

Abstrakt

Predkladaná dizertačná práca sa venuje úlohe 3D príznakových reprezentácií pri sémantickej interpretácii mračien bodov. Práca skúma túto problematiku z dvoch komplementárnych perspektív: analýzy ručne navrhnutých geometrických príznakov a návrhu hybridných prístupov založených na hlbokom učení, ktoré integrujú explicitné geometrické informácie do neurónových sietí.

V prvej časti práce hodnotíme 3D detektory kľúčových bodov, lokálne deskriptory a ich vzájomné kombinácie. Experimenty realizujeme na scénach s rôznou mierou oklúzie a komplexity. Výsledky ukazujú, že hoci ručne navrhnuté príznaky poskytujú interpretovateľný opis lokálnej geometrie povrchu, ich výkon je výrazne závislý od stability detekcie kľúčových bodov. Oklúzia a komplexnosť scén znižujú opakovateľnosť detektorov, čo priamo ovplyvňuje kvalitu párovania deskriptorov.

V druhej časti práce sa zameriavame na segmentáciu mračien bodov pomocou hlbokého učenia a navrhujeme hybridnú architektúru HyGDANet, ktorá rozširuje model GDANet o kovariančné geometrické príznaky, štatistické charakteristiky okolia a smerovo orientované reprezentácie PointSIFT. Analyzujeme prínos jednotlivých príznakov, ich kombinácií a rôznych stratégií fúzie.

Experimentálne výsledky ukazujú, že explicitné geometrické informácie môžu dopĺňať naučené reprezentácie, avšak ich prínos závisí od spôsobu integrácie. Jednotlivé príznaky prinášajú mierne zlepšenia, zatiaľ čo ich priame kombinovanie môže viesť k redundancii.

Práca ukazuje, že lokálna geometrická informácia zostáva kľúčová pre porozumenie mračnám bodov, avšak jej úloha sa mení z primárnej reprezentácie na doplnkový zdroj informácií v rámci modelov hlbokého učenia. Výsledky poskytujú odporúčania pre návrh hybridných architektúr kombinujúcich explicitné a naučené príznaky.

Kľúčové slová: mračná bodov, sémantická segmentácia, geometrické príznaky, hlboké učenie, hybridné architektúry, PointSIFT