual 3.35:	Ciri-ciri set data Zoo	119

Jadual 3.36:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Zoo	120
Jadual 3.37:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Zoo	121
Jadual 3.38:	Ciri-ciri set data Tic-Tac-Toe	121
Jadual 3.39:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam Eukland & Hoang (2006, 2002) dan Hoang (1997) untuk data Tic-Tac-Toe	122
Jadual 3.40:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Tic-Tac-Toe	122
Jadual 3.41:	Ciri-ciri set data Wisconsin Breast Cancer	124
Jadual 3.42:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam CIL (2009) untuk data Wisconsin Breast Cancer	125
Jadual 3.43:	Keputusan ujian hipotesis Bootstrap untuk data Wisconsin Breast Cancer	125
Jadual 3.44:	Ciri-ciri set data Pima Indian Diabetes	126
Jadual 3.45:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam CIL (2009) untuk data Pima Indian Diabetes	127
Jadual 3.46:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Pima Indian Diabetes	127
Jadual 3.47:	Ciri-ciri set data Wine	128
Jadual 3.48:	Prestasi pengelasan rangkaian Clustered-HMLP, HMLP dan sistem pengelas lain yang direkodkan di dalam CIL (2009) untuk data Wine	128

Jadual 3.49:	Keputusan ujian hipotesis Bootstrap rangkaian Clustered-HMLP melawan HMLP untuk data Wine	129
Jadual 4.1:	Ciri-ciri set data sebenar transformer	136
Jadual 4.2:	Prestasi pengelasan rangkaian Clustered-HMLP dan HMLP untuk sistem diagnosis kerosakan transformer	137
Jadual 4.3:	Pecahan data-data DL dan NDL di dalam set data latihan dan ujian	141
Jadual 4.4:	Bilangan nod masukan, nod keluaran dan pemerihal yang digunakan oleh sistem pengelasan sebatian DL dan NDL	142
Jadual 4.5:	Keputusan prestasi sistem yang direkodkan di dalam Miguel Soler <i>et al.</i> (2003) dan prestasi sistem Clustered-HMLP yang dicadangkan di dalam penyelidikan ini	143

SENARAI RAJAH

Muka Surat

Rajah 2.1:	Pemodelan asas neuron	18
Rajah 2.2:	Rangkaian neural suap depan	19
Rajah 2.3:	Rangkaian neural suap balik	20
Rajah 2.4:	Seni bina rangkaian Perseptron Lapisan Tunggal	25
Rajah 2.5:	Tiga kelas boleh pisah linear yang dipisahkan oleh tiga hiperkekisi	25
Rajah 2.6:	Seni bina rangkaian Perseptron Berbilang Lapisan	28
Rajah 2.7:	Seni bina rangkaian Perseptron Berbilang Lapisan Hibrid	31
Rajah 2.8:	Seni bina rangkaian Fungsi Asas Jejarian	41
Rajah 2.9:	Hubungan suhu dan kadar penguraian gas-gas hidrokarbon	60
Rajah 2.10:	Rangka kerja sepunya pada kebanyakan ubat	75
Rajah 2.11:	Sebahagian daripada aturan pengelasan pepohon keputusan	78
Rajah 3.1:	Seni bina Rangkaian Perseptron Berbilang Lapisan Hibrid Berkelompok	90

TERJEMAHAN ISTILAH

<i>Bahasa Melayu</i>	<i>Bahasa Inggeris</i>
Agregat	Aggregate
Ahli kimia ubat	Medicinal chemistry
Algoritma Genetik	Genetic Algorithm
Analgesik	Analgesic
Analisis Diskret Linear Fischer	Fischer Linear Discrete Analysis
Analisis Gas Terlarut	Dissolved Gas Analysis
Analisis Komponen Utama	Principal Component Analysis
Antibakteria	Antibacterial
Antidepresen	Antidepressant
Antidiabetis	Antidiabetic
Antihipertensi	Antihypertensive
Antihistamina	Antihistaminic
Antiinflamatori	Antiinflammatory
Antikulat	Antifungal
Apungan	Float
Aspartat	Aspartate
Atrisi	Attrition
Aturan	Rule
Aturan Lima Lipinski	Lipinski Rule of Five
Benigna	Benign

Berasaskan Kasar	Rough-Based
Berat molekul	Molecular weight
Berkadar songsang	Inversely proportional
Berkeping	Flaky
Bersel	Cellular
Bersudut	Angular
Bias / berat sebelah	Bias
Bioavailabiliti	Bioavailability
Boleh pisah linear	Linear separable
Bukan seakan ubat	Non drug-like
Cecair penebat elektrik	Electric insulating fluid
Cerakin	Assay
Cerakin in vitro	In vitro assays
Cerakin in vivo	In vivo assays
Ciri pemetaan ruang	Feature Space Mapping
Corak	Pattern
Dalam talian	On-line
Diuretik	Diuretic
Ekspresi gen	Gene expression
Ekstravasat	Extravasate
Elemen Linear Adaptasi	Adaptive Linear Element
Elemen Linear Adaptasi Berbilang	Multiple Adaptive Linear Element
Entiti kimia baru	New chemical entities

Evolusi	Evolutionary
Faktor pelupa	Forgetting factor
Faktor Pembelajaran Optimum	Optimal Learning Factor
Farmakokinetik	Pharmacokinetics
Farmaseutik	Pharmaceutical
Fasa ujian	Testing phase
Fizikokimia	Physicochemical
Fasa latihan	Training phase
Fungsi Analisis Pembeza Layan	Discriminant Function Analysis
Fungsi Asas Awan	Cloud Basis Function
Fungsi Asas Jejarian	Radial Basis Function
Fungsi Asas Jejarian Hibrid	Hybrid Radial Basis Function
Fungsi Pencegahan Ralat Tepu	Error Saturation Prevention Function
Fungsi Pengaktifan Sigmoid	Sigmoid Activation Functions
Fungsi penghad tetap	Hard limiter
Fungsi Ralat Rentasan	Cross-entropy Error Function
Hidrokarbon	Hydrocarbon
Hiperkekisi	Hyperplanes
Hiperkolesterolemia	Hypercholesterolemia
Hipertensi sistemik	Systemic hypertension
Hipotesis alternatif	Hypothesis alternative
Hipotesis nol	Hypothesis Null
Hubungan Kuantitatif Struktur-aktiviti	Quantitative Structure-activity Relationship

Hukum pembuat keputusan	Decision making rule
Ikatan boleh gilir	Rotatable bond
Imej penderiaan jauh	Remote sensing image
In vitro	In vitro
Isyarat fonokardiogram	Phonocardiogram signal
Jarak min kuasa dua	Mean square distance
Jauh kepada setempat	Remote to local
Jeda keyakinan	Confidence interval
Jelmaan Gelombang Kecil db4	db4 Wavelet Transform
Jiran Terdekat ke-N	N-Nearest Neighbor
Jurukimia ubat	Medicinal chemist
Kabur logik	Fuzzy logic
Kadar kena	Hit
Kadar pembelajaran	Learning rate
Kadar penumpuan	Convergence rate
Kaedah Kekunci Gas	Key Gas Method
Kaedah Nisbah	Ratio Method
Karkas	Carcass
Kebarangkalian	Probabilistic
Kebiasaan	Refractivity
Kebilaziman	Abnormalities
Kebolehan	Capability

Kebolehan pengitlakan terwujud	Inherent generalization ability
Kebolehan untuk dimajukan	Developability
Kecekapan	Accuracy
Kecerunan	Gradient
Kecukupan modal	Capital adequacy
Keesahan Silang Lipatan ke- <i>k</i>	<i>k</i> -fold Cross-validation
Kelangsungan	Survival
Kelasakan	Robustness
Kelemahan aorta	Aortic insufficiency
Kemas kini	Update
Ketelapan	Permeability
Keteorian termodinamik	Theoretical thermodynamic
Keterbiasaan Bayesian	Bayesian Regularization
Ketumpatan aromatik	Aromatic density
Keunitan	Unity
Kiub	Cubic
Kombinatorial kimia	Combinatorial chemical
Kompetitif Penalti Pesaing	Rival Penalized Competitive
Komplikat	Complicated
Korpuskel	Corpuscular
Kotak hitam	Black boxes
Kromatin tawar	Bland chromatin
Kromatografi cecair berprestasi tinggi	High performance liquid chromatography

Kuasa Dua Terkecil	Least Square
Kuasa Dua Terkecil Givens	Givens Least Square
Kuasa Dua Terkecil Ortogon	Orthogonal Last Square
Kubus	Cubical
Lapisan pusat	Cluster layer
Lejang	Stroke
Linear sesecebis	Piecewise linear
Lesi intraepitelial skuamus gred tinggi	High grade intra-epithelial squamous lesion
Linear	Linear
Luar talian	Off-line
Luas polar permukaan	Polar surface area
Malignan	Malignant
Masalah penentu-dalamam multivariat	Multivariate interpolation problem
Memanjang	Elongated
Menentu luar	Extrapolate
Mesin Bantuan Vektor	Support Vector Machine
Mesin Bantuan Vektor Linear	Linear Support Vector Machine
Mesin Pembelajaran Pengkuantuman	Learning Vector Quantization
Mesin Pepohon Keputusan Linear	Linear Machine Decision Tree
Metabolisme	Metabolism
Min kuasa dua ralat	Mean square error
Min Kuasa Dua Terkecil	Least Mean Square

Minima setempat	Local minima
Model Serebelum Kawalan Artikulasi	Cerebellar Model Articulation Controller
Momentum teroptyimum	Optimised momentum
Mudah tunai	Liquidity
Nafi khidmat	Denial of service
Neo-kognisi	Neocognition
Nilai-Boolean	Boolean-value
nilai- <i>p</i>	<i>p</i> -value
Nod limfa	Lymphatic
Novel	Ne novo
Nukleus terdedah	Bare nucleoi
Nyahcas separa	Partial discharge
Padanan	Fitness
Pagar	Hedge
Panasea	Panacea
Patologi	Pathological
Pekali pembahagian etanol-air	Partition coefficient ethanol-water
Pelbagai kuadratik	Multi-quadratic
Pelbagai kuadratik songsang	Inverse multi-quadratic
Pelekatan pinggir	Marginal adhesion
Pemanasan lampau	Overheating
Pembelajaran tak terselia	Unsupervised learning

Pembelajaran terselia	Supervised learning
Pembinaan Pemerihal Ke Hadapan	Lookahead Feature Construction
Pemerihal	Descriptor
Pemetaan Pengorganisasian Sendiri	Self Organizing Maps
Pemetaan Ciri Pengorganisasian Sendiri	Self Organizing Feature Maps
Pemilih ciri	Features selection
Pemproban	Probing
Pemula serangan / Onset	Onset
Penanda aras	Benchmark
Pencarian Langkah Perubahan	Variable Step Search
Penderma ikatan hidrogen	Hydrogen bond donor
Penerima ikatan hidrogen	Hydrogen bond acceptor
Pengagihan	Distribution
Penganggar Kebolehjadian Maksimum	Maximum Likelihood Classifier
Penganggar Kernel Bayesian Naive	Naive Bayesian Kernel Estimator
Pengarkaan	Arcing
Pengaspiratan Jarum Halus	Fine Needle Aspiration
Pengekstrakan	Extraction
Pengekstrakan peraturan kabur	Extracting fuzzy rule
Pengelasan	Classification
Pengelasan corak	Pattern classification
Pepohon Regresi dan Pengelasan	Classification and Regression Tree
Pengelasan Oblik	Oblique Classifier

Pengenalpastian sistem	System identification
Pengguna kepada punca	User to root
Pengiraan bermaklumat	Informative measurement
Pengitlakan	Generalization
Pengitlakan Suap Hadapan	Generalized Feedforward
Pengkuantaman Vektor	Vector Quantization
Pengoptimuman Genetik	Genetic Optimization
Pengoptimuman Partikel Kerumun	Particle Swarm Optimization
Penjumlahan gas boleh bakar terlarut	Total dissolved combustible gases
Penstrukturran Pepohon Gelombang Kecil	Tree Structured Wavelet
Penuras	Filter
Penyakit arteri koronari	Coronary artery disease
Penyaringan Truput-Tinggi	High-throughput Screening
Penyerapan	Absorption
Pepohon keputusan	Decision Tree
Peramal fungsi	Function approximation
Perambatan Balik	Back Propagation
Perambatan Balik Nevada	Nevada Back Propagation
Perduaan	Binary
Perkumuhan	Excretion
Perseptron	Perceptron
Perseptron Berbilang Lapisan	Multilayered Perseptron
Perseptron Berbilang Lapisan Hibrid	Hybrid Multilayered Perceptron

Perseptron Berbilang Lapisan Hibrid Berhierarki	Hierarchical Hybrid Multilayered Perceptron
Perseptron Berbilang Lapisan Hibrid Berkelompok	Clustered Hybrid Multilayer Perceptron
Perseptron Satu Lapisan	Single Layer Perceptron
Pertumbuhan Kawasan Secara Titik Benih Automatik	Automatic Seed Based Region Growing
Petunjuk ubat	Lead
Plat tipis gelugur	Thin-plate-spline
Pra-pengelasan	Pre-classification
Prestasi	Performance
Proantosianin	Proanthocyanin
Progressi	Progression
Pseudo Songsang	Pseudo-Inverse Matrices
Purata Kuasa Dua Terkecil	Least Mean Square
Purata-c Kabur	Fuzzy c-mean
Purata-c Kabur Adaptasi	Adaptive Fuzzy c-mean
Purata-k	k-mean
Purata-k Boleh Gerak	Moving k-mean
Ralat Ramalan Jadi Semula	Recursive Prediction Error
Ralat Ramalan Jadi Semula Ubahsuai	Modified Recursive Prediction Error
Ralat Ramalan Jadi Semula Ubahsuai Berkelompok	Clustered Modified Recursive Prediction Error
Ramalan satu langkah ke hadapan	One step ahead prediction
Ranggi	Petal

Rangka kerja ciri ubat	Pharmacophore
Rangkaian neural buatan	Artificial neural network
Rangkaian neural Kebarangkalian	Probabilistic neural network
Rangkaian Neural Simulator Stuggart	Stuggart Neural Network Simulator
Regresi Linear	Linear Regression
Rekombinan	Recombinant
Repositori	Respository
Rona	Hue
Ruang kimia	Chemistry space
Saiz keluarga kucing	Catsize
Saling tindak	Interact
Seakan ubat	Drug-like
Sebarang	Arbitrary
Sebatian	Compound
Secaman	Identical
Sedatif	Sedative
Sel lesi intraepitelial skuamus gred rendah	Low grade intra-epithelial squamous lesion
Sel tunggal epithelium	Single epithelial cell size
Sempadan	Vedge
Sisihan piawai	Standard deviation
Sistem kecerdikan buatan	Artificial intelligent system
Sistem pengesan penceroboh	Intrusion detection system

Sistem Regresi Logistik	Logistic Regression
Skala-kelabu	Grey-scale
Spektrum Pengutuban Antara Muka	Interfacial Polarization Spectra
Stenosis aorta	Aortic stenosis
Stenosis pulmonari	Pulmonary stenosis
Struktur kekisi	Lattice structure
Suap depan	Feedforward
Tak bersandar	Independent
Tak lanar	Irregular
Tegangan	Stress
Tegar	Rigid
Teknik pandangan berbeza	Multiple views technique
Teori Resonans Adaptasi	Adaptive Resonance Theory
Terapeutik	Therapeutic
Terma Polinomial Tertib Tinggi	High Order Polynomial Terms
Tersedia	Available
Tersedia segera	Ready Access
Tisu berserabut	Fibrosis
Toksilogi	Toxilogical
Toksisiti	Toxicity
Toleransi	Tolerability
Topologi	Topology
Tuntutan pengkomputeran	Computational demand

Turun tercuram

Steepest descent / Gradient Descent

Voltan balikan

Return voltage

SINGKATAN ISTILAH

10CV	-	10-fold Cross-validation
ACD	-	Available Chemicals Directory
ADALINE	-	Adaptive Linear Element
ADME	-	Absorption, distribution, metabolism and excretion
ADMET	-	Absorption, distribution, metabolism, excretion and toxicity
AR	-	Aromatic density
ART	-	Adaptive Resonance Theory
BP	-	Back Propagation
BR	-	Bayesian Regulazation
C ₂ H ₂	-	Asetilena
C ₂ H ₄	-	Etilena
C ₂ H ₆	-	Etana
CC	-	Combinatorial chemical
CH ₄	-	Metana
CIL	-	Computational Intelligence Laboratory
Clustered-HMLP	-	Clustered Hybrid Multilayer Perceptron
Clustered-MRPE	-	Clustered Modified Recursive Prediction Error
CMC	-	Comprehensive Medicinal Chemistry
CN2	-	CN2 Software
CO	-	Carbon monoksida
CO ₂	-	Carbon dioksida
DD	-	Drug discovery

DGA	-	Dissolved Gas Analysis
DL	-	Drug-like
FDA	-	Food and Drug Administration
FSM	-	Feature Space Mapping
GD	-	Steepest descent / Descent gradient
H ₂	-	Hidrogen
H ² MLP	-	Hierarchical Hybrid Multilayered Perceptron
HBA	-	Hydrogen bond acceptor
HBD	-	Hydrogen bond donor
HMLP	-	Hybrid Multilayered Perceptron
HRBF	-	Hybrid Radial Basis Function
HTS	-	High-throughput Screening
ITI	-	Incremental Decision Tree Induction Software
K5	-	5-Nearest Neighbor
kNN DVDM	-	k-Nearest Neighbor with DVDM Disctance
kNN	-	k-Nearest Neighbor
LFC	-	Lookahead Feature Construction
LM	-	Levenberg–Marquardt
LMDT	-	Linear Machine Decision Tree
Log P	-	Partition coeficient ethanol-water
LVQ	-	Learning Vector Quantization
MADALINE	-	Multiple Adaptive Linear Element
MDDR	-	MACCS-II Drug Data Report

MKM	-	Moving k-mean
MLP	-	Multilayered Perseptron
MRPE	-	Modified Recursive Prediction Error
MW	-	Molecular weight
NB + kernel est	-	Naive Bayesian Kernel Estimator
NCE	-	New chemical entities
NDL	-	Non drug-like
NEV-prop	-	Nevada Back Propagation
nilai- <i>p</i>	-	Probability (<i>p</i> -value)
NR	-	Rotatable bond
OC1	-	Oblique Classifier
OLS	-	Orthogonal Last Square
P-10X	-	Pengulangan 10 Kali
PD	-	Partial discharge
PSA	-	Polar surface area
Q*	-	Q_STAR Algorithm
RBF	-	Radial Basis Function
RNB	-	Rangkaian Neural Buatan
RO5	-	Lipinski Rule of Five
RPE	-	Recursive Prediction Error
SLP	-	Single Layer Perceptron
SOFM	-	Self-organizing Feature Maps
SOM	-	Self-Organizing Maps

SVM	-	Support Vector Machine
TNRD	-	Tenaga Nasional Reasearch Department
UCI	-	University California, Irvine Machine-Learning Respository
VSS	-	Variable Step Search
WDI	-	World Drug Index

RANGKAIAN NEURAL PERSEPTRON BERBILANG LAPISAN HIBRID BERKELOMPOK UNTUK PENGELASAN CORAK YANG LEBIH BAIK

ABSTRAK

Rangkaian neural berdasarkan konsep Perseptron dan Fungsi Asas Jejarian (RBF) sering digunakan sebagai pengelas corak pintar. Namun, rangkaian neural berasaskan konsep Perseptron mempunyai kelemahan seperti kadar penumpuan yang perlahan, proses pencarian pemberat optimum rangkaian yang sering terperangkap di dalam minima setempat dan sensitif kepada nilai pembolehubah awalan. Manakala, rangkaian neural berasaskan konsep RBF berhadapan dengan tiga masalah tipikal seperti fenomena pusat mati, kehadiran pusat bertindih dan pusat yang terperangkap di dalam minima setempat. Maka, penyelidikan ini mencadangkan satu seni bina rangkaian neural baru yang dinamakan Perseptron Berbilang Lapisan Hibrid Berkelompok atau Clustered-HMLP. Seni bina rangkaian Clustered-HMLP adalah berasaskan seni bina rangkaian Perseptron Berbilang Lapisan Hibrid yang diubahsuai melalui penambahan satu lapisan tambahan yang dinamakan lapisan pusat. Ciri-ciri lapisan pusat diadaptasi daripada rangkaian RBF. Rangkaian Clustered-HMLP ini dilatih menggunakan satu algoritma pembelajaran baru iaitu Ralat Ramalan Jadi Semula Ubahsuai Berkelompok atau Clustered-MRPE. Algoritma Clustered-MRPE merupakan gabungan di antara algoritma pengelompokan Purata-k Boleh Gerak dan Ralat Ramalan Jadi Semula Ubahsuai yang telah diubahsuai. Keupayaan rangkaian Clustered-HMLP diuji menggunakan 14 set data penanda aras UCI. Analisa prestasi menunjukkan, secara keseluruhannya rangkaian Clustered-HMLP mencatatkan prestasi pengelasan corak terbaik berbanding 12 pengelas pintar konvensional. Seterusnya, rangkaian Clustered-HMLP telah berjaya diaplikasikan untuk

pembinaan Sistem Diagnosis Kerosakan Transformer dan Sistem Pengelasan Sebatian
Seakan Ubat dan Tak Seakan Ubat.

CLUSTERED HYBRID MULTILAYERED PERCEPTRON NEURAL NETWORK FOR BETTER PATTERN CLASSIFICATION

ABSTRACT

Perceptron based and Radial Basis Function (RBF) neural networks are commonly used for pattern classification. However, their performances are limited to several weaknesses. For the Perceptron based neural networks, their training procedures are often trapped at a local optimum with slow convergence rate and sensitive to initial parameter values. Whereas, three typical problems for the RBF network are dead centers, centers redundancy and trapped centers in local minima. Thus, this study introduces a new neural network architecture called Clustered Hybrid Multilayered Perceptron or Clustered-HMLP. In this work, the Hybrid Multilayered Perceptron network architecture has been modified by introducing an additional layer called cluster layer to form the proposed neural network. The cluster layer concept is adopted from the RBF network architecture. The proposed Clustered-HMLP is then trained using a new modified training algorithm called Clustered Modified Recursive Prediction Error or Clustered-MRPE. The Clustered-MRPE algorithm is a combination of the modified version of the conventional MRPE and the Moving k-mean clustering algorithms. The capability of the Clustered-HMLP network is demonstrated using 14 UCI benchmark datasets. The results indicate that the introduction of pre-classification process at additional cluster layer favors the proposed Clustered-HMLP network by producing better performance as compared to other 12 conventional intelligent classifiers. Furthermore, the proposed Clustered-HMLP network has successfully been applied to develop a Transformer Fault Diagnosis System and Drug-like and Non Drug-like Classification System.

BAB 1

PENGENALAN

1.1 Pengenalan

Secara semula jadi, manusia menyimpan informasi yang telah dipelajari di dalam bentuk suatu sambungan kompleks sistem saraf rangkaian neural yang terletak di dalam otak manusia. Apabila diberi suatu set masukan dan keluaran, neuron-neuron manusia akan “mempelajari” hubungan di antara masukan dan keluaran data tersebut melalui sambungan pemberat yang dibina di antara neuron. Motivasi daripada konsep ini, maka lahirlah sistem kecerdikan buatan yang dikenali sebagai rangkaian neural buatan (RNB).

Sejak pengenalan model asas RNB oleh McColluch & Pitts (1944) dan penemuan konsep Perambatan Balik oleh Rumelhart *et al.* (1986), prospek rangkaian neural sebagai sistem kecerdikan buatan mula mendapat perhatian di kalangan penyelidik. Secara praktikal, rangkaian neural telah digunakan di dalam pelbagai aplikasi seperti sistem peramal fungsi (*function approximation*), pengenalpastian sistem (*system identification*), pemprosesan data (*data processing*) dan yang paling popular ialah sebagai sistem pengelasan corak (*pattern classification*).

Populariti dan kejayaan pengaplikasian rangkaian neural sebagai pengelas corak didorong oleh dua faktor. Faktor pertama, tidak seperti modul operasi sistem pengaturcaraan klasik, rangkaian neural tidak perlu membina suatu algoritma penyelesaian spesifik untuk menyelesaikan setiap permasalahan pengelasan corak yang

berlainan (Mellit, 2008). Sebaliknya, sistem rangkaian neural mempunyai kebolehan seakan (mimik) otak manusia untuk belajar perhubungan masukan-keluaran sesuatu permasalahan corak. Maka, dengan menggunakan kebolehan tersebut rangkaian neural akan membina suatu aturan pengelasan atau penyelesaian kepada permasalahan tersebut. Faktor kedua, rangkaian neural memiliki suatu kelebihan yang dipanggil kebolehan pengitlakan terwujud (*inherent generalization ability*) (Benardos & Vosniakos, 2007). Dengan kebolehan ini, sesebuah rangkaian neural mampu mengenalpasti dan mengecam suatu bentuk corak seakan (corak yang hampir sama tetapi tidak serupa) yang tidak terkandung di dalam maklumat corak yang dipelajari.

Disebabkan oleh potensi dan keupayaan pengelasan yang ditunjukkan, terdapat usaha berterusan di kalangan penyelidik untuk membangunkan dan mengembangkan lagi sistem kecerdikan buatan ini. Hasilnya, pelbagai seni bina dan algoritma pembelajaran baru (atau terubahsuai) yang dipertingkatkan kebolehannya telah berjaya diperkenalkan. Secara tidak langsung, penyelidikan berterusan seperti ini akan memastikan rangkaian neural akan terus kekal relevan sebagai suatu sistem kecerdikan buatan yang semakin baik dari semasa ke semasa.

1.2 Perkembangan Rangkaian Neural

Model sesebuah rangkaian neural boleh dibezakan di antara satu sama lain melalui jenis seni bina dan algoritma pembelajaran yang digunakan. Pada hari ini, usaha-usaha penambahbaikan atau modifikasi terhadap seni bina dan algoritma pembelajaran telah

menjadi fokus utama di dalam bidang penyelidikan rangkaian neural. Usaha-usaha penyelidikan ini dilakukan bertujuan untuk meningkatkan potensi dan keupayaan pengelasan corak sesuatu rangkaian neural. Motivasi daripada itu, pelbagai jenis rangkaian neural telah berjaya dibangunkan seperti model Elemen Linear Adaptasi Berbilang (*Multiple Adaptive Linear Element, MADALINE*), rangkaian neural Kebarangkalian (*Probabilistic*), rangkaian Perseptron Berbilang Lapisan (*Multilayered Perseptron, MLP*), rangkaian neural Bersel (*Cellular*), rangkaian Fungsi Asas Jejarian (*Radial Basis Function, RBF*), rangkaian neural Hopfield, rangkaian neural Evolusi (*Evolutionary*), Teori Resonans Adaptasi (*Adaptive Resonance Theory, ART*) dan sebagainya.

Di antara semua model yang telah diperkenalkan, rangkaian MLP dan RBF merupakan dua rangkaian neural utama yang sering digunakan di dalam permasalahan berkaitan dengan pengelasan corak (Ciocoiu, 2002). Kedua-dua rangkaian ini juga dikenali sebagai penganggar universal (Chakraborty & Pal, 2008). Gelaran tersebut diberikan kerana rangkaian MLP dan RBF mempunyai kebolehan pengelasan corak yang baik dan memiliki prosedur pengaplikasian yang mudah.

Rangkaian MLP dan rangkaian Perseptron Lapisan Tunggal (*Single Layer Perceptron, SLP*) merupakan rangkaian neural jenis Perseptron yang terbina daripada susunan pengkaskadan model Perseptron Rosenblatt (Rosenblatt, 1985). Rangkaian SLP terkenal dengan kebolehannya untuk menyelesaikan permasalahan berkaitan dengan boleh pisah linear (*linear separable*) (Ishak, 2007 dan André & Rangayyan, 2005). Kebolehan rangkaian MLP pula adalah lebih luas, iaitu ia mampu untuk menyelesaikan

permasalahan pengelasan di antara masukan-keluaran yang membabitkan fungsi tak linear sebarang (*arbitrary*) (Sharda & Delen, 2006). Pada awal pengenalannya, rangkaian neural jenis Perseptron telah dikritik hebat kerana beberapa kelemahan. Ini termasuk kelemahannya untuk menyelesaikan permasalahan jenis X-OR dan memiliki algoritma pembelajaran yang berkeupayaan rendah (Irwin, 1997). Bagaimanapun, permasalahan ini telah dapat diselesaikan dengan pengenalan konsep pembelajaran Perambatan Balik (*Back Propagation, BP*). Sejak daripada itu, rangkaian MLP terus berkembang dan telah digunakan secara meluas di dalam bidang pengelasan corak. Malah, hampir 70% daripada pengaplikasian rangkaian neural di dalam bidang pengelasan corak adalah menggunakan rangkaian MLP yang dilatih dengan algoritma pembelajaran BP (Tsai, 2009).

Rangkaian RBF telah diperkenalkan oleh Broomhead & Lowe (1988) berdasarkan pemerhatian mereka terhadap tindak balas setempat pada neuron biologi (Yu & He, 2006). Selain turut mempunyai kebolehan pengelasan yang baik, rangkaian ini juga mempunyai seni bina yang lebih ringkas dan proses pembelajaran yang lebih pantas berbanding rangkaian MLP. Prestasi pengelasan rangkaian RBF sangat bergantung kepada lokasi pusatnya (Han & Xi, 2004). Pusat-pusat adalah data masukan kepada nod keluaran rangkaian RBF yang digunakan untuk mewakili data masukan mentah. Lokasi pusat rangkaian RBF boleh ditentukan menggunakan teknik seperti Pengkuantaman Vektor (*Vector Quantization*), Pepohon Keputusan (*Decision Tree*), Pemetaan Pengorganisasian Sendiri (*Self Organizing Maps, SOM*) dan antara teknik yang paling popular ialah menggunakan algoritma pengelompokan. Algoritma pengelompokan seperti Purata-k (Montazera *et al.*, 2009 dan Pedrycza *et al.*, 2008) lebih cenderung digunakan

kerana prestasinya yang baik, susun atur algoritmanya yang ringkas dan tidak menggunakan beban pengkomputeran yang tinggi (Oyana, 2007 dan Ding *et al.*, 2007).

Secara umum, prestasi rangkaian neural dipengaruhi oleh seni bina dan algoritma pembelajarannya. Oleh itu, sambungan masukan linear terus di antara nod masukan dan nod keluaran pada seni bina rangkaian MLP dan RBF konvensional telah dicadangkan untuk meningkatkan prestasi kecekapan dan pengitlakannya (Poggio & Girosi, 1990). Hasilnya, rangkaian RBF dengan sambungan linear telah berjaya dihasilkan oleh Mashor (2000c, 1995) dan Poggio & Girosi (1990). Rangkaian hibrid yang memiliki kedua-dua sistem linear dan tak linear ini telah terbukti mempunyai prestasi yang lebih baik daripada rangkaian RBF konvensional (Billings & Fung 1995). Konsep yang sama turut diaplikasikan kepada rangkaian MLP dengan algoritma pembelajaran BP. Bagaimanapun, modifikasi ini gagal meningkatkan prestasi rangkaian MLP konvensional kerana sambungan tambahan tersebut (sambungan linear) tidak dapat dieksplorasi oleh algoritma BP. Sebagai penyelesaian, algoritma pembelajaran Ralat Ramalan Jadi Semula Ubahsuai (*Modified Recursive Prediction Error, MRPE*) telah diperkenalkan untuk melatih rangkaian MLP hibrid ini oleh Mashor (2000b). Penyelidikan tersebut menamakan seni bina rangkaian baru tersebut sebagai rangkaian Perseptron Berbilang Lapisan Hibrid (*Hybrid Multilayered Perceptron, HMLP*). Gabungan rangkaian HMLP dengan algoritma pembelajaran MRPE telah terbukti mempunyai prestasi pengelasan yang lebih baik berbanding rangkaian MLP, RBF dan rangkaian RBF hibrid konvensional (Mashor 2000a, 2000b).

Perkembangan-perkembangan penyelidikan yang dilakukan ini pada dasarnya bertujuan untuk meningkatkan keupayaan pengelasan corak rangkaian neural konvensional. Dari semasa ke semasa, penambahbaikan terhadap seni bina dan algoritma pembelajaran rangkaian neural konvensional masih dan perlu dilakukan dalam usaha meningkatkan keupayaannya. Ini bersesuaian dengan keadaan semasa yang menuntut kepada pembinaan sistem pengelasan corak yang lebih berkebolehan untuk menyelesaikan pelbagai bentuk permasalahan corak yang semakin kompleks dan mencabar.

1.3 Penyataan Masalah dan Motivasi

Prestasi sebenar suatu rangkaian neural ditentukan oleh kebolehan sesuatu rangkaian tersebut untuk melakukan pengitlakan (*generalization*) semasa berada di dalam keadaan optimum (Lin *et al.*, 2009, Mrázová & Wang, 2007 dan Kavogli, 1999). 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 (Vlahogianni *et al.*, 2005 dan Principe *et al.*, 2000). Keadaan optimum pula ialah keadaan di mana semua parameter rangkaian seperti nod masukan, nod tersembunyi, nod keluaran, nilai awalan pusat dan nilai pemberat sambungan berada pada kombinasi terbaik atau optimum semasa proses pembelajaran dilakukan.

Proses pembelajaran rangkaian MLP biasanya dilakukan menggunakan algoritma pembelajaran BP. Walaupun prestasi yang diperoleh adalah baik, namun algoritma ini

sering dikaitkan dengan beberapa masalah utama. Masalah-masalah tersebut ialah kadar penumpuan (*convergence rate*) yang perlahan (Guangjun *et al.*, 2008) dan proses pencarian pemberat dan nilai ambang optimum rangkaian sering terperangkap di dalam minima setempat (*local minima*) serta sensitif kepada nilai awalan pembolehubah yang telah diset sebelum pembelajaran dilaksanakan (Choi *et al.*, 2008).

Rangkaian RBF konvensional pula mempunyai masalah di dalam menentukan lokasi pusat yang terbaik. Lokasi pusat rangkaian RBF biasanya ditentukan menggunakan algoritma pengelompokan Purata-k. Seperti algoritma pengelompokan tipikal yang lain, algoritma pengelompokan Purata-k mempunyai tiga kekurangan utama. Kekurangan tersebut ialah fenomena pusat mati, kehadiran pusat bertindih dan pusat terperangkap di dalam minima setempat (Mat-Isa, 2008a & Maffezzoni & Gubian, 1995).

Masalah-masalah kepada rangkaian MLP dan RBF konvensional ini telah mempengaruhi kebolehan pengitlakan dan prestasi pengelasannya. Prestasi pengelasan yang rendah dan tidak stabil akan membatasi perkembangan aplikasi rangkaian neural untuk menyelesaikan masalah pengelasan corak di dalam dunia sebenar. Terutamanya jika permasalahan tersebut membabitkan pengaplikasian rangkaian neural di dalam bidang-bidang kritikal seperti kejuruteraan; yang memerlukan ketepatan sistem yang tinggi, dan juga pengaplikasian di dalam bidang perubatan; di mana ia melibatkan nyawa manusia.

Sebagai respons kepada permasalahan tersebut, penyelidikan ini mencadangkan pembinaan suatu seni bina rangkaian neural baru bersama-sama dengan sebuah algoritma pembelajaran terubahsuai. Beberapa ciri positif lain turut diintegrasikan ke dalam

rangkaian baru yang diperkenalkan. Konsep sambungan linear dan konsep prapengelasan adalah ciri-ciri positif yang dimaksudkan. Ciri-ciri positif ini telah diadaptasi dan dikenal pasti hasil daripada pengkajian ilmiah yang dilakukan secara mendalam terhadap evolusi perkembangan rangkaian neural jenis Perseptron (iaitu SLP, MLP dan HMLP) dan RBF (rujuk Bahagian 2.2.2). Justeru itu, secara hipotesisnya, suatu rangkaian yang mempunyai keupayaan dan prestasi yang lebih baik akan dapat dihasilkan.

1.4 Objektif dan Skop Kajian

Penyelidikan ini akan mengetengahkan dua objektif utama untuk dipenuhi. Dua objektif utama tersebut ialah:

1. Membina sebuah seni bina rangkaian neural baru yang mengintegrasikan ciri positif rangkaian neural jenis Perseptron dan RBF.
2. Memperkenalkan sebuah algoritma pembelajaran baru terubahsuai untuk melatih seni bina rangkaian baru yang diperkenalkan.

Berdasarkan motivasi daripada penyelidikan-penyeleidikan terdahulu, satu seni bina baru rangkaian neural akan diperkenalkan di dalam penyelidikan ini khusus sebagai pengelas corak data. Seni bina tersebut dinamakan rangkaian neural Perseptron Berbilang Lapisan Hibrid Berkelompok (*Clustered Hybrid Multilayer Perceptron, Clustered-HMLP*). Seni bina ini mengintegrasikan ciri positif rangkaian HMLP dan RBF konvensional. Berbanding rangkaian HMLP konvensional, rangkaian Clustered-HMLP terdiri daripada satu lapisan masukan, satu lapisan tersembunyi, satu lapisan keluaran dan

satu lapisan tambahan yang dipanggil lapisan pusat. Pengenalan lapisan pusat pada seni bina rangkaian Clustered-HMLP diilhamkan daripada seni bina rangkaian RBF. Ini bermakna, setiap data mentah yang masuk akan dipra-kelaskan (*pra-classification*) terlebih dahulu untuk mencari lokasi pusat-pusat pada lapisan pusat rangkaian Clustered-HMLP. Selesai proses pra-pengelasan, semua data masukan mentah akan diwakili oleh pusat-pusat rangkaian Clustered-HMLP. Keluaran lapisan pusat ini kemudiannya akan dirambat kepada nod tersembunyi dan nod keluaran untuk melengkapkan proses pembelajaran rangkaianya.

Bagi proses pembelajaran rangkaian neural Clustered-HMLP yang dibina, algoritma pembelajaran Ralat Ramalan Jadi Semula Ubahsuai Berkelompok (*Clustered Modified Recursive Prediction Error, Clustered-MRPE*) dicadangkan. Algoritma Clustered-MRPE merupakan algoritma pembelajaran yang dihasilkan melalui gabungan di antara algoritma pembelajaran MPRE terubahsuai dengan algoritma pengelompokan Purata-k Boleh Gerak (*Moving k-mean, MKM*). Modul operasi algoritma ini dibahagikan kepada dua prosedur. Pada prosedur pertama, lokasi pusat-pusat pada lapisan pusat akan ditentukan dahulu menggunakan algoritma pengelompokan MKM, sebelum dirambat sebagai masukan kepada nod tersembunyi dan nod keluaran rangkaian Clustered-HMLP. Pada prosedur kedua, dengan menggunakan data masukan yang telah dirambatkan tadi (semasa prosedur pertama), padanan parameter sambungan pemberat di antara nod pusat dengan nod tersembunyi, sambungan pemberat di antara nod pusat dengan nod keluaran dan padanan pincang rangkaian Clustered-HMLP akan ditentukan menggunakan algoritma MRPE yang telah diubahsuai. Proses pembelajaran rangkaian Clustered-HMLP tamat setelah prosedur kedua ini selesai.

Skop kajian untuk penyelidikan ini ialah untuk memperkenalkan seni bina rangkaian Clustered-HMLP yang dilatih menggunakan algoritma pembelajaran Clustered-MRPE sebagai sistem pengelasan corak. Oleh itu, prestasi dan keupayaan pengelasan rangkaian Clustered-HMLP akan diuji menggunakan 16 buah eksperimen. Eksperimen ini akan membabitkan penyelesaian permasalahan pengelasan terhadap 14 jenis set data penanda aras yang diperoleh daripada Repositori (*Respository*) Mesin Pembelajaran University California, Irvine (UCI, 2009). Untuk penilaian prestasi, prestasi pengelasan yang dicatatkan oleh rangkaian Clustered-HMLP untuk setiap eksperimen akan dibandingkan dengan prestasi 12 sistem-sistem pengelasan lain yang direkodkan di dalam terbitan-terbitan ilmiah sebelum ini termasuk rangkaian HMLP. Analisis perbandingan di antara semua sistem akan dilakukan dan sistem pengelasan terbaik untuk setiap eksperimen akan ditentukan.

Pengaplikasian terhadap rangkaian Clustered-HMLP akan dilakukan di dalam penyelidikan ini untuk menguji tahap keupayaan dan keboleharapannya. Oleh itu, dua sistem pintar menggunakan aplikasi rangkaian Clustered-HMLP akan dibina untuk menyelesaikan dua jenis permasalahan pengelasan dunia sebenar masing-masing di dalam bidang kejuruteraan dan perubatan. Di dalam bidang kejuruteraan, sebuah sistem diagnosis kerosakan transformer akan dibina berdasarkan teknik Analisis Gas Terlarut (*Dissolved Gas Analysis, DGA*). Sistem ini diharapkan mampu meningkatkan mutu diagnosis transformer semasa proses penyelenggaraannya dengan menyediakan keputusan diagnosis berkecekapan 100%. Pengaplikasian kedua ialah pembinaan sistem pengelasan sebatian (*compound*) seakan ubat (*drug-like, DL*) dan tak seakan ubat (*non drug-like, NDL*) dengan menggunakan pemerihal (*descriptor*) yang diadaptasi daripada

Aturan Lima Lipinski (*Lipinski Rule of Five, RO5*) dan aturan Veber. Sistem ini adalah satu alat bantu untuk suatu teknologi biologi klinikal yang digunakan bagi meningkatkan kecekapan proses penemuan ubat (*drug discovery, DD*).

1.5 Garis Panduan Tesis

Secara keseluruhannya, tesis ini mengandungi lima bab. Bab 1 memberi penerangan ringkas mengenai penyelidikan yang akan dilakukan. Penerangan ini merangkumi latar belakang pengenalan, objektif, penyataan masalah dan motivasi serta skop penyelidikan.

Bab 2 akan memfokuskan tentang kajian ilmiah berkenaan evolusi seni bina dan algoritma pembelajaran rangkaian neural dan aplikasinya sebagai sistem pengelas corak. Sub topik evolusi rangkaian neural Perseptron dimulakan dengan perbincangan mengenai seni bina rangkaian SLP dan diteruskan sehingga ia berevolusi menjadi rangkaian MLP dan HMLP. Evolusi seni bina rangkaian RBF turut dibincangkan sejurus selepas itu. Perbincangan tentang evolusi algoritma pembelajaran pula akan memberi penekanan kepada dua algoritma pembelajaran iaitu algoritma BP yang digunakan untuk melatih rangkaian MLP dan algoritma pengelompokan Purata-k yang digunakan untuk melatih rangkaian RBF. Masalah dan kekurangan kedua-dua algoritma akan dikenal pasti dan dibincangkan. Kemudian, beberapa penyelesaian terbaik yang dicadangkan oleh penyelidik-penyelidik sebelum ini akan dibentangkan dan diulas. Ulasan secara kritikal akan dilakukan untuk menentukan kebaikan dan keburukan setiap penyelesaian yang dicadangkan. Selepas itu, satu sub topik telah disediakan untuk membincangkan aplikasi-

aplikasi semasa rangkaian MLP, RBF dan HMLP di dalam menyelesaikan permasalahan membabitkan pengelasan corak. Dua topik terakhir akan membincangkan secara terperinci tentang dua aplikasi rangkaian Clustered-HMLP terhadap dua permasalahan dunia sebenar yang telah dipilih di dalam penyelidikan ini. Pengaplikasian tersebut ialah pembinaan sistem diagnosis transformer berdasarkan teknik DGA dan sistem pengelasan sebatian DL dan NDL menggunakan pemerihal berasaskan RO5 dan Veber.

Bab 3 dibahagikan kepada tiga bahagian utama. Bahagian pertama dan kedua masing-masing akan menerangkan secara terperinci seni bina rangkaian Clustered-HMLP dan algoritma pembelajaran Clustered-MRPE yang dicadangkan di dalam penyelidikan ini. Bahagian ketiga di dalam bab ini pula akan membincangkan tentang analisa atau eksperimen penilaian yang telah dilakukan untuk menguji kebolehan dan prestasi rangkaian Clustered-HMLP. Kaedah analisa, jenis parameter pengukuran dan data-data yang digunakan ialah perkara-perkara yang akan dibincangkan di bahagian ini. Keputusan prestasi rangkaian Clustered-HMLP untuk semua eksperimen akan dianalisa dan dibincangkan secara terperinci. Kemudian, prestasi rangkaian Clustered-HMLP akan dibandingkan dengan prestasi sistem-sistem lain yang terdapat di dalam kajian ilmiah penyelidikan terdahulu.

Fokus perbincangan di dalam Bab 4 pula adalah berkaitan dengan pengaplikasian rangkaian Clustered-HMLP untuk menyelesaikan dua kes permasalahan dunia sebenar. Kajian kes mengenai pembinaan sistem diagnosis kerosakan transformer menggunakan teknik DGA akan dibincangkan terlebih dahulu. Perbincangan bersambung di dalam kajian kes kedua di mana sebuah sistem pengelasan sebatian DL dan NDL menggunakan

pemerihal berasaskan RO5 dan Veber akan diperkenalkan. Seperti Bab 3, latar belakang, kaedah analisa dan jenis parameter pengukuran merupakan kandungan perbincangan bagi setiap kajian kes. Keputusan eksperimen akan dianalisa dan dibandingkan dengan keputusan sistem lain yang telah direkodkan di dalam terbitan-terbitan lepas.

Bab 5 merupakan bab terakhir di dalam tesis ini. Semua keputusan dan ulasan yang diperoleh di dalam penyelidikan ini akan disimpulkan di dalam Bab 5. Beberapa cadangan untuk mendalami penyelidikan ini pada masa hadapan turut dibincangkan di dalam bab ini.

BAB 2

EVOLUSI SENI BINA DAN ALGORITMA PEMBELAJARAN RANGKAIAN

NEURAL SEBAGAI PENGELAS CORAK

2.1 Pengenalan

Rangkaian neural telah terbukti mempunyai kebolehan yang tinggi di dalam menyelesaikan permasalahan kompleks berkaitan dengan pengelasan corak (Silva *et al.* 2008, Sadik & Mustafa, 2007 dan Lung 2007). Minat terhadap pengkajian rangkaian neural telah bermula sejak kurun ke-19 berdasarkan pengkajian para penyelidik tentang bagaimana otak manusia berfikir. Rangkaian neural semakin mendapat perhatian umum selepas pengenalan algoritma Perambatan Balik (*Back Propagation, BP*) di dalam penerbitan “Perwakilan Pembelajaran Dalaman oleh Ralat Balik (*Learning Internal Representations by Error Propagation*)” pada tahun 1986 oleh Rumelhart *et al.* (1986). Sejak daripada itu, seni bina dan algoritma pembelajaran rangkaian neural telah mengalami pelbagai evolusi penambahbaikan dan pengubahsuaian. Kesan daripada evolusi-evolusi tersebut, pelbagai jenis sistem rangkaian neural terkini yang lebih cerdik dan pintar telah berjaya dihasilkan oleh para penyelidik.

Bab ini dibahagikan kepada tiga bahagian utama. Pada bahagian pertama, topik berkaitan rangkaian neural akan dibincangkan. Perbincangan meliputi ulasan secara terperinci tentang evolusi seni bina dan algoritma pembelajaran rangkaian neural serta pengaplikasian semasa rangkaian neural sebagai pengelasan corak. Bahagian kedua dan

ketiga masing-masing membincangkan tentang aplikasi rangkaian neural di dalam bidang kejuruteraan untuk mendiagnosis kerosakan transformer secara dalam talian (*on-line*) dan pengaplikasian rangkaian neural sebagai sistem bantuan di dalam teknologi biologi klinikal untuk proses penemuan ubat (*drug discovery, DD*). Sub topik Ulasan akan diperuntukkan di akhir setiap bahagian utama bagi menjustifikasi motivasi dan inspirasi yang diperoleh daripada ulasan penyelidikan terdahulu, untuk dimuatkan di dalam penyelidikan ini. Turut dibincangkan adalah skop sumbangan penyelidikan ini di dalam setiap bidang yang telah dibincangkan iaitu bidang pembangunan rangkaian neural, teknologi penyelenggaraan sistem bekalan kuasa dan DD.

2.2 Rangkaian Neural Buatan

Para penyelidik telah berusaha sejak berabad-abad yang lalu untuk memajukan kajian di dalam bidang neurobiologi dan psikologi. Tujuannya ialah untuk memahami prinsip biofizik mengenai cara otak manusia berfikir. Hasilnya para penyelidik telah berjaya mengenalpasti dan menghuraikan fungsi yang dimainkan oleh sistem rangkaian saraf neural sebagai sistem pemprosesan maklumat utama di dalam otak manusia.

Seiring dengan kemajuan teknologi pengkomputeran, wujud cadangan di kalangan penyelidik untuk membina suatu sistem kecerdikan buatan (*artificial intelligent system*). Sistem yang dicadangkan ini dibangunkan dengan meniru dan mengadaptasi konsep pemprosesan sistem saraf neural manusia. Melalui pendekatan ini, para penyelidik berharap agar sistem pintar yang dihasilkan akan mempunyai keupayaan

untuk menjalankan fungsi-fungsi yang mimik otak manusia seperti pengelasan corak, peramal fungsi, pengenalpastian sistem, pemprosesan data, membuat keputusan dan sebagainya. Sistem yang dimaksudkan dikenali sebagai sistem rangkaian neural buatan (RNB).

Norgaard *et al.* (2000) mentakrifkan RNB 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. Haykin (1998) pula mentakrifkan RNB sebagai pemproses teragih selari besar yang mempunyai satu kecenderungan semulajadi untuk menyimpan pengetahuan berpengalaman dan menggunakan.

Sejak diperkenalkan oleh McColluch & Pitts (1944) pada tahun 1940-an, RNB telah diaplikasikan untuk menyelesaikan pelbagai bentuk masalah di dalam bidang sains dan kejuruteraan. Antara bentuk pengaplikasian yang paling popular ialah untuk menyelesaikan permasalahan berkaitan dengan pengelasan corak (Mezghani & Mitiche, 2008 dan Suma & Murali, 2008).

Secara amnya, proses pengelasan corak boleh dibahagikan kepada dua peringkat iaitu pengekstrakan pemerihal (*feature extraction*) dan pengelasan (Xu *et al.*, 2009, Quteishat, 2008, Duda *et al.*, 2002, Nugent *et al.*, 1999, Young & Clavert, 1974 dan Tou & Gonzalez, 1974). Pengekstrakan pemerihal membabitkan pemilihan ciri signifikan daripada masukan corak, dan menukarkannya kepada sebarang fungsi pengiraan bermaklumat (*informative measurement*) yang boleh mewakili ciri-ciri statistik masukan corak (Chiang, 2001). Sebagai contoh, corak abjad “E” dan “F” boleh dibezakan dengan

mengira bilangan lejang (*stroke*) yang dimiliki oleh abjad-abjad tersebut. Maka, pemerihal yang digunakan di dalam kes pengelasan corak abjad E dan F ialah bilangan lejang.

Peringkat pengelasan pula membabitkan proses penggunaan sebarang aturan pembuat keputusan (*decision making rule*) untuk membezakan masukan corak kepada kelas-kelas sasaran tertentu berdasarkan pemerihal yang diberi (Duda & Hart, 2002). Di dalam penyelidikan ini, fokus akan diberikan kepada peringkat pengelasan sahaja. Proses pengelasan akan dilaksanakan menggunakan aturan pembuat keputusan jenis RNB.

2.2.1 Seni Bina dan Algoritma Pembelajaran

Kebanyakan model rangkaian neural buatan mempertimbangkan neuron di dalam sel sebagai satu unit pemprosesan asas (Rumelhart, 1995). Neuron adalah unit pemprosesan informasi bagi suatu rangkaian neural buatan. Operasi yang dilakukan di dalam neuron tersebut akan menentukan fungsi dan jenis pengoperasian sesuatu rangkaian neural. Rajah 2.1 menunjukkan pemodelan neuron asas untuk suatu rangkaian neural buatan (Haykin, 2008, Gallant, 1995 dan Winston, 1992).

Berdasarkan Rajah 2.1, model asas neuron dibentuk daripada tiga komponen iaitu satu set sinaps atau sambungan rangkaian, satu penambah dan satu fungsi pengaktifan. Setiap sinaps pada neuron akan dicirikan dengan satu nilai pemberat. Andaikan neuron k yang dianalisis mempunyai n data masukan atau sinaps. Data atau signal, v_j pada masukan sinaps ke- j yang disambungkan pada neuron, k akan didarabkan dengan nilai

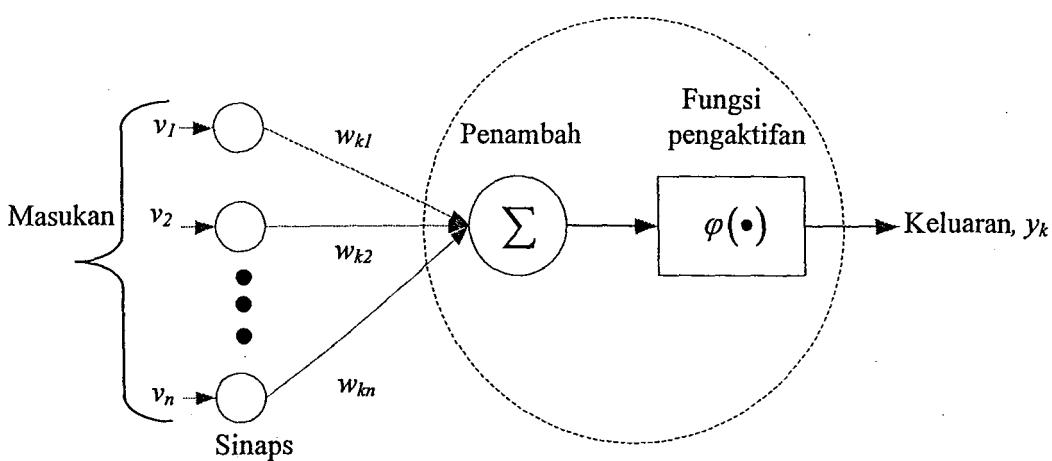
pemberat sinaps ke- j tersebut, w_{kj} . Penambah pula akan menambah semua signal v_j yang telah didarabkan dengan pemberat sinaps masing-masing untuk mendapatkan satu nilai tunggal keluaran penambah, x_k . Jumlah keluaran penambah, x_k ditunjukkan seperti persamaan berikut:

$$x_k = \sum_{j=1}^n w_{kj} v_j \quad (2.1)$$

Kemudian, hasil keluaran bagi neuron k akan diperolehi selepas nilai x_k melalui fungsi pengaktifan, φ seperti berikut:

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

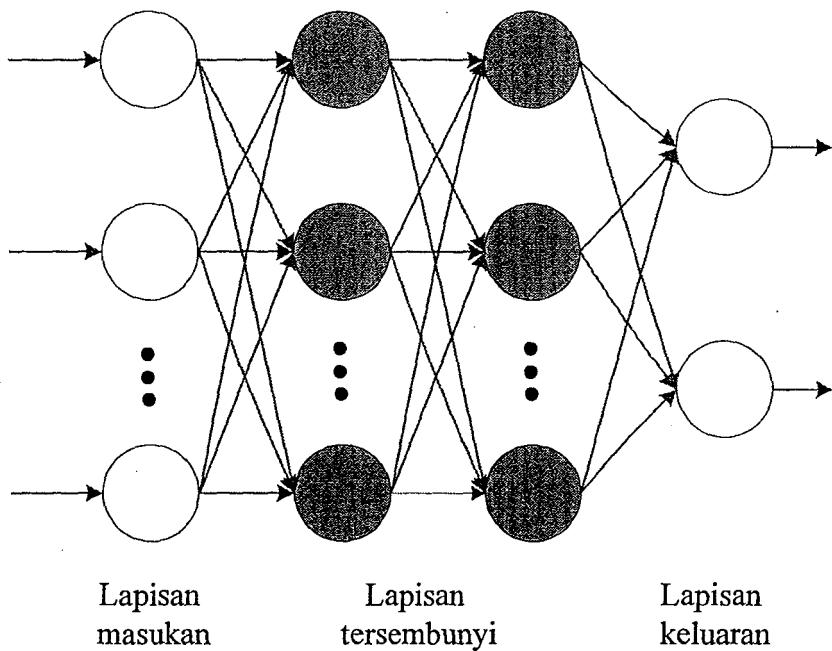
di mana y_k adalah keluaran bagi neuron k . Fungsi pengaktifan yang sering digunakan ialah seperti fungsi penghad tetap (*hard limiter*), linear sesecebis (*piecewise linear*), sigmoid dan linear (Nauck *et al.*, 1997 dan Haykin, 1994).



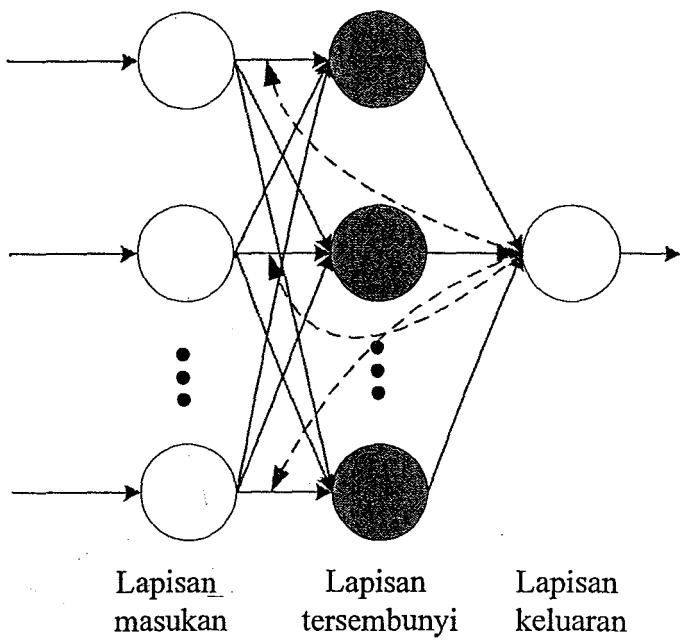
Rajah 2.1: Pemodelan asas neuron (Haykin, 2008)

RNB boleh dibezakan di antara satu sama lain melalui jenis seni bina atau algoritma pembelajaran yang digunakan (Welstead, 1994). Seni bina suatu rangkaian neural ditentukan oleh kedudukan dan sambungan di antara neuron dalam suatu rangkaian. Secara amnya, seni bina rangkaian neural boleh dibahagikan kepada dua jenis utama iaitu rangkaian neural suap depan (*feedforward*) dan rangkaian neural suap balik (Haykin, 2008, Norgaard *et al.*, 2000 dan Gallant, 1996).

Rajah 2.2 menunjukkan seni bina suatu rangkaian neural suap depan. Struktur ini dinamakan sedemikian rupa kerana rangkaian neural suap depan hanya membenarkan setiap neuron untuk menerima data masukan daripada neuron pada lapisan terdahulu sahaja. Sebaliknya, seni bina rangkaian neural suap balik mempunyai sekurang-kurangnya satu gelung suap balik seperti yang ditunjukkan di dalam Rajah 2.3.



Rajah 2.2: Rangkaian neural suap depan



Rajah 2.3: Rangkaian neural suap balik

Menurut Haykin (1994), proses pembelajaran kepada rangkaian neural adalah suatu proses yang mana parameter-parameter bebas rangkaian neural dipadankan melalui proses stimulasi yang berterusan oleh persekitaran yang mana rangkaian neural itu berada. Terdapat dua fasa yang perlu dilalui oleh setiap rangkaian neural semasa proses pembelajaran iaitu fasa latihan (*training phase*) dan fasa ujian (*testing phase*) (Abdul-Kader, 2009). Pada fasa latihan, rangkaian neural akan dimasukkan dengan satu set data latihan. Data latihan ini akan digunakan oleh rangkaian neural tersebut untuk mempelajari ciri-ciri statistik data masukan (iaitu data latihan) bagi mewakili keseluruhan corak data tersebut. Ciri-ciri statistik ini adalah seperti corak perubahan data keseluruhan, corak pengelompokan data dan sebagainya (Mat-Isa, 2003). Proses pembelajaran akan menentukan nilai optimum parameter-parameter bagi rangkaian neural tersebut supaya mencapai kemampuan pengitlakan (*generalization*). Keupayaan rangkaian untuk

mewakili keseluruhan data akan diuji semasa fasa ujian menggunakan set data ujian yang baru. Kaedah pembelajaran RNB boleh dibahagikan kepada dua mod iaitu pembelajaran terselia (*supervised learning*) dan pembelajaran tak terselia (*unsupervised learning*) (Haykin, 2008).

2.2.2 Evolusi Rangkaian Neural

Kecekapan sistem saraf manusia untuk menjalankan fungsi kompleks seperti mengecam, menghafal serta mentafsir corak amat dikagumi oleh para penyelidik. Justeru itu, pelbagai usaha penyelidikan telah dilakukan untuk menjadikan pembinaan sistem kecerdikan RNB sebagai suatu realiti.

Hipotesis untuk membina sistem RNB yang pada mulanya samar dan diragui telah memasuki era baru dengan penerbitan jurnal perintis bertajuk “Kalkulus Logik Perubahan Idea Di dalam Aktiviti Saraf (*A Logical Calculus of The Ideas Immanent in Nervous Activity*)” oleh McColluch & Pitts (1944). Di dalam penerbitan tersebut, mereka telah berjaya membina satu model RNB asas yang berupaya melakukan proses pengiraan fungsi matematik dan logik. Hebb (1949) mengiktiraf penemuan penyelidikan McColluch & Pitts (1944) tersebut dan diperkuuhkan oleh beliau melalui pengenalan hukum pembelajaran yang dipanggil Hukum Hebb. Kemudian, Rochester dari International Business Machines (IBM) cuba mengaplikasikan simulasi hipotetikal RNB menggunakan komputer (Zini & d'Onofrio, 2003). Malangnya usaha tersebut telah gagal. Sebaliknya, pada tahun 1962, Widrow dan Hoff telah berjaya membina model Elemen Linear

Adaptasi (*Adaptive Linear Element, ADALINE*) dan Elemen Linear Adaptasi Berbilang (*Multipule Adaptive Linear Element, MADALINE*) untuk meramal bit penstriman (Widrow & Winter, 1988). Di dalam masa yang sama, model Perseptron telah diperkenalkan oleh Rosenblatt (1958). Penemuan Perseptron dianggap penting kerana model ini kemudiannya telah menjadi sebagai rujukan utama kepada penghasilan rangkaian neural jenis Perseptron seperti rangkaian neural Perseptron Lapisan Tunggal (*Single Layer Perceptron, SLP*) dan rangkaian neural Perseptron Berbilang Lapisan (*Multilayered Perceptron, MLP*) (Logeswaran, 2002).

Perkembangan RNB mengalami zaman suram pada tahun 1970-an disebabkan oleh demonstrasi yang dikemukakan oleh Minsky & Papert (1969) tentang kelemahan dan kekangan pada struktur Perseptron di dalam bukunya yang bertajuk “Perseptron”. Walaubagaimanapun, pada 1985, minat terhadap RNB diperbaharui setelah kelemahan Perseptron yang dikemukakan oleh Minsky dan Papert telah berjaya diatasi dengan pengenalan teori BP oleh Rummelhart *et.al.* (1986) dan Cun (1986). Teori tersebut mencadangkan supaya maklumat mengenai ralat pada nod keluaran dibawa balik ke nod tersembunyi.

Sejak daripada itu, usaha-usaha pembangunan teknologi RNB dan pengaplikasiannya sebagai pengelas corak pintar telah berkembang secara drastik. Hasilnya, beberapa lagi penemuan baru telah berjaya dicapai bagi memperbaiki model asal RNB McCulloch. Sebagai contoh, Hopfield telah berjaya membangunkan beberapa rangkaian neural berdasarkan pemberat tetap dan pengaktifan adaptasi (Liu & You, 2008 dan Lee *et al.*, 1998). Neo-kognisi (*Neocognition*) pula telah dibangunkan oleh

Fukushima (1988) untuk menyelesaikan masalah pengecaman aksara. Teori Resonans Adaptasi (*Adaptive Resonance Theory, ART*) pula telah diperkenalkan oleh Grossberg pada lewat 1980-an (Carpenter & Grossberg, 1987). Lain-lain perkembangan dalam pembinaan RNB adalah seperti pembinaan model Kohonen yang memperkenalkan konsep Pemetaan Tersendiri ke atas satu atau dua dimensi struktur kekisi (*lattice structure*) (Kohonen, 2001, 1982). Dua contoh terakhir ialah pengenalan rangkaian Fungsi Asas Jejarian (*Radial Basis Function, RBF*) oleh Broomhead & Lowe (1988) dan pengenalan rangkaian Perseptron Berbilang Lapisan Hibrid (*Hybrid Multilayered Perceptron, HMLP*) oleh Mashor (2000b).

Hari ini, rangkaian neural suap hadapan MLP dan RBF telah digunakan secara meluas untuk menyelesaikan pelbagai masalah di dalam bidang pengelasan corak. Populariti ini adalah berdasarkan keupayaan kedua-dua rangkaian tersebut untuk menghasilkan pemetaan hubungan tidak linear yang kompleks di antara data masukan dan keluaran untuk mencapai kapasiti pengitlakan yang baik, serta mudah untuk diimplementasikan.

2.2.2.1 Evolusi Rangkaian Neural Perseptron

Obsesi Rosenblatt (1958) terhadap mata lalat telah memberi inspirasi kepadanya untuk membina model Perseptron. Perseptron ialah model kepada neuron manusia yang mengaplikasikan pengubahsuaian pemberat secara iteraktif. Konsep Perseptron kemudiannya telah menjadi asas kepada pembinaan rangkaian neural suap hadapan SLP.

Kekangan pada fungsi rangkaian SLP yang terhad telah mendorong kepada pembinaan sebuah lagi rangkaian neural suap depan jenis Perseptron iaitu rangkaian MLP (Óvido & Celestino, 2008 dan Dumas II, 2006). Rangkaian neural jenis Perseptron terus berevolusi apabila rangkaian MLP dengan sambungan linear diperkenalkan oleh Mahsor (2000b) pada tahun 2000. Rangkaian tersebut juga dikenali sebagai rangkaian HMLP.

2.2.2.1.1 Rangkaian Perseptron Lapisan Tunggal

Rangkaian neural Perseptron Lapisan Tunggal (*Single Layer Perceptron, SLP*) merupakan rangkaian neural suap hadapan pertama yang telah dibina. Rangkaian SLP berkebolehan untuk mengelaskan permasalahan corak berbentuk boleh pisah linear (*linear separable*). Seni bina rangkaian SLP terdiri daripada satu lapisan nod masukan dan satu lapisan nod keluaran. Setiap lapisan nod tersebut terbina daripada pengkaskadan satu atau lebih model Perseptron Rosenblatt (1958). Rajah 2.4 menunjukkan seni bina rangkaian SLP dengan lima nod yang mampu mengecam corak boleh pisah linear kepada dua kelas (dua nod keluaran) berdasarkan tiga ciri masukan (tiga nod masukan). Penambahan kepada hasil pendaraban semua pemberat dan masukan akan menentukan aturan padanan hiperkekisi (*hyperplanes*) untuk suatu permasalahan boleh pisah linear. Hiperkekisi tersebut akan memisahkan setiap kelas keluaran seperti yang ditunjukkan pada Rajah 2.5.