



近代人工智慧技術於鋼鐵製程之應用

中鋼公司研發處智慧技術組 (T74) 研究員 / 許朝詠
中鋼公司研發處智慧技術組 (T74) 正研究員 / 陸振原
中鋼公司研發處智慧技術組 (T74) 組長 / 吳崇勇

關鍵字：鋼鐵工業、鋼鐵製程、人工智慧、深度學習、電腦視覺

摘要

本文深入探討近代人工智慧技術在鋼鐵製程中的具體應用，以及在導入人工智慧初期所面臨的各種挑戰，以及解決方案。鋼鐵製程是一個複雜的工業領域，而人工智慧技術，特別是深度學習和電腦視覺技術，為其帶來了創新和轉變的機會。然而，在傳統製造業實施數位轉型並不容易，全球僅有少數企業已經進入全面的轉型階段，而大多數企業仍在試點階段，面臨著技術適應性、員工培訓、數據整合等挑戰。中鋼公司積極投入智慧化製程研發與應用，通過不斷提出智慧化方案、嚴格審核篩選、研發實施可行性高的方案，展現了在數位轉型的堅持與努力。本文介紹中鋼公司在面對鋼鐵製程中的挑戰時所採取的技術對策，包括前處理策略、選

擇適當的深度學習技術、空間金字塔池化技術的應用以及集成式物件比對技術的後處理。這些技術對策有助於提高鋼鐵製程的效率、品質和安全性。最後，以實際案例說明在導入創新技術的過程中，所面臨的挑戰、選擇及解決方案。

一、前言

在科技急遽發展的當下，人工智慧 (Artificial Intelligence, AI) 已逐漸推廣至各個工業領域，特別是在鋼鐵製程中，其應用的重要性日益顯著。近代人工智慧技術，尤其是深度學習和電腦視覺技術，不僅拓展了無限的可能性，也為工業領域帶來了創新與轉變的契機。通過深度學習技術的應用，企業得以實現更精準的生產控制、優化製造流

程並提升產品品質。

然而，數位轉型的道路並非一帆風順。根據2019年由麥肯錫和世界經濟論壇發表的報告「全球『燈塔工廠』網絡：來自第四次工業革命前沿的最新洞見」[1]中提到，全球只有3%的企業真正進入了全面的轉型階段，而26%的企業開始進入工廠轉型階段。更為挑戰的是，高達71%的企業仍處於進行局部試點的階段。在這些進行試點的企業中，約29%的企業其試點期已超過兩年，56%的企業進行了一至兩年的試點，而15%的企業剛剛開始進行試點。這些數據揭示了企業在數位轉型過程中面臨的種種挑戰和困難，例如技術適應性、員工培訓、資料整合等。

中鋼公司自2017年開始積極投入智慧化製程的研發與應用。每年由現場出題，提出上百個智慧化方案，經過嚴格的審核與篩選，最終留下約20個可行性較高的方案進行研發與實施。這樣的做法不僅體現了中鋼在數位轉型道路上的堅持與努力，也反映了其在面對困難與挑戰時，透過不斷的嘗試與調整，尋找最適合自身發展的智慧製造方向。

本文將深入探討近代人工智慧技術在鋼鐵製程中的具體應用與實踐，並說明再導入初期所遭遇的各種挑戰並提出相應的解決方法，最後以具代表性的實際案例說明不同問題的解決方式，期望能為相關領域的研究與實踐提供有益的參考與啟示。

二、鋼鐵製程所遭遇的挑戰


在中鋼的產線智慧化經驗中，看似光明的技術創新之路並非一帆風順，同樣面臨了「試點困境」，深度學習技術在眾多領域展現出卓越的性能，尤其在影像辨識與分析方面，但當這些技術被應用到實際的鋼鐵製程時，多個預料之外的挑戰逐漸浮現。

（一）取像品質的巨大變異


由於鋼鐵製程的連續性，產線必須24小時不間斷運作。這種作業模式造成光線強度、色彩飽和度及色彩白平衡等因素在一整天內的變化極為劇烈。不同時間點所拍攝的影像在品質上的差異，直接影響到影像辨識的準確性和可靠性。如圖1所示為日夜拍攝同一產線所產生的影像差異，夜間的光線條件與白天存在極大的區別，這對模型的辨識能力，也對數據預處理和模型優化提出了新的挑戰。

（二）計算能力的限制

在一些特定的應用環境中，例如高溫、粉塵或高濕的條件下，放置傳統電腦主機或其他計算設備變得極為困難，僅能以邊緣裝置執行，在這些情況下，模型必須能夠運行在邊緣運算裝置上。這些裝置通常具有較低的計算能力和儲存容量。因此，模型的複雜度和運算需求必須在確保辨識準確性的同時，做到盡可能的優化和簡化。



(a)



(b)


圖 1 日夜拍攝同一產線所產生的影像差異：(a) 日間自然光線拍攝鋼捲影像；(b) 夜間工廠燈光拍攝鋼捲影像

(三) 物體尺寸的不一致性

由於環境條件的影響，相同物件在不同的拍攝情況下會展現出不同的視覺效果。其中，由於拍攝角度和距離的變化，物體的尺寸在影像中的呈現會有顯著的差異，此外，不同生產設備間的變異也可能造成較大的視覺差異。如圖2所示為不同產線噴號機所產生的鋼胚序號差異，可以明顯看出在字體、尺寸及清晰度上都有極大的差異。這些變化對於影像辨識模型來說是一個挑戰，因為它必須能夠識別出在各種不同條件下的物體，並做出正確的判斷。

(四) 模型調整的彈性不足

深度學習模型在訓練完成後，其結構和參數基本上是固定的。這意味著，當模型在某些情況下的表現不佳時，我們無法通過簡單調整參數或門檻值來改善其表現。通常需要重新收集數據來重新訓練模型，這不僅耗時耗能，也對快速應對產線上的變化提出了極大的挑戰。圖3所示為不同扁鋼胚上的序號，在同一模型所辨識的結果，可以看出在許多視覺效果相同的字元上有著極大差異的辨識結果。如第二塊胚的第一個「2」可以被辨識，而第三塊胚的第一個「2」則辨識不出



(a)



(b)

圖 2 不同產線噴號設備所產生的影像差異：(a) 產線 A 噴號字體較大且清晰；(b) 產線 B 噴號字體較小



圖 3 相同模型對不同鋼胚上的字元偵測差異

來；相同的問題也發生在第一塊胚及第二塊胚的字元「1」上面。

透過深入探討這些挑戰，我們可以更精確地理解深度學習技術應用上的實際困境，並尋找更為精準和有效的解決方案，以提出適合工業應用之物件偵測技術，能輕易且廣泛地應用到各製程。

三、面對挑戰所提出的技術對策

面對上述的挑戰，中鋼並未止步不前，而是積極尋找技術對策，以期在深度學習技術的導入過程中，能夠更精準、更高效地解決問題。以下，我們將探討針對先前提到的四大挑戰所提出的技術解決方案。

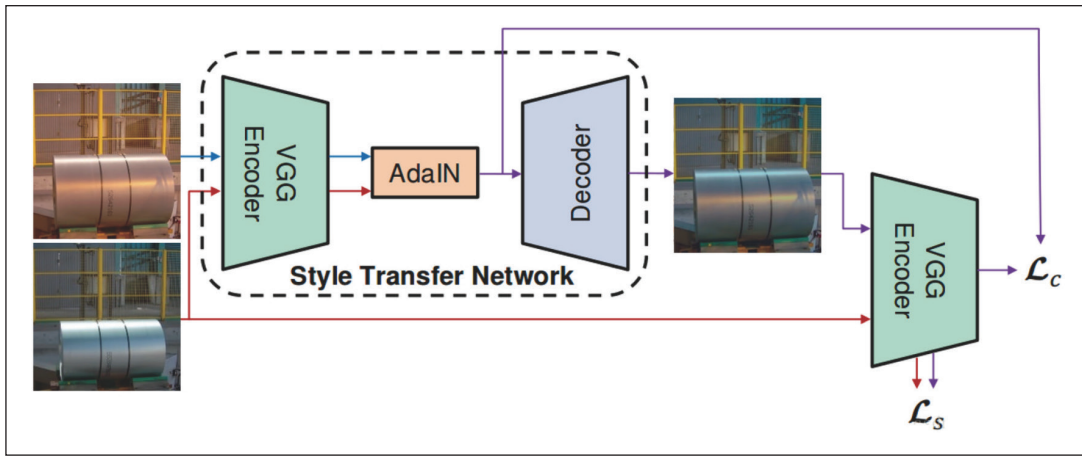


圖 4 風格遷移技術流程圖

(一) 前處理的策略

考慮到取像品質差異大的問題，中鋼選擇利用風格遷移（Style Transfer）[2]技術進行取像正規化。風格遷移技術其主要概念是透過深度學習在抽取特徵的過程找到代表亮度、色調及對比度等影像參數的視覺化特徵，將此特徵作為標準，植入所有的訓練及待測影像中，達到視覺環境標準化的目的。如圖4所示為風格遷移技術的流程方塊圖，首先我們將圖1中日間拍攝的影像作為標準影像，自影像中抽出影像特徵，接著再將夜間拍攝到的燈光影像作為載體，將特徵植入影像當中，則得到一張光線條件與日間拍攝相近的影像。透過風格遷移技術將影像的亮度、色調、對比度調整至一個統一的標準，不僅能夠降低訓練資料的變異性，也能夠在一定程度上減少所需的訓練資料量，提高模型的學習效率與預測準確度。

(二) 可輕量化的深度學習技術

針對計算能力受限的挑戰，中鋼選擇採用中央研究院所提出的跨階段局部網路架構（Cross Stage Partial Network, CSPNet）[3]。CSPNet在保證輕量化的同時，仍能保留相對較高的偵測正確率，適合在計算資源有限的邊緣運算環境中運行。如圖5所示，CSPNet

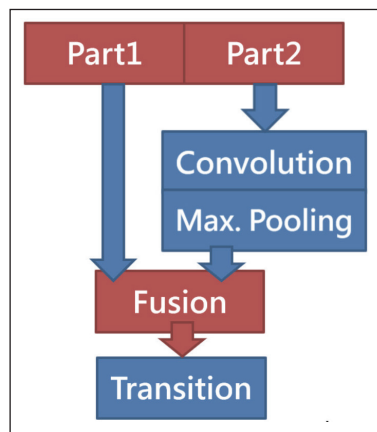


圖 5 跨階段局部網路架構圖

提出保留 DenseNet [4]重複使用特徵的優點，同時利用截斷梯度流防止過多的重複梯度訊息以降低計算複雜度。

(三) 空間金字塔池化技術的應用

為了解決被偵測物體尺寸不一的問題，中鋼採用了空間金字塔池化 (Spatial Pyramid Pooling, SPP) 技術[5]。如圖6所示為空間金字塔池化技術架構方塊圖，該技術透過不同層的特徵向量組合成特徵向量，能夠讓不同尺寸的輸入影像得到可比對的單一尺寸特徵，從而解決了因物體尺寸變化帶來的比對問題，提高模型在不同尺寸物體上的辨識能力。

(四) 集成式物件比對技術的後處理

在模型後處理階段，中鋼提出了一種集成式物件比對技術。該技術能夠整合來自不同模型的辨識結果，通過集成學習的方式有效提升模型的正確率，並在一定程度上彌補單一模型因調整彈性不足所帶來的問題。資料擴增技術[6]常用於深度學習模型訓練，由於深度學習模型訓練需要大量影像資料，在資料不足的情況下常需透過影像處理技術將資料增加。使用資料擴增的原因有兩個：增加手上僅有資料的效率以及增加模型的普適性(Generalization)。舉例來說，如果有一張影像裡面有一隻臉朝左的小貓，如果把影像左右顛倒，訓練資料就會有一張臉朝右的小

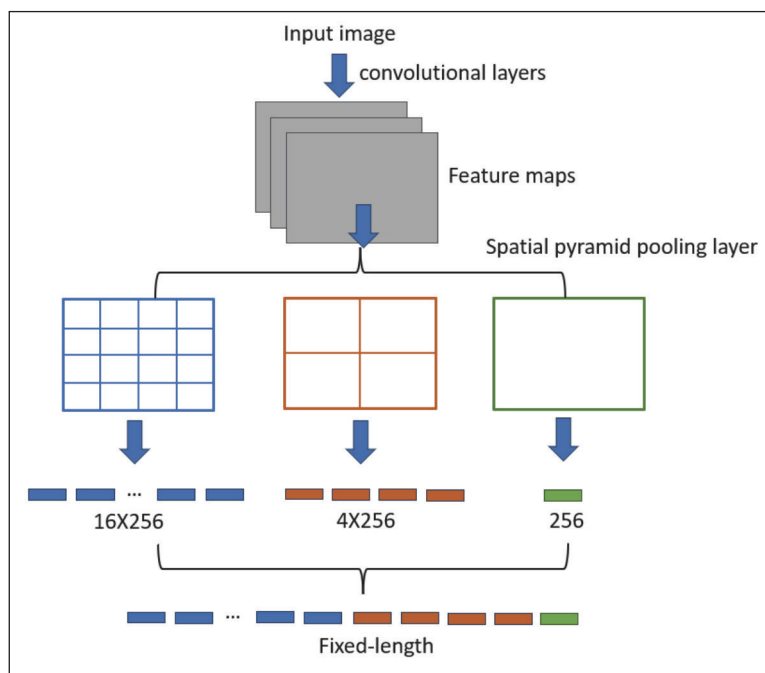


圖 6 空間金字塔池化技術架構圖



貓。所以透過資料擴增，我們可以把一張影像擴展成很多不同的影像，並且使用這些擴展出來的影像來訓練模型，可以讓模型的辨識能力更好。

在所提出的集成式比對技術中，資料擴增的應用目的是讓原來的模型可以更有效地從原來不可辨識的影像中辨識出目的物，因此，如圖7所示，我們選用的資料擴增技術是生成對抗網路(Generative Adversarial Network, GAN)，以序號辨識為例，我們把模型不能識別的序號作為輸入，而輸出則是可識別的相同字元，以此訓練出一個用於資料擴增的生成對抗網路。

當影像擴增後，我們將所擴增的n張影像全數通過原來的辨識模型，得到n個辨識結果。最後將n個結果以集成式比對單元整合成一個結果，即是影像識別系統的輸出。

因此，原來的影像I會被GAN擴增為影像集 $S = \{I_1, I_1, \dots, I_n\}$ ，影像集中的每一張影像都會透過識別模型中產生一個識別結果 h_i ，最後集成式比對技術整合出一個比對結果H。若原來模型的比對正確率為p，則集成式比對所產生的比對結果正確率為：

$$f(p) = \sum_{i=1}^n C_i^n p^{n-i} (1-p)^i \quad (1)$$

若 $p > 0.5$ ，則 $f(p) > p$ 。

透過這些技術對策的實施，中鋼在深度學習技術的導入過程中，不僅成功克服了一系列的技術挑戰，逐漸解決深度學習技術在工業領域應用的落地問題，也為相似領域的企業提供實踐經驗與參考。為了更進一步說明相關經驗，在接下來的章節中，我們將以實際案例說明這些技術應用的情況。

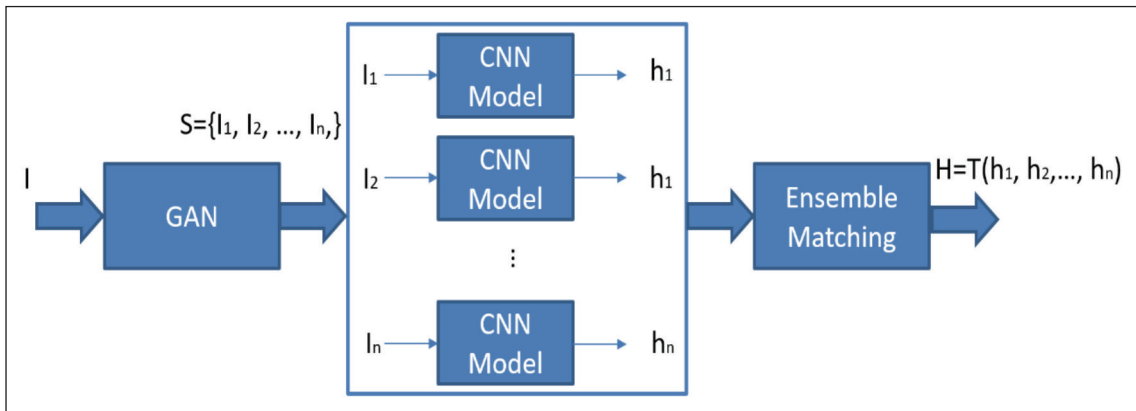


圖 7 集成式比對技術架構圖

四、鋼品序號辨識

由於鋼鐵產品體積龐大、製程繁雜且產線長，鋼品在產線上難以追蹤，造成製程資料無法詳細記錄，因此，鋼品身分識別一直是國內外鋼廠積極想解決的問題。穩定追蹤各鋼品身分有助於產線建立完整生產履歷並記錄鋼品各製程參數，以方便改善製程與品管。中鋼已將鋼捲序號辨識技術建置於第三冷軋包裝線，現場架設四台攝影機，各攝影機配置位置如圖8，分別為 Cam_1、Cam_2、Cam_3及Cam_4。Cam_1及Cam_3目前只用來協助現場收集鋼捲表面影像資料，並未在

本專案執行階段中做其他用途。Cam_2（北面）及Cam4（南面）則為序號辨識專用的攝影機，其中，本系統的影像擷取系統則透過Cam_4來判斷鋼捲的停斷點，讓 Cam_1至Cam_4依據停頓點同時來拍攝並保存影像。表1所示為攝影機Cam_2及Cam_4所拍攝的鋼捲影像，這些鋼捲影像的字元排序方向，主要分為三大類：縱向、橫向及雙橫向。

本案例的字元系統內含有2組辨識模型，第1組模型用來搜尋字元區域，第2組則是用來識別字元。執行辨識流程如圖9所示，首先，當鋼捲進入攝影機拍攝範圍時，系統將




圖 8 產線鋼品識別硬體架構圖



表 1 攝影機 Cam_2 及 Cam_4 所拍攝的鋼捲影像

產線一					
攝影機編號	Cam_2	Cam_4	Cam_2	Cam_4	Cam_4
字元方向	縱向	縱向	橫向	橫向	雙橫向
樣本量	3866	2546	2013	22844	614
影像					

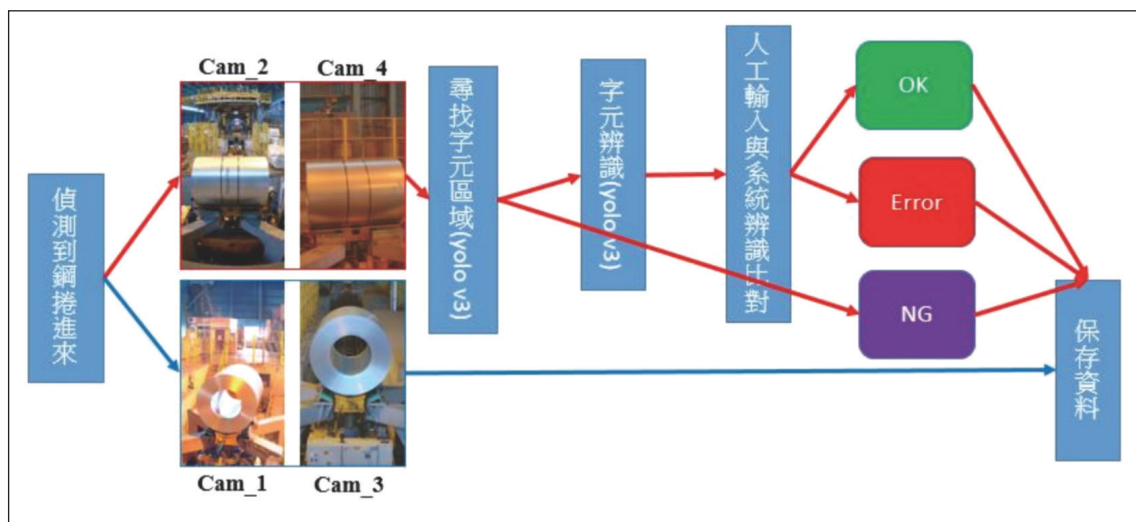


圖 9 產線鋼品識別系統流程圖

會擷取4台攝影機的影像畫面，其中Cam_2及Cam_4的影像將透過第1組模型去搜尋字元區域的位置，並判斷字元區域的長寬比，來確認字元為橫向排序或縱向排序，再進一步統一轉換為橫向方位，接著再透過第2組模組將字元依序切割並做識別，最後將系統識別結果與Level 2人工輸入的序號做比對，其結

果將保存於資料庫。

如圖10所示為現場辨識系統的實際影像，針對上述Level 2人工輸入的序號與鋼捲序號識別系統的比對結果，將由下方幾種狀態表示：



圖 10 產線鋼品識別系統實際畫面

1. 正確(OK)：表示完全正確
2. 錯誤(Error)：表示系統判斷錯誤，或者是 Level 2提供的序號是錯誤的
3. 序號異常 (NG)：表示鋼捲序號因受到環境等外在因素影響，導致系統無法識別的情形。

透過過去所訓練的模型並輔以近期的資料，我們將模型微調後進行測試，測試樣本採用2019/04/28~05/14期間的影像，分別為產線一Cam_2 和 Cam_4，除此之外，已先將測試樣本大部分反光等等NG影像做排除，其測試結果如下表2所示。由結果可發現其正確率可達到99.6%，辨識效果良好。

鋼品序號辨識在電腦視覺應用中屬於相對簡單的案例，其原因除了深度學習技術的

蓬勃發展外，足量的資料是主要的因素，由於鋼品序號的影像資料每天都可以收集到相當數量，因此在模型的訓練上相對容易許多。相對於此類問題，異常偵測在深度學習中就容易遭遇困難，因為異常的資料相對很少，不容易透過足量資料來訓練一個良好且有效的模型。因此，我們在下一章透過高爐封口異常偵測說明當訓練資料稀缺的情況下，該如何透過深度學習技術來實現電腦視覺應用。

五、高爐風徑區異常偵測

高爐為鋼鐵製程中不可或缺的重要元素，但該設備在製程監控上仍較為被動，需透過人工監視來確保其安全及運作正常。高爐風徑區焦炭與粉煤之燃燒反應，可供應煉



表 2 產線一實際測試的辨識結果

攝影機編號	Cam_2		Cam_4	
	橫向	縱向	橫向	縱向
測試張數	487	801	2045	357
完全正確	487 ($\frac{487}{487} = 100\%$)	796 ($\frac{796}{801} = 99.38\%$)	2045 ($\frac{2045}{2045} = 100\%$)	348 ($\frac{348}{357} = 97.48\%$)
漏字	0	0	0	0
錯誤	0	0	0	0
上下顛倒	0	5	0	9
整體正確率	99.6%			

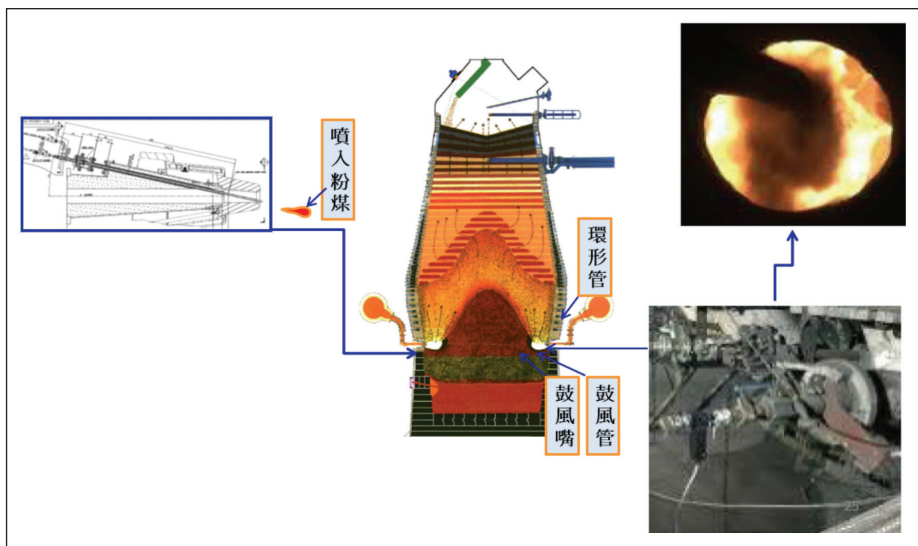



圖 11 高爐風徑區粉煤噴吹監視系統

鐵所需的熱與還原氣體，由於該區亦為高爐爐氣之分配器，故其穩定性直接影響高爐之作業效率。根據經驗，風徑區可能遭遇的問題包含噴槍堵塞、大塊落料與浮渣倒灌等，若能針對這些異狀進行即時監測並採取適當的解決措施，將有助提升高爐操作之穩定與人員作業的安全。目前高爐對於風徑區之監

視仍以人工監看為主，如圖11所示，中鋼已於鼓風管之窺視孔（Peep Sight）安裝監控攝影機，並將監控畫面延伸至控制室供控制人員觀察。然由於上述監視系統目前尚無法提供自動監測警示功能，因此控制室人員須隨時觀察，否則將無法在異況發生的第一時間進行處理。



(a)



(b)

圖 12 所拍攝 (a) 風口影像與其 (b) 切割結果比對

為能即時、長時間且自動地對每一風口進行的監測，技術開發過程具有許多挑戰：首先在取像硬體與機構須足夠穩定，能夠對抗現場高溫、高粉塵與振動，如此才能夠搜集到清晰的影像。此外，由於系統是採機器視覺原理進行檢測，但是因為風口數量相當多，因此單位時間內所需處理的影像資料量也變的相當大，如何在有限的時間內完成異況的判斷也變的相當具有困難性。最後，由於各種異常狀況影像可遇而不可求，因此在異況影像收集遇上瓶頸，最終因資料不足而無法訓練出準確的判斷模型。因此，中鋼針對上述發生的問題，導入先進技術以將之逐一克服。

在完成保護機構設計及製作後，攝影機即可順利地安裝並取得風口影像。如圖12(a)所示為中鋼二號高爐所安裝攝影機取得的影像，在風口影像中有三項重要的物件：風口窺視孔孔徑、注嘴長度及噴注面積。由於影

像中三個物件互有連接，與傳統物件偵測問題不同，在此我們所關心的問題是如何準確將三個物件偵測並切割開來。2015年所提出的全卷積網路 (Fully Convolutional Network, FCN) [7]完美地解決了這個問題，將識別平均準確度只有40%的成績提升到了62.2% (在 Pascal VOC資料集上的結果，FCN論文數據)，畫素級別識別精確度則是90.2%。這已是一個相當完美的結果，幾乎超越了人類對影像進行分割的能力。下圖12(b)所示為風口物件切割的結果，可明顯看出風口、注嘴及噴注面積切割效果相當優異。

由影像切割的結果我們可以以其長度、面積及半徑等計算出的6項參數包含：1. 風口中心座標；2. 風口半徑(R)；3. 風口平均亮度(I)；4. 注嘴長度(L)；5. 噴注面積(A)；6. 邊緣參數(E)。透過上述參數及相關門檻值，我們可對噴注中的風口影像進行自動監控，所監控的事件分為狀態自我檢測及異況偵測。狀態



自我檢測即針對風口會發生的正常狀況進行檢測，包含起注、停噴、影像失焦、風口堵塞及影像歪斜等，當狀態變化至可能影響系統偵測異況時，則通知維護人員進行日常維護；而異況偵測則是自動偵測非常態性變化，如浮渣、大塊落料及注嘴吃短等，一旦發生必須即刻通知現場人員進行處置。下表3所列為各偵測事件與其利用影像參數進行判斷之判斷邏輯。如此，即可在異常影像資料不足的情況下，訓練出異常偵測的電腦視覺模型。

六、無人天車

鋼品在中鋼產線上運送非常仰賴天車作業，而天車運行需要大量作業人力（一部天車需要4名天車手輪班作業），機具作業自動化是鋼鐵工業數位轉型的重要基礎建設，若能將天車吊運作業自動化，不僅可大幅降低作業人力需求，對發展智慧運儲系統也有相當程度的幫助，近年來國內外大型鋼廠皆對天車自動化投入相當多的資源。相較於人工操作天車吊運

作業，自動化天車雖因安全考量而限制其運行速度，但由於能不間斷持續工作，兩者在吊運量上無明顯差別；受惠於自動化的穩定運行，自動化天車馬達壽命得以延長、鋼捲吊運損傷即客訴降低、及人力精簡後工安意外及人事成本得以降低，考量無人化天車的各種優勢，中鋼於2014年初決議發展無人化天車，於106年6月完成無人天車運行所需技術開發，107年開始上線運行，至今已擴展至3座倉庫，完成數十萬顆鋼捲吊運。

無人天車的基本技術需求，主要是將人眼所視的環境資訊，透過電腦視覺技術轉換為對應的控制指令與操作邏輯，再交由天車自動執行。簡言之，就是將天車操作人員看見的鋼捲位置、放置位置及操作方法，都轉換為天車指揮系統可以判讀的資訊，再透過運動控制達到自動化，因此電腦視覺扮演其中最關鍵的技術因素。

（一）高解析度影像三維座標重建技術開發

由於二維影像上所提供的座標僅為平面座標（二維座標），由於缺乏高度座標（z軸座標），除無法有效指示天車指揮系統，也無法與天車的三維座標進行轉換。為使電腦視覺座標系統與真實世界連結，我們首先提出高解析度影像三維座標轉換技術，我們在二維攝影機外，增加一部三維掃描器（3D scanner），利用高解析度影像與三維掃描器資訊提出高解析度影像三維座標重建技術，

表 3 各偵測事件與其判斷邏輯

事件	判斷邏輯
起注	$A \geq T_A$
停噴	$A < T_A$
失焦	$E < T_E$
風口堵塞	$(I < T_I) \& (A \geq T_A)$
影像歪斜	$\sqrt{(x-x_0)^2 + (y-y_0)^2} > T$
浮渣	$(A \geq T_A) \& (R < T_R)$
大塊落料	$(A \geq T_A) \& (R < T_R)$
注嘴吃短	$L < T_L$

如圖13所示為三維空間與高解析度影像對應關係圖，相機的成像原理，主要是三維空間投影到二維空間的表現，假設拍攝的物件與環境都不變的情況下，所有的數學運算，將只是單純的相機座標轉換運算。圖中平面為高解析度影像所拍攝的影像平面，平面為真實空間的地平面，O為攝影機在掃描器三維空間的座標，平面上的一點代表掃描器空間中由O點通過該點所延伸出的直線（如圖中紅色虛線）。因此，二維影像與三維空間的關係可以表示為：

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = R * \begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} r_{00} & r_{01} & r_{02} \\ r_{10} & r_{11} & r_{12} \\ r_{20} & r_{21} & r_{22} \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} \quad (2)$$

因此，由反矩陣即可計算出高解析度影像的三維座標：

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = R^{-1} * \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} r_{00} & r_{01} & r_{02} \\ r_{10} & r_{11} & r_{12} \\ r_{20} & r_{21} & r_{22} \end{bmatrix}^{-1} \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} \quad (3)$$

然而，只有符合 Homography [8, 9]上列方程式關係才存在（只有共面才可能符合條件，亦即z為常數），因此，上述單應轉換則退化成：

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} r_{00} & 0 & r_{02} \\ 0 & r_{11} & r_{12} \\ 0 & 0 & 1 \end{bmatrix}^{-1} \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} \quad (4)$$

針對單應矩陣的四個參數，我們在平面上設置四個點（ p_1, p_2, p_3, p_4 ），作為對應到攝影機成像平面中的四個對應點（ p_1', p_2', p_3', p_4' ），利用四組點對應關係我們可以求出由p平面映射到p'平面的轉換矩陣及其反轉換矩陣，再由其空間直線特性可知，p'平面




圖 13 高解析度影像與實際空間關係示意圖



上的任意點 $U'(x', y')$ ，可經由反轉換矩陣求得 p 平面上的對應點 $U(x, y, 0)$ ，而 U 與 O 之間的線段即是投影到 U' 上的線段，故在線段 \overline{OU} 上最靠近 O 的點 T 即是 U' 的真實座標，如此，我們就可以得到 U' 的3D重建座標 T 。

(二) 板車儲位偵測技術開發

為使駕駛能快速指示天車指揮系統裝車位置，我們以對比度極高的白色反光板作為定位標誌，當板台上儲位由駕駛員以指示標誌標示出來後，我們的系統必須自動偵測板台上擺放指示標誌的數量及個別位置，如圖14所示為平板車指示標誌自動偵測之系統方塊圖，在司機完成擺放指示標誌後，高解析度攝影機拍下停等區畫面，首先我們對拍攝的畫面進行前處理，其目的是利用背景去除技術偵測板台實際位置，用以縮小搜尋指

示標誌的範圍；接著我們對板台影像進行二值化[10]，由於指示標誌為白色高亮度的物體，因此在RGB三個通道的亮度值都會非常高，因此我們將RGB的亮度門檻值都調高。為了避免二值化影像上的雜訊干擾判斷，我們對二值化後的影像進行去雜訊及水平濾波，最終指示標誌位置被完全偵測出來。

雖然無人天車因使用成效良好而開始被廣泛應用，然而，上述電腦視覺並沒有使用最新的深度學習技術，而是依靠傳統影像處理技術來實現；由於天車在裝卸鋼捲時，需要非常精準的定位，誤差超過5公分就可能吊不起鋼捲，但深度學習在位置偵測的精準度上並無優勢，加上判斷速度較慢，傳統影像處理有些技術，應用上會比深度學習來的更好。並非最新的技術即是最適切的技術，需考量其應用目的及環境與資料特性，選擇合

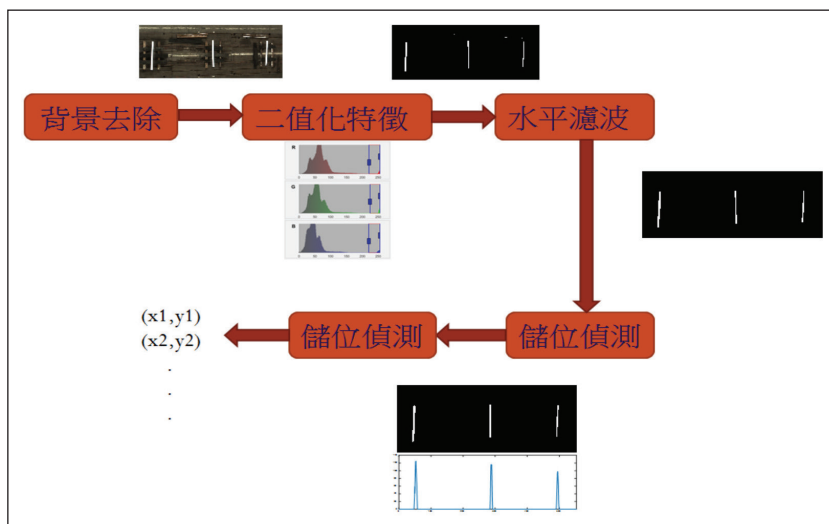


圖 14 平板車指示標誌自動偵測之系統方塊圖



適的技術來解決問題，方能完美解決技術落地問題。

七、結論

透過中鋼公司的三個案例經驗，我們歸納出以下結論，代表了在鋼鐵製程中應用人工智慧技術時所需考慮的不同情境和實踐經驗。

（一）資料充足模型訓練易成功：

中鋼公司的經驗說明，當擁有充足的資料時，模型訓練更容易成功，這反映出資料量和質量對於深度學習模型的重要性。充足的資料可以提供更多的訓練樣本，幫助模型更好地理解 and 預測製程中的變化。

（二）資料不足時透過正常資料訓練出異常偵測模型：

異常偵測問題是最常見的資料缺乏問題，因為異常情況出現的比例遠低於正常情況，因此，透過大量正常資料訓練出參數擷取模型，將影像中所關注的事件數據化，在透過這些數據來描述異常情況，即可從正常資料中訓練出異常事件的偵測模型。

（三）選擇適切的技術勝過最新的技術：

無人天車案例提供了實用的技術選擇經驗，選用技術時重要的是要綜合考慮各種因

素，包括成本、可行性、環境條件等。這種經驗強調了理性和實際性在技術選擇中的價值，而不是盲目地追求最新技術。

透過這三個案例分享說明了在鋼鐵製程中應用人工智慧技術時，應該考慮的因素和方法。鋼鐵業的成功經驗也可以應用於其他行業，強調了實踐經驗的價值，以實現最佳效益。

參考文獻

1. 麥肯錫與世界經濟論壇“全球“灯塔工厂”网络:来自第四次工业革命前沿的最新洞见”，2019.
2. L. A. Gatys, A. S. Ecker and M. Bethge, “Image style transfer using convolutional neural networks”, Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), pp. 2414-2423, Jun. 2016.
3. C. Y. Wang, H. Y. M. Liao, Y. H. Wu, P. Y. Chen, J. W. Hsieh, and I. H. Yeh, “CSPNet: A New Backbone that can Enhance Learning Capability of CNN,” 2019.
4. G. Huang, Z. Liu, K. Q. Weinberger, et al. “Densely connected convolutional networks,” arXiv preprint arXiv:1608.06993, 2016.
5. K. M. He, X. Y. Zhang, S. Q. Ren, J. Sun, “Spatial pyramid pooling in deep convolutional networks for visual recognition.” In Computer Vision – ECCV2014, 346-361, 2014.
6. C. Shorten, and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” J. Big Data, 6:60, 2019.
7. J. Long, E. Shelhamer, and T. Darrell, “Fully convolutional networks for semantic segmentation,” In Proceedings of the IEEE conference on computer vision and pattern recognition, pp.3431-3440, 2015.
8. R. Hartley and A. Zisserman, “Multiple View Geometry in Computer Vision,” Cambridge University Press, second edition, 2003.
9. Z. Zhang, “A flexible new technique for camera calibration,” IEEE Trans. on Pattern Analysis and Machine Intelligence, pp.1330-1334, 2000.