Allineamento di nuvole dense di punti con ICP pesato tramite segmentazione basata su eigenfeature

Marica Franzini^{1[0000-0002-3921-5178]}, Vittorio Casella^{1[0000-0003-2086-7931]} e Ambrogio Maria Manzino^{2[0000-0001-9237-3047]}

¹ Università degli Studi di Pavia, (marica.franzini; vittorio.casella)@unipv.it
² Politecnico di Torino, ambrogio.manzino@formerfaculty.polito.it

Abstract. L'allineamento delle nuvole di punti tramite ICP è ancora oggi oggetto di ricerca soprattutto in fotogrammetria da drone dove le superfici considerate, si pensi ad esempio al rilievo di campi coltivati, non permettono sempre la convergenza dell'algoritmo. Gli autori propongono in questo articolo l'utilizzo di una struttura a doppia densità (bassa in aree pianeggianti e alta in zone con discontinuità) per favorire la risoluzione del problema. La costruzione della struttura è completamente automatica e si avvale delle moderne tecniche di Machine Learning. I risultati ottenuti mostrano come l'approccio proposto porti a ottimi risultati anche con nuvole significativamente distanti tra loro.

Keywords: UAV, Fotogrammetria, Nuvole Dense di Punti, Allineamento, Eigenfeatures, K-Means, Clustering, ICP

1 Introduzione

Le nuvole di punti dense possono essere ormai considerate il principale prodotto fotogrammetrico da UAV (*Unmanned Aerial Vehicle*). Sono state ampiamente studiate in letteratura da numerosi punti di vista; l'allineamento delle nuvole è, tra questi, un aspetto di fondamentale importanza soprattutto in casi in cui i blocchi fotogrammetrici vengono processati separatamente (grandi dataset acquisiti su vaste aree o serie temporali). Una tecnica spesso adottata per l'allineamento è ICP (*Iterative Closest Point*) in cui ad ogni punto della prima nuvola viene associato il punto più prossimo della seconda [1]. Le coppie di punti così ottenute vengono utilizzate per stimare una trasformazione rigida, solitamente una roto-traslazione a sei parametri [2]. L'operazione viene quindi iterata finché l'ultima trasformazione può essere considerata trascurabile. La convergenza dell'algoritmo è fortemente influenzata dalla morfologia delle nuvole da allineare poiché alcuni tipi di geometrie possono portare a un'instabilità della soluzione [3]. Ad esempio, è il caso di superfici pianeggianti, come i terreni coltivati, in cui le nuvole prodotte sono sostanzialmente parallele tra loro; in questo caso ICP ha difficoltà a determinare i parametri della trasformazione in quanto potrebbero permanere tre gradi di libertà, la traslazione nel piano parallelo alle nuvole e la rotazione intorno all'asse perpendicolare ad esse. La scelta di un sottoinsieme di punti collocati in zone di discontinuità può risolvere il problema portando alla convergenza dell'algoritmo; la scelta di tali punti è tuttavia un aspetto cruciale che influenza fortemente l'accuratezza finale dell'allineamento [4]. Nel presente lavoro, gli autori propongono la selezione di due sottoinsiemi di punti a densità differente in relazione alle caratteristiche morfologiche del terreno: densità bassa nelle aree pianeggianti e alta in presenza di discontinuità come fossati o rilevati. L'approccio proposto presenta un doppio vantaggio: riduce la complessità del calcolo, riducendo il numero di punti da elaborare, ed evita di sovrappesare le aree pianeggianti, favorendo la convergenza di ICP.

2 Metodologia

La metodologia proposta per la registrazione della nuvola di punti è costituita da una procedura a quattro passi: estrazione e selezione degli eigenfeature, classificazione non supervisionata tramite k-means, segmentazione della nuvola di punti e registrazione ICP ponderata. Tutti i passaggi sono implementati in Matlab, versione 2019b.

2.1 Estrazione e selezione degli eigenfeature

La scelta dell'intorno per la determinazione degli eigenfeature di ogni punto dipende strettamente dalle caratteristiche della nuvola considerata con particolare riferimento alla sua densità e alla sua forma 3D. Tale scelta può essere basata su una definizione a priori dell'area di ricerca in termini di raggio o numero di punti [5, 6], oppure adattando tale parametro alle caratteristiche locali [7, 8]. Se il secondo metodo richiede una conoscenza empirica della scena, il primo risulta essere più versatile poiché non direttamente connesso ad un dataset specifico. Nel presente articolo viene adottata la ricerca a raggio costante poiché l'area è pianeggiante e ha densità uniforme. Questo significa che, per ciascun elemento delle nuvole, viene generata la lista di *k* punti più prossimi ricadenti all'interno del raggio di ricerca.

Per ciascun elemento X, congiuntamente ai suoi k punti più prossimi, vengono derivati gli autovalori normalizzati e_i , con i = 1,2,3, attraverso PCA (Principal Component Analysis). Questi valori, ottenuti dalla matrice di covarianza, rappresentano la variazione della distribuzione dei punti lungo le tre principali direzioni ortogonali. Gli autovalori possono quindi essere combinati al fine di ottenere ulteriori descrittori di forma chiamati eigenfeature [7, 8] che comprendono: linearità L_e , planarità P_e , dispersione S_e , omnivarianza O_e , anisotropia A_e , eigentropy E_e , somma degli autovalori Σ_e e cambio di curvatura C_e ; in Tabella 1 sono riportate le rispettive formule. L'estrazione degli eigenfeature è stata implementata grazie all'utilizzo del toolbox GeoFEX, sviluppato dell'Istituto di Fotogrammetria e Telerilevamento di Karlsruhe in Germania [9].

Tuttavia, nonostante siano stati determinati tutti gli eigenfeature elencati, è necessario considerare il fatto che essi possano contenere informazioni ridondanti o irrilevanti; la linearità, ad esempio, che esprime la somiglianza locale della nuvola ad elementi di forma lineari, non contribuisce in modo significativo all'individuazione di terreno pianeggianti o presenza di discontinuità. Nel nostro caso specifico, eigenfeature come il cambio di curvatura, potrebbero invece contenere informazioni utili per migliorare ICP. Come evidenziato da alcuni autori [10, 11], è spesso consigliabile selezionare un sottoinsieme degli eigenfeature contenente le caratteristiche più rilevanti. Poiché utilizzeremo una classificazione non supervisionata, la selezione di tale sottoinsieme non è semplice in quanto non esiste un'etichetta di classe preesistente per possa guidare tale scelta. Tuttavia esistono tecniche di selezione adottabile in tali circostanze; tra queste è stato adottato il Laplacian Score (LS), proposto da [12], che si basa sull'osservazione che dati appartenenti alla stessa classe sono spesso vicini tra loro, quindi, la rilevanza di un dato eigenfeature può essere valutata dal suo potere di conservare le proprietà locali delle nuvole.

Eigenfeature	Formula	Eigenfeature	Formula
Linearità	$L_e = \frac{e_1 - e_2}{e_3}$	Anisotropia	$A_e = \frac{e_1 - e_3}{e_1}$
Planarità	$P_e = \frac{e_2 - e_3}{e_1}$	Eigenentropy	$E_e = -\sum_{i=1}^{3} e_i \cdot ln(e_i)$
Dispersione	$S_e = \frac{e_3}{e_1}$	Somma degli autovalori	$\Sigma_e = e_1 + e_2 + e_3$
Omnivarianza	$O_e = \sqrt[3]{e_1 \cdot e_2 \cdot e_3}$	Cambio di curvatura	$C_e = \frac{e_3}{e_1 + e_2 + e_3}$

Tabella 1. Formulazione matematica degli eigenfeature.

2.2 Clustering tramite K-means

K-means è un metodo per il clustering il cui scopo è suddividere le n osservazioni in k gruppi, o cluster; ad ogni gruppo appartengono osservazioni che presentano tra di solo delle similarità secondo criteri prefissati. L'appartenenza di un'osservazione ad un cluster viene determinata in modo iterativo riducendo le distanze interne; in altri termini, k-means identifica k centroidi e attribuisce ogni osservazione al più prossimo, cercando di mantenere la dimensione dei cluster la più piccola possibile [13]. L'algoritmo minimizza tale dimensione attraverso l'uso di funzioni obbiettivo del tipo [14]:

$$J = \sum_{j=1}^{k} \sum_{i=1}^{n} \|x_i^{(j)} - c_j\|^2$$
(1)

dove *k* e *n* sono rispettivamente il numero di cluster e di osservazioni, e c_j è il centroide del *j-esimo* cluster. Le osservazioni $x_i^{(j)}$ sono vettori che contengono ognuno gli *m* descrittori considerati. Per ogni nuvola di punti, tali descrittori possono esse composti, ad

esempio, da sei parametri: la posizione 3D del punto e i rispettivi valori RGB; nel presente lavoro, questi vettori contengono l'insieme degli eigenfeature selezionati (Sezione 2.1). La funzione obbiettivo (1) può essere rappresentata da diverse metriche di distanza, tra le quali quella Euclidea e la City-Block, entrambe testata nel presente lavoro. La distanza Euclidea tra due osservazioni, a e b, aventi ognuna m dimensioni, viene calcolata tramite la (2), mentre la metrica City-Block (chiamata talvolta Manhattan) è definita dalla (3) [14, 15]:

$$d = \sqrt{\sum_{i=1}^{m} (a_i - b_i)^2} \qquad (2) \qquad d = \sum_{i=1}^{m} |a_i - b_i| \qquad (3)$$

Se consideriamo due punti nel piano xy, la distanza più breve tra loro è lungo la congiungente, ovvero la distanza Euclidea. La metrica City-Block calcola invece la somma delle distanze lungo le direzioni x e y, come farebbero le persone che si trovassero a camminare in una città, come Manhattan, in cui è possibile muoversi intorno agli edifici ma non attraversarli diagonalmente.

Infine, in un approccio non supervisionato, non è sempre noto il numero di cluster, k, in cui suddividere i dati. Esistono tuttavia metodi che permettono di stimarlo; tra questi il coefficiente di silhouette [16, 17] capace di misurare quanto ogni osservazione sia simile agli altri elementi del proprio cluster; un valore alto indica che le osservazioni sono correttamente inseriti all'interno del gruppo di appartenenza e la numerosità del cluster è appropriata. Nel nostro caso, k-means viene utilizzato per suddividere i punti in cluster che hanno caratteristiche morfologiche simili. Come anticipato nell'introduzione, la natura dei dati può influenzare in modo significativo l'allineamento tramite ICP: il terreno pianeggiante potrebbe comportare instabilità nella soluzione mentre la presenza di discontinuità, come fossati o scarpate, può, al contrario, facilitarne la convergenza. La procedura di clustering, basata su eigenfeature, dovrebbe permettere la separazione di queste due tipologie di terreno per cui, dal punto di vista teorico, k dovrebbe essere posto uguale a 2. Tuttavia, come riportato nel Paragrafo 4.2, viene eseguita una preliminare analisi del coefficiente di silhouette [18] al fine di confermare la correttezza dell'ipotesi.

2.3 Segmentazione della nuvola di punti

ICP è un algoritmo capace di allineare nuvole di punti sovrapposte tramite una procedura iterativa che minimizza una metrica di errore ad ogni successivo passaggio. L'allineamento non richiede l'identificazione preliminare di punti omologhi perché si basa sull'associazione automatica di ogni punto di una nuvola al punto più prossimo appartenente all'altra nuvola. Una volta effettuata l'associazione una trasformazione di coordinate viene stimata ed applicata tra di esse al fine di minimizzarne la reciproca distanza. La procedura viene quindi reiterata e ripetuta fino a ridurre al minimo la distanza reciproca.

Come indicato nella sezione introduttiva, alcune tipologie di geometrie possono portare ad una deficienza di rango che comporta alla mancanza di univocità della trasformazione minimizzante; questo accade ad esempio quando si prendono in considerazione due piani paralleli (si pensi ad esempio a blocchi UAV acquisiti su aree pianeggianti). Questa situazione introduce intuitivamente tre gradi di libertà: una traslazione planimetrica e una rotazione attorno all'asse verticale. La scelta di un opportuno sottoinsieme di punti è una strategia comunemente adottata per migliorare la stabilità della soluzione. Basandosi sulla classificazione ottenuta nella fase precedente (Sezione 2.2), viene effettuato un sotto-campionamento in cui le due nuvole vengono segmentate in due regioni caratterizzate da densità di punti differente: inferiore nelle aree pianeggianti (cluster # 1) e maggiore in terreni variabili (cluster # 2). Sovrapponendo alle nuvole una griglia di 2 m di lato, viene effettuato il sotto-campionamento: alle celle che giacciono su terreno pianeggiate viene imposta una densità di 1 pt/m² (distanza lineare tra i punti di 1 m) mentre per le altre si ne fissa una pari a 64 pt/m² (interdistanza di 12.5 cm). L'attribuzione di una griglia ad un cluster viene effettuata imponendo una opportuna soglia al loro rapporto. L'utilizzo di questa struttura introduce molteplici vantaggi: migliora la stabilità dell'algoritmo (suo compito principale) evitando di sovrappesare le aree pianeggianti, diminuisce la complessità del calcolo ICP, e riduce il rumore delle nuvole grazie all'interpolazione.

2.4 Allineamento delle nuvole tramite ICP ponderata

Le strutture costruire nella sezione precedente sono quindi state utilizzate per stimare l'allineamento tramite ICP. Poiché non vengono utilizzati i dati originari, ma un loro sottoinsieme, è possibile affermare che viene eseguita una stima ponderata dell'allineamento poiché i punti presenti nelle aree di discontinuità (fossati e rilevati) hanno un peso maggiore, grazie alla maggiore numerosità, rispetto a quelli che giacciono in zone pianeggianti. Questa strategia conferisca una maggiore stabilità alla soluzione finale.

In ICP ogni punto di una struttura è accoppiato con il punto più prossimo dell'altra utilizzando un approccio basato su k-d tree; viene quindi eseguita una reiezione degli outlier basata sulla mutua distanza, le differenze radiometriche e la divergenza tra le normali. Le coppie così selezionate vengono utilizzate per stimare una trasformazione rigida a sei parametri secondo la metrica punto-piano [1, 19], la cui formulazione è:

$$CPT_{opt} = arg \ arg \ \sum \left((CPT \cdot PCB_i - PCA_i) \cdot n_i \right)^2 \tag{4}$$

in cui PCB_i è il generico appunto appartenente alla struttura *B*, PCA_i è il corrispondente punto per la struttura *A*, n_i è il vettore normale al punto PCA_i , *CPT* è la matrice di trasformazione 4x4 (memorizzata nella struttura *tform* di Matlab) stimata all'iterazione precedente e CPT_{opt} è quella ottenuta per quella corrente; il processo viene iterato fino a quando l'ultima trasformazione è di entità trascurabile. La descrizione completa dell'implementazione di ICP è riportata in [20].

3 Il dataset utilizzato

I dati sono stati acquisiti da un sistema HEXA-PRO[™] di proprietà del Laboratorio di Geomatica dell'Università di Pavia. Il drone era equipaggiato con una camera Parrot Sequoia capace di acquisire contemporaneamente un'immagine RGB e quattro immagini nelle bande del verde (G: 530-570 nm), rosso (R:640-680 nm), rosso vicino (RE: 730-740 nm) e infrarosso vicino (NIR: 770-810 nm). Le principali caratteristiche sono riportate in Tabella 2.

Sensore	Risoluzione	Pixel	Lunghezza focale	GSD @70 m
RGB	4608 × 3456	1.34 µm	4.88 mm	1.9 cm
G, R, RE, NIR	1280×960	3.75 μm	3.98 mm	6.8 cm

Tabella 2. Principali caratteristiche della camera Parrot Sequoia.



Fig. 1. La struttura dei sotto-blocchi in cui le linee azzurre rappresentano i perimetri di acquisizione, le aree di sovrapposizione sono chiaramente visibili. L'area considerata nel presente articolo è evidenziata in rosso.

Il blocco è stato acquisito nei pressi della Cascina Santa Sofia, in provincia di Pavia; il test-site è costituito da un'ara pianeggiante di circa 36 ettari, esclusivamente coltivata a riso. La zona è stata rilevata con cinque missioni di volo in accordo con lo schema riportato in Figura 1. In totale il blocco è costituito da più di 1300 immagini multispettrali, composta ognuna da quattro bande. La quota relativa di volo è di 70 m e il ricoprimento longitudinale e trasversale è rispettivamente del 80% e del 60%. L'articolo, essendo metodologico, si focalizza in particolare sui sotto-blocchi 3 e 4; il primo è composto da 293 immagini e ha un'estensione di 12 ettari, il secondo di 226 immagini con un'estensione di 9.5 ettari. In Figura 1, l'area di sovrapposizione è evidenziata in rosso.

Il processamento fotogrammetrico è stato condotto con il software Pix4D Mapper Pro, nella versione 4.4.9. Poiché il dataset utilizzato è stato acquisito allo scopo di analizzare l'uso dei dati Parrot Sequoia per applicazioni di agricoltura di precisione, maggiori dettagli sono disponibili in [21], solo le quattro bande multispettrali, sono state considerate. Inoltre, poiché l'articolo concerne l'allineamento di nuvole dense di punti, è stato considerata la configurazione più sfavorevole ossia l'orientamento diretto: i parametri esterni sono ottenuti dal ricevitore GPS integrato nel sensore, nessun punto di controllo a terra è stato quindi inserito nella triangolazione; i parametri interni sono stati direttamente letti dai file EXIF delle immagini (tali parametri sono determinati per ogni camera direttamente dal produttore). L'affidabilità dei parametri interni è buona e gli scostamenti tra quelli nominali e quelli ottimizzati sono inferiori allo 0.1% [22]. Il processamento ha seguito l'usuale workflow [23, 24]: allineamento delle immagini, estrazione dei punti di legame (nuvola sparsa), triangolazione aerea e generazione della nuvola densa di punti. I due blocchi considerati sono stati processati separatamente per cui sono state ottenute due nuvole di punti aventi una densità compresa tra 11 e 14 punti al m².

4 Risultati

La sezione descrive i risultati ottenuti utilizzando la strategia proposta per l'allineamento delle nuvole di punti. Poiché l'articolo ha un approccio metodologico, solo una parte dei dati fotogrammetrici disponibili è stato preso in considerazione: i blocchi 3 e 4 mostrati in Figura 1. Per la stessa ragione solo le nuvole generate in un approccio a georeferenziazione diretta sono state considerate. Tale configurazione è infatti la più svantaggiosa poiché la camera Parrot dispone di un ricevitore GPS di livello navigazionale e i dati di orientamento ottenuti sono affetti da errori non trascurabili; di conseguenza, le nuvole generate a partire da questi dati sono lontane tra loro. La Figura 2 mostra un frammento delle ortofoto così generate dove è evidente la presenza di un significativo scostamento planimetrico tra di loro. Per valutare l'allontanamento in quota ed eventuali rotazioni è invece utile estrarre dei profili lungo l'area di sovrapposizione (Figure 3a) come riportato in Figura 3b. L'immagine mostra i profili, larghi circa 1 m, estratti per i blocchi 3 e 4, riporti rispettivamente in blue e rosso; la figura evidenzia chiaramente uno spostamento altimetrico e la presenza di una significativa rotazione tra le nuvole.



Fig. 2. Un estratto delle ortofoto generate nell'area di sovrapposizione dove è evidente un significativo scostamento planimetrico



Fig. 3. Posizione del profilo longitudinale Est-Ovest nella zona di sovrapposizione (a); profili estratti per il blocco 3 (in blu) e per il blocco 4 (in rosso) dove è evidente uno scostamento altimetrico e una significativa rotazione tra le nuvole (b)

Alcuni passaggi preliminari sono stati eseguiti sulle nuvole prima dell'allineamento tramite ICP; in particolare è stata determinata l'area di inviluppo della zona di sovrapposizione e le nuvole sono state ritagliate in accordo con quest'ultima. Inoltre, è stato applicato un ulteriore buffer precauzionale, per evitare eventuali effetti di bordo. Le nuvole così ottenute sono state elaborate seguendo i passaggi descritti in Sezione 2: estrazione e selezione degli eigenfeature, clustering tramite K-means, segmentazione e allineamento tramite ICP.

4.1 Estrazione e selezione degli eigenfeature

Il primo passo della procedura è l'estrazione degli otto eigenfeature per ogni punto delle due nuvole (Sezione 2.1). È stato utilizzato un raggio di ricerca costante all'interno dei quali i punti prossimi sono stati identificati; il raggio è stato posto pari a 1 m, basandosi sulle caratteristiche dell'area e la densità delle nuvole, ottenendo in questo modo un numero medio di punti prossimi pari a 51. La matrice di covarianza e gli autovalori sono stati quindi determinati e gli eigenfeature sono stati calcolati utilizzando le formule riportate in Tabella 1. Gli eigenfeature sono quindi normalizzati nell'intervallo [0, 1] e memorizzati in una matrice aventi tante righe quanto il numero di punti e otto colonne.

La graduatoria laplaciana [12] è stata quindi utilizzata per determinare quali eigenfeature sono maggiormente rilevanti. Poiché tale scelta deve essere adatta per entrambe le nuvole, la graduatoria è stata elaborata tre volte: utilizzando il solo blocco 3, il solo blocco 4 ed i due dataset in modo congiunto. Le classifiche così ottenute sono state quindi mediate ottenendo una classifica globale (Figura 4a): le barre rappresentano la media delle posizioni ottenute per ogni eigenfeature; valori bassi indicato posizioni alte nella classifica di significatività. Due caratteristiche, dispersione e cambio di curvatura, risultano essere maggiormente nelle prime posizioni di significatività rispetto ad altre come linearità o anisotropia. Tale risultato risulta essere particolarmente idoneo alle caratteristiche del test site; essendo quest'ultimo prevalentemente pianeggiante, gli eigenfeature individuati dovrebbero permettere l'individuazione degli elementi e delle forme utili per la convergenza di ICP. Inoltre, la separazione tra questi primi due eigenfeature e gli altri suggerisce che essi contengono tutte le informazioni necessarie per le fasi successive; per tale motivo, solo la dispersione e il cambio di curvatura saranno utilizzati.



Fig. 4. Graduatoria globale degli eigenfeature analizzati (a); Coefficiente di silhouette medio per un numero di cluster compreso tra 2 e 10 (b)

4.2 Clustering tramite K-means

K-means è un algoritmo iterativo per il clustering che assegna ogni osservazione ad uno specifico gruppo in modo che la somma delle distanze degli elementi rispetto al centroide del cluster sia minimo; la procedura fornisce per ogni osservazione l'indice del gruppo a cui è stata associata. Nel nostro caso, le osservazioni sono rappresentate dai due eigenfeature selezionati nella sezione precedente, la dispersione e il cambio di curvatura; tali informazioni sono utilizzate per raggruppare i punti in insiemi utili per l'allineamento delle nuvole. Anche se in numero k di cluster dovrebbe essere posto uguale a due, al fine di separare le area piatte dal terreno che presenta discontinuità, come fossati e rilevati, è stata comunque condotta un'analisi preliminare tramite il coefficiente di silhouette. Questo metodo permette di determinare quanto ogni osservazione sia perfettamente inserita nel cluster di appartenenza; per fare questo l'algoritmo restituisce per ogni dato un indicatore che varia da -1 a 1: valori alti indicano come l'elemento sia correttamente inserito, mentre valori bassi significano che il punto potrebbe

trovare una collocazione migliore in un altro cluster. Il numero ottimale di cluster k è quello che massimizza il coefficiente di silhouette sull'intervallo di possibili valori k. La Figura 4b mostra i risultati ottenuti per un numero di cluster compresi tra 2 e 10; il coefficiente di silhouette è massimo per k = 2 e decresce all'aumentare degli insiemi. Questo risultato supporta la nostra ipotesi iniziale dell'utilizzo di due gruppi: terreno pianeggiante e con discontinuità.

Una volta stabilito il numero di cluster, K-means è stato eseguito per ognuna delle due nuvole di punti utilizzando due metriche, distanza Euclidea e City-Block. In Figura 5 sono riportati i risultati: i punti rossi appartengono al cluster #1 identificato come terreno piatto, i punti blu sono invece attribuiti al cluster #2 caratterizzato dalla presenza di rilevati e fossati. Le immagini superiori, Figura 5a e 5b, si riferiscono alla metrica Euclidea rispettivamente per il blocco 3 e per il blocco 4; le immagini inferiori, Figura 5c e 5d, a City-Block.



Fig. 5. Risultati ottenuti tramite K-means: distanza Euclidea per blocco 3 (a) e blocco (b); metrica City-Blocco per blocco 3 (c) e blocco 4 (d)



Fig. 6. Ortofoto prodotta con la banda verde del sensore Parrot Sequoia (blocco 3)

In Figura 6 è riportata l'ortofoto prodotta per il blocco 3 utilizzando la banda verde del sensore. La figura permette di identificare la posizione degli elementi di interesse:

le strade sterrate (le vetture utilizzate per il rilievo sono inoltre visibili) e i canali di irrigazione. Da una prima comparazione visuale, è evidente che esiste una buona corrispondenza tra gli elementi individuati e il cluster #2. Tuttavia, le due metriche testate mostrano delle differenze: City-Block mostra risultati più uniformi e completi nelle aree di discontinuità mentre la distanza Euclidea sembra fare più fatica con risultati irregolari. Entrambe classificano punti interni alle zone coltivate come elementi appartenenti al cluster #2; questo accade soprattutto per City-Block. Questo comportamento potrebbe essere connesso alla presenza di erbe infestanti all'interno delle colture; questo tipo di vegetazione, tipicamente più alta, potrebbe essere identificata come elemento di interesse e quindi classificata nel secondo gruppo. Tale risultato non deve essere interpretato necessariamente come un errore se esso contribuisce ad una migliore convergenza per ICP. Nel nostro caso, tuttavia, tale fenomeno sembra essere connesso alla presenza di noise nelle nuvole di punti prodotte; confrontando le Figure 5c e 5d nella porzione in alto a sinistra delle immagini, è evidente come la stessa area presenta risultati di clusterizzazione diversi. Ricordando che i due blocchi sono stati elaborati indipendentemente, utilizzando le posizioni ottenute dal ricevitore GPS integrato con il sensore, questa disparità potrebbe essere dovuta ad una diversa qualità degli orientamenti generando una nuvola più rumorosa per il blocco 3 oppure ad una diversa qualità nelle immagini acquisite. Anche se meno evidente, lo stesso fenomeno è presente per le Figure 5a e 5b, ottenuto con la distanza Euclidea.

Infine, la maggior regolarità ottenuta dalla metrica City-Block potrebbe essere spiegata considerando che gli elementi ricercati, strade sterrate e canali, hanno una struttura abbastanza simile alle strade urbane caratterizzate dalla presenza di elementi lineari e ortogonali tra loro. Data questa maggiore completezza, solo i risultati ottenuti con City-Block saranno utilizzati come punto di partenza per la creazione della struttura a doppia densità necessaria per la registrazione ICP.

4.3 Segmentazione delle nuvole di punti

Per effettuare la segmentazione, una griglia di 2 metri di lato è stata sovrapposta alle nuvole di punti. Utilizzando i risultati ottenuti dalla classificazione ogni cella così ottenuta viene sotto-campionata opportunamente: alle celle che giacciono su terreno pianeggiante viene fissata una densità pari a 1 pto/m², mentre le restanti viene imposta una densità di 64 pti/m². Il criterio per attribuire ad una cella la corrispondente densità è fissato imponendo una soglia sulla presenza dei due cluster al suo interno: se almeno il 25% dei punti che cadono in una cella sono classificati come cluster #2, la cella appartiene alla classe ad alta densità, in caso contrario a quella inferiore. La soglia scelta è prudenziale ed a favore della classe ad alta densità in modo da non trascurare nessuna possibile area utile per raggiungere la convergenza di ICP.

In Figura 7a e 7b sono riportati ottenuti per i blocchi 3 e 4; le celle a bassa densità, 1 pto/m², sono riportate in grigio chiaro, mentre quelle ad alta, 64 pti/m², in grigio scuro. Le strade sterrate ed i canali sono ben rappresentati in entrambi i casi anche se è ancora presente la presenza di rumore in alcune zone pianeggianti del blocco 3, come già discusso nel paragrafo precedente.



Fig. 7. Risultato della segmentazione della nuvola in celle a densità diversa ottenute per il blocco 3 (a) e per il blocco 4 (b). In grigio chiaro le celle a bassa densità (1 pto/m²), in grigio scuro quelle ad alta (64 pti/m²).

L'asimmetria ottenuta potrebbe portare tuttavia ad una instabilità nella soluzione ICP e, per questo motivo, si è provveduto ad effettuare una analisi combinata delle due segmentazioni ottenute. In particolare, è stato eseguito un confronto tra i due risultati al fine di mantenere solo le celle ad alta densità classificate come tali in entrambe le nuvole. In Figura 8a è riportata, a titolo di esempio, la nuova segmentazione per il blocco 3; il risultato è più pulito e le forme ricercate, strade e canali, sono maggiormente evidenti.



Fig. 8. La nuova struttura del blocco 3 ottenuta dopo l'analisi combinata delle due segmentazioni (a); La segmentazione manuale effettuata per il blocco 3 (b).

Per valutare la qualità della procedura automatica proposta viene effettuato un confronto con una segmentazione ottenuta per via manuale [21]. In Figura 8b è riportata la struttura di tale segmentazione per il blocco 3: le linee sono regolari e definite e non sono presenti spot neri nelle zone pianeggianti. Un primo confronto visivo tra le immagini di Figura 8 mostra una significativa concordanza; la procedura automatica sembra portare a risultati paragonabili a quelli manuali.

Per quantificare tale concordanza, è stata calcolata la matrice di confusione tra le due soluzioni. Ogni cella della segmentazione manuale (valore vero) viene confrontata con la cella corrispondente della segmentazione automatica (valore predetto). Vengono considerati entrambi i blocchi e viene prodotto un'unica matrice di confusione che riassume i risultati (Figura 9). Sulla diagonale principale sono riportate le celle classificate correttamente; c'è un buon accordo soprattutto nelle aree a bassa densità con più del 95% di esse classificate correttamente. La qualità diminuisce intorno al 75-77% considerando le celle ad alta densità; questa differenza nei risultati deve essere tuttavia attribuita più a un'errata classificazione dell'operatore umano che a un errore dell'algoritmo automatico. Osservando le immagini riportate in Figura 8, soprattutto nel punto in cui le strade sterrate si intersecano, è evidente come le due classificazioni, automatica e manuale, abbiano ottenuto risultati differenti: bassa densità per la prima e alta per la seconda. Logicamente parlando, la parte superiore di una strada è pianeggiante, quindi l'algoritmo ha funzionato bene; l'operatore umano ha invece semplificato la realtà introducendo in questo modo una fonte di errore. Tuttavia, il risultato conferma il buon accordo tra la segmentazione manuale-automatica e la precisione complessiva è del 92,5%.



Fig. 9. Matrice di confusione tra segmentazione manuale ed automatica (DB: Densità Bassa; DA: Densità Alta).

4.4 Allineamento delle nuvole tramite ICP ponderata

Le strutture prodotte alla fase precedente sono state quindi utilizzate per stimare, tramite ICP, la trasformazione 3D utile per allineare le due nuvole di punti. Per valutare la qualità della trasformazione ottenuta viene valutata la distanza tra le due nuvole di punti prima e dopo l'applicazione di ICP. I risultati sono riportati in Tabella 3 in cui le colonne rappresentano rispettivamente: l'identificativo dello scenario e i principali descrittori statistici per le componenti orizzontali, verticale e 3D. La distanza iniziale tra le due nuvole presenta valori elevati, come previsto, mentre ICP produce un buon allineamento tra di loro con un residuo 3D di circa 16 cm.

La qualità ottenuta è anche verificata graficamente tramite l'utilizzo dei profili longitudinali. Grazie a ICP il blocco 4 viene infatti allineato al blocco 3 permettendo l'estrazione di un nuovo profilo. In Figura 10 il risultato ottenuto dopo questa operazione: in rosso e blu i due profili originali (riportati anche in Figura 3b), mentre in verde il nuovo profilo per il blocco 4 dopo l'allineamento tramite ICP. Le due nuvole sono ora posizionate correttamente; tuttavia, è presente una leggera deformazione nella parte sinistra del profilo che non può essere eliminata con una trasformazione rigida. Il fenomeno potrebbe essere ricondotto ad un problema di calibrazione del sensore con seguente deformazione della nuvola; in questo caso solo una ricalibrazione potrebbe ridurre o eliminare tale scostamento.

#AsitaAcademy2021

		delta E (m)	delta N (m)	delta H (m)	delta 3D (m)
Prima di ICP	min	1.230	-0.872	0.349	1.424
	max	2.076	0.183	4.903	5.219
	media	1.657	-0.334	2.529	3.110
	std	0.091	0.149	1.081	0.882
	rmse	1.659	0.366	2.750	3.232
Dopo ICP	min	-0.345	-0.360	-0.357	0.003
	max	0.334	0.355	0.363	0.364
	media	0.001	0.001	0.041	0.145
	std	0.080	0.084	0.101	0.058
	rmse	0.080	0.084	0.110	0.159

Tabella 3. Statistica sulla distanza tra le due nuvole prima e dopo l'applicazione di ICP.



Fig. 10. Profili longitudinale per il blocco 3 (linea blu) e per il blocco 4 prima dell'allineamento con ICP (linea rossa) e dopo (linea verde)

5 Conclusioni

Il contributo riguarda la valutazione di una procedura automatica per l'allineamento di nuvole di punti applicabile a dataset generati da diverse tecniche di rilevamento come la fotogrammetria da drone o i laser scanner, sia aerei che terrestri. Nel caso esaminato vengono allineate due nuvole prodotte da un sensore multispettrale da drone.

La procedura proposta si basa sull'applicazione dell'algoritmo ICP. Sono stati estratti gli eigenfeature per tutti i punti e solo i due più significativi, dispersione e cambio di curvature, sono stati quindi utilizzati per effettuare la classificazione delle nuvole in due gruppi: terreno pianeggiante e con presenza di discontinuità (rilevati o fossati). Sono state testate due metriche, Euclidea e City Block, ma solo la seconda ha mostrato risultati utili per le fasi successive. Le nuvole sono state quindi segmentate in strutture a doppia densità; più elevata, 1 pti/m², per le aree di interesse e meno densa, 64 pti/m², per le aree pianeggianti. Tali strutture sono state quindi utilizzate come dato di input per l'algoritmo ICP.

L'allineamento finale ottenuto tra le due nuvole mostra buoni risultati dimostrando come la procedura proposta sia applicabile anche a dataset critici come quello utilizzato (terreno pianeggiante con significativi scostamenti e rotazioni iniziali). Nei risultati mostrati si vede come la distanza 3D tra le due nuvole passi dai 3 metri iniziali ai circa 15 cm finali (valori comparabili alla dimensione di discretizzazione delle nuvole).

Attualmente la procedura è completamente automatica ad eccezione della selezione del raggio di ricerca per la determinazione degli eigenfeature (fissato manualmente uguale a 1). Le attività future riguarderanno l'automazione di questo passaggio con l'uso di raggi di ricerca variabili o l'utilizzo dell'eigen-entropia [25].

Infine, poiché il dataset utilizzato per il presente lavoro è un sensore multispettrale, solo la banda verde ha contribuito alla generazione della nuvola di punti. Per questo motivo, al momento, nessuna informazione sul colore è stata inserita nella procedura implementata. Verranno pertanto presi in considerazioni nuovi dataset, acquisiti con sensori ottici, al fine di capire se le informazioni radiometriche in esse contenute possano influenzare e migliorare i risultati.

Riferimenti bibliografici

- Yang, C., Medioni, G.: Object modelling by registration of multiple range images. Image Vis. Comput. 10, 145–155 (1992). https://doi.org/10.1016/0262-8856(92)90066-C
- Mallet, C., Bretar, F., Roux, M., Soergel, U., Heipke, C.: Relevance assessment of fullwaveform lidar data for urban area classification. ISPRS J. Photogramm. Remote Sens. 66, S71--S84 (2011). https://doi.org/10.1016/j.isprsjprs.2011.09.008
- Gelfand, N., Ikemoto, L., Rusinkiewicz, S., Levoy, M.: Geometrically stable sampling for the ICP algorithm. In: Proceedings of International Conference on 3-D Digital Imaging and Modeling, 3DIM. pp. 260–267. IEEE (2003)
- Glira, P., Pfeifer, N., Briese, C., Ressl, C.: Rigorous strip adjustment of airborne laserscanning data based on the icp algorithm. ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci. 2, 73–80 (2015). https://doi.org/10.5194/isprsannals-II-3-W5-73-2015
- Friedman, J.H., Bentley, J.L., Finkel, R.A.: An Algorithm for Finding Best Matches in Logarithmic Expected Time. ACM Trans. Math. Softw. 3, 209–226 (1977). https://doi.org/10.1145/355744.355745
- Arya, S., Mount, D.M., Netanyahu, N.S., Silverman, R., Wu, A.Y.: An optimal algorithm for approximate nearest neighbor searching in fixed dimensions. J. ACM. 45, 891–923 (1998). https://doi.org/10.1145/293347.293348
- Farella, E.M., Torresani, A., Remondino, F.: Sparse point cloud filtering based on covariance features. Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch. 42, 465–472 (2019). https://doi.org/10.5194/isprs-archives-XLII-2-W15-465-2019
- Weinmann, M., Jutzi, B., Hinz, S., Mallet, C.: Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. ISPRS J. Photogramm. Remote Sens. 105, 286–304 (2015). https://doi.org/10.1016/j.isprsjprs.2015.01.016
- Weinmann, M., Urban, S., Hinz, S., Jutzi, B., Mallet, C.: Distinctive 2D and 3D features for automated large-scale scene analysis in urban areas. Comput. Graph. 49, 47–57 (2015). https://doi.org/10.1016/j.cag.2015.01.006

#AsitaAcademy2021

- Weinmann, M., Jutzi, B., Mallet, C.: Feature relevance assessment for the semantic interpretation of 3D point cloud data. ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci. 2, 313–318 (2013). https://doi.org/10.5194/isprsannals-II-5-W2-313-2013
- 11. Roffo, G.: Feature Selection Library (MATLAB Toolbox). (2016)
- He, X., Cai, D., Niyogi, P.: Laplacian Score for feature selection. Adv. Neural Inf. Process. Syst. 507–514 (2005)
- Jain, A.K.: Data clustering: 50 years beyond K-means. Pattern Recognit. Lett. 31, 651–666 (2010). https://doi.org/10.1016/j.patrec.2009.09.011
- Bora, M.D.J., Gupta, D.A.K.: Effect of Different Distance Measures on the Performance of K-Means Algorithm: An Experimental Study in Matlab. (2014)
- Deza, E., Deza, M.M., Deza, M.M., Deza, E.: Encyclopedia of Distances. In: Encyclopedia of Distances. pp. 1–583. Springer Berlin Heidelberg (2009)
- Hadi, A.S., Kaufman, L., Rousseeuw, P.J.: Finding Groups in Data: An Introduction to Cluster Analysis. Technometrics. 34, 111 (1992). https://doi.org/10.2307/1269576
- Lletí, R., Ortiz, M.C., Sarabia, L.A., Sánchez, M.S.: Selecting variables for k-means cluster analysis by using a genetic algorithm that optimises the silhouettes. Anal. Chim. Acta. 515, 87–100 (2004). https://doi.org/10.1016/j.aca.2003.12.020
- Rousseeuw, P.J.: Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. J. Comput. Appl. Math. 20, 53–65 (1987). https://doi.org/10.1016/0377-0427(87)90125-7
- Low, K.: Linear Least-squares Optimization for Point-to-plane ICP Surface Registration. Chapel Hill, Univ. North Carolina. 2–4 (2004)
- Franzini, M., Ronchetti, G., Sona, G., Casella, V.: Geometric and radiometric consistency of parrot sequoia multispectral imagery for precision agriculture applications. Appl. Sci. 9, 5314 (2019). https://doi.org/10.3390/app9245314
- Franzini, M., Ronchetti, G., Sona, G., Casella, V.: Geometric and Radiometric Consistency of Parrot Sequoia Multispectral Imagery for Precision Agriculture Applications. Appl. Sci. 9, 5314 (2019). https://doi.org/10.3390/app9245314
- Fernández-Guisuraga, J.M., Sanz-Ablanedo, E., Suárez-Seoane, S., Calvo, L.: Using unmanned aerial vehicles in postfire vegetation survey campaigns through large and heterogeneous areas: Opportunities and challenges. Sensors (Switzerland). 18, 586 (2018). https://doi.org/10.3390/s18020586
- Casella, V., Chiabrando, F., Franzini, M., Manzino, A.M.: Accuracy assessment of a UAV block by different software packages, processing schemes and validation strategies. ISPRS Int. J. Geo-Information. 9, (2020). https://doi.org/10.3390/ijgi9030164
- Casella, V., Chiabrando, F., Franzini, M., Manzino, A.M.: Accuracy Assessment of a Photogrammetric UAV Block by using Different Software and Adopting Diverse Processing Strategies. GISTAM 2019 - Proc. 5th Int. Conf. Geogr. Inf. Syst. Theory, Appl. Manag. 77– 87 (2019). https://doi.org/10.5220/0007710800770087
- Palamidessi, C., Romanelli, M.: Feature selection in machine learning: Rényi min-entropy vs Shannon entropy, https://arxiv.org/pdf/2001.09654.pdf, (2020)