



機器學習於橋墩沖刷預測之應用

張世昇／國立臺灣大學土木工程研究所電腦輔助工程組 碩士班研究生

陳翊翔／國立臺灣大學土木工程研究所電腦輔助工程組 碩士班研究生

張書瑋／國立臺灣大學土木工程研究所結構工程組 助理教授

張家銘／國立臺灣大學土木工程研究所結構工程組 助理教授

林詠彬／財團法人國家實驗研究院國家地震工程研究中心 研究員

張國鎮／國立臺灣大學土木工程研究所結構工程組 特聘教授

陳俊杉／國立臺灣大學土木工程研究所電腦輔助工程組 教授

台灣山區地勢陡峻、東西方向狹窄，豪雨期間河川流速湍急，導致橋墩常面臨嚴重的沖刷。橋樑沖刷深度目前多依賴經驗公式推估，但在精準度及適用性皆有許多改善空間。伴隨科技進步，橋樑沖刷的監測技術已可以精準的量測沖刷深度並擷取到非常大量的資料，因應大數據時代及人工智慧的發展，可以透過長期量測的資料建立精準的沖刷預測模型。本文介紹由國家地震工程研究中心研發的橋墩沖刷監測系統，並探討如何透過機器學習，將濁水溪流域的自強大橋長期監測的沖刷資料建立沖刷深度預測模型，藉由類神經網路高度非線性特性反應水位、流速對單一橋墩的沖刷深度之影響，並探討將此預測模型發展為泛用於其他橋墩之可行性。

簡介

橋樑損壞原因眾多，與河川水流相關因子則佔大多數（圖 1），台灣的橋樑也不例外。台灣位於菲律賓海板塊及歐亞大陸板塊的交界處，地理環境十分特殊，地形多為高山、丘陵、台地組成。由於山區地勢陡峻、東西方向狹窄，河川東西流向、坡度大，水流十分湍急，常面臨的問題是豪雨期間沖刷所造成的基礎裸露，導致橋樑的穩定性及承載力不足。以下列事件為例，2000 年碧利斯颱風過境時，高屏大橋無預警斷落、2008 年辛樂克颱風侵台期間，溪水暴漲導致后豐大橋斷裂、2009 年莫拉克颱風來襲的時候，台灣中南部地區有近百座橋樑因為橋墩受沖刷影響造成橋樑毀損等。以上的斷橋事件皆造成人民嚴重傷亡，因此如何因應橋樑沖刷的議題發展工程的解決方案實在刻不容緩。

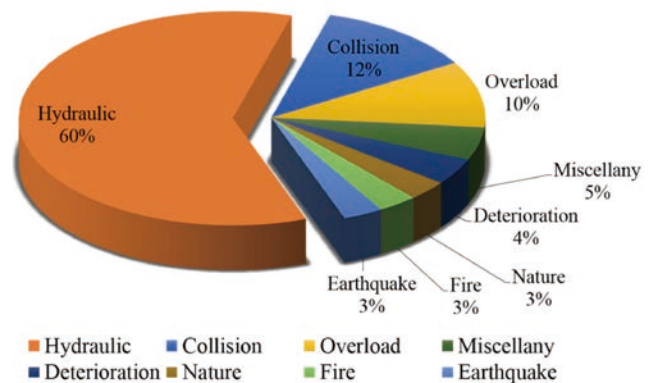


圖 1 橋樑損壞原因統計圖^[1]

過往許多學者針對沖刷的問題進行探討及研究，Melville^[2]、Sheppard and Miller^[3]、Raudkivi and Ettema^[4]、Graf and Istiarto^[5]、Breusers 等人^[6]透過縮尺沖刷實驗探討沖刷的物理機制，並依據實驗結果提出不同的經驗公式。近年來伴隨機器學習（Machine Learning）的

發展成熟，Baten 等人 [7]、Zounemat-Kermani 等人 [8]、Choi and Cheng [9]、Lee 等人 [10]、Toth and Brandimarte [11] 利用不同的演算法將縮尺模型實驗所量測的資料和現地獲得的觀測資料結合，嘗試建立沖刷深度推估模型，探討河川的水位、流速、橋墩尺寸、土壤粒徑等參數和沖刷深度之間的關聯性。上述的方法在應用的精準度及適用性皆有許多改善空間。

國家地震工程研究中心（National Center for Research on Earthquake Engineering, NCREE）針對橋樑沖刷議題，在過去幾年已發展可適用於現地險峻環境的橋樑沖刷監測系統，並於濁水溪流域的名竹大橋、中沙大橋、自強大橋和西濱大橋裝設此監測系統，於 2015 年開始監測至今，累積了非常龐大的觀測資料 [12]。這些資料包含河流的歷史水位、流速、橋墩的即時監測畫面及沖刷監測系統每個加速度感測節點之歷時資料。本文以自強大橋為例，介紹如何利用此長期監測的數據配合機器學習的方法建立水位、流速兩種河流資訊和橋墩沖刷深度之間的關聯性模型，並應用於預警系統以提升洪水來臨時用路人之安全。

橋梁沖刷監測系統

本文先針對由國家實驗研究院的國家地震工程研究中心、國家晶片系統設計中心、國家奈米元件實驗

室、國家高速網路與計算中心、儀器科技研究中心及台灣颱風洪水研究中心共同開發的橋梁沖刷監測系統做一簡介與說明，相關技術細節請參閱 [12]。

系統架構

橋梁沖刷監測系統整體架構如圖 2 所示，此架構可分為橋體上及橋體下兩部分。架設於橋體上的儀器用於監測河流狀態，當颱風或豪雨發生時，湍急的水流會對橋墩造成嚴重的沖刷，因此需針對河流的水位及流速進行監測並得到即時的資訊。架設於橋體下則為橋墩沖刷監測系統，其主要目的在於即時監測橋墩沖刷深度，並長期記錄橋墩周圍的河床沖刷及回淤歷程，避免橋墩因為過度暴露而危害橋梁安全。

水位和流速量測原理

水位的量測方式是將水位計裝設於橋面版上的欄杆旁，藉由雷達波的發射並接收脈衝，當雷達波遇到水位面反射會形成回波，由發射波與回波的時間差可得到即時的水位面變化，再藉由水位計的高程推算當時的水位高度。水位資料的取樣頻率約為 1 Hz，解析度為 ± 1 mm。水流速的量測是由天線對河川水面發射微波訊號，同時接收自河川水面反射的回波訊號，將發射訊號和回波訊號透過都卜勒效應得知兩者之頻差，可推求河川表面之流速，其資料的取樣頻率約為 0.5 Hz，解析度為 ± 0.01 m/s。




圖 2 橋梁沖刷監測系統架構示意圖




圖 3 沖刷監測系統感測器與運作原理示意圖

表 1 自強大橋強降雨沖刷事件列表

場址	事件編號	事件時間
自強大橋	1	2016/09/27 – 2016/10/31
	2	2017/04/22 – 2017/04/25
	3	2017/04/27 – 2017/04/30
	4	2017/05/25 – 2017/06/08
	5	2017/06/09 – 2017/06/18
	6	2017/06/30 – 2017/07/22
	7	2017/07/24 – 2017/08/03
	8	2017/08/23 – 2017/08/30
	9	2017/10/14 – 2017/10/17
	10	2018/01/06 – 2018/01/14

橋樑沖刷感測原理

橋樑沖刷監測系統的沖刷感測器設計原理是將三軸加速度規裝設在金屬鋼球中，並將金屬鋼球以五十公分為間距固定於鋼筋籠中，再將整個鋼筋籠以垂直的方式埋設在橋墩旁的河床底下，透過水流衝擊金屬球所引致的振動做為判斷該深度有無沖刷的依據。圖 3 為沖刷感測系統與運作原理示意圖，當河川流量較小時，沖刷感測器的感測節點被泥土覆蓋住，此時的感測節點處於穩定的狀態。當強降雨發生期間河川水流湍急，會對橋墩周圍造成局部沖刷的現象，此時橋墩周圍的覆土高度會逐漸下降，原本處於泥土中的感測節點會逐漸裸露並遭受水流及泥土的沖擊和擾動而產生振動。因此透過加速規所量測到的振動訊號可以識別每個感測節點是否受到沖刷而裸露在河水中，進而判斷沖刷深度的範圍。

數據蒐集與特徵分析

強降雨資料蒐集及建立

本文所採用的資料包括近三年的水位、水流速和沖刷感測節點的加速度訊號，皆來自於國家地震工程研究中心於 2015 年裝設於自強大橋 P8 橋墩的即時橋墩沖刷監測系統。由於長期監測的資料量非常龐大，本文僅針對雨季期間有明顯沖刷事件的資料進一步做探討。這些事件可透過現地攝影機所拍攝的畫面先擷取出水面高過於橋墩周圍覆土之時間段資料，根據這些原則，自強大橋總共可以擷取出 10 場完整的強降雨沖刷事件資料，如表 1。

資料前處理

檢視原始資料後可發現部分記錄之水位和流速的歷時資料有明顯錯誤和不合理的現象，初步研判應為量測儀器故障或訊號干擾所造成。本研究參照現地攝影畫面、經濟部水利署（Water Resources Agency, WRA）和台灣颱風洪水研究中心（Taiwan Typhoon and Flood Research Institute, TTFRI）在自強大橋所量測的水位和流速資料相互比對，並使用漢佩爾辨識法（Hampel Identifier）將異常質移除和高斯分佈權重之移動平均法（Moving Average by Gaussian Distribution Weighting）將資料平滑化，最後再透過內插方式將每分鐘之資料點補齊。圖 4 整理上述之修正原則，圖 5 以 2017 年 6 月 9 日至 2017 年 6 月 18 日的強降雨事件為例，比較修正前與修正後之水位與流速資料。由圖 5 可以發現此修正有效地將強降雨期間量測到之高度震盪的水位與流速除去雜訊與平滑化，讓此段期間的資料更為合理。




圖 4 水位、流速修正流程圖

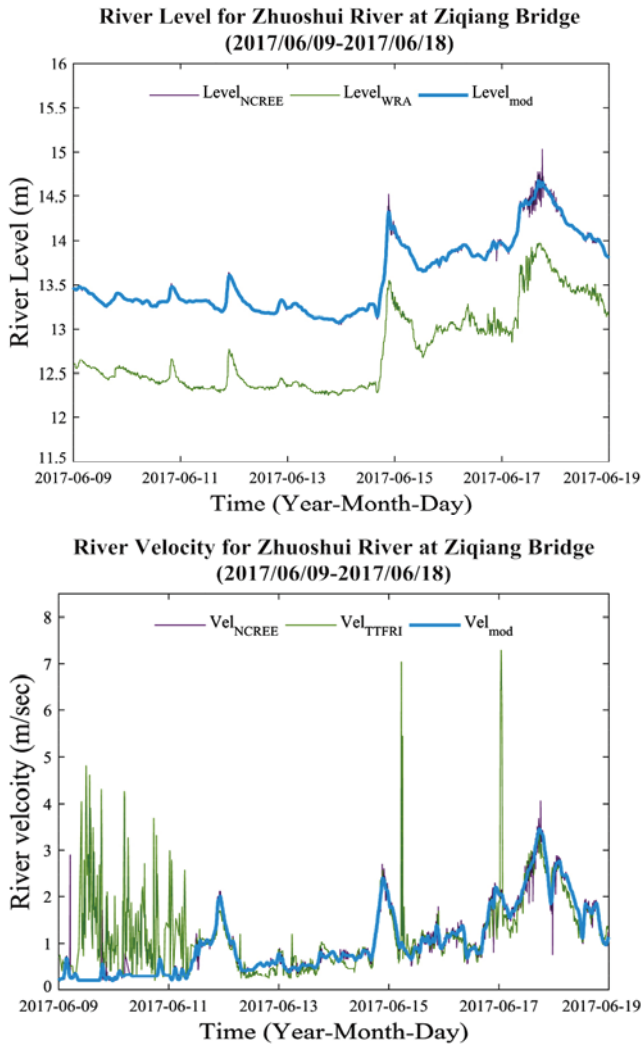


圖 5 2017/06/09-2017/06/18 降雨沖刷事件修正前與修正後之水位 (上圖) 和流速 (下圖)

本文採用監督式機器學習，需有真值做資料模型訓練。沖刷深度的真值以加速度訊號為準，並透過平均值、變異數與唯一值等三條件做為最後真值判斷的依據。在每個感測節點所輯錄的加速度歷時中可以量測到在非汛期無洪水沖刷時會有 $\pm 0.01\text{ g}$ 至 $\pm 0.03\text{ g}$ 的起伏，初步判斷為加速規本身的特性或是外在的訊號干擾。本文利用此特性，第一條件是利用加速度訊號平均值，因為感測節點的位移會造成加速規的電壓值改變而基線值偏移，因此以每秒為單位求得訊號的平均值並觀測其變化可以得知該感測點是否因為水流衝擊而移動。第二條件係以每秒鐘訊號的變異數做為判斷的依據，將無降雨事件發生時的變異數設定為門檻值，依其訊號和雜訊比可知道該感測點是否受到水流衝擊而引致振動。感測節點在靜止狀態時相當不穩定，因此另外增加第三條件，以每秒鐘不重複出現的個數 (Number of Unique Number) 並依據每個感測節點的特性設定一門檻值，當不重複出現的個數超過其門檻值則視為水流衝擊而引致振動，以上述的條件將三軸向的加速度取平均值、變異數和每分鐘不重複出現的個數再取交集，則可以互相參照並提升識別的可信度。

圖 6 示意上述沖刷深度真值判斷流程，從識別結果顯示該時刻的沖刷深度範圍，並以五十公分為間距將每個時刻的沖刷深度範圍進行標籤作業。標籤的順序係以沖刷深度淺至深而小至大。標籤作業完成後，沖刷深度的標籤大小與水位和流速的趨勢相當一致，如圖 7 所示。

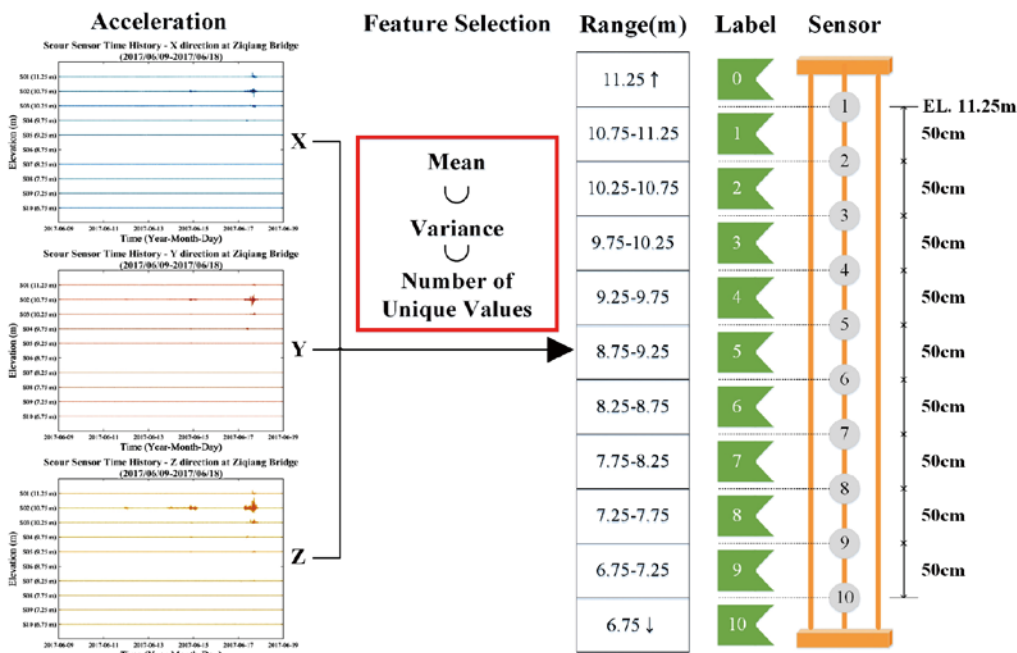


圖 6 沖刷深度識別及標籤作業方式




圖 7 自強大橋 2017/06/09-2017/06/18 事件之水位、流速和冲刷深度標籤趨勢

機器學習方法

深度學習與類神經網路

深度學習是一種以類神經網路 (Artificial Neural Network) 為基礎所演進的方法，而類神經網路的發想來自於人類大腦的神經網路，是一種模仿生物之神經網路所產生的數學模型。Hebb 於 1949 年根據突觸可塑性的基本理論提出赫布理論 (Hebbian theory) [13]，建立了學習過程中神經元 (Neuron) 互相影響的基礎。Rosenblatt 於 1958 年提出感知器 (Perceptron) [14]，將神經細胞結構數學模型化，如圖 8 所示。




圖 8 神經元構造與感知器架構圖

類神經網路的數學模型與運作方式相對單純，假設每個神經元都是一簡單函數，而神經元的運作模式是將每個輸入值乘個別權重 (Weight) 後加上閾值 (Bias)，總和便成為神經元中激活函數 (Activation Function) 的輸入。其中激活函數是由使用者事先定義好的非線性函數，用來模仿神經元的複雜度。1980 年代多層感知器 (Multilayer Perceptron, MLP) 的應用開始逐漸增加，但發展上遇到理論與效率的瓶頸，直到 1986 年 Rumelhart 等人提出反向傳播 (Backpropagation) [15] 可以有效改善參數調整之速率。LeCun 等人 [16] 於 1989 年成功將反向傳播應用於手寫字體的辨識，展示反向傳播之演算法可有效提升類神經網路模型的訓練速度。Hinton 等人 [17] 於 2006 年成功地發展多層隱藏層 (Hidden Layer) 的類神經網路模型，如圖 9 所示，多層隱藏層為模型提供了更高的抽象層次，進而提高了模型的預測能力，揭開深度學習的濫觴。




圖 9 深度類神經網路架構圖

模型訓練

在訓練類神經網路模型之前，需先定義整個類神經網路的架構，包含隱藏層的層數 (Hidden Layer)、每層的類神經數量 (Neuron Number)、訓練過程中數據集的採樣大小 (Batch Size)、激活函數 (Activation Function)、神經丟棄率 (Dropout Rate)、求解器 (Optimizer) 和每次訓練的迭代次數 (Epoch)，如圖 10 所示。本文建立模型的過程中，先嘗試不同隱藏層和神經元數量，最後提供一定範圍內的大量參數組合，如表 2 所示，並依照圖 11 之流程使用隨機搜尋法 (Random Search Method) 每次隨機找出 75 種參數組合進行模型訓練並以 4 次交叉驗證 (4-fold Cross-validation) 找到最佳的模型參數組合，詳細說明請參閱 [18]。




圖 10 預測沖刷深度模型架構圖

表 2 類神經網路模型參數組合

Hidden Layer	1, 2, 3
Neuron Number	15, 25, 35, 45, 55
Activation Function	softplus function,relu function
Dropout Rate	0.25,0.5
Batch Size	10,30,50,70,90
Optimizer	Adagrad
Epoch	200

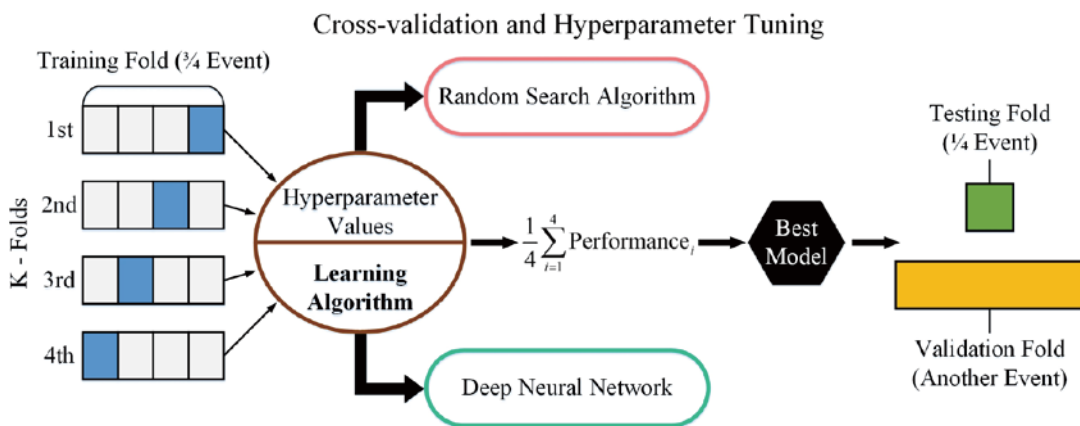


圖 11 訓練模型參數流程圖

由於輸入的特徵向量僅有水位和流速兩種，為了增加一些具有影響的特徵向量，因此將水位和流速分別進行一階微分做為訓練模型的特徵，利用兩種特徵向量組合以 1 分鐘 1 個資料點和前處理完成後的沖刷深度標籤進行分類模型訓練。經由本研究對於特徵向量組合進行探討過後，發現水位和流速以 1 分鐘 1 個資料點為特徵向量所建立的模型對於預測其他獨立事件的精準度較為穩定且準確，詳細說明請參閱^[18]。

沖刷深度預測

本文首先評估增加訓練樣本的事件數量能否有效提升預測模型的精準度，另外也驗證同一橋墩單一強降雨沖刷事件的訓練模型是否可延伸至其他強降雨沖刷事件。本文將較早發生之多場強降雨事件做為訓練樣本進行模型訓練，以預測較晚發生事件的沖刷深度。而每一次用來建立模型的事件，皆有四分之三的资料點做為訓練樣本，其他四分之一則做為測試資料

(Testing Data) 使用，其他較晚發生的事件則做為驗證資料 (Validation Data)。本文以最晚發生於 2018 年 1 月 6 日至 2018 年 1 月 14 日的強降雨事件作為驗證指標，評估訓練事件的數量對於預測事件的精準度，結果如圖 12 所示，不論是 2 個參數或是 4 個參數在 1 至 5 場事件所訓練的模型對於預測 2018/01/06-2018/01/14 事件的精準度皆有穩定上升的趨勢，約為 55% 至 60%，加入第 6 場事件進行訓練後其精準度則大幅提升 10%，接著再增加訓練樣本則沒有顯著提升的效果，最好的預測精準度大約為 70%。

預警系統需能準確掌握沖刷歷程。本文以預測 2017/06/09-2017/06/18 事件為例，將預測的分類結果轉換為深度並與實際沖刷歷程進行比較，發現兩者整體趨勢相當一致，如圖 13 所示。特別有趣的是在這場事件中沖刷發生的過程共有 3 個峰值，代表沖刷極為嚴重的時刻，這些時刻機器學習模型都可精準掌握，對未來發展預警系統有很重要的意涵。




圖 12 不同樣本數量訓練之模型對於 2018/01/06-2018/01/14 事件之預測精準度

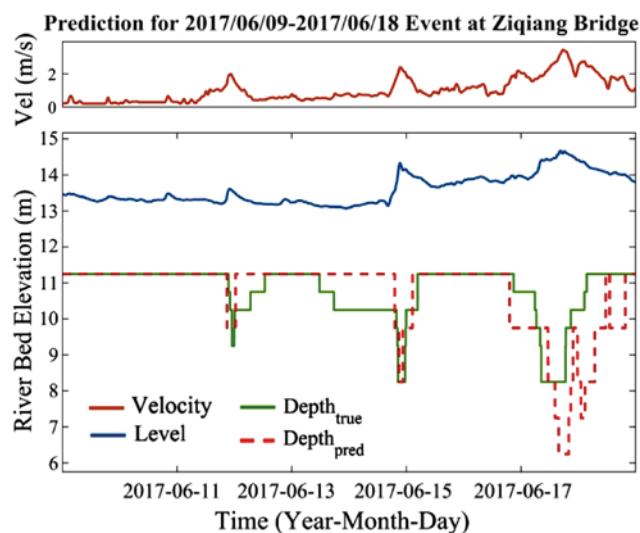


圖 13 預測自強大橋 2017/06/09-2017/06/18 事件之冲刷歷程

結論與展望

本文成功地運用監督式機器學習發展以現地水位和流速歷程為基礎的橋樑冲刷深度預測模型，也驗證單一強降雨冲刷事件的模型可延伸預測其他強降雨冲刷事件，在冲刷歷程預測也可精準掌握冲刷極為嚴重的時刻。本研究的成果對未來工程實務發展橋墩冲刷預警系統有重要的意涵，針對目前的成效，未來若能量化冲刷發生前河床和橋墩周圍土壤之初始狀態，並將橋墩尺寸、幾何形狀和河床土壤參數加入模型訓練的特徵向量，將有助於提高冲刷預測模型之精準度並延伸此方法泛用於其他橋墩之冲刷深度預測。

參考資料

- Shirole, A. M. and Holt, R. C. (1991), Planning for a comprehensive bridge safety assurance program. *Transportation Research Record*, 1290, 39-50.
- Melville, B. W. (1984). Live-bed scour at bridge piers. *Journal of Hydraulic Engineering*, 110(9), 1234-1247.
- Sheppard, D. M. and Miller, W. (2006), Live-bed local pier scour experiments. *Journal of Hydraulic Engineering*, 132(7), 635-642.
- Raudkivi, A. J. and Ettema, R. (1983), Clear-water scour at cylindrical piers. *Journal of Hydraulic Engineering*, 109(3), 338-350.
- Graf, W. H. and Istiarto, I. (2002), Flow pattern in the scour hole around a cylinder. *Journal of Hydraulic Research*, 40(1), 13-20.
- Breusers, H. N. C., Nicollet, G., and Shen, H. W. (1977), Local scour around cylindrical piers. *Journal of Hydraulic Research*, 15(3), 211-252.
- Bateni, S. M., Borghei, S. M., and Jeng, D. S. (2007), Neural network and neuro-fuzzy assessments for scour depth around bridge piers. *Engineering Applications of Artificial Intelligence*, 20(3), 401-414.
- Zounemat-Kermani, M., Beheshti, A.-A., Ataie-Ashtiani, B., and Sabbagh-Yazdi, S.-R. (2009), Estimation of current-induced scour depth around pile groups using neural network and adaptive neuro-fuzzy inference system. *Applied Soft Computing*, 9(2), 746-755.
- Choi, S. U. and Cheong, S. (2006). Prediction of local scour around bridge piers using artificial neural networks. *Journal of the American Water Resources Association*, 42(2), 487-494.
- Lee, T. L., Jeng, D. S., Zhang, G. H., and Hong, J. H. (2007), Neural network modeling for estimation of scour depth around bridge piers. *Journal of Hydrodynamics, Ser. B*, 19(3), 378-386.
- Toth, E. and Brandimarte, L. (2011), Prediction of local scour depth at bridge piers under clear-water and live-bed conditions: comparison of literature formulae and artificial neural networks. *Journal of Hydroinformatics*, 13(4), 812-824.
- 林詠彬、古孟晃、李柏翰、廖泰杉、吳志泓、陳倫奇 (2016)，橋梁冲刷防災雲端監測技術。科學發展月刊，519，28-33。
- Hebb, D.O. (1949), *The Organization of Behavior*, Wiley: New York, USA.
- Rosenblatt, F. (1958), The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986), Learning representations by back-propagating errors. *Nature*, 323(6088), 533.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D. (1989), Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1(4), 541-551.
- Hinton, G. E., Osindero, S., and Teh, Y. W. (2006), A fast learning algorithm for deep belief nets. *Neural Computation*, 18 (7), 1527-1554.
- 張世昇 (2018)，機器學習應用於橋梁冲刷監測系統之研究，碩士論文，國立臺灣大學工學院土木工程學系。