

人工智慧於土木工程應用之回顧

范慶龍

陸軍軍官學校土木工程學系

摘要

近年來，人工智慧快速發展，並隨著大量、複雜之基礎設施的老化，使得機器學習與深度學習方法在土木工程上的應用引起了人們極大的興趣。由於人工智慧具有檢測土木工程結構損壞、施工安全和缺失的卓越能力，此類的應用已經迅速增加。在本文中，已對土木工程相關之文獻實施系統性的回顧，主要目的係對各種人工智慧技術和演算法進行調查整理、討論和分析。最後，總結機器學習與深度學習之最新技術的工程方面的應用成果與研究方向，以及了解這些技術的優點和局限性。此外，基於計算機視覺之深度學習將在結構健康監控發揮重要的作用，並成為建築設施維護與管理的重要技術。藉由不同人工智慧的演算法，以建構出自動化與智慧化的模型，對於未來土木工程技術的進步做出重大貢獻。

關鍵詞：人工智慧，機器學習，深度學習，土木工程

一、前言


1950 年代電腦(又稱電子計算機)發明以來，人類就希望電腦透過學習過程能夠像人類一樣的思考且擁有智慧。而人工智慧(Artificial intelligence, AI)一詞於1956年達特茅斯研討會(Dartmouth conference)首次被提出來，該會議主要探討電腦進行智慧資訊處理的相關問題，揭示電腦未來發展的方向。然而，何謂人工智慧？維基百科定義人工智慧是指透過普通電腦程式來呈現人類智慧的技術。換言之，人工智慧係指的是能模仿人類的智慧執行任務的系統或機器，可以根據所收集的資訊不斷自我調整與進化。如何確認機器具有智慧呢？於是英國密碼學家圖靈(Turing)於1950年提出圖靈測試(Turing test)，測試目的在驗證機器能否表現出與人同等智能，主要測試的方法是由一個測試者對兩個對象——機器(A)與人類(B)在無法看見對方的

房間進行對話，若測試者無法將 A 與 B 區別出人類和機器，也就是 A 通過測試。而圖靈測試也成為了現在驗證與設計人工智慧的一項重要的準則；因此，圖靈被稱為人工智慧之父。

人工智慧的發展過程與資料科學和大數據關係密切，並通過機器學習(Machine learning)與深度學習(Deep learning)的手段達到人工智慧之目的，這些學門、方法與人工智慧的關係如圖一所示[1]。1950 年代電腦發展初期，受限於計算速度慢、儲存空間小等硬體因素，再加上資料量不足；因此，早期電腦僅能執行簡單的數理邏輯運算，理想中的人工智慧並沒有突破性的發展。1980 年代，科學家不再使用傳統邏輯推理方法，取而代之的是統計學、機率學等統計理論，使電腦能透過資料自行學習一套技術，稱為機器學習。機器學習是讓電腦能夠自行從歷史資料中學會一套技

能，並能逐步完善精進該項技能[2]。簡言之，機器學習，指的是可以從資料中歸納規則的方法。Farrar 和 Worden[3]指出機器學習被定義為人工智能的一個子集，它使用統計模型通過理解資料的結構，然後將其擬合到模型中來提高機器的準確性。

Hinton 等人於 1986 年提出了多層感知器(Multi-Layer Perceptron)，以及反向傳播的訓練演算法，使人工神經網路(Artificial neural network, ANN) 在 1980-1990 年代相當盛行。然而，梯度消失(Vanishing Gradient)使得多層 ANN 無法順利傳播。所謂梯度消失是指當梯度從後往前傳時，梯度不斷減小，最後變為零；此時，淺層的神經網路的權重得不到更新，前方隱藏層的學習率低於後方隱藏層的學習率，即隨著隱藏層數目的增加，分類準確率反而下降了，這種現象稱之為「梯度消失」。Hinton 2006 年提出深度信念網路(Deep Belief Network)和限制玻爾茲曼機(Restricted Boltzmann Machines, RBM)來解決梯度消失問題，並有效地訓練多層 ANN，命名為深度學習(Deep learning)。其實，後來才發現要避免梯度消失可以通過批量標準化(Batch Normalization)、權重的初始化、學習率的調整和激活函數等方法。



圖一：AI 與大數據、資料挖掘之關係圖[1]

人工智慧出現在 20 世紀 50 年代至 70 年代的電腦科學領域，並在資料挖掘和模式識別等各個子領域取得了實質性的成功。相反，人工智慧直到最近才引起土木工程專家的注意[4]。由於機器學習是備受矚目的新興方法，可快速、準確的進行土木工程的檢查與建築設施的結構健康監控。尤其，建築物結構的損壞研究，透過機器學習方法可以提取損壞的特徵與分析檢查結果，並進行各種損壞的分類。Amezquita-Sanchez 和 Adeli[5]指出機器學習特別適用於結構健康監測的損壞檢測。例如：最近的研究有建築物結構健康監測與損傷模式[6]、學校建築結構抗震評估[7]，以及混凝土大壩結構健康監測[8]。尤其，Adeli 和 Yeh[9]發表了第一篇關於神經網路的土木與結構工程應用之論文。自此之後，機器學習在土木工程中得到了廣泛的應用。其中，ANN 的實務應用包括：建築成本估算[10-13]、施工安全之問題[14-15]、施工風險評估[16-17]，以及相關缺失預測與診斷[18-19]。

深度學習的概念最初是在 20 世紀 80 年代與 ANN 一起提出的[20]。然而，當用於模型開發的資料有限時，神經網路沒有表現出比其他機器學習方法顯著的優勢。從 1990 年代到 2000 年代，電腦硬體仍然不足以訓練具有許多隱藏層的神經網路，以及開發大量參數模型的資料集。在 2010 年代，硬體發展已達到使用 GPU 和雲計算的里程碑，這直接有利於神經網路建模研究。深度神經網路(deep neural networks, DNN)建立了許多隱藏層，以解決現實環境中複雜的非線性問題，例如：人臉辨識、語音辨識等。

二、機器學習與深度學習之原理


機器學習為實現人工智慧的方法，是幫助電腦更有效率學習的理論體系，它需

要進行適當的訓練，才能根據輸入資料的數值、提取特徵，並執行新資料的預測任務。機器學習可區分成監督式學習(Supervised learning)、非監督式學習(Unsupervised learning)與強化學習(Reinforcement learning)，這三種機器學習模式有許多不同的方法或演算法，如圖二。

監督式學習是從有標記(label)的訓練資料中學習一種模型，訓練資料輸入(input)的資料必需有答案(label)，讓機器去找出一個最好的模型，用於分類、迴歸；也就是使用正確解答的資料讓模型學習的方式。分類的目的是找出資料屬於哪一類，將輸入的資料分至各個不同的類別，忽視同一類別內之微小差異，輸出為離散數值；迴歸的目的是發掘資料的趨勢，與分類相反的是將輸入資料當作一個類別來處理，分析同一類別內的差異，輸出為連續數值。因此，分類是以盡可能區分整個資料來畫線，而迴歸是以盡可能重疊整個資料來畫線。

非監督式學習是使用未標記資料進行學習的過程，即通過具有符合一般規則的未指定輸出的資料集，並且可以按照特定趨勢組合在一起[4]。非監督式學習的訓練資料只有輸入的資料沒有答案(label)，而是從訓練資料中學習特徵，讓機器從中找出規則，由於不需事先給定任何標記過的訓練範例，就能夠自動對輸入的資料進行分群，常用的演算法為集群演算法。強化學習是從現在的環境來決定行為，並會隨時根據新進來的資料逐步修正，是一種互動式的學習過程。強化學習不會給予正確解答，而是透過獎勵與懲罰方式來評估行動的優劣，以決定學習的最佳行動。

監督式機器學習方法有支持向量機(Support vector machine, SVM)、決策樹(Decision tree, DT)、隨機森林(Random forest, RF)及貝氏網路(Bayesian Network, BN)；非監督式機器學習方法則有群集分析(Cluster analysis, CA)、主成分分析(Principal component analysis, PCA)。另外，



圖二：機器學習的三種學習模式與演算法[1]

人工神經網路(Artificial neural network, ANN)因為演算法不同可分成監督式(例如：Back Propagation Neural Network, BPNN; Probabilistic Neural Network, PNN)和非監督式(Kohone Neural Network)二種類型。由於人工神經網路於2012年開發出多個隱藏層的深度學習網路架構，並且在圖像偵測方面的性能也較以往顯著提高。從此，深度學習方法變得非常流行。尤其，2017年Google Tensorflow 1.0的發布，使得卷積神經網路(Convolutional neural network, CNN)成為研究人員運用深度學習的重要選擇之一。本研究針對經常使用的機器學習/深度學習方法之原理做介紹。

一、支持向量機


支持向量機(SVM)是由 Vapnik[21]所提出來基於內核的機器學習方法，所謂支持向量(Support vector)是指最接近邊界的資料，為了避免輸入的新資料分類錯誤，盡量使這些資料遠離邊界。支持向量與邊界的距離稱為間距(margin)。SVM的原理是在資料空間中劃分出二個超平面(圖3中二條虛線)，以區隔出不同的資料種類。訓練資料集 $D = \{x_i, y_i\}$; $y_i = \{-1, +1\}$ 及 w 為法向量，可決定超平面的方向； b 為偏差值，可決定超平面與原點之間的距離，資料空間的任一點 x 到超平面的距離為 r 。

若這些訓練資料是線性可分的，可以選擇分離兩類資料的兩個平行超平面，這兩個超平面分別為 $w^T x - b = 1$ 及 $w^T x - b = -1$ 。間隔(margin)的距離為 $2/\|w\|$ ，為了使間隔之間的距離儘可能分離，需要最小化 $\|w\|$ 。在最大間隔正中間的超平面即「最佳超平面(Optimal hyperplane)」(如圖三)。在現實環境中，各種類別的資料樣本並非總是線性可分的。因此，SVM 引入軟間距(soft margin)和核技巧(kernel trick)來解決


SVM 的局限性。為了處理非線性可分離的資料，可以在軟間距方法中將其他變數(slack variables)添加到 SVM 進行優化。另外，內核技巧的主要概念是將特徵空間映射到更高的維度，用以提高類別之間的可分離性(如圖四)。

二、決策樹

決策樹(Decision tree)具有監督式之資料特徵提取與描述功能，將輸入變數根據目標設定來選擇分枝屬性與分枝方式，並以樹狀的層級架構呈現目標變數與各個變數之層級關係，以探勘出分類之規則，且分類規則容易被理解[22]。在決策樹中，條件的部分稱為節點(node)，而每個節點代表一個屬性；最上層的條件為根節點(root node)，為全部資料的合集；樹的分枝(branch)為測試屬性中的某個值，表示條件測試的結果；最後，決策樹分類的類別為葉節點(leaf nodes)。



圖三：支持向量與最佳超平面(線性可分)




圖四：支持向量機內核分類(非線性可分)

決策樹是根據目標設定來選擇分枝變數與分枝方式，運用樹枝狀的層級架構呈現，以提取分類的規則，經過修剪後的決策樹模型可以做為資料探索或預測，並且找出目標變數與各變數之層級關係，是屬於一種監督式學習的方法。分類過程如同一個倒立的樹狀結構，從最上層的根節點開始，在每個節點選擇一個特徵，經由分枝的結果做出決策，繼續往下一層進行分類，直到將資料分成二類(圖五)。


三、隨機森林

單一分類器有時不能有效處理分類問題，需組合數種不同的學習方法，藉以達到比原本單一方法更佳的结果，並可增加模型的穩健性與準確率，這種組合多個學習方法的模型稱為集成學習(Ensemble learning)。集成學習的概念是由多個決策樹的組合可以提供更高的準確性預測，它往往會通過消除歸因於特定資料集的各個模型中的噪聲，並且為分類模型提供更好的性能[23]。集成學習通過整合多個模型來解決同一問題，以促進機器學習方案的準確性。特別地，與單個分類器相比，多個分類器參與整體分類，能夠獲得更準確的結果。



圖五：決策樹分類過程與結果

隨機森林(Random forest, RF)是由Breiman[24]開發的一種集成學習方法，用於解決分類和迴歸問題。RF基於迴歸和分類樹(CART)的集成學習，在CART的訓練中進行隨機選擇變數，從樹的節點之變數集中隨機選擇一個包含 n 個變數的子集，然後再從這個子集中選出一個最佳變數(optimal variable)用於分割。隨機森林結合裝袋法(Bagging: bootstrap aggregating)和隨機子空間法(Random subspace method)建構許多個決策樹，並透過各個決策樹預測值進行投票(分類)或平均(迴歸)，以獲得最後預測結果。隨機森林建構流程如圖六。




圖六：隨機森林之建構概念與流程[25]

四、人工神經網路


人工神經網路(ANN)是由輸入層、隱藏層和輸出層所組成的架構(圖七)，輸入層是接受外在環境的訊息，可依問題特性將輸入資料轉換成適應網路的訊號；輸入層每個神經元只接受一個輸入變數作為其輸入值，並將其值送至下一層的各神經元，輸入層神經元的數量等於輸入變數的數量。隱藏層介於輸入層與輸出層之間，作為彼此間交互作用的內在結構，以解決非線性的問題；隱藏層的層數及神經元的數量並無特定規則，可視資料複雜度進行適當的調整；層數越多則計算就越耗時，容易出現局部優化的現象，神經元太少則無法處理複雜問題，而過多會導致過擬合。輸出層是處理輸出至外在環境的訊

息，神經元數量則是依回應問題而定，並使用非線性轉換函數將輸入資料轉成輸出訊號，以計算機率作為分類的依據。

ANN 透過使用非線性激活函數(例如 sigmoid、tanh)對權重和偏差(bias)的輸入進行前饋計算(feedforward computation)，並加總每個神經元的權重值。網路將輸入饋送到下一層的神經元以獲得最終輸出，這在網路感知器階段中稱為前饋過程(即感知器學習規則)。激活函數的參數也被定義為每個隱藏層的神經元對輸入層神經元的每個結果的權重[27]。ANN 常使用的激活函數為 Linear、Sigmoid、Threshold 和 Rectified linear unit (ReLU)如圖八所示。



圖七：人工神經網路的組成架構[4]




圖八：四種激活函數之示意圖[26]

五、貝式網路

貝氏網路(Bayesian Network)是一種以有向非循環圖呈現統計推理的機率模型，並利用變數間的因果關係進行預測分

析。其目的係將決策問題中的不確定的事件，使用一組隨機變數，以及變數之間的影響關係來分析其中的機率，並能隨時根據新的資訊或證據進行修訂，進而推論出不確定事件的事後機率[28]。有向非循環圖每個節點都包含相關連的變數之機率值，並由父節點(Parent node)來決定下一個子節點(Children node)的相關機率值，所以貝氏網路是描述變數間相互影響的機率關係，以瞭解事件發生的機率大小。貝氏網路依據 $P(X_i | \text{parents}(x_i))$ 之條件機率寫出條件機率表，該表的每一列為所有可能發生的 $\text{parents}(x_i)$ ，每一行為所有可能發生的 X_i ，且任一行的機率總和為 1。透過條件機率表可以清楚地將事件給條理化，並得知貝氏網路結構圖中各節點間之因果關係(圖九)。



圖九：有向非循環圖之條件機率表[28]

六、群集分析


群集分析是一種典型的非監督式機器學習，對未知類別資料進行劃分，並依一定的規則劃分成若干群組，將相似(距離相近)群的資料聚在同一個群組中，相異性大的資料分為不同群組，用來表示資料之間的性質及關係。群集分析常用的演算法為 K-means，該演算法係從資料中依據預期要劃分的群集數(k)，隨機選取 k 個種子(seed)，並以這些種子當作這些群集的初始重心，k 個種子確定後，接著要將其他剩餘的資料被分派到距離最近的群集中，再

重新計算各群的重心，然後再比較每一個資料與新的群集中心的距離，並重新分群，反覆以上計算過程，直到重心不再移動為止。K-means 計算與分群過程如圖十。


七、主成分分析

一般而言，資料維度越多，才能充分表達資料的特徵；然而，在機器學習上，資料維度過多時容易發生維度災難(curse of dimensionality)的現象。因此，需透過維度刪減來減少所需處理的運算量，以及保留具代表性的特徵維度。主成分分析(PCA)是機器學習中，維度縮減的主要方法之

一，其原理是將原有相關的變數之線性組合(linear combination)，以產生少數無相關的主成分。假設有 m 個原始變數，將挑選其中 n 個能夠解釋大部分原始變數的主成分， n 會遠小於 m ，也就是希望以最少的 n 個新的主成分來代表原有 m 個變數的資訊，以達到變數縮減的目的。這些經由轉換後的主成分之間為獨立，可避免共線性造成模式估計偏差的問題。換言之，主成份分析是將原始資料中多個具相關性的變數轉換成彼此獨立的新變數(即主成分)，並利用主成分解釋原始資料中大部分的變



圖十一：主成分分析的原理說明[30]



圖十二：卷積神經網路組成架構

異，每個主成分均為原始變數的線性組合。第一主成分(PC1)的變異數最大，能解釋原始資料中最多的變異量；第二主成分(PC2)變異數次大，且能解釋第一主成分未能解釋之變異，PCA 操作過程如圖十一。

八、卷積神經網路


卷積神經網路(CNN)是基於視覺的深度學習方法，是一種特殊的網路建模方法，受神經科學的啟發，模仿視覺皮層內的圖像，其中單個神經元僅在接受場(receptive field)中對刺激做出反應。不同的神經元可以部分地相互重疊，以覆蓋整個接受場。CNN 是由一個或多個之卷積層(convolutional layer)、池化層(pooling layer)，以及完全連接層(full connected layer)所組成(圖十二)。架構中的隱藏層特別擅長篩選多維輸入，可以從圖像的數千個像素獲得的紅色、綠色和藍色(RGB)之飽和度值。在訓練過程中，CNN 方法使用預定義維度的內核和網格來掃描圖像，並學習識別某些關鍵特徵，例如：人臉的線條和輪廓。因此，CNN 能夠自動學習圖像特徵，可從訓練資料中分層學習表示形式，並經由特徵學習對圖像中對象種類產生偵測的結果。CNN 係針對訓練資料調整和共享權重，對參數進行概括、優化和簡化，並自動降低具有更高特徵區分和提取能力的參數[31]。

三、人工智慧在土木工程之應用


(一)風險評估

在過去幾年中，執行風險評估的方法正在發生變化，尤其，應用機器學習方法已成功改進工程風險評估的結果。Hegde 和 Rokseth[32]回顧學術資料庫(Scopus and Engineering Village)出版有關機器學習方法於風險評估的現況，調查結果顯示汽車業及營造業採用機器學習方法進行風險評估的比例數量最高(圖十三)；其所使用的

方法最多為 ANN，其次依序為 SVM、DT、RF(圖十四)。



圖十三：各行業使用機器學習在風險評估 [32]



圖十四：風險評估中常用的機器學習[32]


(二) 缺失探勘

人工智慧的研究發展歷程是從「推理」，進階到以「知識」為重點，再進化到具有「學習」的能力。所以，人工智慧在構建電腦系統時，能夠通過模仿人為推理過程，並使電腦以類似專家的準確性，有智慧地推薦出解決問題之決策。機器學習涉及到電腦科學的領域，是人工智慧的一個分支，也是實現人工智慧的一個途徑，即以機器學習為手段，具備學習解決問題的能力。以下整理這十幾年來有關機器學習方法在工程缺失的應用(表一)。這些方法包括：支持向量機(SVM)、決策樹(DT)、人工神經網路(ANN)、貝氏網路(BN)、群

集分析(CA)、關聯規則(association rules, AR)等。

(三)結構工程


Salehi 和 Burgueño[1]回顧 2009-2017 年之間重要土木期刊、資料庫及美國土木工程學會文庫等(Web of Science, Scopus, Science Direct, ASCE Library, Engineering Village, Wiley Online Library, Sage, and Emerald)，總結過去十年中開發的有關人工智慧方法(即機器學習、模式識別和深度學習)在結構工程中的應用。圖十五顯示過去十年中人工智慧方法在結構工程中的使用的研究出版物的數量。可以看出，在這十年大多數方法的使用都有所增加。然而，以進化計算、模糊邏輯和專家系統等技術為特色的研究數量沒有明顯的變化。即使神經網路的使用已經引起了研究人員的高度關注，但在過去的十年裡，關於這種方法的新研究也保持了相當的穩定性。相比之下，以機器學習和模式識別的研究明顯增加是顯而易見。這二種方法在結構工程中的應用包括：結構健康監測和損傷檢測、地震工程和抗震設計、結構可靠性、結構識別和績效評估。圖十六顯示人工智慧方法在結構工程中最常見的主題為結構健康監控。



圖十五：結構工程中使用 AI 的研究數量[1]

表一：機器學習方法分析工程缺失

作者	機器學習方法					
	SVM	DT	ANN	BN	CA	AR
Cheng [33]			•			
Chae & Abraham [34]			•			
Sinha & Fieguth [35]			•			
Syachrani et al [36]		•				
Amadore et al. [37]					•	
Cheng et al. [38]						•
Lee et al. [39]						•
Elmasry et al. [40]				•		
Gui et al. [41]	•					
Lin & Fan [42]					•	•
Lin & Fan [22]		•			•	




圖十六：AI 在結構工程的主要研究主題[1]


(四)建築物損壞

Fan[29]提出 SVM-based clustering 用於檢測四種不同的鋼筋混凝土(RC)損壞類型(鋼筋裸露、剝落、白華和裂縫)，這是混合非監督式與監督式的機器學習方法。首先，使用群集分析依據圖像中損傷特性實施分群，其結果作為 SVM 分類之基準，群組數量的設定通常為損壞種類的二倍。所建議混合式機器學習(Hybrid machine learning, HML)的性能是採用人工註釋的圖像數據實施六項指標的評估。最終，比較 SVM 與 SVM-based clustering 二種機器

學習之分類效益，在三種模型之分類實驗中，混合式機器學習優於單一監督式機器學習(SVM)；其中，SVM-based clustering 對裂縫的檢測效益最佳，準確率為 99.3%(圖十七)，其次為鋼筋裸露、剝落和白華之三種損壞之檢測，準確率為 94.9%(圖十八)。因此，混合式機器學習可快速從數位圖像提取損壞特徵，在一定時間內完成多類 RC 損壞之分類。該研究是促進設施損壞評估的有效方法，這對設施的主管機關和使用者的安全是有用的。



圖十七：機器學習對 RC 裂縫之檢測[29]



圖十八：機器學習對 RC 損壞(鋼筋裸露、剝落和白華)之檢測[29]


(五)深度學習於土木工程之回顧

導入機器學習的人工之智慧，其特點是根據資料自行學習規則，通常要事先對充分表達資料的特徵量，而採用深度學習的人工智慧僅需要讀取資料就能提取出特徵量。深度學習已成為機器學習和模式識別的新熱點話題，其中最具代表性的功能是端到端、分層學習[43]。這種自動學習是通過動態調整與每個神經元相關的網路互連來實現的，並具有多個(深度)隱藏層以提高辨識能力。大多數基於深度學習的方法可以在網格單元自動學習特徵，將學習的結果或規則用於分類工作。深度學習方法主要用於基於網格的數據結構，以解決非線性多類分類問題[44]。


Mostafa 和 Hegazy[45]回顧 2015-2019 年(ASCE, Elsevier, Wiley, IEEE Xplore, and others)圖像分析包括：偵測與分類、量化、物件追蹤，以及邊緣檢測，最常使用的技術是 ANN(50 篇期刊論文)，其次為其他機器學習方法(SVM、DT、RF)，而在土木工程三個研究主題為施工安全、進度監控及損傷評估(圖十九)。隨時間推移，這三個主題研究的比例也隨之增加；尤其是損壞評估。Akinosho 等人[46]回顧 2012 至 2020 年(Scopus and ScienceDirect)有關深度學習在土木工程方面的主要研究，例如：結構健康監測、施工工地安全、建築建模與性能模擬、工程造價預測、行為識別、建築能源需求預測、BIM 模型分類等。這些研究所使用的深度學習結構之中，以 CNN 數量最多(圖二十)。

(六)深度學習於施工安全案例

Fang 等人[47]提出 Faster R-CNN 於施工工地遠端監控視頻中未戴安全帽(non-hardhat-use, NHU)偵測目標的識別方法。為了驗證該方法對施工環境的適應性，作者分析了施工現場的各種視覺條件，並根據其視覺條件對圖像進行分類。



圖十九：土木工程三個研究主題比例[45]



圖二十：深度學習在土木期刊的研究[46]

之後，採用準確率(Accuracy)和召回率(Recall)，以判斷 Faster R-CNN 方法對不同施工條件的適用程度，例如：視覺範圍、天氣、時間及工人姿勢(圖二十一)，實驗結果表明，Faster R-CNN 對 NHU 檢測中的各種背景和工人姿勢變化具有高度穩健性，且準確率和召回率均在 90% 以上，足以提升工地安全監管水平。

(七)深度學習於建築工人追蹤案例

工地現場是一個高危險的工作場域，施工安全監控一直是監造與業主共同關心的議題，為有效提升工地的職場安全，必須透過各類攝影設備進行監視，以有效掌握意外事件的發生。因此，許多工地在每角落都安裝監視或視頻，以追蹤工人動態與行為；然而，工人追蹤的影像分析中有

許多的限制，包括：尺度變化、工人制服、遮蔽、姿勢變化、突然移動、背景雜亂和光照變化。為了解決克服以上問題，使用深度學習方法可以有效解決尺度變化、外觀相似性、一些遮擋、姿勢變化、背景雜亂和光照變化。因此，Angah 和 Chen[48] 基於 Mask R-CNN 提出一種多目標追蹤準確度 (Multi-Object Tracking Accuracy, MOTA)，對於遮蔽導致的一些漏檢與跟踪能夠通過重新匹配來適應錯誤，作者在施工工地現場使用 MOTA，經由四個視頻進行測試，其結果顯示 MOTA 之準確率為 81.8%，如圖二十二所示。

三、結論

近年來，人們對人工智能(AI)在工程領域中的應用越來越感興趣，它激發了許多願景和期望。尤其，土木工程使用各種 AI 方法逐漸增長，本研究集中在過去十年中受到廣泛關注的 AI 方法(即機器學習和深度學習)，以及這些方法在各個工程領域中的應用。回顧這些方法的理論背景，並探討最新的工程方面的應用成果與研究方向。

機器學習方法在土木工程結構中的檢測應用，以及監控和修復受到越來越多的關注。當前正處於 AI 技術革命的邊緣，人工智能可能會主導結構健康監測和老化土木基礎設施管理方面的工作。另外，運用深度學習方法進行圖像資料的分類，以便從中識別隱含的特徵，並對學習到的特徵進行偵測。尤其，在土木工程基於深度學習的損壞檢測技術已經在實務上具有相當的成效。這與使用手動製作特徵與計算複雜度高的傳統機器學習有所不同，深度學習使用網路學習的最佳特徵，從而顯著地提高分類的準確度。



圖二十一：施工現場的各種視覺條件[47]



圖二十二：MOTA 對於施工現場的遮蔽之追蹤測試[48]

由於使用 AI 方法仍有一些挑戰和限制，這些限制包括缺乏對 AI 方法的合理選擇、不完整資料的影響，以及計算效率的忽略。尤其，本研究回顧的一些論文表明所使用的 AI 方法具有良好的性能，但是該方法在計算方面卻是相當的昂貴。因此，未來在工程上的應用必須加以面對的問題，才能使得 AI 方法具有良好的準確性與計算效率。此外，AI 的最佳參數或超參數的設定某程度也會影響到模型的性能。不管是圖像或數值資料集，在資料整理過程和預處理方式，對於提升 AI 模型的性能及效益評估至關重要。因此，未來實施 AI 方法的應用或研究必須考慮到上述問題，以便選擇最佳模型之參數。

Salehi 和 Burgueño[1]認為從探索性用途轉向針對性和合理性地實現不同的演算法選項變得非常重要，因為不同的 AI 方法可以根據應用導致不同程度的性能和準確性。眾所周知，沒有最好的學習技術，所有的方法和模型都有優點與局限性。因此，從確定問題的性質，再對給定問題的適用性的方法進行評估，並根據所蒐集的資料而採取不同的 AI 方法。Wolpert 和 Macready[49]表明不可能採用獨特的最佳方法，而最佳技術始終取決於問題的性質。Mohri 等人[50]指出適當的方法的選擇取決於研究資料集中樣本的數量和性質，以及評估的特徵。總之，不存在一個對所有問題具有普遍優勢的方法；相反地，一定存在某個方法在解某種問題時表現最好。因為每種 AI 方法都有其適合處理的資料，沒有絕對最完美的方法；尤其，在面對複雜的問題與大量資料時，通常需要使用不同的方法或演算法，才能有效克服。

我們相信未來基於計算機視覺之深度學習將在結構健康監控發揮重要作用，將成為建築設施維護與管理的重要技術。持

續透過圖像分析與影像處理系統的開發，整合各種 AI 方法的優點，對圖像的光譜特性與表面分類的運算能力，進行不同損壞特徵資料的訓練與測試，以獲得更精確的數量、面積、位置及損害程度等相關資訊，並建構出自動化和智慧化的模型，對於土木工程技術的進步做出重大貢獻。

參考文獻：

- [1] Salehi, H. and Burgueño, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering Structures*, 171, 170-189.
- [2] Mitchell, T.M. (1997). Does machine learning really work? *AI Magazine*, 18(3), 11-20.
- [3] Farrar C.R., and Worden, K. (2012). *Structural Health Monitoring: A Machine Learning Perspective*. Wiley, Hoboken.
- [4] Flah, M., Nunez, I., Chaabene, W.B., and Nehdi, M.L. (2021). Machine learning algorithms in civil structural health monitoring: A systematic review. *Archives of Computational Methods in Engineering*, 28(4), 2621-2643.
- [5] Amezcua-Sanchez, J.P., and Adeli, H. (2015). Synchrosqueezed wavelet transform-fractality model for locating, detecting, and quantifying damage in smart high-rise building structures. *Smart Materials and Structures*, 24(6), 065034.
- [6] Chang, C.M., Lin, T.K., and Chang, C.W. (2018). Applications of neural network models for structural health monitoring based on derived modal properties measurement. *Measurement*, 129, 457-470.
- [7] Chi, N.W., Wang, J.P., Liao, J.H., Cheng, W.C., and Chen, C.H. (2020). Machine learning-based seismic capability evaluation for school

- buildings. *Automation in Construction*, 118, 103274.
- [8] Kang F., Li, J., and Dai, J. (2019). Prediction of long-term temperature effect in structural health monitoring of concrete dams using support vector machines with Jaya optimizer and salp swarm algorithms. *Advances in Engineering Software*, 131, 60-76.
- [9] Adeli, H., and Yeh, C. (1989). Preceptron learning in engineering design. *Microcomputer in Civil Engineering*, 4, 247-256.
- [10] Wilmot, C.G., and Mei, B. (2005). Neural network modeling of highway construction costs. *Journal of Construction Engineering and Management*, 131(7), 765-771.
- [11] Petroutsatou, K., Georgopoulos, E., Lambropoulos, S., and Pantouvakis, J.P. (2012). Early cost estimating of road tunnel construction using neural networks. *Journal of Construction Engineering and Management*, 138(6), 679-687.
- [12] Marzouk, M., and Amin, A. (2013). Predicting construction materials prices using fuzzy logic and neural networks. *Journal of Construction Engineering and Management*, 139(9), 1190-1198.
- [13] Jafarzadeh, R., Ingham, J.M., Wilkinson, S., Gonzalez, V., and Aghakouchak, A.A. (2014). Application of artificial neural network methodology for predicting seismic retrofit construction costs. *Journal of Construction Engineering and Management*, 140(2).
- [14] Ayhan, B.U., and Tokdemir, O.B. (2020). Accident analysis for construction safety using latent class clustering and artificial neural networks. *Journal of Construction Engineering and Management*, 146, 04019114.
- [15] Pereira, E., Ali, M., Wu, L., and Abourizk, S. (2020). Distributed simulation-based analytics approach for enhancing safety management systems in industrial construction. *Journal of Construction Engineering and Management*, 146, 04019091.
- [16] Bai, L., Wang, Z., Wang, H., Huang, N., and Shi, H. (2020). Prediction of multiproject resource conflict risk via an artificial neural network. *Engineering, Construction and Architectural Management*, 28(10), 2857-2883.
- [17] Park, J.K., Hossain, S., Oh, J., Yoo, H., and Kim, H. (2020) Assessment of risk potential due to underground box structure installation employing ANN model and field experimental approaches. *Journal of Performance of Constructed Facilities*, 34(4), 04020057-1.
- [18] Murugan, S.B., and Sundar, M.L. (2017). Investigate safety and quality performance at construction site using artificial neural network. *Journal of Intelligent & Fuzzy Systems*, 33(4), 2211-2222.
- [19] Butcher, J.B., Day, C.R., Austin, J.C., Haycock, P.W., Verstraeten, D., and Schrauwen, B. (2014). Defect detection in reinforced concrete using random neural architectures. *Computer-Aided Civil and Infrastructure Engineering* 29(3), 191-207.
- [20] Gawehn, E., Hiss, J.A., and Schneider, G. (2016). Deep learning in drug discovery. *Molecular informatics*, 35(1), 3-14.
- [21] Vapnik, V.N. (1995). *The Nature Of Statistical Learning Theory*, Springer-Verlag, New York.
- [22] Lin, C.L., and Fan, C.L. (2019). Evaluation of CART, CHAID, and QUEST algorithms: A case study of construction defects in Taiwan. *Journal of Asian Architecture and Building Engineering*, 18(6), 539-553.

- [23] Athanasiou, A., Ebrahimkhanlou, A., Zaborac, J., Hrynyk, T., and Salamone, S. (2020). A machine learning approach based on multifractal features for crack assessment of reinforced concrete shells. *Computer-Aided Civil and Infrastructure Engineering* 36(5), 565-578.
- [24] Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32.
- [25] 范慶龍 (2021)，監督式機器學習於土地覆蓋分類效益之研究，*臺灣土地研究*，第24卷，第1期，67-94。
- [26] Kriegeskorte, N. (2015). Deep neural networks: A new framework for modeling biological vision and brain information processing. *Annual Review of Vision Science*, 1, 417-446.
- [27] Ghassemieh, M., and Nasser, M. (2012). Evaluation of stiffened end-plate moment connection through optimized artificial neural network. *Journal of Software Engineering and Applications*, 5(3), 156-167.
- [28] Fan, C.L. (2020). Defect risk assessment using a hybrid machine learning method. *Journal of Construction Engineering and Management*, 146(9), 04020102.
- [29] Fan, C.L. (2021). Detection of multidamage to reinforced concrete using support vector machine – based clustering from digital images. *Structural Control and Health Monitoring*, 28(12), e2841.
- [30] 賽多利斯 (Sartorius) , <https://www.sartorius.com/en/knowledge/science-snippets/what-is-principal-component-analysis-pca-and-how-it-is-used-507186>，檢索日期：2021/12/21。
- [31] Wang, Y., and Wang, Z. (2019). A survey of recent work on fine-grained image classification techniques. *Journal of Visual Communication and Image Representation*, 59, 210-214.
- [32] Hegde, J., and Rokseth, B. (2020). Applications of machine learning methods for engineering risk assessment – A review. *Safety Science*, 122, 104492.
- [33] Cheng, H.D. (1996). Automated real-time pavement distress detection using fuzzy logic and neural networks. *SPIE Proc. on Nondestructive Evaluation of Bridges and Highways*, 2946, 140-151.
- [34] Chae, M.J., and Abraham, D.M. (2001). Neuro-fuzzy approaches for sanitary sewer pipeline condition assessment. *Journal of Computing in Civil Engineering*, 15(1), 4-14.
- [35] Sinha, S.K., and Fieguth, P.W. (2006). Neuro-fuzzy network for the classification of buried pipe defects. *Automation in Construction*, 15(1), 73-83.
- [36] Syachrani, S., Jeong, H.S., and Chung, C.S. (2013). Decision tree-based deterioration model for buried wastewater pipelines. *Journal of Performance of Constructed Facilities*, 27(5), 633-645.
- [37] Amadore, A., Bosurgi, G., and Pellegrino, O. (2014). Classification of measures from deflection tests by means of fuzzy clustering techniques. *Construction and Building Materials*, 53, 173-181.
- [38] Cheng, Y., Yu, W.D., and Li, Q. (2015). GA – based multi-level association rule mining approach for defect analysis in the construction industry. *Automation in Construction*, 51, 78-91.
- [39] Lee, S., Han, S., and Hyun, C. (2016). Analysis of causality between defect causes using association rule mining. *International Journal of Civil, Environmental, Structural, Construction*

- and Architectural Engineering, 10(5), 654-657.
- [40] Elmasry, M., Zayed, T., and Hawari, A. (2017) Defect based deterioration model for sewer pipelines using Bayesian belief networks. *Canadian Journal of Civil Engineering*, 44(9), 675-690.
- [41] Gui, G., Pan, H., Lin, Z., Li, Y., and Yuan, Z. (2017). Data-driven support vector machine with optimization techniques for structural health monitoring and damage detection. *KSCE Journal of Civil Engineering*, 21, 523-534.
- [42] Lin, C.L. and Fan, C.L. (2018). Examining association between construction inspection grades and critical defects using data mining and fuzzy logic. *Journal of Civil Engineering and Management*, 24(4), 301-315.
- [43] Chen, Y., Jiang, H., Li, C., Jia, X., and Ghamisi, P. (2016). Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 54, 6232-6251.
- [44] Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*, MIT Press.
- [45] Mostafa, K., and Hegazy, T. (2021). Review of image-based analysis and applications in construction. *Automation in Construction*, 122, 103516.
- [46] Akinosho, T.D., Oyedele, L.O., Bilal, M., Ajayi, A.O., Delgado, M.D., Akinade, O.O., and Ahmed, A.A. (2020). Deep learning in the construction industry: A review of present status and future innovations, *Journal of Building Engineering*, 32, 101827.
- [47] Fang, Q., Li, H., Luo, X., Ding, L., Luo, H., Rose, T.M., and An, W. (2018). Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. *Automation in Construction*, 85, 1-9.
- [48] Angah, O., and Chen, A.Y. (2020). Tracking multiple construction workers through deep learning and the gradient based method with re-matching based on multi-object tracking accuracy. *Automation in Construction*, 119, 103308.
- [49] Wolpert, D.H., and Macready, W.G. (1997). No free lunch theorems for optimization. *IEEE transactions on evolutionary computation*, 1(1), 67-82.
- [50] Mohri, M., Rostamizadeh, A., and Talwalkar, A. (2012). *Foundations of Machine Learning*, The MIT Press, Cambridge, Massachusetts.

A Review of Artificial Intelligence in Civil Engineering Applications

Ching-Lung Fan

Department of Civil Engineering, ROC Military Academy

Abstract

In recent years, the rapid development of artificial intelligence (AI) and the deterioration of large and complex infrastructures have made the application of machine learning and deep learning methods in civil engineering of great interest. The application is rapidly increasing due to the remarkable capabilities of AI in detecting structural damage, construction safety, and defects in civil engineering. In this paper, a systematic review of literature related to civil engineering has been conducted with the main purpose of surveying, discussing and analyzing various AI techniques and algorithms. Finally, summarize the engineering application achievements and research directions of the latest technologies of machine learning and deep learning, and understand the advantages and limitations of these technologies. In addition, computer vision-based deep learning will play a role in structural health monitoring as an important technology for building facility maintenance and management. Through different AI algorithms, an automated and intelligent model has been constructed, which will make a significant contribution to the advancement of civil engineering technology in the future.

Key words : artificial intelligence, machine learning, deep learning, civil engineering

