

應用機械學習於高壓瓶閥音洩故障診斷研究

陳昭雄^{*1} 陳建中¹ 李昱輝¹ 林克衛²

¹大葉大學機械與自動化工程學系

515006 彰化縣大村鄉學府路 168 號

²高雄科技大學車輛工程系

824004 高雄市燕巢區深中路 58 號

*chao@mail.dyu.edu.tw

摘 要

本文應用音洩技術於高壓瓶閥體的洩漏偵測，發展機械學習方法進行模型和參數的訓練，以達到閥體各種故障的自動診斷目的。在不同測試壓力和故障模式下，將麥克風裝設在閥門外感測閥體洩漏訊號，再利用資料擷取卡擷取訊號到電腦號進行特徵處理。時域的特徵值包括均方根值 (Root mean square)、平均值 (Mean) 和變異量 (Variance)。利用離散傅立葉轉換 (Discrete Fourier Transform, DFT) 將訊號轉換到頻域，為了減少頻譜特徵值的個數，將 DFT 頻譜中的振幅由大到小排列，取前最大 50 個振幅和所相對應的頻率共 100 個，做為機械學習訓練的特徵值。以人工智慧機器學習方式，建立加權 k-近鄰演算法 (Weighted k-nearest-neighbors, wkNN)、人工類神經網絡 (Artificial Neural Network, ANN) 和二次支持向量機 (Quadratic support vector machine, qSVM) 三種機械學習模型和相對應的訓練演算法，藉以辨識出高壓閥體在不同通氣壓力下，閥體墊圈半破裂、墊圈全破裂、破裂盤和閥芯髒污等四種故障，並且比較這三種音洩學習模型的優劣。最後，透過各種實驗驗證本文所提方法的有效性，閥體故障辨識率整體可達 98% 以上。

關鍵詞：高壓閥體，音洩技術，故障檢測，機械學習

Fault Diagnosis of High-Pressure Bottle Valves Based on Acoustic Emission Using Machine Learning

CHAO-SHIUNG CHEN^{*1}, JIAN-JHONG CHEN¹, YU-HUEI LI¹ and KE-WEI LIN²

¹Department of Mechanical and Automation Engineering, Da-Yeh University

No. 168 University Rd., Dacun, Changhua 515006, Taiwan, R. O. C.

²Department of Vehicle Engineering, National Kaohsiung University of Science and Technology

No. 58, Shenzhong Rd., Yanchao Dist., Kaohsiung City 824004, Taiwan, R. O. C.

*chao@mail.dyu.edu.tw

ABSTRACT

Machine learning models were used to classify acoustic emissions from 700-bar high-pressure



bottle valve bodies to identify leakage and diagnose various valve faults under different test pressures and failure modes. A microphone was installed outside a valve to sense acoustic leakage signals that were then captured by a data acquisition card for transmission to a computer. For classification, time-domain features were selected, including the signal's root mean square, mean, and variation values. Signals were converted to the frequency domain by using the discrete Fourier transform (DFT). To reduce the number of spectral characteristic values, the 50 frequencies with the greatest amplitudes in the DFT spectrum were selected. Weighted k-nearest-neighbors, artificial neural network, and quadratic support vector machine models were trained to classify four of the following types of faults in high-pressure valves under different pressure scenarios: half-ruptured valve body gasket, fully ruptured gasket, ruptured disk, and dirty valve core. The method was experimentally validated and achieved an identification rate for valve body faults of over 98%.

Key Words: high pressure valve, sound leakage technology, fault detection, machine learning

一、前言

高壓氣態儲氫是目前廣泛應用的儲氫方式，主要透過高壓儲氣瓶來進行氫氣的儲存和釋放。高壓儲氣瓶分為純鋼製金屬瓶、鋼製內膽纖維纏繞瓶、金屬內膽纖維纏繞瓶和塑膠內膽纖維纏繞瓶等 4 種，而金屬內膽纖維纏繞瓶型瓶是目前產業界的發展重點。儲氫系統主要由高壓氣瓶、瓶閥、減壓閥等零部件組成，為燃料電池汽車不可缺少的組成部分，是影響燃料電池汽車安全和穩定性的重要因素。其中，瓶閥有密封氣瓶、掌握氣體導通啟閉的作用，一旦其品質產生問題，將會影響儲氫系統及燃料電池汽車的正常使用，嚴重時還會引發危害事故。因此，研發安全性高、密封性強，具有良好開關特性的車用高壓瓶閥，確保儲氫氣瓶處於良好狀態，才能成為解決儲氫難題，推動氫能及燃料電池汽車產業化進展的關鍵因素。根據我國交通部 82-0 氫儲存系統與 83-0 氫儲存系統組件公告內容，包含了耐壓試驗、環境溫度及極端溫度氣壓循環試驗、於燃燒時運行系統性能終止之驗證試驗等十幾種試驗，然而這多屬破壞性試驗，屬於產品認證時的試驗項目。根據 ISO 11623 標準使用液壓驗證試驗和內部和外部目視檢查進行定期檢查。然而，這種手動方法既昂貴又耗時，且它包括多個檢查步驟，還依賴於主觀判斷，導致結果的變異。針對使用中壓力容器定期檢驗，目前國際上已經有非破壞性檢測的發展，包括超聲波掃描 [2, 14]、X 射線斷層掃描 [3, 6] 和音洩 (Acoustic emission, AE) [1, 4, 5]。音洩技術可進行線上即時腐蝕缺陷檢測和故障診斷。在過去的幾十年裡，大量的實驗和文獻 [7, 8] 探討了儲氫壓力容器的結構響應。這些研究顯示，儲氫瓶的損壞並非突然的，而是漸進的。它由幾種失效模式組成，例如基體開裂、纖維/基

體界面脫粘以及隨著內壓增加而累積的纖維斷裂。因此，監測和分析儲氫瓶及其閥件的損傷演變對於評估其結構完整性具有重要意義。此外，儲氫瓶與其閥件極易受到磨損、划痕、衝擊和老化等各種損壞的影響。這些損壞會降低儲氫瓶的承載能力和疲勞性能。因此需要對儲氫瓶及其閥件進行線上故障偵測，以確保其安全。利用人工智慧和機器學習進行故障診斷的技術，近年來引起研究者的高度重視，並在該領域有許多研究論文的發表 [9-11]。Salah [8] 等人提出支援向量機 (Support vector machine, SVM) 參數自動調整的閥體故障檢測方法，透過 AE 波形分析來識別閥門功能，設計訓練和測試樣本驗證 SVM 故障檢測模型，結果顯示自動閥門故障檢測模型的準確率超過 98%。Wang 等人 [12, 13] 提出一種基於示功圖 (Indicator diagram) 和 SVM 的往復式空壓機閥門故障診斷方法，採用影像處理方法，得到往復式空壓機示功圖的特徵用來訓練 SVM，最後利用 SVM 模型監測系統閥門的 5 種故障識別。

本文建立一套基於音洩技術之非破壞 700bar 高壓瓶閥體故障檢測技術，音洩感測麥克風裝設在閥門外擷取洩漏訊號，用前置放大器對訊號進行放大處理，經過訊號調理電路後，用資料擷取卡對該訊號進行擷取，再在電腦中對訊號進行分析和處理，取得在不同測試壓力和故障模式下之音洩特徵。以人工智慧機器學習方式，建立加權 k-近鄰演算法 (Weighted k-nearest-neighbors, wkNN)、人工類神經網絡 (Artificial Neural Network, ANN) 和二次支援向量機 (Quadratic support vector machine, qSVM) 三種機械學習模型和訓練演算法，以能辨識出高壓閥體在不同通氣壓力下，閥體墊圈半破裂、墊圈全破裂、破裂盤和閥芯髒污等四種故



障，並且比較這三種模型的優劣。

二、音洩檢測高壓瓶閥實驗系統架構

本文音洩檢測高壓瓶閥實驗架構如圖 1 所示，透過氣壓泵提供具有一定壓力的氣體，經手動調節減壓閥的閥杆來設置所需壓力，並經過氣動定值器後，為被測容器閥提供穩定氣壓。音洩感測麥克風貼在閥門壁外擷取訊號，用前置放大器對訊號進行放大處理，經過訊號調理電路後，以資料擷取卡對該訊號進行擷取，最後在電腦中對訊號進行分析和處理。以下詳細敘述各裝置的規格與功能：

1. 個人電腦：配備為 Intel (R) Core (TM) i5-10400 @ 2.90GHz 2.90GHZ 的 CPU，作業系統為 Microsoft Windows 10，安裝記憶體為 16.0GB，GPU 為 NVIDIA GeForce GTX1650，進行音洩訊號分析和處理，擷取訊號實域和頻域的特徵值，建立機械學習的模型和訓練法則。
2. 音洩麥克風：如圖 2 所示，為 MPA 668-812 麥克風套件，經過防爆認證，符合危險區域和爆炸性環境使用要求，可保證在危險氣體環境中的使用安全，它由麥克風 MP 668 和前置放大器 MA812 組成，探頭和前置放大器可分離；其中，MP668 是 1/2 英寸預極化自由場測量傳聲器。頻率檢測範圍是 15~70kHz，諧振頻率 40kHz，工作電流 4 mA，靈敏度 44.5 mV/Pa。
3. 前置放大器 MA812：為壓電陶瓷晶片，產生的電荷量非常小，且阻抗很高，在實際應用中，為實現壓電陶瓷晶片微弱訊號的輸出，將高阻抗的前置放大器安裝到感測器後端，使其對檢測訊號進行放大處理。
4. 資料擷取器：如圖 3 所示，為國家儀器公司 (National Instruments, NI) 所生產型號 NI-9230 的資料擷取器。有 3 個輸入通道，最大取樣速率 12.8 kB/sec，類比輸入電壓 -30 V ~ 30 V，內建以軟體進行選擇的 AC/DC 耦合、IEPE 開/短路偵測與 IEPE 訊號處理功能。輸入通道可同步量測訊號。各個通道均有內建的反失真濾波器，可依取樣率自動調整。資料擷取器可對放大後的檢測訊號進行 A/D 轉換，使其成為二進位形式的數位訊號，對數位訊號進行分析和處理。

三、量測方法和訊號特徵擷取

音洩屬於物理現象，它指在物體自身形變或受到外部作用情況下，因彈性能量迅速釋放而引發的瞬態應力波產生。




圖 1. 音洩檢測高壓瓶閥實驗架構



圖 2. 音洩檢測麥克風




圖 3. NI-9230 的資料擷取器

如果材料中出現了音洩現象，聲源發射出的各個訊號所涵蓋的資訊可對其內部結構、狀態變化和缺陷性質造成干擾。因此，借助靈敏度足夠的儀器設備對這些發射訊號進行接收和處理，再對音洩源進行特徵參數的研究與分析，便可實現材料結構、內部缺陷、發展趨勢和變化程度等的推斷。本章節介紹音洩檢測高壓瓶閥的方法和訊號特徵擷取的方式。

(一) 音洩檢測方法

如果閥門出現洩漏，洩漏口處會在閥門壓差作用下形成噴流，不僅會擾亂氣體流動，而且會使閥門與流體間產生相互作用，閥壁上會有高頻應力波產生，並向外進行能量輻射。應力波包含洩漏口位置、洩漏強度等資訊，它會沿著閥體傳



播到兩側管道，採用音洩技術進行閥門檢漏，閥門洩漏時產生音洩訊號的原因如下：

1. 機械振動：流體未充滿閥體時，處於波動狀態，流體不斷碰撞閥體產生機械振動發聲。
2. 汽蝕效應：流體充滿閥體時，由於洩漏孔處液體壓力小於汽化壓力，部分液體汽化成氣泡。下游流體擴張同時壓力升高，氣泡在高壓以及碰壁時會發生破裂，導致汽蝕效應發聲。
3. 湍流：閥門洩漏時產生的湍流是產生音洩訊號的重要因素。

圖 4 為閥門洩漏模型，內漏過程由三個區組成，洩漏點附近為混合區，其範圍為離漏孔距 4 倍閥門直徑的長度，其次是過渡區，其範圍為離混合區 6 倍閥門直徑的距離，最後就是充分發展區。聲壓在漏孔附近比較小，當到達離漏孔 3~4 倍的直徑距離時聲壓最大，然後隨離漏孔距離的增加而減小，混合區與過渡區的交界處形成的湍流是產生音洩訊號的重要因素，由於湍流處的流體壓力是變化的，從而產生流體波動，使閥體身上產生彈性振動訊號。

(二) 訊號特徵擷取

用於機械學習的訓練資料以高壓瓶的故障狀況分為閥體墊圈半破裂、墊圈全破裂、破裂盤和閥芯髒污等四種，流經閥體的氣體壓力有 0 kg、6 kg 和 12 kg 三種。音洩感測器的取樣頻率為 12800 Hz，輸出電壓單位為 mV。每筆資料偵測 5 sec，共有 64000 個數據，每種故障和不同氣體壓力分別偵測 20 筆，因此，總共有 $2 \times 3 \times 20 = 120$ 筆資料用於機械學習的訓練。又將這 120 筆資料分成兩部分，67% 用於機械學習參數的訓練，而 33% 用於驗證訓練結果的辨識率。另外，又分別在四種故障情況下加入背景噪音，測試辨識的強健度。資料前處理是音洩故障診斷中重要的一步，在此階段原始的聲音訊號必須盡可能濾除雜訊以進行後續的分析。首先，利用 4 階的巴特沃斯濾波器 (Butterworth filter) 設計 50 Hz~5000 Hz 的帶通濾波器 (Band-pass filter)，如圖 5 所示，以濾除低於 50 Hz 的 DC 訊號和高於 5000 Hz 的聲音雜訊。接著，應用漢寧窗口 (Hanning window)，如圖 6 所示，將每筆資料擷取 8192 點 0.64 秒的窗資料，各段有 50% (4096 筆) 重疊，以進行後續的快速傅立葉轉換 (FFT)。因此，每筆資料 64000 個數據可以分成 $64000/8192 \approx 8$ 段，經由漢寧窗口可以擷取到 15 筆窗資料，120 筆的原始音洩資料總共可獲得 $120 \times 15 = 1800$ 筆窗資料進行後續的特徵處理。在各




圖 4. 閥門內洩漏模型




圖 5.4 階 50 Hz~5000 Hz 帶通的巴特沃斯濾波器




圖 6. 8192 筆資料的漢寧窗口

種閥體故障狀況所擷取的 8192 點 0.64 秒窗資料，將分別擷取 103 個特徵值供機械學習訓練使用，其中在時域的特徵值有 3 個，而在頻域的特徵值有 100 個，分別敘述如下：

1. 時域的特徵值

圖 7 為時域下的窗訊號圖形，由圖中可以看出在時域下，音洩聲音的強度和變異量與閥體的故障和通過的氣體壓力有相關性。時域的特徵值計算如下：






圖 7. 閥體全破裂在時域量測的信號

- (1) 均方根值 (Root mean square)

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

其中 $N = 8192$ 個資料點, x_i 為窗資料的資料點。

- (2) 平均值 (Mean)

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

- (3) 變異量 (Variance)

$$\sigma = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (3)$$

圖 8 為在時域計算出的均方根值、平均值和變異量的立體圖形。從時域圖中可以粗略看出如下特性：

- (1) 噪音的平均值皆介於 -1 mV 至 1 mV 間。
- (2) 閥體故障的噪音能量大小 (RMS)：墊圈半破裂 < 墊圈全破裂 < 閥芯髒污 < 破裂盤，墊圈半破裂介於 50-200 mV、墊圈全破裂 70-250 mV、閥芯髒污 80-250 mV 和破裂盤 80-




圖 8. 閥體全破裂量測訊號的 RMS、Mean 和 Variance 值

300mV。以及通過的氣體壓力越大，這三個特徵值也相對變大。

- (3) 閥體故障的噪音變異量：墊圈半破裂 < 墊圈全破裂 < 閥芯髒污 < 破裂盤，從圖形可看出，大都在 $10 \times 10^4 \text{ mV}^2$ 以下。

2. 頻域的特徵值

將時域的窗資料經由離散傅立葉轉換 (Discrete Fouriertransform, DFT)，可得頻域的資料如圖 9 所示。由圖中可以觀察出 FFT 頻譜主要集中在 50Hz 到 2kHz 之間，為了減少頻譜特徵值的個數，將 FFT 頻譜中的振幅由大到小排列，取前最大 50 個振幅和所相對應的頻率共 100 個，做為機械學習訓練的特徵值，如圖 10 所示。從頻譜圖中可以初步觀察如下現象：

- (1) 主要的前 50 大振幅的頻率集中在 100Hz 附近，最大振幅介於 20-40 之間。
- (2) 閥體故障的噪音頻域振幅大小，可以觀察到墊圈半破裂 < 閥芯髒污 < 破裂盤 < 墊圈全破裂，墊圈半破裂最大值 30 mV (在 89 Hz)、閥芯髒污 33 mV (在 80 Hz)、破裂盤 36mV (在 105 Hz) 和墊圈全破裂 40 mV (在 100 Hz)。






圖 9. 閥體全破裂在頻域的 FFT 信號




圖 10. 閥體全破裂量測信號頻域的前 50 個最大振幅位置

通過的氣體壓力越大，最大振幅也相對變大。

- (3) 當通過的氣體壓力越大時，前 50 大振幅的頻率分布會比較廣，此表示除了噪音振幅增大外，頻率也較分散。
- (4) 閥體閥芯髒污當通過的氣體壓力較高時在頻率 2000 Hz 的地方會有特殊的噪音出現。

四、機械學習模型與訓練

利用前面所擷取的聲音訊號特徵值，接著需建立機器學習模型的訓練。不同的機器學習模型有不同的配置架構和訓練法則，產出的也結果不同，各有優缺點。本文選用三種最被廣泛使用的訓練模型：加權 k-近鄰演算法、人工類神經網絡和二次支持向量機，分別敘述如下：

(一) 加權 k-近鄰演算法

最近鄰演算法 (kNN) 不需要經過訓練，根據資料彼此之間的距離進行分類。對於一個需要辨識的輸入向量 $\mathbf{x}$ ，在訓練資料集中尋找與向量 $\mathbf{x}$ 最接近的 k 個向量集合，然後 $\mathbf{x}$ 的類別歸類為這 k 個向量集合中類別數最多的那一類。而 wkNN 是最近鄰演算法 (kNN) 的變體，其再根據鄰近相似度設計不同的權重來加深鄰近對歸類的影響，而能有更好的分類效果。執行步驟如下：

1. 給定 $L = \{(\mathbf{y}_i, \mathbf{x}_i), i = 1, \dots, N_i\}$ 的訓練資料， $\mathbf{x}_i$ 是特徵向量， $\mathbf{y}_i$ 是相對應的歸類別。給一新的特徵向量 $\mathbf{x}$ ，需預測它的歸類別 $\hat{\mathbf{y}}$ 。
2. 在 L 的資料集中尋找 $k + 1$ 個距離最鄰近的鄰居，距離的計算方式如下：

$$d(\mathbf{x}_i, \mathbf{x}) = \sqrt{\left(\sum_{s=1}^p (\mathbf{x}_{is} - \mathbf{x}_s)^2\right)} \quad (4)$$

3. 第 $k + 1$ 個鄰居用於標準化前 k 個鄰居的距離介於 0~1 之間如下：

$$D(\mathbf{x}_i, \mathbf{x}) = \frac{d(\mathbf{x}_i, \mathbf{x})}{d(\mathbf{x}_{k+1}, \mathbf{x})} \quad (5)$$

4. 利用高斯核仁函數 (Gaussian kernel function) 計算前 k 個鄰居的權重值：

$$W(D(\mathbf{x}_i, \mathbf{x})) = \frac{1}{\sqrt{2\pi}} \left(-\frac{D^2(\mathbf{x}_i, \mathbf{x})}{2} \right) \quad (6)$$



5. $\mathbf{x}$ 的類別預測 $\hat{y}$ 為這 k 個最近鄰的加權多數：

$$\hat{y} = \max_r (\sum_{i=1}^k W(D(\mathbf{x}_i, \mathbf{x})) I(y_i = r)) \quad (7)$$

(二) 人工類神經網絡

ANN 為生物神經網路啟發的計算模型，是一種強大的機器學習技術適用於各種應用。本文 ANN 的架構如圖 11 所示，分為輸入層 (Input layer)、第一和第二兩隱藏層 (Hidden layer) 和輸出層 (Output layer)。輸入層 $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ 為窗資料擷取的特徵值，輸出層有三個神經元 $\mathbf{y} = [y_1, y_2, y_3]^T$ 。每個神經元的數學模型，如圖 12 所示，數學式如下：

$$net_k = \sum_{i=1}^m w_{ki} x_i + b_k \quad (8)$$

$$y_k = \varphi(net_k) = \frac{1}{1 + \exp^{-net_k}} \quad (9)$$

其中 w_{ki} 為神經元的權重值 (Weights)、 b_k 為偏移量 (Bias)、 $\varphi(\cdot)$ 為激勵函數 (Activation Function) 和 y_k 為神經元的輸出。訓練的目的為找到每個神經元最佳的權重值，最小化如下的價值函數：

$$E = \frac{1}{2} \sum_{i=1}^p \| \mathbf{y}^i - \mathbf{d}^i \|^2 \quad (10)$$

其中 $\mathbf{y}^i$ 為第 i 筆訓練資料的實際輸出， $\mathbf{d}^i$ 為第 i 筆訓練資料所要的輸出。

(三) 二次支持向量機

二次支持向量機使用二次核函數 (Quadratic kernel function) 在類別之間進行非線性分類，與線性 SVM 相比，允許更複雜的決策邊界，可以在非線性資料集上獲得更好的分類性能。首先，將輸入空間的資料映射到高維空間的特徵空間，定義徑向基核函數 (Radial basis kernel function, RBF kernel) 如下：

$$K(\mathbf{x}^i, \mathbf{x}^j) = \phi(\mathbf{x}^i) \phi(\mathbf{x}^j)^T = \exp^{-\gamma \|\mathbf{x}^i - \mathbf{x}^j\|^2} \quad (11)$$

其中 $\mathbf{x}^i$ 、 $\mathbf{x}^j$ 為訓練的特徵向量， $\gamma > 0$ 。二次支持向量機的最佳化問題如下：




圖 11. ANN 架構圖




圖 12. 神經元的輸出

$$\min_{\lambda} \Gamma(\lambda) = \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y^i y^j K(\mathbf{x}^i, \mathbf{x}^j) \lambda_i \lambda_j - \sum_{i=1}^l \lambda_i \quad (12)$$

$$\begin{aligned} \text{約束條件: } \quad & \sum_{i=1}^l \lambda_i y^i = 0 \\ & 0 \leq \lambda_i \leq C \quad i = 1, 2, \dots, l \end{aligned}$$

其中 λ_i 為拉格朗日常數 (Lagrange parameter)， y^i 、 y^j 為訓練所要的輸出， $C > 0$ 為評估訓練誤差的參數。當解出最佳的 λ_i^* ，則最佳的超平面的向量 ω^* 和純量 b^* 可由下式計算：

$$\omega^* = \sum_{i=1}^l \lambda_i^* y^i \phi(\mathbf{x}^i) \quad (13)$$

$$y^i \left(\sum_{j=1}^l \lambda_j^* y^j \phi(\mathbf{x}^j)^T \phi(\mathbf{x}^i) + b^* \right) - 1 = 0 \quad (14)$$

最後分類的超平面可以得到如下：

$$d(\mathbf{x}) = \text{sgn}(\omega^{*T} \phi(\mathbf{x}) + b^*) \quad (15)$$

五、實驗與結果

圖 13 為本文實驗設備架設與系統測試架構實體圖，閥體音洩檢測的訊號經由資料窗取出片段資料後，分別擷取時






圖 13. 實驗設備架設與系統測試架構實體圖

域和頻域 103 個特徵進行機械學習的訓練和驗證。閥體半破裂、全破裂、破裂盤和閥芯髒污在 0kg、6k 和 12kg 三種氣體壓力下，各有 900 筆的特徵資料，其中 600 筆用於機械學習的訓練，300 筆用於驗證辨識的準確度。壓力 0kg 代表氣瓶閥體在無故障時所量測的背景音。

(一) 機械學習的訓練

本文以 Matlab 軟體平台撰寫程式，進行機械學習參數的訓練和辨識率的驗證。利用 `knnsearch (X, Y)` 函數執行 wkNN 的運算，wkNN 在訓練階段僅僅是把訓練樣本保存起來，沒有參數需要經過訓練。待收到測試樣本後再進行分類處理。而 ANN 參數的訓練是利用 Matlab 軟體的 `nntool` 工具，建構類神經網路的結構、設定訓練參數、選擇學習的演算法和模型效能的評估。輸入層是 103 個的特徵數據，兩個隱藏層各別有 50 個和 10 個神經元，輸出層四個神經元分別代表四種故障種類閥體半破裂（輸出 1）、全破裂（輸出 2）、破裂盤（輸出 3）和閥芯髒污（輸出 4），學習法則選擇倒傳遞學習演算法（Back propagation）。qSVM 的訓練是利用 Matlab 軟體的 `fitcsvm (X, indx)` 函數進行，經由 RBF kernel 函數（11）式將特徵數據轉換到更高維度的特徵空間，在線性約束條件下，透過解決（12）式的線性約束二次規劃（Linearly constrained quadratic programming）問題，而得到最佳的非線性歸類邊界（15）式。三種機械學習方法分別在閥體半破裂、全破裂、破裂盤和閥芯髒污的資料組裡進行學習，學習的輸出為四種故障分類。而不同氣體壓力下，氣體

表 1. 三種機械學習方法訓練和執行辨識的時間

	wkNN	ANN	qSVM
訓練的時間 (sec)	0	50.32	29.56
執行辨識的時間 (sec)	0.0212	0.0432	0.0668

壓力 0 kg，為閥體未通入氣體所量測到的聲音訊號，為背景音的雜訊。而 6 kg 和 12 kg 的分類為通過氣體壓力 6 kg 或 12 kg 下所量測到的聲音訊號。機械學習的訓練和辨識的驗證結果如表 1。機械學習的訓練時間 wkNN 無需訓練所需時間為 0。而 qSVM 需 29.56 sec 小於 ANN 的 50.32 sec。ANN 使用 MATLAB 內建的超參數優化系統，設定疊代次數上限為 30 次。最佳化的演算法為使用貝氏優化（Bayesian optimization），隨機選擇幾個參數設定值作為基準點，並以參數值對準確率影響的趨勢去尋找辨識率最高的最佳模型，所費時間最長。一般 qSVM 方法只能用於兩種分類的方式，本文為了分類四種故障種類，必須訓練 qSVM 四種不同模型，所以會花費較長時間。而訓練後執行辨識驗證的時間 wkNN 為 0.0212 sec 最快，ANN 為 0.0432 sec 次之，qSVM 最慢 0.0668 sec。

(二) 辨識結果

在訓練後的辨識率驗證，分別用無背景噪音和有背景噪音的量測訊號進行驗證，驗證結果說明如下：

1. 無背景噪音的辨識率

將無背景噪音的各種故障量測訊號，各別輸入 wkNN、ANN 和 qSVM 三種訓練完成的模型，在四種故障種類和在通氣 0 kg、6kg 和 16kg 下的辨識率，辨識率彙整如表 2。

表 2. 在無背景噪音不同氣體壓力下三種機械學習方法訓練後驗證辨識率的結果（單位：%）

類別	wkNN	ANN	qSVM
半破裂	0 kg	75	82
	6 kg	70	77
	12 kg	82	86
	辨識率	82.7	87.3
全破裂	0 kg	80	85
	6 kg	73	80
	12 kg	87	89
	辨識率	85.7	89.3
破裂盤	0 kg	80	85
	6 kg	82	86
	12 kg	88	93
	辨識率	87.3	90.7
閥芯髒污	0 kg	86	84
	6 kg	89	88
	12 kg	96	94
	辨識率	90.7	92.7
總辨識率	86.6	92.0	98.9



由表中可以看出，通氣壓力較低下，雖然閥體有故障偵測到的聲音訊號較弱，辨識率較低，而通氣壓力較大時聲音訊號的特徵較容易顯現出來。在總辨識率方面， $qSVM > ANN > wkNN$ ， $qSVM$ 有最佳的辨識效果，四種故障種類的總辨識率為可達 98.9%。 $wkNN$ 雖然不需訓練，執行方式簡單，但辨識率較差，總辨識率為 86.6%。而 ANN 的總辨識率為 92.0%，其辨識率和隱藏層所取的神經元個數有關，且倒傳遞學習演算法的訓練方式較容易陷入區域最小值 (Local minimum) 的問題。

2. 有背景噪音的辨識率

在四種故障種類下，加入環境的背景噪音，用來測試三種機械學習模型辨識率的強健性。圖 14 為加入背景訊號的時域窗訊號圖形，由圖中可以看出在時域下，背景噪音對量測訊號造成很大干擾，時域圖形更加混亂，肉眼看不出量測訊號間的差異性，讓辨識更加困難。圖 15 為量測訊號的 RMS、Mean 和 Variance 值，從圖中可以看出如下特性：

- (1) 閥體故障的噪音變異量都變大，四種故障量測值皆靠近至 $10 \times 10^4 \text{ mV}^2$ 。
- (2) 四種故障量測值的立體圖形在 RMS 方向皆有分成兩群的趨勢，通氣壓力越大，趨勢越明顯。
- (3) 四種故障量測值的立體圖形皆非常相似，表示背景噪音對量測訊號有相當程度的干擾，純粹以時域的特徵值，將很難辨識出故障種類。

圖 16 為將故障模式的時域窗訊號透過 DFT 轉換的頻域圖形，圖 17 為量測信號頻域的前 50 個最大振幅和頻率位置。從圖中可以看出如下特性：

1. 比較無加背景噪音和加背景噪音的 DFT 圖形，可觀察出故障模式的 DFT 圖形明顯可以看出在 1200Hz 的地方有多出來的頻譜圖形，此應該為背景噪音的頻譜，振幅大小約 5 mV 左右。
2. 由前 50 個最大振幅和頻率位置圖形中觀察，墊圈半破裂、墊圈全破裂和破裂盤三種故障約在 100Hz 處和沒加背景噪音一樣，有最大的振幅，此為故障種類的頻譜。但是，皆在 250Hz 附近有多出來的前 50 大振幅分佈，此為背景噪音所造成。

將有背景噪音的各種故障量測訊號，各別輸入 $wkNN$ 、 ANN 和 $qSVM$ 三種訓練完成的模型，在四種故障種類和在通氣 0 kg、6kg 和 16kg 下的辨識率彙整如表 3。由表中可以看出，閥體故障偵測到的聲音訊號和所加背景音雜訊產生干擾，辨




圖 14. 在背景噪音下，閥體全破裂在時域量測的信號




圖 15. 背景噪音下，閥體全破裂 RMS、Mean 和 Variance 值






圖 16. 在背景噪音下，閥體全破裂 DFT 轉換的頻譜




圖 17. 背景噪音下，閥體全破裂頻域前 50 個最大振幅位置

表 3. 在背景噪音不同氣體壓力下三種機械學習方法訓練後

驗證辨識率的結果

單位: %

類別	wkNN	ANN	qSVM
半破裂	0 kg	72	80
	6 kg	68	74
	12 kg	79	83
	辨識率	79.7	85.3
全破裂	0 kg	75	80
	6 kg	70	77
	12 kg	83	84
	辨識率	82.1	86.2
破裂盤	0 kg	72	82
	6 kg	68	82
	12 kg	84	90
	辨識率	82.3	87.7
閥芯髒污	0 kg	80	85
	6 kg	77	84
	12 kg	87	92
	辨識率	85.7	90.1
總辨識率	80.5	87.3	97.4

識率普遍降低，總辨識率 wkNN 從 86.6%降至 80.5%下降 8.1%最多，ANN 從 92.0%降至 87.3%下降 4.7%次之，而 qSVM 從 98.9%降至 97.4%下降 1.5%最少，因此，在辨識強健性方面 qSVM>ANN>wkNN。

六、結論

本文使用音洩感測技術偵測高壓閥體的故障聲音訊號，以人工智慧機器學習方式，建立 wkNN、ANN 和 qSVM 三種機械學習模型和相對應的訓練演算法，而能辨識出高壓閥體在不同通氣壓力下，閥體墊圈半破裂、墊圈全破裂、破裂盤和閥芯髒污等四種故障，並且比較這三種音洩學習模型的優劣，結論如下：

1. 閥體故障的音洩訊號在時域皆非常相似，經由 DFT 轉換，在頻域可以得到較大差異的頻譜特徵，再利用人工智慧機器學習方式，經由各種訓練，提升故障的辨識率。
2. 三種機械學習模型在辨識率和辨識強健度方面，皆是 qSVM>ANN> wkNN。wkNN 不需訓練，以特徵資料彼此之間的距離進行分類，執行速度簡單且快速，但容易受干擾辨識率差。而 ANN 的辨識精度受到隱藏層和神經元個數影響很大，訓練時間較久，訓練過程容易陷入區域最小值（local minimum）的問題。而 qSVM 透過二次核函數在類別之間進行非線性分類，辨識率高可達 98%以上，且具有相當的辨識強健性，很適合應用於高壓閥體的音洩檢測技術。
3. 加入背景音干擾時，在 DFT 後的頻譜中可以發現背景音



的頻率所在位置，在進行訊號前處理時，可以考慮發展特殊的帶阻濾波器（Notch Filter）先濾除，以避免對後續的特徵辨識產生干擾。

4. 對於高壓閥體機器學習的故障診斷系統，本文所提方法能滿足以下條件：（a）對於各種故障狀況有足夠的偵測訓練資料；（b）具備適當的資料預處理演算法，包括具有擷取資料重疊、適當寬度的資料窗口和低通濾波器的雜訊濾除；（c）適當且有用的特徵提取和高精度診斷的機械學習模型和演算法。本文所提方法從實際的實驗可以印證其具備足夠的精確性和強健性，可以推薦應用於實際線上高壓閥體故障監測的應用程式。
5. 當故障種類增加時，辨識頻譜細微處的特徵變成非常重要，如果要取更多點的頻譜特徵值進行機械學習模型的訓練，會造成電腦運算的負擔。可以利用頻譜影像辨識技術（Spectrum image recognition technology）解決此問題。

參考文獻

1. Caffrey, C. Mc, T. Sillanpää, H. Huovila, J. Nikunen, S. Hakulinen and P. Pursula (2017) Energy autonomous wireless valve leakage monitoring system with acoustic emission sensor. *IEEE Transactions on Circuits and Systems*, 64(11), 2884-2893.
2. Dukler, Y., Y. Ge, Y. Qian, S. Yamamoto, B. Yuan, L. Zhao, and J. T. Yen (2018) Automatic valve segmentation in cardiac ultrasound time series data. *Medical Imaging 2018: Image Processing*, 10574, 493-504.
3. Li, W., H. Li, J. Song, J. C. Guo, H. Zhang, H. Wei and B. Yang (2021) Fine-control-valve of halide perovskite single crystal quality for high performance X-ray detection. *Science Bulletin*, 66(21), 2199-2206.
4. Li, Z. L., H. F. Zhang, D. G. Tan, X. Chen and H. X. Lei (2017) A novel acoustic emission detection module for leakage recognition in a gas pipeline valve. *Process Safety and Environmental Protection*, 105, 32-40.
5. Kaewwaewnoi, W., A. Prateepasen and P. Kaewtrakulpong (2010) Investigation of the relationship between internal fluid leakage through a valve and the acoustic emission generated from the leakage. *Measurement*, 43(2), 274-282.
6. Marcovici, S., V. Sukhovatkin and P. Oakham (2014) X-ray light valve (XLV): a novel detectors' technology for digital mammography. *Medical Imaging 2014: Physics of Medical Imaging*, 9033, 1043-1048.
7. Shi, M. J. Y. B. Liang, L. S. Qin, Z. Heng and Z. Q. Huang (2021) Prediction method of ball valve internal leakage rate based on acoustic emission technology. *Flow Measurement and Instrumentation*, 81, 21-30.
8. Salah M., K. H. Ali, L. M. Hui, M. Hee and L. Salman (2018) Automated valve fault detection based on acoustic emission parameters and support vector machine. *Alexandria Engineering Journal*, 57(1), 491-498.
9. Shubita, R. R., A. S. Alsadeh and I. M. Khater (2023) Fault detection in rotating machinery based on sound signal using edge machine learning. *IEEE Access*, 11, 6665-6672.
10. Tayyab, S. M., E. Asghar, P. Pennacchi and S. Chatterton (2020) Intelligent fault diagnosis of rotating machine elements using machine learning through optimal features extraction and selection. *Procedia Manufacturing*, 51(1), 266-273.
11. Tran T. and J. Lundgren (2020) Drill fault diagnosis based on the scalogram and MEL spectrogram of sound signals using artificial intelligence. *IEEE Access*, 8, 203655-203666.
12. Wang, F., L. Song, L. Zhang and H. Li (2010) Fault diagnosis for reciprocating air compressor valve using p-V indicator diagram and SVM. *Proceedings of the 3rd International Symposium on Information Science and Engineering (ISISE)*, Shanghai, China.
13. Wang, Y., C. Xue, X. Jia and X. Peng (2015) Fault diagnosis of reciprocating compressor valve with the method integrating acoustic emission signal and simulated valve motion. *Mechanical Systems and Signal Processing*, 56-57, 197-212.
14. Wifstad, S. V., L. Lovstakken, J. Avdal, E. A. R. Berg, H. Torp, B. Grenne and S. Fiorentini (2022) Quantifying valve regurgitation using 3-D doppler ultrasound images and deep learning. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 69(12), 3317-3326.

收件：113.09.03 修正：113.09.18 接受：113.10.29

