

基於特徵關係演算法創建線框模型之研究

吳栩賢¹ 謝佑明² 莊子毅^{3*}

摘要

點雲結構化為被廣泛研究之課題，現今演算法的適應性及成果的細緻度仍有改善的空間。本研究提出特徵關係 (Feature Relationship Algorithm, FRA) 演算法，FRA 能萃取物件幾何之頂角隅特徵點和邊緣特徵點，並自動重建特徵點間之連線關係，獲得可描述物件幾何之線框模型。相較於現有演算法，FRA 更適應物件之不同尺度和幾何變化，且具備高度自動化和細緻成果。初步驗證顯示，在模擬和點間距平均為 3 cm 的實際資料中，萃取出來的 VertexNode RMSE 分別可達 5 mm 與 4.3 cm，演算法能成功產製出完整的物件線框模型。本研究成果可望獲得提升不同幾何與不同尺度構件之點雲模型重建任務下的自動化及細緻程度。

關鍵詞：點雲特徵萃取演算法、特徵點連線關係、線框模型、自動化、幾何重建

1. 研究動機與目的

點雲資料隨著資訊科技技術的進步，已展現更加廣泛的應用需求，透過影像測繪與光達掃描儼然已成為新興空間資訊資料蒐集的主要途徑。使用光達掃描物件進行高精度建模與物件分割、分類與辨識，更是現行研究探討之任務，然而，離散的點雲在完成資料蒐集後，勢必需要進行點雲結構化以利後續加值應用。現行方法多是以規則或三角網格亦或是藉由深度學習神經網路和演算法架構解決資料結構化的問題。但當同一物件同時擁有不同種類、不同尺度之點特徵時，其演算法的適應性與成果細緻度皆有改善空間，並且在 Scan-to-BIM 任務往往需要人工進行輔助，以確保描述物件幾何之特徵點及其空間關係的正確性與準確性。除此之外，目前以深度學習演算法進行點雲物件分割分類以及模型重建之處理成果，在向量建置準確度上仍然面臨挑戰如圖 1，深度學習模型預測成果有多處於物空見不合理的向量建置。有鑒於此，本研究針對以上之弱點提出新研擬的特徵關係 (Feature

Relationship Algorithm, FRA) 演算法。FRA 為端至端的演算架構，針對點雲物件相對直覺地幾何特徵點進行偵測與分類，並自動重建特徵點連線關係。演算法除了可應用於點雲建模以重建物件線框向量模型外，在點雲物件偵測、分割分類處理，亦或描述點雲局部區域空間資訊權重上，皆具有正面的效益，進而可提升使後續點雲加值處理之演算效能。圖 2 展示以 FRA 演算法針對圓桌物件離散點雲 (灰色點) 萃取出之幾何特徵點 (紅色：頂角隅特徵點；藍色：邊緣特徵點)，並自動重建特徵點連線關係之線框向量模型成果。

現今各點雲演算法與人工智慧模型在進行三維點雲的非規則初始資料，勢必需要解決以下問題：

- (1) 點雲之於電腦是個不規則的三維陣列並沒有具備任何幾何資訊，改變陣列中的點雲排列也不會影響該點雲物件。
- (2) 點雲於物空間中需與彼此之間建立集合才具幾何意義，且點雲資料不具規則間距，導致各演算於讀取時不但須尋找局部鄰近點雲進行特徵萃取外，更需考量局部點雲於整體物件之相對關係。

¹ 國立臺灣科技大學營建工程系 碩士

² 國立臺灣科技大學營建工程系 副教授

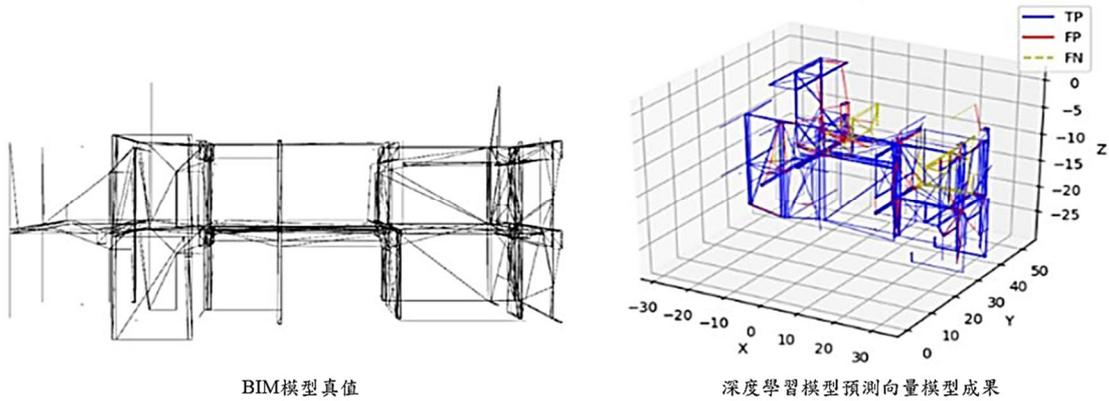
³ 國立陽明交通大學土木工程學系 助理教授

* 通訊作者, E-mail: jtychuang@nycu.edu.tw

收到日期：民國 111 年 10 月 01 日

修改日期：民國 111 年 10 月 28 日

接受日期：民國 111 年 11 月 16 日



BIM模型真值
 深度學習模型預測向量模型成果
 圖 1 深度學習重建向量模型之比較 (Chuang & Sung, 2021)

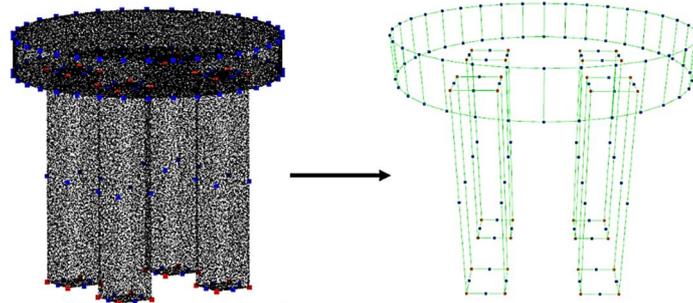


圖 2 FRA 演算成果之特徵點連線關係向量模型示意圖

(3) 點雲加上旋轉、位移與尺度變化後，雖然歐式坐標所產生的三維陣列內容會有所不同，但在各框架點雲物件演算需同時具備相因應變化與不變性。

點雲幾何特徵萃取方法的演進，可從較早期的半徑搜尋法 (Rabbani *et al.*, 2006)，依照不同點密度調整搜尋半徑大小，搜尋鄰近點之關係或是進行法向量計算後，搜尋半徑內點位法向量進行區域成長，並同時進行分類建立鄰近點關係，完成點雲結構化任務。亦或，透過二維網格將點雲物件投影至二維坐標系 (Priestnall *et al.*, 2000)，建立點群與對應網格關係進行資料結構化。另外，由不規則三角網格建立相鄰點關係 (Axelsson, 1999) 與八分樹演算法 (賴志恆, 2003) 則是將各點雲不斷進行三維網格切割直至每一點位都有相對應之網格而完成點雲結構化程序。同時，亦具有透過混合策略之方法，如先網格化後搭配霍夫轉換 (黃國彥, 2005)，藉由點雲參數化至各網格空間進行結構化。近年，相關研究發展運用深度學習技術於三維點雲的處理，如 PointNet (Qi *et al.*, 2017a)，其演算架構是透過輸入多層感知器前預先訓練旋轉矩陣於 T-Net 層，解決

旋轉不變性再應用最大池化解決無序性。但此設計除了易造成幾何資訊損失外，多層感知器資訊無法有效的前後交換導致有損訓練成果。進階版的 PointNet++ (Qi *et al.*, 2017b) 則是基於上一代的骨架下設計了自動編碼網路層 (encoder-decoder) 進而學習點雲特徵，擁有更加大小尺度幾何特徵資訊於前後網路層交換參數，改善過度損失因大特徵而被忽略的小特徵點雲資訊。同時，隨著算力極限的成長使得有更多演算法可跨領域進行輔助，而發展出跨世代神經網路 CNN 模型輔助解決點雲結構化 (Chuang & Sung, 2021)，或是先透過點雲物件二維影像來進行物件分割模型預測，再進行與三維點雲特徵之匹配來解決點雲結構化問題。

除此之外，隨著自動駕駛技術突破及市場需求增加，近期研究普遍以深度學習神經網路為主軸，但此類架構在數學演算上相對無法依據角點的物空間資訊進行探討與解釋。因此偵測的點雲特徵角點往往不同於人類視覺認定。相反地，基於機器學習或演算策略所組成的處理架構，可相對地專注於特定目標特徵以進行特徵角點萃取，萃取成果也相對地直覺與直接。另一方面，點雲物件模型重建與

特徵角點偵測成果具有直接的相對關係，特徵角點彼此要能夠有足夠的幾何資訊供使用者勾勒出正確的重建範圍，亦或建立正確的模型關係。然而於現地點雲掃描後進行點雲模型重製的探討相對甚少，點雲模型化對於深度學習訓練的成果與 Scan-to-BIM 應用皆有值得探討與精進之空間。

有鑑於此，本研究提出特徵關係 (Feature Relationship Algorithm, FRA) 演算法，由離散點雲中透過研究中提出的掃描球 (ScanningBall) 建構局部特徵點描述，在考量應用所需的最小空間解析度、資料品質與點密度之參數配置下，可避免忽略同一物件中不同尺度之幾何變化，萃取出可描述物件幾何之頂角隅特徵點 (VertexNode) 與邊緣特徵點 (EdgeNode)。特徵點可繼承點雲之幾何資訊包含掃描球中心點坐標、特徵點種類、點位編號、局部

幾何參數，以及研究研擬混合式評分指標 SI (ScanningBall Index) 為各萃取特徵點進行穩健度檢核計算。除此之外，FRA 演算法提出三種特徵點自動連線策略，重建特徵點間之連線關係以進而獲得可描述物件幾何之線框模型，不管是在 Scan-to-BIM 或是物件點雲模型重建等應用皆具有高度的應用潛力。

2. 研究方法與架構

圖 3 展示由點雲資料建置向量模型之兩階段處理架構。第一階段的 FRA 特徵點萃取演算包含前處理階段與掃描物件獲得局部幾何資訊、特徵萃取與特徵點分類。第二階段的 FRA 特徵點模型重建演算則進行特徵點連線關係向量化之演算。

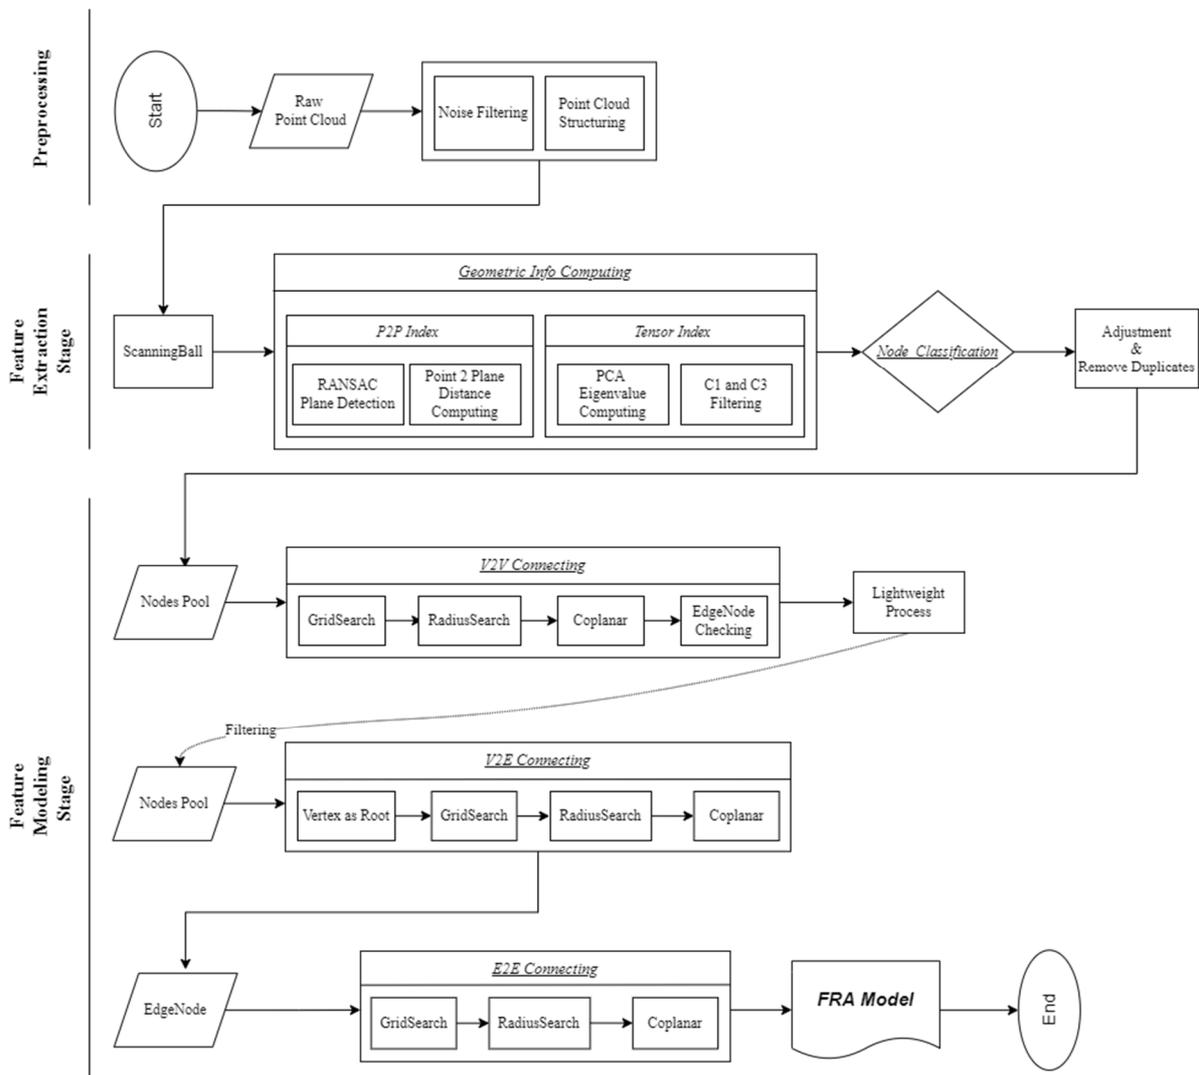


圖 3 FRA 細部演算流程

針對蒐集到的物件點雲首先進行預處理程序，排除物件雜訊並使用八分樹簡易結構化後進行第一階段 FRA 特徵點萃取演算，其中，透過研擬的掃描球 (ScanningBall)，演算法可以依據物件空間解析度之需求自適應地調整 ScanningBall 的半徑，基於框選框選的局部點雲計算所需的幾何資訊，並完成該點位的特徵萃取與分類。研究中對於物件特徵點定義為兩種類別，第一類為頂角隅特徵點，為敘述三面以上相交之特徵點；第二類為邊緣特徵點敘述兩面相交之特徵點。同時，第二階段 FRA 特徵點模型重建演算則針對萃取出頂角隅特徵點 (VertexNode) 與邊緣特徵點 (EdgeNode) 透過提出的 VertexNode to VertexNode (V2V)、VertexNode to EdgeNode (V2E) 以及 EdgeNode to EdgeNode (E2E) 三種連線策略，重建特徵點間彼此的連線關係，進而獲得物件的線框向量模型。

2.1 FRA 演算架構設計

本研究參考實際資料處理面臨之課題進行演算法開發，目標為二，本研究提出的 FRA 演算法除了可透過點雲幾何資訊進行頂角隅特徵點 (VertexNode) 及邊緣特徵點 (EdgeNode) 之萃取外，同時可自動重建特徵點之間的連線關係，實現物件點雲的線框向量模型重建任務。然而，有別於目前已知的特徵點描述，大多僅基於周圍鄰近點變化作為點特徵之間的區別，本研究提出掃描球 (ScanningBall) 的概念，以使用者需求的物空間解析度與點雲平均點間距作為設置掃描球半徑之依據，建構每個點位的球形單元，並以球型單元內的點雲計算其特徵描述參數。其中，描述參數包含掃描球內的點位至物件平面距離估計、球形張量編碼指標、VertexNode 或 EdgeNode 間的連線關係以及連線數量的類別屬性。因此，研究中的特徵萃取程序可透過掃描球針對點雲進行迭代掃描以獲得不同尺度、不同空間幾何特色之物件特徵點。萃取出來的特徵點類別包含研究中提出之 VertexNode、EdgeNode 以及各自的點特徵連線關係 (Connection)。VertexNode 用於描述三面以上相交之特徵點而 EdgeNode 描述兩面相交或曲面邊緣特徵

點可用於反映物件邊緣的幾何變化，連結關係則記錄該特徵點應具有的連接關係對象與個數。藉由此三種類別資訊進而生成點特徵連線關係，建置特徵向量模型。

FRA 演算框架包含點雲特徵點萃取與點雲向量化兩個主要處理程序，考量演算法開發往往必須考量計算複雜度、記憶體配置、參數維度與設定、訓練樣本數量與多樣性以及對於不同資料品質處理之穩健度，因此研究中將著重於 (1)在特徵點之描述，透過引入多元區域特徵以及旋轉與尺度不變特性完成點雲結構化；(2)在維持萃取點分類準確率的前提下，降低掃描球框選次數、藉以降低程式計算負擔；(3)提升演算法處理不同點雲場景、點雲尺度、點雲資料品質之自適應性。意即，研究提出的特徵萃取策略將注重於特徵點描述能力及建構特徵點間連線關係向量演算之適用性。

2.1.1 點雲資料前處理

前處理任務包含移除點雲雜訊與簡易點雲結構化，而對於雜訊移除本研究採取鄰近點數判定法，透過給定之半徑生成的圓球體框選檢查點位周圍符合半徑內的所有點位，若圓球體內點數統計低於閾值則該檢查點位則被認定為雜訊並移除。此辦法可針對具有一定精度品質之點雲進行稀疏雜訊移除之任務。另一方面，研究中以八分樹演算實現簡易點雲結構化，然而，八分樹在本研究中僅演算一個階層，並未向下搜尋以達到每一點位都擁有一個分支與網格，此部分的結構化僅切割點雲物件於物空間中八個網格，降低過多的演算負擔。意即，八分樹點雲結構化僅是為了提高後續掃描球處理時的搜尋效率並降低演算負擔。

2.1.2 FRA 特徵點萃取演算

演算內容包含點雲資料前處理與建構掃描點雲物件之幾何資訊，考量點雲資料前處理可協助資料搜尋之演算效率。完成前處理後，FRA 演算法將依據使用者設定之物空間解析度與物件點雲之點間距，進行掃描球之掃描半徑配置，並依據物空間解析度之採樣間距完成掃描程序獲取物件幾何資

訊後，方可分類出物件點雲的 VertexNode 與 EdgeNode，並將此兩類特徵點引入 FRA 特徵點模型重建演算之特徵點向量化處理。

FRA 使用掃描球掃描點雲物件，目的為匡選局部點雲後計算其空間資訊，匡選示意圖如圖 4(a)、4(c)，其執行過程與半徑搜尋法相仿，但不同之處在於蒐集的幾何幾訊及應用目的。掃描球進行物件掃描之過程將進行兩大幾何資訊搜集，分別為透過 RANSAC 偵測掃描球內局部點雲之平面資訊成果示意圖如圖 4(b)、4(d)，以及使用 PCA 分析局部點雲的分布狀況之張量指標。之後，基於以上建構之幾何資訊執行特徵點萃取與特徵點分類判別。其中，考量處理實務資料時資料品質的多樣性，FRA 掃描球之半徑配置將直接影響演算法之應用適應與適應性，不同半徑配置將與萃取成果品質環環相扣。依據文獻 (張中豪, 2013) 之建議，應將掃描球半徑設置為被掃描點雲物件平均點間距的 4.5 倍。此配置不僅能有最穩定的張量計算與張量編碼，對於雜訊亦有最佳的容許度。然而，本研究的半徑設置需顧及掃描球內平面偵測的穩定性，同時考量實務處理時物件的多樣性且資料幾何可能具有不同尺度大小之變化。因此研究中的半徑設置首先考慮資料品質進行自適應調整，同時掃描球的掃描間距則可依據使用者所需的成果空間解析度進行設置，同時確保掃描球之間的資料重疊。透過掃描間距的配置，除了可減少針對點雲資料的掃描次數，降低演算負擔，亦可確保在使用者成果空間解析度的前提下，不會因平滑作用而忽略小尺度的幾何特徵變化。

2.1.3 FRA 特徵點萃取與分類指標

待完成點雲掃描及獲取掃描球內部幾何資訊

計算後，FRA 則基於點位之掃描球將萃取之特徵點分類為 VertexNode 與 EdgeNode，並計算特徵點分類穩健性。其中，分類穩健性評分是考量掃描球中心點位與內部偵測平面之空間關係以及張量編碼指標資訊之評分機制，由研究中提出由 SP2P 與 ST 系數建構之掃描球指標 (ScanningBall Index, SI) 呈現，其中 SP2P 代表特徵點於物空間之貼合度也能確立特徵點是否位於空間幾何變化處。ST 則是針對掃描球內之張量編碼特徵強度指標，提出的自適應之純量評估指標。透過此兩個系數，研究中提出掃描球指標 SI，其考量了掃描球內部中心點至偵測成果平面距離以及其張量編碼指標進行等比權重評分，可反應出特徵點在點雲物件上的貼合度、幾何特徵描述強度的綜合性評估。在理想的情況下，高精度點雲勢必具有高分的 SI 指標，反之雜訊較多的點雲 SI 指標整體勢必相較低分。SI 指標為純量指標，最大分數為 1 最小為 0，分數越大者亦即此特徵點萃取之信心指數越高，其角點位置於物空間幾何描述越有可能具有本研究提出之頂角隅或邊緣特徵點。

2.1.4 FRA 特徵點模型重建演算

特徵點模型重建演算策略乃基於第一階段萃取的 VertexNode 與 EdgeNode 為基石，建立連線關係向量。FRA 提出三種特徵點的連線策略，即 VertexNode to VertexNode (V2V)、VertexNode to EdgeNode (V2E) 以及 EdgeNode to EdgeNode (E2E) 演算。這三種連線關係在 FRA 演算框架中有著固定的先後順序，優先執行 V2V 演算接續 V2E 演算最後執行 E2E 演算。三種連線關係完整的呈現了物空間點雲物件的幾何連線關係可能性。

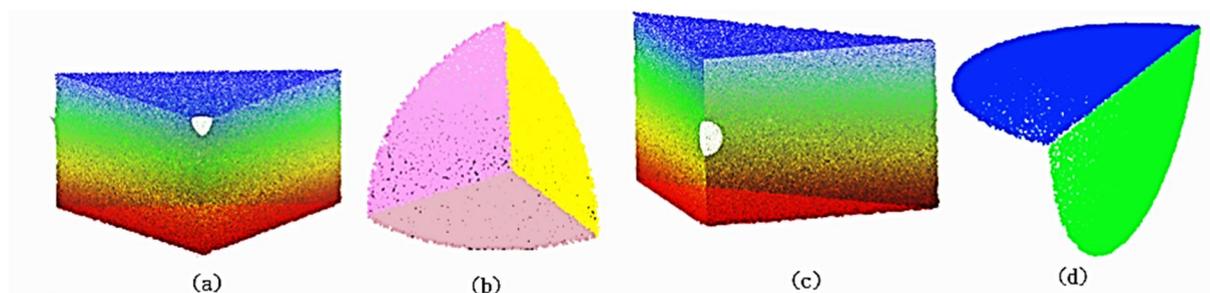


圖 4 掃描球框選局部點雲示意圖與局部點雲平面偵測成果圖

V2V 的連線策略程序分別包含八分樹網格搜尋、半徑搜尋分群、兩特徵點平面方程式共面條件檢核、兩點連線線方程式上是否有 EdgeNode 存在以及輕量化程序。第一個八分樹網格搜尋僅是為了降低演算負擔排除於物空間並無任何點雲相連的特徵點。第二步驟半徑搜尋演算，會將迭代檢查中的 VertexNode 對其餘 VertexNode 進行點至點距離計算，並且依據點至點的向量變化大小進行分組，以便後續檢查時避免重複連線。第三共面條件檢核是由掃描球計算幾何資訊時，保留 RANSAC 偵測平面的面方程式，檢查 VertexNode 與各分組內的 VertexNode 是否有著相同的平面方程式，若符合有則可向下接續第四步演算，反之則跳過繼續檢查其餘 VertexNode。第四執行為 EdgeNodeChecking 則是檢查兩 VertexNode 連線線方程式上是否存在 EdgeNode，假設有均勻分布存在於兩 VertexNode 之間且每 EdgeNode 間距在閾值內，則可代表物空間中兩 VertexNode 之間確實存在著連線關係。最後在確立存在 V2V 連線關係後將執行輕量化演算，將兩 VertexNode 連線線方程式上之所有 EdgeNode 刪除，只留下最接近線段中點之 EdgeNode 僅此用於代表幾何描述。輕量化演算意義在於確認物空間中的兩個 VertexNode 間存在 V2V 連線關係後，將分布於兩 VertexNode 之間的 EdgeNode 刪減留下最接近兩 VertexNode 中點的 EdgeNode 來描述邊緣幾何，除了增加成果資料的簡潔性更減少後續其餘連線關係建置時出錯的可能性。完成以上兩階段檢查後則可確立物件點雲的 V2V 連線關係。

V2E 連線策略之狀況可適用於處理因物件點雲蒐集不完全導致在幾何上未能取樣到 VertexNode，或者點雲物件在物空間中呈現閉合幾何的狀況，例如圓柱體，並非由 VertexNode 環繞而成，而 V2E 策略可完成此類物件幾何之特徵點連線。如上所述，V2E 演算接續在 V2V 程序之後，其原因為 V2V、V2E 及 E2E 三類演算皆共用待連線的候選特徵點群，透過各階段處理後賦予之特徵點標籤，後續演算可針對剩餘特徵點進行處理。

E2E 連線策略之目的為完成曲面點雲物件連線向量化或者處理僅蒐集到物件部分點雲之狀況，針

對萃取出 EdgeNode 但缺乏 VertexNode 之幾何之場景進行向量化。圖 5 呈現三個連線策略可處理之資料狀況示意圖。

3. 測試驗證

為驗證 FRA 演算法之可行性與成效，研究中運用 BIM 模型產製之模擬點雲與實際點雲資料進行測試。模擬點雲測試著重於評估演算法在不同幾何特徵描述點位、不同尺度特徵點萃取，執行策略可行性測試。並利用特徵萃取點位與 BIM 角點真值之均方根誤差 (Root Mean Square Error, RMSE) 與穩健度評分指標 SI 指標進行量化評估。本研究使用 Revit 軟體繪製銳角三角錐體、圓錐體、正八邊柱體與圓柱體呈現各式基礎幾何物件，為求演算架構之自適性調整可行性。最後測試 FRA 演算架構於模擬室內、室外 BIM 模型場景之萃取成果驗證。另一方面，實際資料測試乃針對國立成功大學圖書館部分外牆點雲進行測試驗證與分析。

3.1 基本幾何物件模擬資料測試

模擬測試中針對可構成個是物件之基本幾何特徵進行處理，展示對於各式形狀物件之可行性。圖 6 展示測試中處理之立方體、三角錐、圓錐、八邊柱體與圓柱體之點雲、萃取出之 VertexNode (紅色點) 及 EdgeNode (藍色點)，以及由特徵點關係 (綠色) 重建的物件線框向量模型。

表 1 呈現物件萃取出之 VertexNode 與 BIM 模型之角點真值位置所計算之 RMSE，以及描述物件特徵點分類穩健性的掃描球指標 SI。

立方體點雲尺寸為 10 cm×10 cm×10 cm，包含點間距 1 mm 共 60,000 點之理想無雜訊點雲物件。三角錐之此測試主要為檢視 FRA 演算法在物件幾何具有平面夾角小於 90 度下之表現。其中三角錐體底部為邊長為 0.5 m 之正三角形，而側邊邊長為 1 m。另一方面，圓錐體測試為以底部直徑為 1 m、錐體高 1 m 之幾何進行曲面圓錐體之 VertexNode 萃取測試。研究中將 RANSAC 距離閾值降低使平面偵測時將曲面微分為數個均等平面，可確實萃取出圓錐之 VertexNode。同時，也驗證

V2E 與 E2E 兩種連線策略同時進行之可行性。除此之外，八邊柱體物件是由邊長 0.5 m 之正八邊形與柱高 1 m 構成，透過測試可驗證 FRA 在處理物件幾何具有平面夾角為鈍角之可行性。最後，值得注意的是底部直徑為兩公尺(m) 且柱高為兩公尺(m) 之圓柱體測試，透過測試可驗證 FRA 演算得 E2E 連線策略處理曲面物件之效益。除了圖 4 之視覺化成果外，表 1 之量化指標顯示即使是處理具有不同尺度的物件，FRA 演算法對於 VertexNode 的萃取精度可獲得 3 至 6 mm，同時在特徵點分類之 SI 皆可達到約 0.8 的等級，顯示 FRA 演算法之成效。

3.2 多尺度室內空間模擬資料測試

研究中運用 BIM 室內模型產製之點雲進行 FRA 演算法於多尺度物件點雲幾何模型重建任務，其中室內物件包含圓桌、沙發、方桌與內部牆體。測試成果顯示，FRA 演算架構能夠完整搜尋室內物件並實現特徵點萃取任務，同時，特徵點連線策略可針對各物件逐一完成計算，可針對不同尺度的物件確實重建描述物件幾何的線框向量模型。其中，整體空間的 VertexNode 之 RMSE 約 5 mm，SI 平均指標高於 0.8。圖 7 呈現重建物件的視覺化成果，其中紅色點為 VertexNode，藍色點為 EdgeNode，綠色線段代表特徵點連線關係。

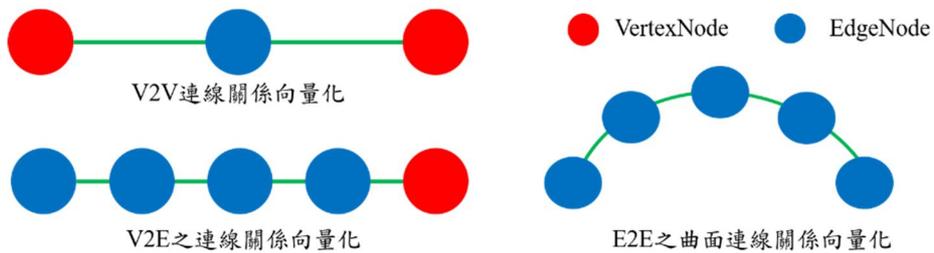


圖 5 FRA 連線策略示意圖

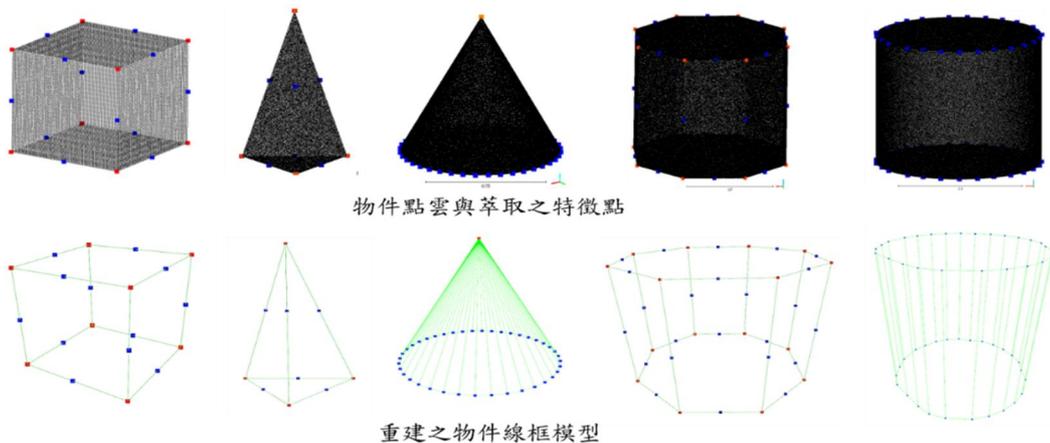


圖 6 FRA 模擬測試之視覺化成果

表 1 FRA 模擬測試精度指標

	特徵點種類	RMSE	SI
立方體	VertexNode	0.0031m	0.96
	EdgeNode	N/A	0.95
三角錐	VertexNode	0.0051m	0.86
	EdgeNode	N/A	0.881
圓錐	VertexNode	0.0042m	0.901
	EdgeNode	N/A	0.96
八邊柱體	VertexNode	0.006m	0.87
	EdgeNode	N/A	0.91
圓柱體	VertexNode	N/A	N/A
	EdgeNode	N/A	0.79

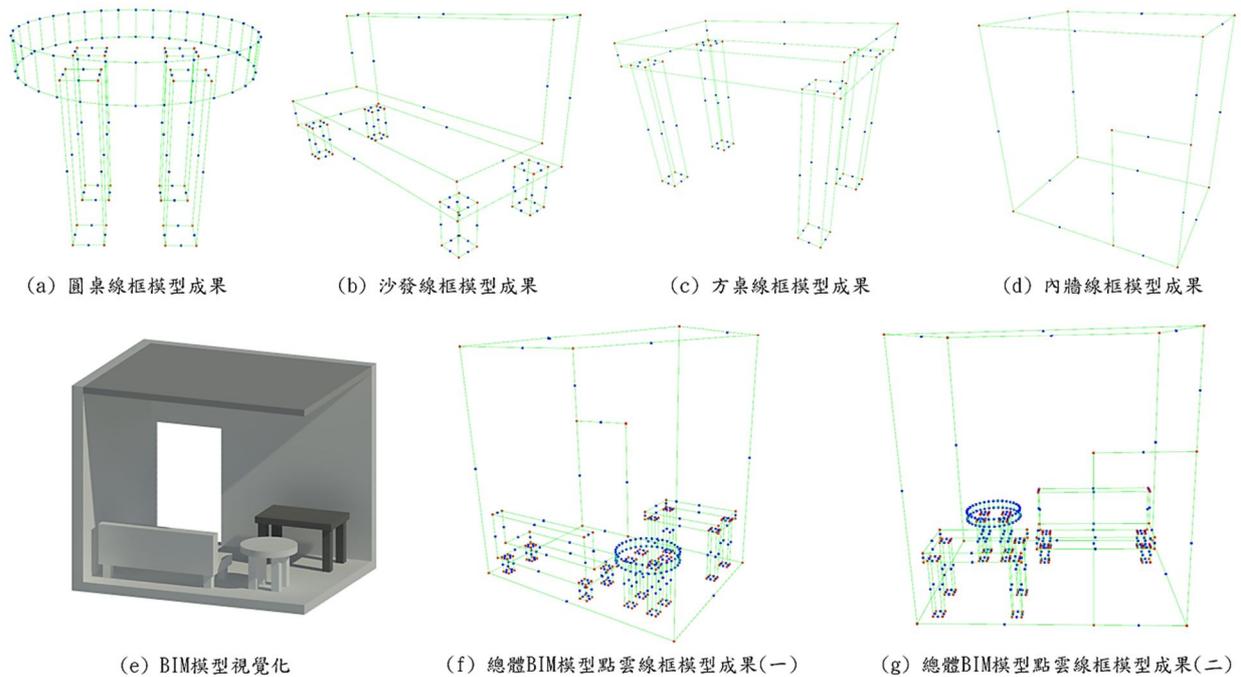


圖 7 多尺度室內物件重建模型之視覺化成果

然而，FRA 演算法在內部牆體時，由於內部牆體弱缺乏外部點雲則會失去平面轉折之幾何特徵，將造成特徵點的萃取得分過低。為求針對門框點雲可完成特徵點萃取，因此在該區域將部分外部牆體一同納入計算程序。但由於本研究採用混合式得分指標判別，混合指標之優點在於現地點雲掃描並非完整測繪時，使用者可依據測試資料之完整性對 SI 指標權重進行微調，使得部分掃描不完整之特徵點都能完成使用者需求完成萃取。此外，值得一提的是，在圓桌、沙發與方桌三者的支撐腳與上方物件平面連接處，VertexNode 與上方 EdgeNode 並無執行 V2E 演算，主要原因為 V2E 演算條件需要在 VertexNode 與第一個候選 EdgeNode 之連線共線式上需有複數個 EdgeNode，才足以觸發連線策略。至於內部牆體特徵點連線建置時，半徑搜尋的閥值則可調整至公尺 (m) 等級，顯示 FRA 演算法的參數適應性並足以勝任不同尺度物件之線框模型重建任務。

3.3 LoD3 房屋外觀模擬資料測試

為驗證 FRA 演算法可重建 LoD3 等級之建物模型，測試模型包含山形屋頂、外部冷氣壓縮機、

門框與窗框，特徵尺度由公分 (cm) 等級的冷氣壓縮機至公尺 (m) 等級的屋頂、房屋牆體。此外，門、窗框之邊緣特徵點僅由單平面構成並僅具有 EdgeNode 特徵，可用以考驗特徵萃取演算自適性。圖 8 展示 LoD3 房屋線框向量模型重建之視覺化成果。其中，運用 BIM 物件標籤將點雲渲染成不同顏色以代表各物件，並在 VertexNode 的 RMSE 與 SI 量化指標上，分別達到約 8 mm 及 0.85。透過本測試可驗證應用 FRA 演算法於房屋主建物結構以及側邊細節特徵模型重建之成效，顯示 FRA 演算架構具有輔助自動化建置 LoD3 房屋模型或重建屋頂面細部幾何任務之效益。

3.4 實際點雲資料測試

本測試使用成大圖書館局部外牆之點雲以精進探討 FRA 演算架構處理點雲具有雜訊且掃描不完全時之成效。測試中需基於 SI 指標之適應性進行參數調整，以將不完整掃描之平面邊緣特徵點萃取出，並別除非雜訊之相對低密度平面邊緣特徵點，以萃取出可靠的物件特徵點。如圖 9 所示，本測試針對局部外牆點雲並濾除非結構構建之點雲進行測試。

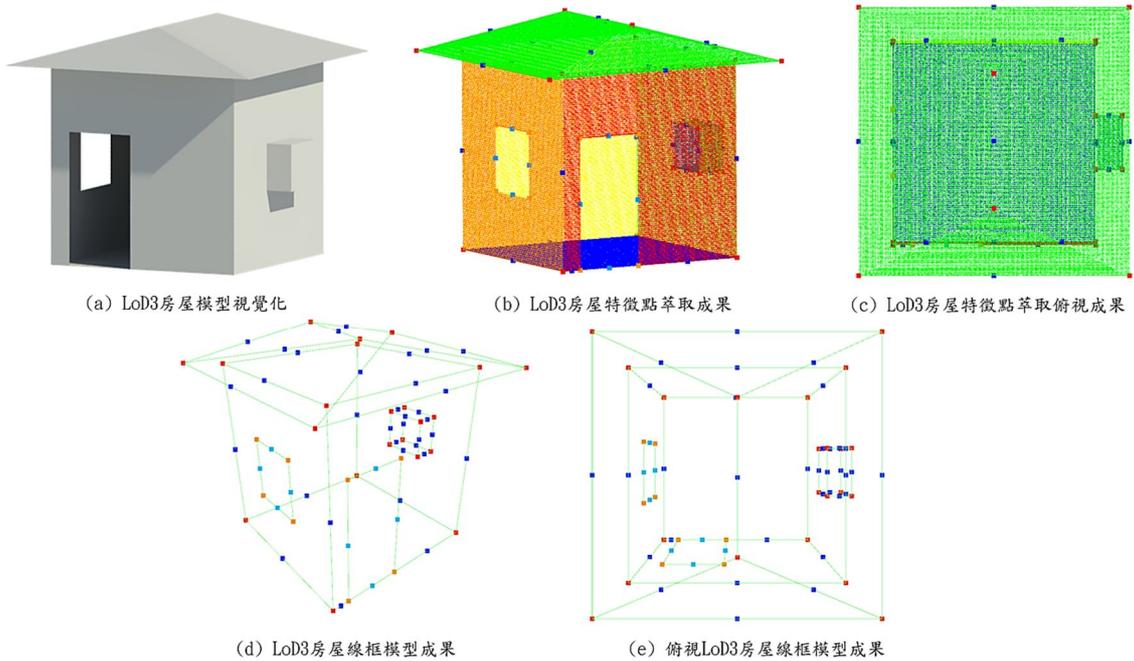


圖 8 線框向量模型重建之視覺化成果

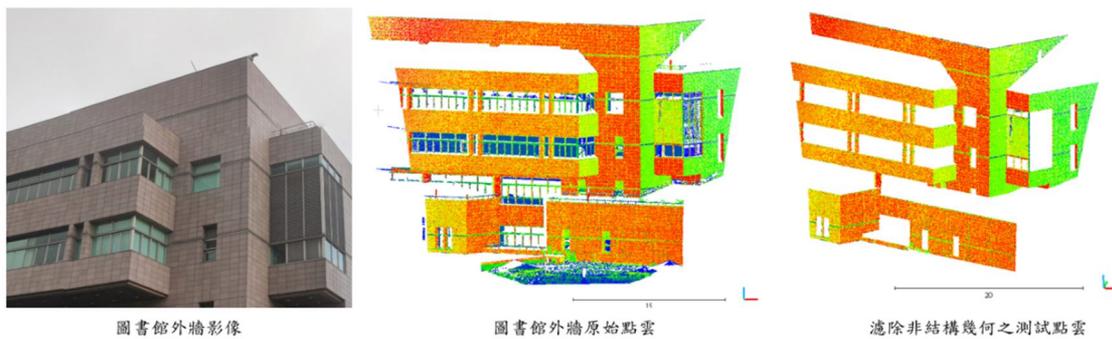
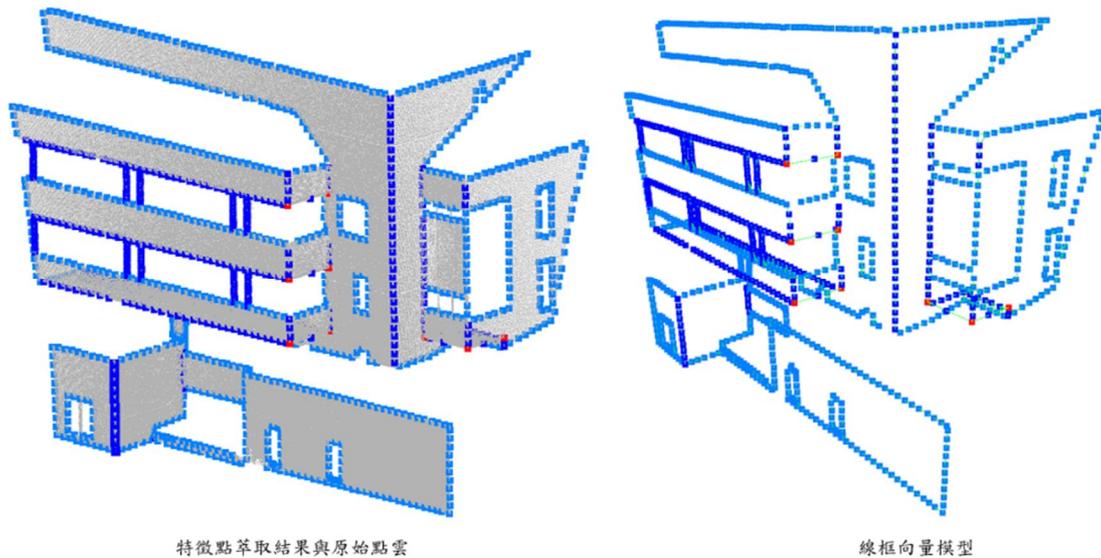


圖 9 實際點雲測試資料

由於掃描作業產生的點雲資料特性，本資料在垂直牆面之點間距約為 31 mm，但平行地面之牆面點間距約 100 mm。如此將造成兩面相交處之掃描球內部點密度不平均，並導致 RANSAC 偵測結果不穩定。因此，本次實驗掃描球半徑配置約為 200 mm 進行實驗，同時因為平面邊緣點特徵萃取僅具有 SI 指標中的張量編碼指標，因此邊緣特徵點的 SI 值並訂低於兩面相交之邊緣特徵點。研究中依據每一特徵點之 SI 得分轉換成 RGB 色彩輔助於視覺化呈現能夠一目了然每一特徵點之穩健性，區分出深藍色之高分邊緣特徵點與淺藍色之低得分邊緣特徵點。FRA 產製之線框向量模型視覺化成果如圖 10 所示。

檢視演算成果中，有幾處顯現出本演算法之侷

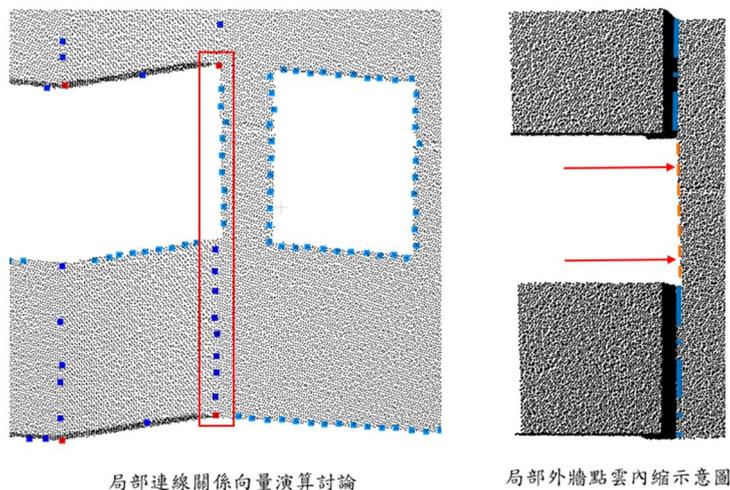
限，以下將逐一進行說明與分析。首先是在執行 V2V 演算時原先預設如圖 11 左圖紅框處會執行 V2V 連線並且能完成輕量化呈現，但由於實際點雲因拍攝視角緣故，部分點雲牆體內縮導致如圖 11 右圖的橘虛線邊緣線點雲不在兩點連線深藍虛線共線上，導致特徵萃取的淺藍色 EdgeNode 幾乎不在兩 VertexNode 之間的 EdgeNodeChecking 連線共線，若放大 EdgeNodeChecking 兩點連線共線檢核閥值，則捨去了局部牆體測繪出內縮的原始點雲幾何特徵，有失資料之特徵萃取解析度並且違背呈現真實原始資料的面貌，研究中不放棄 EdgeNodeChecking 閥值進行演算，因此分別進行兩次 V2E 演算與進行 E2E 演算完成封閉線框模型向量化建置。



特徵點萃取結果與原始點雲

線框向量模型

圖 10 線框向量模型視覺化成果



局部連線關係向量演算討論

局部外牆點雲內縮示意圖

圖 11 演算成果討論

另一演算侷限為，線框模型部分連線不完全處如圖 12 紅圈處，原因包含測繪不全導致點密度不穩定、測繪原始點雲部分點雲破碎與特徵萃取使用之掃描球半徑尺寸較大使得線框模型成果之物空間解析度較低影響。其中為求單平面邊緣特徵點能順利連線部分封閉線框模型，放大 E2E 連線演算之半徑搜尋閾值，產生與先前討論之部分單平面邊緣特徵點或邊緣特徵點將產生局部斜線連線，此課題在研究中不視為演算錯誤。

4. 結論

針對 FRA 特徵萃取演算中可歸納出幾項優缺點，首先對於同一點雲物件下不同尺度大小的特徵點，本研究使用掃描球框選局部點雲皆能成功萃取

特徵點。本研究 FRA 演算架構萃取出之特徵點位符合物空間幾何描述，對於建模、前處理有著更加直觀的利用價值。經過實際點雲測試後，FRA 演算程序一對於高雜訊、不穩定點間距交面、物件表面紋理皆會造成特徵點點位偏差或是 SI 指標得分較低，實驗成果也證實 SI 混合得分指標有助於處理測繪不完全之點雲特徵萃取外，更可以提供使用者每一特徵點之穩健度評分。FRA 演算程序二則會因應不同資料解析度與品質，產生不同的連線向量不連續，此課題為閾值設定與使用者之物空間解析度兩者權衡下之課題，未來若能加入前處理資料標記與機器學習模型導入預測參數配置，相信能大幅提升複雜場景之適應性。

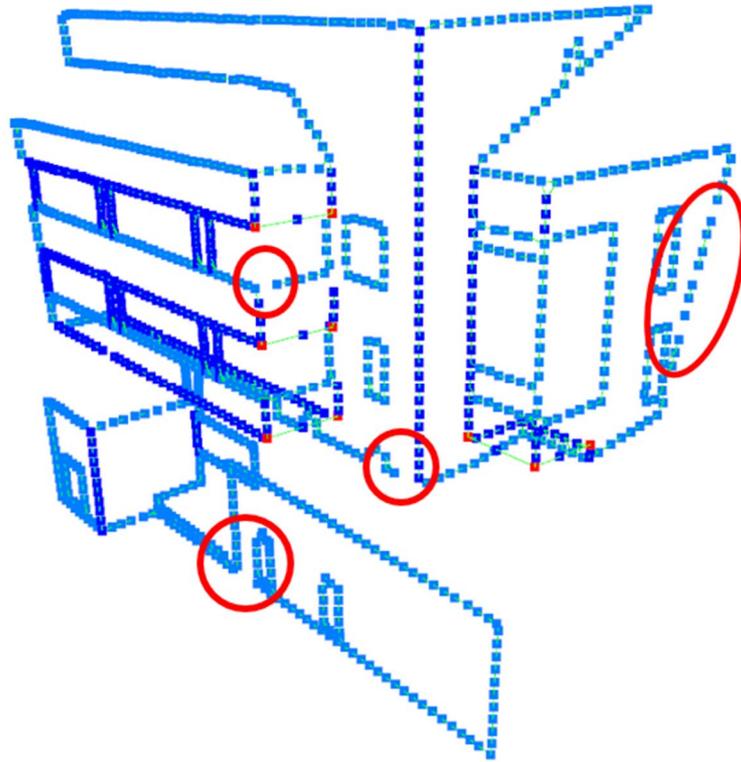


圖 12 線框模型連線不全標記示意圖

參考文獻

- 賴志恆，2003。雷射掃描點雲資料八分樹結構化之研究，國立成功大學測量工程學系碩士論文。 [Lai, C.H., 2003. Organizing laser scanning point cloud data based on octree structure, Master Thesis, National Cheng Kung University, Taiwan, ROC. (in Chinese)]
- 黃國彥，2005。結合三維網格及迭代式霍夫轉換進行光達點雲資料結構化處理，國立臺灣大學土木工程學系碩士論文。 [Huang, K.Y., 2005. Structuralization of LiDAR point cloud by combining 3-D grid structure and iterated hough transform, Master Thesis, National Taiwan University, Taiwan, ROC. (in Chinese)]
- 張中豪，2013。自適性張量分析應用於光達點雲特徵萃取，國立臺灣大學土木工程學系碩士論文。 [Chang, C.H., 2013. Feature extraction of LiDAR point clouds based on adaptive tensor analysis, Master Thesis, National Taiwan University, Taiwan, ROC. (in Chinese)]
- Axelsson, P., 1999. Processing of laser scanner data - Algorithms and applications, *ISPRS Journal of Photogrammetry and Remote Sensing*, 54: 138-147, DOI: 10.1016/S0924-2716(99)00008-8.
- Chuang, T.Y., and Sung, C.C., 2021. Learning-guided point cloud vectorization for building component modeling, *Automation in Construction*, 132: 103978, DOI: 10.1016/j.autcon.2021.103978.
- Priestnall, G., Jaafar, J., and Duncan, A., 2000. Extracting urban features from LiDAR digital surface models, *Computers, Environment and Urban Systems*, 24: 65-78, DOI: 10.1016/S0198-9715(99)00047-2.
- Qi, C.R., Su, H., Mo, K., and Guibas, L.J., 2017a. Pointnet: Deep learning on point sets for 3D classification and segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA pp. 77-85, DOI: 10.1109/CVPR.2017.16.
- Qi, C.R., Yi, L., Su, H., and Guibas, L.J., 2017b. Pointnet++: Deep hierarchical feature learning on

- point sets in a metric space, Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA, pp. 5099-5108.
- Rabbani, T., Van Den Heuvel, F.A., and Vosselmann, G., 2006. Segmentation of point clouds using smoothness constraint, Proceedings of the International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Dresden, Germany, Vol.36, pp.248-253.

A Study on Feature Relationship Algorithm for Wireframe Modeling

Hui-Yin Ng¹ Yo-Ming Hsieh² Tzu-Yi Chuang^{3*}

Abstract

The study proposes a feature relationship algorithm (FRA) to establish wireframe models from object point clouds. FRA applies a scanning ball to explore local point cloud geometry for determining vertex and edge feature points and further reforms the spatial connections to reconstruct the wireframe model of the object automatically. Experiments on different variables were conducted to show insights into the effectiveness of various point quality for FRA parameter configuration. Validations on data acquired from simulated and actual scans showed promising results, in which the RMSE of the model vertices achieved 5 mm in BIM-to-point cloud cases, and the RMSE of the real point cloud with a point interval of 3 cm data case comes to 4.3 cm. The FRA framework is expected to improve the automated level of point cloud modeling.

Keywords: Point Cloud Feature Extraction, Feature Connection, Wireframe Model, Automation, Model Reconstruction

¹ Master, Department of Civil and Construction Engineering,
National Taiwan University of Science and Technology

² Associate Professor, Department of Civil and Construction Engineering,
National Taiwan University of Science and Technology

³ Assistant Professor, Department of Civil Engineering, National Yang Ming Chiao Tung University

* Corresponding Author, E-mail: jyechuang@nycu.edu.tw

Received Date: Oct. 01, 2022

Revised Date: Oct. 28, 2022

Accepted Date: Nov.16, 2022