

胴裂米以類神經網路檢測之研究

Inspection of Cracked Rice Kernels by Using Neural Networks

國立中興大學農業機械工程學系副教授

萬 一 怒

Ye-nu Wan

國立中興大學農業機械工程學系研究生

楊 智 超

Chih-chao Yang

國立中興大學農業機械工程學系教授

盛 中 漣

Chung-the Sheng

台中區農業改良場副研究員

何 榮 祥

Jung-hsiang Ho

摘 要

本研究探討以類神經網路配合影像處理技術檢測胴裂米，研究中共使用了米粒灰階直方圖法和區塊法等輸入模組，結果顯示以區塊法平均灰階差值的 13 區塊輸入模組及其所用的三層式類神經網路表現較好，其學習可達到 97% 以上的正確率，胴裂粒測試平均正確率在 88% 以上，完整粒測試平均正確率 97% 以上，研究顯示有學習歸納能力的類神經網路，可應用於胴裂米之檢測。

關鍵詞：胴裂米，類神經網路，稻米品質，機械視覺，影像處理。

ABSTRACT

In this research, computer neural networks combining with image processing techniques are applied for cracked rice kernel inspection. Histogram and block methods are used for neural network training and testing. According to the tests, block method of block-gray-level-difference with 13 blocks and its associated 3 layers neural network model have the better performance in detecting cracked kernel. The correct ratio of neural network in learning is above 97%, the correct ratio of neural work in testing cracked kernel is above 88% and in testing sound kernel is above 97%. The study shows that neural network with learning and inducting ability is proper for the application of cracked rice kernel detection.

Keywords: Cracked kernel, Neural network, Rice quality, Machine vision, Image processing.

一、前言

米粒胚乳部份有裂痕之米粒稱為胴裂粒 (fissure or cracked kernels)，裂痕有一條完全橫斷裂痕、兩條橫斷裂痕、多條橫斷裂痕、縱向裂痕及龜甲型裂痕等形狀。胴裂米粒以有一條橫斷裂痕出現的比例較高，有一條完全橫斷裂痕的米粒在碾米時容易斷裂。雖然不同國家與地區的消費者對稻米品質的要求標準有差異，但是米粒的完整與否卻是一個一致性的品質指標，完整的米粒永遠比破碎米有較高的經濟價值，其價位相差往往可達一至二倍以上，以大甲農會碾米廠為例，其所產生的碎米粒大多僅做為飼料加工用，這與完整白米的價格相差很大。

稻米品質檢測為稻米產銷中一個重要的問題，其中檢測胴裂米含量的多寡可判斷該批穀物在收穫、儲藏以及加工過程中是否妥善，瞭解儲藏環境和加工方式對稻米品質的影響。應用電腦影像處理技術自動檢驗胴裂米，除了能連續大量的檢測，並可達到客觀的檢測效果，因此，尋求有效的影像檢測參數及提供耗時較少而可信度高的電腦檢測演算法，是一個值得深入探討的項目。

本研究室先前所發展之糙米品質自動檢測分級機（萬，1997），能自動檢測每次取像的多米粒，其檢測分級的流程，使用了多種與外觀品質相關的特徵參數，在以台農 67 號糙米的檢測實驗中，能將糙米依外觀區分為八類，機體是直接以 PLC 控制，而影像處理電腦與機體控制器之間，設計以旗標交換資料，所發展的糙米品質檢測軟體，能達到使米粒影像處理與檢測機控制系統連線並行作業，初步達到自動檢測之程度。而胴裂米的打光及檢測方式與其它米粒不同，因此其檢測機構與演算法需獨立設計。電腦類神經網路是人工智慧發展的一個分枝，具有在限制條件下自我組織及學習的能力，可對分類標準不易量化的農產品做出有效的分類判斷。本文即在探討以不同的類神經網路模型，經學習方式檢測由下方打光取像的胴裂米。

二、文獻探討

Kunze (1980)研究指出稻米胴裂是由米粒內部應力不平衡所引起的，當乾燥的米粒快速吸收周圍的濕氣，將造成外層胚乳因吸收水份而脹大，而內層胚乳體積變化較慢，而產生斷裂。在穀物乾燥時，不當的使用快速乾燥，米粒外層散失水分而收縮，相對的米粒內層體積變化較小，由於內外胚乳體積變率不同，米粒外層易形成表面龜裂。

陳(1981)探討稻穀胴裂與碾米損失時指出，中長度梗稻其破碎的最大原因並非來自碾米的過程，而是由於穀粒已是胴裂米，而長秈稻的破碎則有許多是由於碾米過程造成的。何等人(1991)探討了乾燥方法與稻穀成熟度對稻米胴裂之影響，指出稻穀在田間隨著成熟度增加稻穀含水率隨之下降、其胴裂率亦隨之增加乾燥至 12% 之稻穀胴裂增加最顯著，稻穀不宜過度乾燥，以免儲存期間因吸濕而造成大量胴裂。

Kunze 與 Peralta (1993)研究指出，若田中的稻穀平均達到 30% 以下的含水率時，白天日曬有些個別的稻穀就可達到很低的含水率，當晚上碰上高濕的水氣就會引起胴裂的發生，愈乾的稻穀加濕時愈容易產生胴裂，這種稻米乾燥後再加濕的循環過程所引起的胴裂現象，在實驗室中即可達到。Stermer 與 Kunze (1994)發展了一套聲音檢測系統，以辨識胴裂的發生，當米粒在破裂的一刹那，會發出尖銳的聲音，使用聲音濾波放大器及電腦連線，可以不接觸式的記錄胴裂發生的時間及次數。

Gunasekaran et al. (1987)研究以不同的打光方式檢測玉米粒的胴裂線，其研究顯示將玉米粒放在一個黑色板的貫穿的小孔上，由下方經小孔打光有最好的效果，可檢查出 90% 的胴裂。Elster 與 Goodrum (1991)利用背面照明方式取得蛋殼影像來偵測蛋殼有無裂痕。

萬與廖(1996)應用機器視覺檢驗糙米，以人工分類之糙米樣本取樣，找出米粒影像之特徵參數包括投影面積、長短軸比、形狀細密度、米粒上下端部寬度平均值、平均紅色與綠色光灰階

值、白垩質比等。以統計方式找出可分辨檢測台農 67 號糙米中正常粒、褐米、青未熟粒、著色粒、青死米、腹白粒、基部未熟粒、畸型粒、發芽粒、白垩質粒及破碎粒等的參數。萬等人(1997)以點光源分別從米粒上方及下方打光，探討不同打光角度對米粒胴裂線取像清晰度的影響。實驗顯示上方打光時胴裂線最清晰之打光角度在水平角 5 度左右，而下方打光胴裂線最清晰的影像是在水平角 20 至 40 度之間，雖然上方與下方兩種打光方式均能得到米粒清晰的胴裂線影像，然而下方打光之有效角度範圍較大。利用上方打光，研究中並設計了一胴裂線檢測演算法，利用一搜尋框，如圖 1 所示，從長軸左邊四分之一處之 A 點，搜尋至長軸右邊四分之一處之 B 點，連續計算搜尋框左右兩邊平均灰階差，以辨識胴裂粒，其辨識正確率可達 93%。




圖 1 胴裂線搜尋範圍(萬等人，1997)
Fig. 1 Cracked line searching area (Wan et al., 1997)

接續之研究，萬(1998)發展了穀物取像之自動散佈及定位裝置，能將米粒以同一方向排列取像，取像每次可包含 24 顆以上的米粒。所取米粒影像經以 C 語言發展的處理程式檢測，依外觀性狀可區分為完整粒、著色粒、畸型粒、異型粒、褐色粒、白垩質粒、青未熟粒及屑米等八類。檢測使用 Pentium 133 MHz 個人電腦，在連續運轉時，平均處理一顆糙米所需時間約 0.098 秒，整體的分類正確率達到 80% 以上。

電腦類神經網路(artificial neural network)是以簡單的運算處理單元連結成網路，達到模擬生物體之大量基本神經元構成的腦神經網路及其學習的功能，由於電腦類神經網路具有簡單的組織及學習能力，可適用於解決原始定義與分類不

十分清楚的領域，因此已被廣泛的應用在許多農業相關的研究上。Liao et al. (1993)利用機器視覺與類神經網路判斷玉米粒之破損或完整，將玉米粒分為冠區、核體區及頂蓋區並選取八個形態參數以倒傳遞類神經網路進行檢測，其分類正確率圓形玉米粒為 89% 以上，扁平形玉米粒為 96% 以上，使用 Compaq 386/33 MHz 個人電腦，每顆玉米粒由取像至分類完成約需 1.5 秒。Steinmetz et al. (1994)以紅色影像分割玫瑰切花之花苞與莖葉，尋找出莖的部分，並以類神經網路對黃色品種玫瑰進行玫瑰莖之直度分析，分級正確率為 82%。Patel et al. (1994)利用機器視覺與類神經網路對雞蛋做裂縫之偵測，以 128 組灰階座標所對應之像素點數，經正規化使其值介於 0.0 到 1.0 之間，做為類神經網路之輸入值，類神經網路使用了 30 個隱藏節點及 1 個輸出節點，判斷正確率最高可達 90%，達到了 USDA 的檢測標準。萬等人(1997)探討以不同類神經網路模型分類糙米，可達到檢測糙米外觀品質的目的。

三、實驗設備與方法

本研究中胴裂米取像，是將選取好的胴裂米以人工放置在先前研製之「稻米品質自動檢測分級機」，如圖 2 所示的輸送帶米粒承孔中取像。經改進 CCD 一次可對輸送帶米孔中的 30 顆米粒取像，CCD 攝影機為 WATEC WAT-202B，解析度為 768×494 ，輸出為 NTSC 視訊，




圖 2 稻米品質自動檢測分級機(萬，1977)
Fig.2 Automatic quality inspection and grading machine of rice (Wan, 1977)

使用 16mm 鏡頭。彩色影像擷取卡 Coreco Oculus-Tcx 解析度 640×480。個人電腦使用 IBM PC/AT Pentium 133 MHz 相容電腦，有 24 MB 主記憶體。取像照明使用 PHILIPS 1.3W PL 日光燈。

研究使用胴裂米為台農 67 號稻米，平均含水率 16.3%，使用 Kett Piceter Model L 型電阻式水份計量測穀物水份。類神經網路的測試與訓練應用 Neural Works Professional II/PLUS 類神經網路軟體，它提供了多種類神經網路模式。

(一) 胴裂米檢測

依照台灣省糧食局編印之胴裂米特徵（稻米品質外觀參考手冊，1994），胴裂米依其胴裂線的形式，可分為橫向、縱向與龜甲型胴裂等，如圖 3 所示。由於縱向胴裂線發生的機率較橫向胴裂小許多，本文僅探討具一條橫斷裂痕之胴裂粒檢測。

1. 取像打光設定

以上方單側打光胴裂米，如圖 4 所示，進入米粒胚乳中的光線會在胴裂線處產生折射與反射，造成胴裂線兩側有灰階差異，此種打光方式所發展的胴裂米檢測方法已於另文中討論（萬等人，1997）。本文探討以下方打光方式之胴裂米檢測，此種打光方式可配合已研發之「稻米品質自動檢測分級機」檢測胴裂米之所需，當米粒在輸送皮帶承載孔中，皮帶將阻擋了上方打光時長軸端部份的進光如圖 5 所示，使得胴裂線特徵不明顯，如圖 6 所示，因此所研製之「稻米品質自動檢測分級機」較適用下方打光方式。

在「稻米品質自動檢測分級機」上胴裂米打光照明之光源配置如圖 7 所示，以雙管日光燈由下方單側照明輸送帶承孔中的米粒，將對各排米粒打光之 θ 角控制在 20° 到 40° 之間，在此角度內，透射的光線在胴裂線會產生折射或反射，如圖 8 所示，因而胴裂線前方之胚乳部份將較為明亮，胴裂線後方因進入光線被反射造成胚乳部份較陰暗，如圖 9 之照片所顯示，凸顯了胴裂特徵。在 CCD 擷取整幅含 30 顆米粒的影像後以臨界值法及間隙追蹤法將各米粒由整幅影像中分割出來，並進行胴裂檢測參數之計算。




圖 3 各種胴裂粒（稻米外觀品質判定參考手冊 I，1994）

Fig. 3 Cracked rice kernels (Rice quality inspection reference book I, 1994)




圖 4 胴裂粒上方打光示意圖

Fig. 4 A cracked kernel lighting from upper right side




圖 5 胴裂粒於承載皮帶中上方單側打光之影像

Fig. 5 A cracked kernel in convey belt lighting from upper right side



圖 6 胴裂粒於承載皮帶上方打光

Fig. 6 Photo of a cracked kernel in convey belt lighting from upper one side




圖 7 胴裂粒打光配置圖

Fig. 7 Lighting design of cracked rice kernels




圖 8 承載皮帶內胴裂粒下方打光示意圖

Fig. 8 A cracked kernel in conveyer belt lighting from under right side



圖 9 下方單側打光之胴裂粒

Fig. 9 Photo of a cracked rice kernel lighting from under right side

2. 類神經網路之輸入模組

類神經網路訓練與測試之輸入模組，研究中比較了直方圖法與區塊法兩種方式。直方圖法

是米粒影像分割後，以程式計算各米粒之灰階統計直方圖(histogram)，然後以 3 種不同方式處理作為網路的輸入值：

- (1)以直方圖[0, 255]灰階範圍內各灰階值所對應之像素點數目作為輸入參數。
- (2)將米粒影像直方圖的[0, 255]灰階對應至[0, 127]，以 128 個灰階區間所對應之像素點數目作為輸入參數。
- (3)將米粒灰階統計直方圖劃分為 64 個灰階區段，各灰階區段所對應之像素點數目作為輸入參數。

完整米與胴裂米在直方圖之灰階分佈並不相同，類神經網路的學習與辨識使用直方圖法的輸入模組，其輸入參數特性和米粒的幾何位置並無關係。

區塊法求出各米粒之水平最長軸，依水平最長軸方向將米粒分為 N 個區塊，如圖 10 所示，並計算各區塊之灰階平均值，研究中使用了三種輸入模式：

- (1)以各區塊之灰階值平均值作為輸入，共有 N 個輸入參數。
- (2)以相鄰兩區塊之平均灰階值差做為輸入，共有 N-1 個輸入參數。
- (3)以相鄰兩區塊之平均灰階差絕對值做為輸入，共有 N-1 個輸入參數。

為了網路輸入之有效性，經研究，區塊範圍可選在 2 至 46 之間，本文探討了 13 區塊及 23 區塊兩種規畫方式，因此區塊法共有 6 種不同形式的輸入模組。胴裂線大多位於胚乳中段位置，區塊法可將其相對位置依照排列輸入，具有「幾何」的意義。




圖 10 區塊法示意圖

Fig. 10 Block method




圖 11 取像區米粒承載孔位置

Fig. 11 The rice kernels picture taken area on convey belt

在輸送帶上取像時一次所包含的 30 顆米粒，為了研究之方便，將米粒承孔依位置編號，其排列如圖 11 所示，以單側打光檢測複排多粒之胴裂米，各位置之米粒除了本身透光率、表皮擦傷、胚芽大小及位置會造成取像的差異，不同排米粒所受光量也不相同，因此研究中亦以相同的六顆胴裂粒，依次從一至五排取像，探討不同打光量對類神經網路檢測的影響。

類神經網路對檢測胴裂的訓練是以胴裂粒與完整粒各 120 顆作為學習樣本，而學習完成之網路檢測性能測試，是以人工選取胴裂粒及完整粒各 360 顆，隨機各分為 3 組，各米粒取像後，分別以區塊法及直方圖法計算出 9 組輸入參數，作為類神經網路訓練及測試，類神經網路輸出值與胴裂檢測之對應如表 1 所示。

表 1 類神經網路輸出值對應糙米胴裂檢測結果
Table 1 Neural network output to the cracked kernel inspection result

網路輸出值	胴裂狀況
1	有
0	無

(二) 誤差倒傳遞類神經網路

人工神經元數學模型 MP 神經元(Zurada, 1992)如圖 12 所示，輸入端相當於生物神經元中的樹突，輸出端則相當於軸突，而加權值則類似生物神經元之神經連結。輸入訊號 X_i 乘以加權值

W_i 後加總，若連結到神經元的總訊號大於臨界值 T ，則該神經元被激發產生訊號輸出 O 。誤差倒傳遞類神經網路(Error Back-Propagation)是多層次前授式網路，採用監督式的訓練，而學習是以最小平方差為指標，以梯度陡降法搜尋最小誤差方向，神經元致動函數可採用 δ 函數或其它非線性的轉換函數，網路學習過程包含輸入訓練值的前向傳遞計算與逐層修正網路連結權重的反向傳遞計算兩階段。

本研究中使用 S 形單極式致動函數對映到 $[0, 1]$ 之間如圖 13 所示，此函數可藉由 λ 的調整增益，如式(1)所示，其導數可用函數本身表示 (Zurada, 1992)。

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} \dots\dots\dots(1)$$

圖 14 為一典型的三層式網路，第一層為輸入層，有 1 個輸入節點，第二層為隱藏層有 J 個節點，最後一層輸出層有 K 個輸出節點。




圖 12 MP 神經元模型

Fig. 12 MP neural network model




圖 13 Sigmoid 單極致動函數

Fig. 13 Sigmoid activation function




圖 14 具有一層隱藏層之網路

Fig. 14 Neural network model with one hidden layer

類神經網路的計算可以用矩陣向量表示，這對許多具有向量處理器的電腦而言其運算將非常快速，式(2)中隱藏層之輸入向量為 Z ，輸出向量為 Y ，而輸出層之輸入向量為 Y ，輸出向量為 O ， W 為網路輸出層之加權矩陣， V 為網路隱藏層之加權矩陣， d 為訓練範例之期望輸出。

$$Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_I \end{bmatrix}, Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_J \end{bmatrix}, O = \begin{bmatrix} O_1 \\ O_2 \\ \vdots \\ O_K \end{bmatrix}, d = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_K \end{bmatrix},$$

$$W = \begin{bmatrix} W_{11} & W_{12} & \cdots & W_{1J} \\ W_{21} & W_{22} & \cdots & W_{2J} \\ \vdots & \vdots & \cdots & \vdots \\ W_{K1} & W_{K2} & \cdots & W_{KJ} \end{bmatrix}, V = \begin{bmatrix} V_{11} & V_{12} & \cdots & V_{1I} \\ V_{21} & V_{22} & \cdots & V_{2I} \\ \vdots & \vdots & \cdots & \vdots \\ V_{J1} & V_{J2} & \cdots & V_{JI} \end{bmatrix} \quad (2)$$

網路訓練時，先由輸入，計算出網路各輸出節點之實際輸出值 O_K ，再以誤差反向傳遞調整網路各連接節點間的權值，誤差修正首先調整輸出層和隱藏層間的連接權重，新的隱藏層和輸出層間的連接權重以向量形式表示如下， η 為學習常數(learning constant)又稱學習速率

$$W' = W + \eta \delta_o y^t \quad (3)$$

輸出層和隱藏層之連接權重修正後，接著進行輸入層和隱藏層之間節點連接權重的調整，新連接權重以向量表示為(Zurada, 1992)

$$V' = V + \eta \delta_y Z^t \quad (4)$$

以誤差倒傳遞修正權重時，通常會加上一

個動量項來改善學習過程中誤差收斂的震盪現象，如式(5)， α 為動量常數，其值可由使用者決定，通常介於 0.1 到 1.0 之間。

$$\Delta w(t) = \eta \delta(t) + \alpha \Delta w(t-1) \quad (5)$$

網路在學習過程中可調整學習常數，加速網路的收斂，例如學習減緩時學習常數應增加，若權重之修正顯現收斂震盪則學習常數應減小。DBD 學習法則(Jacobs, 1988)，是將每個連接均指定了一個獨立的學習速率變數。而 EDBD 學習法則，除了每個學習參數能自動調整之外，各節點連接都有獨立的動量變數，動量項之調整方式與學習常數改變方式相同。

四、結果與討論

網路參數之調整及網路收斂之改善需考慮諸多因素，學習過程中顯示，學習常數及動量常數初始值可設為 0.3 及 0.4，若因收斂不佳要做調整時，兩者均不超過 0.9。訓練初始權值以隨機方式產生，然後經由學習做自動調整。本研究中採用的 EDBD 學習法則，在學習初期誤差降低較快，但不比 δ 法則有較好的收斂，而 EDBD 運算較複雜，故學習速率較 δ 法則慢。實驗顯示收斂良好的網路模式，並不代表該模式具有良好的推廣能力，各網路檢測胴裂粒效能的評估，應以學習完成後該網路對胴裂米檢測的正確率為指標。

(一) 直方圖法輸入模組之胴裂檢測

表 2、表 3 及表 4 為三種類神經網路模式以不同學習法則達到的學習與測試結果，輸入是以 256、128 和 64 個灰階區間建立的三組直方圖輸入模組，三種網路皆使用含一層隱藏層的三層網路，對完整粒與胴裂粒的學習正確率平均在 98%，而使用完整粒與胴裂粒 256 個輸入灰階節點的網路，學習正確率更達到了 100%，在網路的訓練過程中，其均方根誤差均能收斂至 0.1 以下，顯示類神經網路可在監督式的學習下，將訓練樣本做正確的分類。然而此三種網路的測試正確率，完整粒將近 80%，而胴裂粒最高只有

表 2 直方圖法 256 灰階輸入之學習與測試結果
Table 2 Training and testing results by histogram method with 256 gray intervals

		完整率	胸裂粒
學習樣本分類正確率(%)		100.00	100.00
測試樣本分類 正確率(%)	1	82.50	70.00
	2	78.33	75.00
	3	79.17	69.17
	平均	80.00	71.39
各層處理單元：56×16×1 學習法則：δ 學習常數：0.3 致動函數：Sigmoid 學習次數：50000			

表 3 直方圖法 128 灰階輸入之學習與測試結果
Table 3 Training and testing results by histogram method with 128 gray intervals

		完整率	胸裂粒
學習樣本分類正確率(%)		98.33	99.17
測試樣本分類 正確率(%)	1	76.67	61.67
	2	65.83	66.67
	3	75.83	55.83
	平均	72.78	61.39
各層處理單元：128×11×1 學習法則：EDBD 學習常數：0.8 致動函數：Sigmoid 學習次數：50000			

表 4 直方圖法 64 灰階輸入之學習與測試結果
Table 4 Training and testing results by histogram method with 64 gray intervals

		完整率	胸裂粒
學習樣本分類正確率(%)		94.17	97.50
測試樣本分類 正確率(%)	1	80.00	67.50
	2	75.06	80.83
	3	81.67	71.67
	平均	78.89	73.33
各層處理單元：64×8×1 學習法則：δ 學習常數：0.3 致動函數：Sigmoid 學習次數：50000			

73%，和學習結果有一段差距，似乎顯示了訓練時有過度吻合的現象。這其中可能的一個原因即如前所述，直方圖法含有較少的胸裂線在米粒分佈的「幾何」資訊。

圖 15 所示為以右下方單側打光，一次取像去除背景後的 30 顆胸裂米粒影像，同排米粒間的亮度差異較小，而不同排米粒間的亮度差就很顯著，由於是下方打光，米粒表面的瑕疵表現得很明顯，這些因素都會影響米粒灰階直方圖的分佈。

直方圖法之輸入曲線變化含有胸裂粒及完整粒灰階分佈的差異，然而二者的差異並不容易由圖上歸納出來，以位置 1-1 和 1-4 的胸裂粒與完整粒之 64 灰階直方圖輸入模組為例，如圖 16(a)、(b)所示，胸裂粒與完整粒之間只有少許差異，例如胸裂粒直方圖在連續的灰階變化中某灰階區間的像素點數較少，這可能是胸裂線破壞了米粒表面灰階的連續變化，然而這種現象在表面有瑕疵的完整粒中亦容易出現。

單側打光將造成同一顆米粒在同列但不同排位置的影像有明顯的改變，如圖 17 所示為在同一列但不同排的胸裂粒直方圖曲線，不但隨光源位置改變灰階區間，其曲線的形狀也有很大的變化。本試驗顯示，類神經網路在此種條件複雜的情況下，仍能有極佳的訓練正確率與 70% 以上的測試正確率，顯示其具有的學習歸納能力，可適用於農業上不易簡單歸類與條件化時的分類與檢測應用。






圖 15 從右下方單側打光的五排米粒影像
Fig. 15 Photo of five row rice kernels lighting from under right side



(a)



(b)

圖 16 完整粒與胴裂粒灰階範圍直方圖

Fig. 16 Histogram of sound and cracked kernels




圖 17 同列之胴裂粒灰階直方圖曲線

Fig. 17 Histogram of cracked kernels on same column

(二) 區塊法平均灰階值輸入

表 5 為區塊法平均灰階值 23 區塊輸入模組之類神經網路的學習及測試結果，此一網路為雙層網路並不含隱藏層，由表 5 可知，在學習及測試兩個階段，類神經網路對胴裂粒與完整粒均達

表 5 區塊法平均灰階值 23 區塊輸入之學習測試結果

Table 5 Training and testing results by block method of block-gray-level with 23 blocks

		完整率	胴裂粒
學習樣本分類正確率(%)		91.67	90.83
測試樣本分類 正確率(%)	1	95.00	85.00
	2	96.67	90.83
	3	94.17	85.00
	平均	95.28	86.67
各層處理單元：23×1 學習法則：DBD			
學習常數：0.3 致動函數：Sigmoid			
學習次數：50000			

到了 90%以上的檢測正確率，顯示 23 區塊平均灰階值輸入模組為有效的分類方法。

以取像區第二排 6 顆米粒的 23 區塊平均灰階值為例，由圖 18 可看出，同一排六個位置的胴裂粒，其 23 區塊平均灰階值有相似的曲線變化，且與完整粒區塊灰階值變化不同，如圖 19 所示。胴裂粒在區塊 9 到 15 之間，因胴裂線所在，曲線有較大的變化，而完整粒則呈現一平緩的變化。圖 20(a)、(b)為在 1-1 和 1-4 兩位置的胴裂粒與完整粒 23 區塊平均灰階曲線變化，兩種米粒的曲線有相當的差異。

如圖 15 所示一次 30 顆米粒取像，以右下方單側打光，各排間米粒的亮度並不相同，然而同一顆胴裂粒，在同列不同排的區塊平均灰階變化呈現灰階平移的現象，如圖 21 所示。




圖 18 胴裂粒 23 區塊平均灰階值曲線

Fig. 18 Curves of block-gray-level with 23 blocks of cracked kernels




圖 19 完整粒 23 區塊平均灰階值曲線
Fig. 19 Curves of block-gray-level with 23 blocks of sound kernels






圖 21 同列不同排胴裂粒之 23 區塊平均灰階值變化
Fig. 21 Curves of block-gray-level with 23 blocks of a cracked kernel at different column



(a)



(b)

圖 20 完整粒與胴裂粒 23 區塊平均灰階比較圖
Fig. 20 Curves of block-gray-level with 23 blocks of cracked and sound kernels

表 6 為區塊法平均灰階值 13 區塊輸入模組之學習與測試結果，網路模型採用 $13 \times 3 \times 1$ 模式，學習法則為 EDBD，網路結構與學習法則雖與表 5 中的 23 區塊法不同，然而學習與測試

結果相似。胴裂粒與完整粒平均灰階值在 13 區塊灰階曲線與 23 區塊灰階曲線有相似的變化。

(三) 區塊法平均灰階差值輸入模組

表 7 與表 8 為區塊法平均灰階差值 23 與 13 區塊法輸入模組的學習與測試結果，23 區塊輸入模組所用為雙層不含隱藏層的類神經網路模型，13 區塊法輸入模組所用為 $12 \times 6 \times 1$ 的網路模型，13 區塊法輸入模組及其所用的類神經網路模型表現了較好的學習與測試辨別正確率，尤其是對完整米粒的辨別，測試平均達到了 97.5% 的辨識正確率，胴裂粒亦達到平均 88.9% 的測試辨識正確率。

表 6 區塊法平均灰階值 13 區塊輸入之學習與測試結果

Table 6 Training and testing results by block method of block-gray-level with 13 blocks

		完整率	胴裂粒
學習樣本分類正確率(%)		93.33	91.67
測試樣本分類正確率(%)	1	94.17	84.17
	2	95.00	90.00
	3	94.17	82.50
	平均	94.45	85.56
各層處理單元：13×3×1 學習法則：EDBD			
學習常數：0.3 致動函數：Sigmoid			
學習次數：300000			

表 7 區塊法平均灰階差值 23 區塊輸入之學習與測試結果

Table 7 Training and testing results by block method of block-gray-level-difference with 23 blocks

		完整率	胴裂粒
學習樣本分類正確率(%)		93.33	91.67
測試樣本分類 正確率(%)	1	86.67	80.33
	2	92.50	90.83
	3	90.00	87.50
	平均	89.72	86.39
各層處理單元：22×1 學習法則：δ			
學習常數：0.3 致動函數：Sigmoid			
學習次數：100000			

表 8 區塊法平均灰階差值 13 區塊輸入之學習與測試結果


Table 8 Training and testing results by block method of block-gray-level-difference with 13 blocks

		完整率	胴裂粒
學習樣本分類正確率(%)		98.33	97.50
測試樣本分類 正確率(%)	1	96.67	87.50
	2	97.30	91.67
	3	98.33	87.50
	平均	97.50	88.89
各層處理單元：12×6×1 學習法則：EDBD			
學習常數：0.3 致動函數：Sigmoid			
學習次數：150000			


圖 22(a)與(b)為位置 1-1 和 1-4 之胴裂粒與完整粒 23 區塊平均灰階差值曲線。圖中顯示胴裂線存在的前後區塊灰階差有較劇烈的變化，完整粒的曲線則無此現象。圖 23 為同一米粒在同列不同排的區塊灰階變化，使用差值消去了因位置不同所造成曲線灰階的平移，各曲線產生了重疊。圖 24(a)與(b)為 1-1 和 1-4 中胴裂粒與完整粒 13 區塊平均灰階差值曲線，曲線變化與 23 區塊曲線變化類似。

(四) 區塊法平均灰階差絕對值輸入模組

表 9 與表 10 為區塊法平均灰階差絕對值 23 及 13 區塊輸入模組之學習與測試結果，由於區



(a)



(b)

圖 22 完整粒與胴裂粒 23 區塊平均灰階差值曲線變化

Fig. 22 Curves of block-gray-level-difference with 23 blocks of cracked and sound kernels





圖 23 胴裂粒之 23 區塊平均灰階差值曲線變化


Fig. 23 Curves of block-gray-level-difference with 23 blocks of cracked kernels

塊平均灰階差絕對值，為將平均灰階差值在負值區間的圖形映射至正值區間，故其胴裂檢測效能和以區塊平均灰階差作為輸入模組的學習與測試結果類似。

輸入網路資料的前處理例如米粒影像的處理，區塊法與直方圖法的運算時間並沒有明顯的差異，而直方圖法之輸入節點較多，因此連接加權矩陣也較大，網路較為複雜。研究顯示，區塊法輸入模組因包含有胴裂線在米粒位置的幾何特性，尤其是平均灰階差區塊法能消除因位置光照量不同所造成的灰階平移影響，因此，雖然直方圖法學習的收斂較快、辨識正確度較高，然而考慮分類效能的測試，23 區塊法及 13 區塊法明顯地優於直方圖法。研究顯示了類神經網路的使用，不一定需要使用含隱藏層的網路模型，各種網路的適用性，依照輸入參數的特性來決定。本研究以類神經網路檢測胴裂粒與完整粒，結果顯示，一次取像多顆粒的完整粒與胴裂粒檢測，在先前所發展的「稻米品質自動檢測分級機」上是可行的。



(a)



(b)

圖 24 完整粒與胴裂粒 13 區塊平均灰階差值曲線變化

Fig. 24 Curves of block-gray-level-difference with 13 blocks of cracked and sound kernels

表 9 區塊法平均灰階差絕對值之 23 區塊輸入學習與測試結果

Table 9 Training and testing results by block method of absolute value of block-gray-level-difference with 23 blocks

		完整率	胴裂粒
學習樣本分類正確率(%)		98.33	91.67
測試樣本分類正確率(%)	1	95.00	85.83
	2	96.67	91.67
	3	96.67	90.00
	平均	96.11	89.17
各層處理單元：22×1 學習法則：EDBD			
學習常數：0.3 致動函數：Sigmoid			
學習次數：200000			

表 10 區塊法平均灰階差絕對值之 13 區塊輸入學習與測試結果

Table 10 Training and testing results by block method of absolute value of block-gray-level-difference with 13 blocks

		完整率	胴裂粒
學習樣本分類正確率(%)		99.17	97.50
測試樣本分類正確率(%)	1	97.50	87.50
	2	95.83	91.67
	3	97.50	83.33
	平均	96.94	87.50
各層處理單元：12×6×1 學習法則：δ			
學習常數：0.3 致動函數：Sigmoid			
學習次數：300000			

五、結 論

本研究探討以類神經網路配合影像處理，檢測排列米粒中的完整粒與胴裂粒，CCD 每次取像可包含五排共 30 顆米粒。直方圖法以米粒灰階直方圖輸入三層網路，共探討了 256、128 和 64 三種不同灰階的輸入法，研究顯示 256 灰階輸入法對完整粒與胴裂粒的學習正確率為 100%，而測試時完整粒正確率 80%，胴裂粒只有 71%，這可能是由於直方圖中較不含胴裂線分佈的幾何資訊，並且單側打光會造成同一顆米粒在不同位置的影像有許多的改變。

區塊法平均灰階值 23 區塊輸入模組，使用了不含隱藏層的雙層網路，其學習可達到 90% 以上的正確率，胴裂粒測試平均正確率在 86% 以上，完整粒測試平均正確率 95% 以上。區塊法平均灰階值 13 區塊輸入模組使用 13×3×1 的類神經網路模式，學習法則為 EDBD，轉換函數使用 Sigmoid 致動函數，其學習可達到 91% 以上的正確率，胴裂粒測試平均正確率在 85% 以上，完整粒測試平均正確率 94% 以上。

區塊法平均灰階差值之 23 區塊輸入模組所用為雙層不含隱藏層的類神經網路模型，其學習可達到 91% 以上的正確率，胴裂粒測試平均正確率在 86% 以上，完整粒測試平均正確率 89% 以上。區塊法 13 區塊輸入模組所用為 12×6×1 的網路模型，表現了較好的學習與測試辨別正確率，其學習可達到 97% 以上的正確率，胴裂粒測試平均正確率在 88% 以上，完整粒測試平均正確率 97% 以上。輸入模組 23 及 13 區塊平均灰階差絕對值之學習及測試，和以區塊平均灰階差值作為輸入模組的結果類似。

研究顯示區塊法輸入模組包含有胴裂線在米粒位置的幾何特性，尤其是區塊法平均灰階差輸入模組能消除因位置光照量不同所造成的影響，因此，雖然直方圖法學習的收斂較快和辨識正確度較高，然而在分類效能的測試上，區塊法 23 區塊法及 13 區塊法輸入模組明顯地優於直方圖法。

六、誌謝

本研究承蒙行政院農業委員會 86 科技-1.8-糧-0.4(8)計畫之經費補助，特申謝意。研究承蒙台中農業改良場洪梅珠博士，和糧食局曹紹徽股長與黃怡仁先生提供資料與米粒樣本，助理邱靜芬小姐的協助研究與文字校對，在此併申謝忱。

七、參考文獻

1. 稻米外觀品質判定參考手冊。1994。台北：台灣省政府糧食局編印。
2. 萬一怒、廖家興。1996。糙米外觀品質影像特徵之研究。農業機械學刊 5(2):49-63。
3. 萬一怒、林建銘、廖家興、周瑞仁。1997。胴裂米反光特性的分析與應用。農業機械學刊 6(3):89-99。
4. 萬一怒。1997。穀物選別之方法及其裝置。中華民國專利公報 24(31):149-152。
5. 萬一怒、楊智超。1997。電腦類神經網路應用於糙米外觀品質檢測之研究。農林學報 46(4):61-84。
6. 萬一怒。1998。穀物取像之自動散佈及定位裝置的設計研究。農業機械學刊 7 (1)：21-33。
7. 陳貽倫。1981。稻穀胴裂與碾米損失。農業工程學報 27(1):40-47。
8. 何榮祥、宋勳、許愛娜、林國照。1991。乾燥方法與稻穀成熟度對稻米胴裂率及食味品質之影響。台中區農業改良場研究彙報(30):1-13。
9. Elster, R.T. and J.W. Goodrum. 1991. Detection of cracks in eggs using machine vision. Transactions of the ASAE 34(1): 307-312.
10. Gunasekaran, S., T. M. Cooper, A. G. Berlage and P. Krishnan. 1987. Image processing for stress cracks in corn kernels. Transactions of the ASAE 30(1):266-271.
11. Jacobs, R. A. 1988. Increased rate of convergence through learning rate adaptation. Neural Networks, vol. 1, 295-307.
12. Kunze, O. R. 1980. Physical properties of rice related to moisture condition in the grain. In "Physical Properties of Agricultural Materials and Their Influences on Technological Process Conference". C.I.G.R. Godollo, Hungary.
13. Kunze, O. R. and E. K. Peralta. 1993. Practical relative humidity systems that fissure rice and other grains. Applied Engineering in Agricultural of The ASAE 9(1):85-89.
14. Liao, K., M. R. Paulsen, J. F. Reid, B. C. Ni, and E. P. Bonifacio-Maghirang. 1993. Corn kernel breakage classification by machine vision using a neural network classifier.

- Transactions of the ASAE 36(6):1949-1953.
15. Patel, V. C., R. W. McClendon, and J. W. Goodrum. 1994. Crack detection in egg using computer and neural networks. *AI Application*, vol. 8, No. 2, 21-31.
16. Stermer, R. A. and O. R. Kunze. 1994. Acoustical detection of fissures in rice. *Applied Engineering in Agricultural of The ASAE* 10(2):267-271.
17. Steinmetz, V., M. J. Delwiche, D. K. Giles, and R. Evans. 1994. Sorting cut roses with machine vision. *Transactions of the ASAE* 37(4):1347-1353.
18. Zurada, Jacek M. 1992. *Introduction to Artificial Neural Systems*. West Info Access Distribution Pte Ltd.

收稿日期：民國 86 年 8 月 12 日

接受日期：民國 86 年 11 月 6 日