

類神經網路輔助醫療診斷分類模式之建構

¹黃美玲 ²陳幸宜 ¹陳貴琳 ¹李雅雯

¹國立勤益技術學院工業工程與管理學系(台中縣太平市中山路一段 215 巷 35 號)

²中國醫藥大學眼科部(台中育德路 2 號)

E-mail : huangml@ncit.edu.tw

摘要

過去醫學診斷多只靠醫師以往的經驗，但是現今疾病因素多元化，如果能配合資料探勘的技術則可以以輔助醫生以提高診斷正確率。許多研究也證實應用機器學習技術，對於疾病診斷是有相當大的幫助。本研究應用檢驗儀器-神經纖維分析儀(Nerve Fiber Analyzer GDx)，分別對倒傳遞類神經網路、廣義迴歸類神經網路、學習向量量化網路做訓練與測試，其 Receiver Operating Characteristic(ROC)曲線下的面積分別為 0.82、0.762、0.850，顯示學習向量量化網路有較佳的學習效果，因此可以利用學習向量量化網路來輔助醫師診斷，以達到及早發現及早治療的目的。

關鍵字：青光眼、類神經網路、ROC 曲線。

1.緒論

隨著資訊科技的進步以及硬體設備的快速升級，對於資料的收集和儲存已經是很容易的事。在龐大資料下，並不是所有的資訊都是有用的，如何在這龐大的資料中找尋有用的資訊，並做有效率且正確的處理，是一門很重要的課題。近年來，資料探勘(Data mining)是一相當熱門的領域，其目的就是在龐大雜亂無章的資料中，找尋隱含、潛在有用的資訊。資料探勘的種類分為分類、推估、預測、同質分組或關聯規則、群集、描述與視覺化這六種[8]。分類就是依據現有的類別，定義其特徵，藉由訓練來學習規則，然後建立分類器的模型，當遇到一筆新的資料時，即可判定該資料是屬於何種類別。

醫療診斷可說是相當典型的分類問題，醫師藉由患者出現的症狀，依據過去經驗來診斷患者所患的疾病。但是，在現今的生活當中，造成疾病的因素相當多元化，再加上疾病的預防勝於治療，如果可以在患者病發初期時診斷出疾病，即可及早做治療以避免更嚴重的後果。為了達到這個目的，我們希望藉由機器學習(Machine learning)的技術，以輔助醫師做診斷以提高診斷的準確性。

眼睛是我們重要的器官之一，如果不好好的保護會造成極大的不便。青光眼(glaucoma)是一種視神經病變，視神經盤與視野有特徵性缺損伴隨著視網膜神經節

細胞死亡，這樣的病變會造成視野範圍逐漸縮減，直到眼睛看不見。視神經一旦受到傷害，就無法再回復，而青光眼病發初期是無痛且不易發覺，引起的視力受損一般是從視野兩旁開始，視力會逐漸收窄，直至他們的視野範圍只剩餘低於兩成甚至看不見。引起這樣的視神經病變主要是因為眼壓過大；眼壓指的就是眼球內的壓力，而影響眼球壓力的原因是眼球內的房水液。房水液的分泌與排出在正常情況下，為了保持平衡狀態，會使眼睛壓力維持在 20 至 22 毫米汞柱高以下。但是，也有一種青光眼疾病其眼壓是正常的，這種青光眼稱為「正常眼壓性青光眼」，眼壓是正常的，但是由於本身視神經比較脆弱，無法承受正常的眼壓，因而壓傷了視神經。所以，診斷是否罹患青光眼的主要關鍵在於視神經以及視野是否缺損。

在目前已開發國家中，青光眼是導致成年人失明的四大主因之一，而視神經一旦受損是無法再恢復。綜合以上各個論點，為了輔助提升醫師診斷正確率，並能及早發現及早治療，我們藉由 GDx 儀器的檢驗，在配合類神經網路的學習，建立一適合台灣人種的青光眼鑑別系統。

2. 類神經網路

依據神經科學家與醫學家的研究，人類大腦中有無數的神經元，而每一種神經元均掌管不同的感知、推理、記憶與學習工作。類神經網路當初的目的是希望模仿生物的神經網路，仿造神經的組織與運行的資訊處理系統，利用輸入與輸出的資料建構一個系統。現在有許多學者將類神經網路應用到各個領域，例如：工業與工程資料分析、工業與工程故障診斷、影像辨識系統、商業決策、商業預測、醫學疾病診斷、醫學影像診斷。

類神經網路(Artificial Neural Network, ANN)是由許多人工神經元所組成的，人工神經元又稱為類神經元、處理單元，而每一個處理單元的輸出為下一個處理單元的輸入。人工神經元其輸入輸出的關係式，可用以下函數式子表示(2)：

$$Y_j = f\left(\sum_i W_{ij} X_i - \theta_j\right) \quad (1)$$

其中 Y_j = 模仿生物神經元模型的輸出訊號。

f = 模仿生物神經元模型的轉換函數(Transfer Function)，是一個將輸入值乘上權重加總後再經轉換成人工神經元輸出值的數學式。

W_{ij} = 模仿生物神經元模型的神經節強度，又稱連結權種值。

X_i = 模仿生物神經元模型的輸入訊號。

θ_j = 模仿生物神經元模型的偏權值。

一個神經網路的架構分為輸入層、隱藏層、輸出層，由下方做說明：

輸入層：用來表現網路的輸入變數，其處理的單元數目依問題而定。

隱藏層：用來表現輸入神經元間的交互影響，其處理神經元數目並沒有標準的方法以做決定，通常要以試驗的方式來決定其最佳數目，網路可以不只一層隱藏層，也可以沒有隱藏層。

輸出層：用來表現網路的輸出變數，其神經元數目依問題而定。

目前著名的類神經網路模式有數十種，而依照類神經網路的學習方式，大致上可分監督式學習、非監督式學習網路、聯想式學習網路、最佳化應用網路這四大類，這四大類學習方式由以下做介紹(2)：

1、監督式學習網路(Supervised Learning Network)

監督式學習網路必須從問題的中取得訓練範例，包括輸入值與輸出值。首先訓練網路，依據期望輸出值與實際計算值差來調整整個網路權重，網路從中學習兩者間的映射規則以應用新的案例。應用這樣的學習方式主要有感知機網路(Perceptron)、倒傳遞網路(Back-Propagation Network, BPN)、機率神經網路(Probabilistic Neural Network, PNN)、廣義迴歸類神經網路(General Regression Neural Network, GRNN)、學習向量量化網路(Learning Vector Quantization, LVQ)以及反傳遞網路(Counter-Propagation Network, CPN)。

2、非監督式學習網路(Unsupervised Learning Network)

非監督式學習網路指輸入資料，沒有期望的輸出資料，所以沒有最小誤差的要求，訓練方式是根據輸入資料，學習範例間的內部分類規則，無須外在監督可自行調整網路權重矩陣，使網路可自行分類一致或接近的輸出向量，可應用於樣本識別。應用這樣的學習方式主要有自組織映射圖網路(Self-Organizing Map)、自適應共振理論網路(Adaptive Resonance Theory)。

3、聯想式學習網路(Associate Learning Network)

從範例中學習內部聯想記憶規則以應用新的案例，通常應用於資料擷取與雜訊過濾。應用這樣的學習方式主要有霍普菲爾網路(Hopfield Neural Network)、雙向聯想記憶網路(Bi-Directional Associative Memory)。

4、最佳化應用網路(Optimization Application Network)

依據問題設計其變數值，在滿足設計限制條件下，能達到最佳的設計目標。應用這樣的學習方式主要有霍普菲爾—坦克網路(Hopfield-Tank Neural Network)、退火神經網路(Annealed Neural Network)。

2.1 倒傳遞類神經網路

倒傳遞類神經網路(BPN)是目前類神經網路模式中最具代表性，且應用最廣泛、最普遍的。倒傳遞類神經網路是從感知機延伸過來，感知機缺乏隱藏層的學習演算法，所以學習能力受到限制，而在 1974 年時，韋柏斯(P. Werbos)首先提出了隱藏層的學習演算法，但是當時並沒有受到多大的注意，直到 1985 年，派克(D. Parker)再次提出到傳遞類神經網路才受到重視。

倒傳遞類神經網路先取得問題中的訓練樣本以及真實的輸出值，再利用其基本原理—最陡坡降法(The Gradient Steepest Descent Method)，反覆的調節修正各個神經元的權重值，並使誤差最小化。倒傳遞類神經網路是監督式的學習網路，廣泛的運用在預測、分類、診斷等。

2.2 廣義迴歸類神經網路

廣義迴歸類神經網路(GRNN)是一監督式的學習方式網路。在 1988 年時，Donald F. Specht 提出了機率類神經網路(PNN)，此網路屬於監督式學習方式，其基本構想原理是從機率模型所啟發而來。但是，由於機率類神經網路只適合用於做分類問題，對於連續變數的問題卻無法解決。所以在 1991 年，Donald F. Specht 就提出了廣義迴歸類神經網路這個學習演算法。廣義迴歸類神經網路是由機率類神經網路所演變而來，這個演算法不只可以做分類問題，也可以用來學習動態模式並做預測或控制，而且對於線性或非線性的迴歸問題都有很好的處理能力。

廣義迴歸類神經網路是由機率類神經網路演變過來，而機率類神經網路是由機率模型所啟發而來，所以廣義迴歸類神經網路的基本原理也是依據機率模型所延伸的；一群具有 M 維輸入向量的訓練樣本，這些樣本可視為一 M 維空間中的樣本點，廣義迴歸類神經網路利用這些樣本點來估計一個未知樣本點函數值[3]。因為廣義迴歸類神經網路是以機率模行為啟發，所以不需要像傳統迴歸分析一樣先假設一明確函數形式，只需要以機率密度函數的方式呈現[5]。

倒傳遞類神經網路學習過程先是隨機亂數設初始網路連結權重值，接著再將訓練的樣本載入輸入層，經過回想過程計算出輸出的向量值，之後再計算輸出值與訓練樣本的目標值的差距，利用這個差距來修正網路的連結權重值，一直重複這個動作直到網路收斂為止。但是，廣義迴歸類神經網路的學習過程與倒傳遞類神經網路不同，其網路連結權重值是由訓練樣本的輸出與輸入來決定，而以下歸納出不同之處[5]：

- 1.不用初始網路連結權重值。
- 2.學習過程與回想過程無關。
- 3.不使用推論輸出值與訓練樣本的目標值之差距來修正網路連結權重值。
- 4.無迭代學習過程(one-pass learning)。
- 5.學習過程之目的在於尋找最佳平滑參數 σ 。

6.網路的神經元數與訓練樣本有關。

廣義迴歸類神經網路如同機率類神經網路一樣，其輸出值都屬於邏輯的二元值，但是不同於機率類神經網路，不只可以做分類的問題更可以應用於預測或是控制上。廣義迴歸類神經網路算是一個很新的類神經網路，應用的例子不多，不像倒傳遞類神經網路應用那麼普遍，其應用多在於控制與預測上居多。

2.3 學習向量量化網路

學習向量量化網路(LVQ)是一監督式學習網路，在 1988 年時，T. Kohonen 提出了這個網路模式，主要是用來做學習分類的類神經網路。學習向量量化網路的學習速度比倒傳遞類神經網路快，與機率類神經網路比來就比較慢了，但是，在回想速度上比較機率類神經網路快，而且所需的記憶體也比較少。雖然學習向量量化網路是屬於監督式的學習方式，但是，它其實是一種結合監督式學習網路與非監督式學習網路的類神經網路。訓練的過程分為兩個階段，第一個階段屬於非監督式學習方式，先將所有輸入的資料簡單大略的分成幾群；第二階段屬於監督式學習方式，利用目標輸出值，將第一階段的簡單分群在細調為所要的分類結果。

LVQ 算是一個新的類神經網路架構，應用方面並不是很多，而學習向量量化網路的輸出值為邏輯的二元值，所以很適合做分類方面的應用，現在的應用多為故障診斷、訊號分類、圖形辨識等。

2.4 ANN 文獻

1943 年，心理學家 McCulloch 與數學家 Pitts 共同發展了類神經網路的數學模式，在 1949 年時，Donald Hebb 對神經元提出修改規則，1954 年首次運用到電腦做測試。1958 年，神經生物學家羅生布拉特(Rosenblatt)發明感知機(Perceptron)，這是最早的類神經網路模式，隨後 Bernard Widrow 與 Marcian Hoff 也致力做這方面的研究。在 1969 到 1981 年為挫折期，因為一直無法突破理論的困境，雖然如此，還是有不少學者致力於研究。到了 1982 年，霍普菲爾(Hopfield)提出霍普菲爾網路，使類神經網路又再次活絡起來。

從 1943 年的數學模式發展到現在，類神經網路發展了十多種學習網路模式。隨這這幾十年的發展與研究，類神經網路應的領域相當廣泛，在工業與工程上的應用，可用於資料分析、故障診斷、製程監控、決策諮詢、最佳化問題等；在商業與金融上的應用，可用於商業決策、商業預測、商業分析；在科學與資訊上的應用，可用於醫療診斷、氣象預測、性向測驗分析、資料庫聯想搜尋等。下表 1 說明倒傳遞類神經網路、廣義迴歸類神經網路與學習向量量化網路的在各方面的應用，尤其是在醫學方面的應用。

表 1 相關文獻整理

網路	應用例子
BPN	• Li J et al. “Study of the pulmonary heart disease computer-aided diagnosis system based on combining neural network”, 2001 • Ashizawa K et al. “Artificial neural networks in chest radiography: application to the differential diagnosis of interstitial lung disease”, 1999 • Golub R et al. “The prediction of common bile duct stones using a neural network”, 1998
GRNN	• Roush WB et al. “Minimal number of chicken daily growth velocities for artificial neural network detection of pulmonary hypertension syndrome (PHS)”, 2001 • Bathen TF et al. “Quantification of plasma lipids and apolipoproteins by use of proton NMR spectroscopy, multivariate and neural network analysis”, 2000 • Roush WB et al. “Evaluation of broiler growth velocity and acceleration in relation to pulmonary hypertension syndrome”, 2000 • El-Solh AA et al. “Predicting active pulmonary tuberculosis using an artificial neural network”, 1999
LVQ	• Mattfeldt T et al. “Classification of spatial textures in benign and cancerous glandular tissues by stereology and stochastic geometry using artificial neural networks”, 2000 • Frame AJ et al. “A comparison of computer based classification methods applied to the detection of microaneurysms in ophthalmic fluorescein angiograms”, 1998 • Pantazopoulos D et al. “Comparing neural networks in the discrimination of benign from malignant lower urinary tract lesions”, 1998 • Pesu L et al. “Classification of respiratory sounds based on wavelet packet decomposition and learning vector quantization”, 1998

3. 研究方法

本研究採用類神經網路中的倒傳遞類神經網路、廣義迴歸類神經網路、學習向量量化網路這三種，藉此比較這三種方法的鑑別能力。這裡所使用的眼科診斷儀器為 GDx，而為了降低本研究所採用資料的雜訊，在篩選樣本時，受測者的近視超過 500 度，或是視野指數(MD)低於-10 以下的均捨棄不用。因此本研究所使用的資料樣本，正常眼 80 筆，青光眼 80 筆。樣本資料確定後，接著做的就是資料

的先前處理。本研究的變數有十四個，將每一個變數先進行正規劃，隨後先將資料份成 10 組，10 組的資料進行 10 次的交互驗證與測試；交互驗證即依序抽出一組為測試組，其餘為訓練組。進行完 10 次的交互驗證，將網路模擬的網路推論進行後續的分析。

3.1 倒傳遞類神經網路

本研究倒傳遞類神經網路的架構為，一個輸入層，一個隱藏層，一個輸出層。因為變數總共有十四項，所以在輸入層的神經元有十四個；在輸出層方面為一個神經元，目標值為 0 代表沒病，1 代表有病；轉換函數為 tansig；而在隱藏層神經元的多寡，依據葉宜成[2]所建議的三種狀況進行實驗：

簡單問題=(輸入層神經元數+輸出層神經元數)/2=7 或 8

一般問題=(輸入層神經元數+輸出層神經元數)=15

困難問題=(輸入層神經元數+輸出層神經元數)*2=30

在簡單問題方面算出來的神經元為 7.5，我們分別做 7 個跟 8 個神經元，依據這四種神經元個數訓練測試的結果，發現神經元個數為 15 時最好，所以本研究隱藏層神經元個數採用 15 個。架構確定後即可進行網路的訓練。

3.2 廣義迴歸類神經網路

架構為一個輸入層、一個隱藏層、以及一個輸出層。輸入層方面，同樣為十四個神經元；輸出層方面，同樣為一個神經元，0 代表沒病，1 代表有病；但是在隱藏層方面，神經元個數是不需要我們去設定的，網路會依據所輸入的資料去設定。而 GRNN 的設計重點在於平滑參數 σ 的設定， σ 的大小影響一個網路訓練的好壞；平滑參數太小幾乎只受到鄰近範例的影響，太大則受到全部範例的影響，換句話說，太大或太小都會使範例在回想過程中受到許多雜訊干擾，而適中的平滑參數就會將雜訊平滑掉。

依據黃敬淳[1]指出， σ 的選取可利用遞減式搜尋法；遞減式搜尋法即是先設定一平滑參數與折半係數，並設定學習循環次數，用個例子說明一下，假設初始設定平滑參數係數為 1.0，折半係數 0.5，學習訓練循環為 10，剛開始以 $\sigma=1.0$ 去訓練，第二次循環時以 $\sigma=0.5$ ，第三次 $\sigma=0.25$ ，依此類推直到第 10 次 $\sigma=0.0019$ ，然後選取結果最好的 σ ，此 σ 即為最佳的平滑參數。本研究仿照此方法，發現 σ 在 0.25 及 0.125 之間有較好的分類，因此縮小範圍在此區間找出較好的參數，最後選定 $\sigma=0.17$ 實為最佳平滑參數。

3.3 學習向量量化網路

包含一個輸入層、一個隱藏層、以及一個輸出層。在輸入層方面，同樣十四個神經元；隱藏層方面，在 LVQ 中，隱藏層又稱為競爭層，其用意是把資料大略分成幾個子類，這幾個子類再經過輸出層做目標的分類，而競爭層的神經元總是大大於輸出層(可能大大於輸出層神經元的數倍)，本研究採用試誤法，最後發現神經元 64 個以及學習率 0.3 的時候分類結果最好；在輸出層方面，本研究目標是在判斷有病沒病這兩類，加上輸出值是邏輯的二元值，所以輸出層有兩個神經元，其目標輸出的分類向量為[1 0](沒病)以及[0 1](有病)。

除了以上設定外，使用 MATLAB 軟體還需設定 Output class percentages，即典型種類百分比；而這裡使用的資料，沒病的有 80 筆，有病的有 80 筆，所以在 Output class percentages 的設定為[0.5 0.5]。

4.結果與分析

建構了一分類器的模型，接著就是要了解分類器模型的績效及鑑別力。本研究以 ROC(Receiver Operating Characteristic)曲線、明確度(Specificity)、敏感度(Sensitivity)來進行分析。ROC 曲線，其功用在於兩分類系統的區別能力，以下介紹明確度(Specificity)與敏感度 (Sensitivity) 這兩項指標。假設實際有病的 A 類有病 n_1 個，無病 B 類有 n_2 個，經過分類器判別後，判別 A 類有 N_1 個，B 類有 N_2 個，詳細情形以表呈現：

表 2 檢驗結果判斷表

	A 類	B 類	總合
判別 A 類	n_{11}	n_{21}	N_1
判別 B 類	n_{12}	n_{22}	N_2
總合	n_1	n_2	N

$$\text{敏感度(Sensitivity)} = \frac{n_{11}}{n_1} \quad (2)$$

$$\text{明確度(Specificity)} = \frac{n_{22}}{n_2} \quad (3)$$

ROC 曲線是以 X 軸(1-明確度)與 Y 軸(敏感度)所繪製的曲線，曲現下最大面積為 1.0[4]。一般來說，ROC 曲線下的面積越大越好，越大代表分類器模型可以正確判定資料的類別，反之越小則代表鑑別能力越差。

三種類神經網路經過測試訓練，最後 10 組的交互驗證資料綜合起來總共有 160 筆。將這三種類神經網路的測試資料去化 ROC 曲線圖，如圖 1 顯示。由圖來看，發現學習向量量化網路有比較好的測試結果。




圖 1 BPN GRNN LVQ 三種網路之 ROC 曲線圖

表 3 說明各個類神經網路的明確度、敏感度以及 ROC 曲線下的面積。在明確度上，學習向量量化網路比廣義迴歸類神經網路，甚至比倒傳遞類神經網路好很多；在敏感度上，倒傳遞類神經網路和學習向量量化網路都比廣義迴歸類神經網路好；從 ROC 面積來看，廣義迴歸類神經網路最差，而學習向量量化網路最好。綜合以上各點，本研究發現，學習向量量化網路在分類診斷上，與倒傳遞類神經網路和廣義迴歸類神經網路有較好的分類診斷能力。

表 3 三個網路整體資料之 ROC 值

	Sen.	Spe.	AROC
BPN	77.5	81.2	0.820
GRNN	65.0	86.2	0.762
LVQ	75.0	92.5	0.850

5. 結論

經由本研究實證分析，應用 GDx 的檢測，分別對三種類神經網路做比較，結果顯示學習向量量化網路學習效果較佳。因此，建議透過本研究所建構的模型來輔助醫師進行診斷，以達到早期發現早期治療的目的。

誌謝

本研究部分內容承蒙行政院國家科學委員會經費補助(計畫編號：NSC-95-2221-E-167-014)得以完成，特此誌謝。

參考文獻

1. 黃敬淳，2005，“平行式類神經網路電力負載預測系統模式化之研究”，私立東海大學工業工程與經營資訊學系，碩士論文。
2. 葉怡成，1999，類神經網路模式應用與實作，儒林圖書有限公司。
3. 曾育培，2001，“類神經網路於醫療業顧客失約預測之應用”，國立台北科技大學生產系統工程與管理研究所，碩士論文。
4. 程味兒，2004，“比較放射性鉈元素單光子發射電腦斷層攝影的不同判讀方法區別肺部的惡性腫瘤與良性病灶”，私立中國醫藥大學醫學研究所，碩士論文。
5. 劉亭宜，2000，“GRNN 在晶圓製造裡良率模式之建構與分析”，私立元智大學工業工程研究所，碩士論文。
6. Ashizawa K, Ishida T, MacMahon H, Vyborny CJ, Katsuragawa S, Doi K, 1999, “Artificial neural networks in chest radiography: application to the differential diagnosis of interstitial lung disease,” Academic Radiology , Vol.6, pp.2-9.
7. Bathen TF, Krane J, Engan T, Bjerve KS, Axelsson D, 2000, “Quantification of plasma lipids and apolipoproteins by use of proton NMR spectroscopy, multivariate and neural network analysis ,” NMR Biomed, Vol.13, pp.271-288.
8. Berry, M.J.A. and G.S. Gordon, 2000, Mastering Data Mining, John Wiley & Sons, INC. , Canada.
9. El-Solh AA, Hsiao CB, Goodnough S, Serghani J, Grant BJ, 1999, “Predicting active pulmonary tuberculosis using an artificial neural network,” Chest, Vol.116, pp.968-973.
10. Frame AJ, Undrill PE, Cree MJ, Olson JA, McHardy KC, Sharp PF, Forrester JV, 1998, “A comparison of computer based classification methods applied to the detection of microaneurysms in ophthalmic fluorescein angiograms,” Computers in Biology and Medicine, Vol.28, pp.225-238.
11. Golub R, Cantu R Jr, Tan M, 1998, “The prediction of common bile duct stones using a neural network,” Journal of the American College of Surgeons, Vol.187, pp.584-590.
12. Kestler HA, Schule M, Schwenker F, Neumann H, Mattfeldt T, 1999, “Classification of cytological smears of the cervix with neuronal methods,” Biomed Tech (Berl), Vol.44, pp.17-24.
13. Li J, Mu Y, Zhang L, 2001, “Study of the pulmonary heart disease computer-aided diagnosis system based on combining neural network,” Sheng Wu Yi Xue Gong Cheng Xue Za Zhi, Vol.18, pp.573-576.
14. Mattfeldt T, Gottfried H, Schmidt V, Kestler HA, 2000, “Classification of spatial textures in benign and cancerous glandular tissues by stereology and stochastic

- geometry using artificial neural networks,” J Microsc, Vol.198, pp.143-158.
15. Pantazopoulos D, Karakitsos P, Iokim-Liossi A, Pouliakis A, Dimopoulos K, 1998, “Comparing neural networks in the discrimination of benign from malignant lower urinary tract lesions,” Br J Urol. , Vol.81, pp.574-579
 16. Pesu L, Helisto P, Ademovic E, Pesquet JC, Saarinen A, Sovijarvi AR, 1998, “Classification of respiratory sounds based on wavelet packet decomposition and learning vector quantization,” Technol Health Care, Vol.6, pp.65-74.
 17. Roush WB, Wideman RF Jr, 2000, “Evaluation of broiler growth velocity and acceleration in relation to pulmonary hypertension syndrome,” Poult Sci. , Vol.79, pp.280-291.
 18. Roush WB, Wideman RF Jr, Cahaner A, Deeb N, Cravener TL, 2001, “Minimal number of chicken daily growth velocities for artificial neural network detection of pulmonary hypertension syndrome (PHS),” Poult Sci. , Vol.80, pp.254-259.

Construction of Medical Diagnosis Classification Model through Artificial Neural Networks

¹Huang, Mei-Ling, ²Chen, Hsin-Yi, ¹Chen, Kuei-Lin, ¹Lee, Ya-Wen

¹Department of Industrial Engineering & Management

National Chin-Yi Institute of Technology

² Department of Ophthalmology

China Medical University Hospital

E-mail : huangml@ncit.edu.tw

ABSTRACT

Traditionally, medical diagnosis mainly depends on doctors' training and experience. Today, the fast growth of data mining technique can enhance the diagnostic accuracy. This study is to develop and compare the diagnostic performance based on the areas under Receiver Operating Characteristic curves (AROC) building through application of three artificial neural networks: Back-Propagation Network (BPN), General Regression Neural Network (GRNN), and Learning Vector Quantization (LVQ). The AROC are 0.82, 0.762 and 0.85 for BPN, GRNN, and LVQ, respectively. LVQ with better learning effects shows promise for assisting medical diagnosis on glaucoma.

Keywords: glaucoma, artificial neural network, receiver operating characteristic curve