

توصیف گر موضعی جدید با استفاده از نگاشت



مرکاتور به منظور تشخیص اشیای سه بعدی

معصومه رضائی^۱، مهدی رضائیان^{۲*} و ولی درهمی^۳

^۱دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران

^۲ و ^۳ پردیس فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران

چکیده

پردازش ابرهای نقطه‌ای یکی از زمینه‌های در حال رشد در بینایی ماشین است. با پیدایش حس گرهای عمق ارزان قیمت علاقه زیادی به پردازش ابرهای نقطه‌ای و استفاده از آن در تشخیص اشیای سه بعدی ایجاد شده است. در حالت کلی روش‌های تشخیص اشیای سه بعدی به دو دسته موضعی و سرتاسری تقسیم می‌شوند. در روش‌های سرتاسری شکل کلی مدل توصیف شده درحالی که در روش‌های موضعی از خصوصیات هندسی ناحیه موضعی اطراف یک نقطه برای به دست آوردن ویژگی آن نقطه استفاده می‌شود. برخلاف روش‌های سرتاسری، روش‌های موضعی نیاز به قطعه‌بندی ندارند و نسبت به پدیده انسداد و درهم‌ریختگی مقاوم تر هستند. روش‌های مبتنی بر ویژگی‌های موضعی، برخی از ویژگی‌های هندسی را از سطوح محلی اطراف نقاط خاصی به نام نقاط کلیدی استخراج می‌کنند. ویژگی‌های هندسی یک نقطه کلیدی در یک توصیف گر ویژگی کدگذاری می‌شوند. چگونگی توصیف محیط پیرامون یک نقطه کلیدی چالش اصلی این روش هاست. روش‌های موضعی که به طور معمول مورد استفاده قرار می‌گیرند، اغلب به نطفه، تغییر وضوح مش و تبدیل صلب حساس هستند. برای غلبه بر چنین مشکلاتی، در این مقاله توصیف گر موضعی جدیدی بر اساس نگاشت مرکاتور ارائه شده است. نگاشت مرکاتور یکی از معروف ترین نگاشت‌های سه بعد به دو بعد است که فاصله، زاویه، جهت، طول و عرض جغرافیایی نسبی را بین هر دو نقطه در ابرهای نقطه‌ای حفظ می‌کند. به منظور ارزیابی، روش پیشنهادی با تعدادی از روش‌های مطرح مقایسه شده است. برتری این روش بر سایر روش‌ها با استفاده از معیارهای خطای جذر میانگین مربعات، نمودار بازخوانی در برابر دقت، خطای ثبت کردن، خطای چرخش و انتقال نشان داده می‌شود و اثبات می‌شود که این روش قدرت توصیفی خوبی دارد و نسبت به تبدیل صلب، نویز و تغییر وضوح مش مقاوم است.

واژگان کلیدی: ابر نقطه، تشخیص اشیای سه بعدی، توصیف گر موضعی، نگاشت مرکاتور.

A novel local feature descriptor using the Mercator projection for 3D object recognition

Masoumeh Rezaei¹, Mehdi Rezaeian^{2*} & Vali Derhami³

¹Faculty of Electrical and Computer Engineering, University of Sistan and Baluchestan, Zahedan, Iran

²Faculty of Engineering, Computer Engineering Department, Yazd University, Yazd, Iran

³Faculty of Engineering, Computer Engineering Department, Yazd University, Yazd, Iran

Abstract

The processing of point clouds is one of the growing areas in machine vision. With the advent of inexpensive depth sensors, there has been a great interest in point clouds to detect three-dimensional objects. In general, 3D object recognition methods are alienated into two classes: local and global feature-based methods. In global feature-based methods, the entire shape of the model is described,

* Corresponding author

* نویسنده عهده دار مکاتبات

while in local methods, the geometric properties of the local area around a point are used to obtain the characteristic of the point. Unlike global methods, local methods do not entail any segmentation and they are more robust to clutter and occlusion. The local feature-based methods extract some geometric features from local surfaces around specific points named keypoints. The geometric features of a keypoint are encoded into a feature descriptor. How to describe the environment around a keypoint is the main challenge of these methods. The commonly used local feature-based methods often are sensitive to noise, varying mesh resolution, and rigid transformation. To overcome such disadvantages, in this paper, a new local feature descriptor based on the Mercator projection is proposed. The Mercator projection is one of the most popular 3D to 2D projections that can preserve true distance, direction, and relative longitude and latitude between any two points in point clouds. To evaluate, the proposed method has been compared with several state-of-the-art descriptor methods. The superiority of this method over other methods is shown by using the criteria of square Root Mean Square Error (RMSE), Recall versus 1-Precision Curve (RPC), and registration correction, rotation, and translation errors, and it is proved that this method has good descriptiveness power and it is robust to noise and varying mesh resolution.

Introduction

In this paper, we propose a new local descriptor to provide robust and precise geometric features. The geometric features are extracted using the Mercator projection of the neighborhood sphere. Our contributions are as follows: (1) The proposed descriptor directly learns from the point clouds (2) using the proposed method, there is only one representation for each point so the problem of multiple representations of a point is addressed. Also, the Mercator projection has many properties that make it appropriate for data representations in a point cloud. (3) It can accurately describe the geometric properties around a point. (3) The Mercator projection is a conformal projection so it preserves true distances, directions, and relative longitudes and latitudes. (4) It keeps small element geometry, which means Mercator projection preserves the shapes of small regions.

The proposed method

Given a query point p , a sphere of radius r is centered at p for determining the neighbor points. Then Mercator projection is used for mapping the sphere into a plane with considering the Local reference frame (LRF) as previously suggested by Tombaret al. (2010b). The Mercator projection is a cylindrical projection that was proposed by G. Mercator in 1569. In this projection, the surface of a sphere is mapped into a plane. It preserves true distances, directions, and relative longitudes and latitudes. The Mercator projection for each point is identified using two following equations:

$$\begin{aligned} x &= \lambda \\ y &= \ln(\tan(\frac{\phi}{2} + \frac{\pi}{4})) \end{aligned} \quad (2)$$

where λ is the longitude and ϕ is the latitude of a point in the sphere, and (x, y) represents corresponding point in the Cartesian map. For extracting images as the input of the Siamese network, we need ranges for achieved x and y . The variable x is in the interval $[-\pi, \pi]$ but range of y is different for the Mercator projection of each keypoint. As a result, the minimum and maximum of the variable y for all neighbor points are considered as the range of y , then a histogram 30×30 is measured. The Mercator projections of all neighbors are defined and the number of points in each bin counted. Then we normalize the histogram by dividing each bin by the total number of neighbor points, it causes more robustness to noise and mesh resolution.

Results and discussion

The performance of the proposed method is evaluated on the Bologna (Tombari et al., 2010c) and John Burkardt in terms of RMSE, RPC and registration correction rate, rotation and translation errors. The proposed outperforms other methods in term of RPC also the results show that the method is robust to noise, rigid transformation and varying mesh resolution.

Keywords: Point cloud, 3D object recognition, Local descriptor, Mercator projection.

را شامل نمی‌شوند؛ بنابراین اطلاعات هندسی ارزشمندی در آن‌ها از دست می‌رود که تأثیر قابل‌ملاحظه‌ای در دقت الگوریتم‌های بینایی ماشین دارد. همچنین این روش‌ها نسبت به تغییرات روشنایی، سایه و تغییر دید بسیار حساس هستند. با پیشرفت فناوری و دسترسی آسان به حس‌گرهایی مانند رادار، توجه زیادی به استفاده از ابرهای

۱- مقدمه
تشخیص اشیای سه‌بعدی یکی از مسائل اساسی در بینایی ماشین است که در سال‌های اخیر توجه زیادی به آن جلب شده است. در روش‌های سنتی از تصاویر دوبعدی برای تشخیص اشیای استفاده می‌شود. از آن‌جا که این تصاویر نگاشت دنیای سه‌بعدی به دو بعد هستند، اطلاعات عمق

یک نقطه، تک نقطه‌ای در نظر گرفته می‌شود که بیشترین شباهت را با آن دارد [20, 12].

در مرحله بعد مدل‌های منتخب تعیین می‌شوند، که به این عمل ایجاد فرضیه گفته می‌شود که این کار با استفاده از نقاط متناظر انجام و برای هر کدام از آن‌ها تبدیل صورت گرفته مشخص می‌شود، سپس به‌ازای هر زوج مدل و صحنه مرحله ثبت کردن انجام می‌شود. ثبت کردن ابرهای نقطه‌ای به دو مرحله ثبت کردن درشت و ظریف تقسیم می‌شود. در مرحله نخست با استفاده از نقاط متناظر، یک تخمین اولیه از تبدیل بین دو ابر نقطه خواهیم داشت و سپس ثبت کردن ظریف برای انطباق بیشتر و بهبود نتایج حاصل از مرحله قبل استفاده می‌شود. به عبارت دیگر، در مرحله دوم از یک حالت اولیه (خروجی مرحله نخست) آغاز کرده و روندی را برای کمینه کردن یک معیار خطا تکرار می‌کند [20]. روش RANSAC² [7] به‌عنوان معروف‌ترین روش ثبت کردن درشت و روش ICP³ [3] به‌عنوان مهم‌ترین روش ثبت کردن ظریف مطرح می‌شود.

بسیاری از روش‌های توصیف گر موضوعی نسبت به تبدیل اقلیدسی، نطفه و تغییر در وضوح مش مقاوم نیستند [12]. در این مقاله از نگاشت مرکاتور به‌منظور توصیف محیط همسایگی نقاط استفاده کرده‌ایم. نگاشت مرکاتور برای نخستین بار در سال ۲۰۱۹ برای ایجاد تصاویر مربوط به یک شبکه دوقلو سیامی در نظر گرفته شده است [22]. در این روش از تصاویر ۶۰×۶۰ که با استفاده از نگاشت مرکاتور ایجاد شده‌اند، برای نقاط متناظر در مدل و صحنه استفاده شده و سپس این تصاویر برای آموزش یک شبکه سیامی به‌کار برده شده است. درنهایت با استفاده از شبکه آموزش دیده شده، به‌ازای هر تصویر یک ویژگی ۳۲ بعدی استخراج شده است. در مقاله یادشده، تمرکز اصلی روی شبکه سیامی و آموزش آن بوده است. در این مقاله به بررسی نقش مؤثر نگاشت مرکاتور در توصیف نقاط کلیدی پرداخته شده است.

از مزایای روش پیشنهادی می‌توان به موارد زیر اشاره کرد: (۱) این روش به‌صورت مستقیم از ابرهای نقطه‌ای استفاده می‌کند. (۲) با استفاده از روش پیشنهادی به‌ازای هر نقطه، یک نمایش خواهیم داشت که باعث می‌شود، مشکل وجود نمایش‌های متعدد برای یک نقطه به‌ازای دیدهای متفاوت و درنتیجه ابهام حل شود. استفاده

نقطه‌ای برای غلبه بر این محدودیت‌ها جلب شده است [2, 12].

ابرنقطه داده بدون ساختار برای نمایش مجموعه‌ای از نقاط سه‌بعدی است که در آن x ، y و z مختصات هندسی نقاط در یک سامانه مختصات موضعی هستند. با استفاده از ابرنقطه به‌طور معمول سطح خارجی شیء نشان داده شده و در صورت متراکم و دقیق بودن، جزئیات زیادی از هندسه شیء از آن استخراج می‌شود. همچنین ابرنقطه اطلاعات مفیدی برای پردازش اشیاء و محیط فراهم می‌کند [34].

در حالت کلی روش‌های تشخیص اشیاء به دو دسته موضعی و سرتاسری تقسیم می‌شوند. در روش‌های سرتاسری [1, 4, 6, 14, 18, 21, 25, 29]، شکل کلی مدل توصیف شده است و جزئیات مسأله نادیده گرفته می‌شود. این روش‌ها نیازمند یک قطعه‌بندی اولیه هستند که گاهی انجام آن امکان‌پذیر نیست. روش‌های سرتاسری بیشتر برای بازیابی شکل استفاده می‌شوند. در روش‌های موضعی [8-10, 13, 15-17, 23, 24, 27, 28, 31-33] ویژگی هر نقطه با توجه به اطلاعات موضعی آن بیان می‌شود. در عمل بیشتر از روش‌های موضعی استفاده می‌شود؛ زیرا همیشه قطعه‌بندی اولیه نداریم و همچنین به‌طور معمول در حالتی که اشیاء تا حدی هم‌پوشانی دارند و یا پدیده‌ی انسداد و درهم‌ریختگی وجود دارد، که این مسأله در دنیای واقعی به‌وفور دیده می‌شود، روش‌های موضعی نتایج بسیار بهتری ارائه داده و درنتیجه محبوبیت بیشتری دارند [12].

تشخیص اشیاء به‌صورت موضعی از شش مرحله تشخیص نقاط کلیدی، توصیف ویژگی موضعی، تطبیق ویژگی، ایجاد فرضیه، ثبت کردن درشت و ثبت کردن ظریف، و تأیید تشکیل شده است [12]. به‌دلیل حجم بسیار زیاد ابرهای نقطه‌ای، که به‌طور معمول شامل میلیون‌ها نقطه هستند، پیچیدگی محاسباتی بالایی اعمال می‌کنند؛ بنابراین برای کاهش حجم محاسباتی و همچنین کاهش خطا، تعدادی از نقاط که اطلاعات غنی دارند استخراج می‌شوند که به آن‌ها نقاط کلیدی گفته می‌شود. در مرحله دوم، باید اطلاعات هندسی اطراف نقاط به‌وسیله توصیف‌گرهای ویژگی موضعی تعیین شود؛ سپس نقاط متناظر در مدل و صحنه^۱، با توجه به مقادیر ویژگی‌ها مشخص می‌گردد. به‌طور معمول برای پیدا کردن متناظر

² Random Sample Consensus (RANSAC)

³ Iterative Closest Point (ICP)

¹ Scene

از نگاشت مرکاتور در روش پیشنهادی مفید است زیرا: (۳) با استفاده از نگاشت مرکاتور می‌توان به صورت دقیقی محیط اطراف یک نقطه را توصیف کرد. (۴) نگاشت مرکاتور یک نگاشت همدیس است، یعنی این نگاشت زاویه و جهت را به صورت موضعی حفظ می‌کند؛ بنابراین این نگاشت در ابرهای نقطه‌ای می‌تواند تمامی این ویژگی‌ها را بین هر دو نقطه حفظ کند. (۵) این نگاشت، هندسه عناصر کوچک را حفظ کرده و به خوبی می‌تواند خصوصیات هندسی اطراف یک نقطه را توصیف کند.

روش پیشنهادی با تعدادی از توصیف‌گرهای موضعی مطرح، بر اساس نمودار RPC^1 و معیارهای خطای جذر میانگین مربعات^۲، خطای چرخش^۳، خطای انتقال^۴ و ثبت کردن صحیح^۵ مقایسه شده است. نتایج نشان می‌دهد که این روش علاوه بر اینکه ویژگی توصیفی خوبی فراهم می‌کند، نسبت به نوفه و تغییر وضوح مش نیز به نسبت پایدار است.

در ادامه بخش‌های مختلف به این صورت سازمان‌دهی شده است: در بخش دوم مروری بر تعدادی از روش‌های توصیف‌گر موضعی خواهیم داشت و در بخش سوم روش پیشنهادی مطرح خواهد شد؛ سپس در بخش چهارم نتایج حاصل از روش پیشنهادی و همچنین مقایسه با روش‌های توصیف‌گر موضعی دیگر نشان داده شده و در نهایت در بخش پنجم نتیجه‌گیری آورده شده است.

۲- روش‌های پیشین

در این بخش، برخی از توصیف‌گرهای موضعی به اختصار توضیح داده می‌شود. این روش‌ها با توجه به عملکرد خوب آن‌ها در سناریوهای مختلف انتخاب شده‌اند.

در سال ۲۰۰۴، روش 3DSC^۶ مطرح شد که در آن اطراف نقطه‌ی موردنظر یک کره در نظر گرفته می‌شود. قطب شمال با توجه به نرمال سطح در نظر گرفته شده و تقسیم‌بندی به صورت شعاعی و آزمون و بلندی صورت می‌گیرد [8]. تعداد نقاط هر انبارک شمرده شده و هر انبارک با توجه به حجمش وزن می‌گیرد و در نهایت هیستوگرام به عنوان یک توصیف‌گر به دست می‌آید.

در روش PFH^7 برای هر جفت نقاط همسایه، یک قاب داربوکس در نظر گرفته می‌شود [23]. سه متغیر

زاویه‌ای وابسته به نرمال‌های سطحی در این قاب و همچنین فاصله اقلیدسی، چهار هیستوگرام را کدگذاری می‌کنند؛ سپس این چهار هیستوگرام برای ایجاد توصیف‌گر نهایی باهم ادغام می‌شوند. روش $FPFH^8$ به عنوان بهبود روش PFH معرفی شده است که پیچیدگی محاسباتی آن را کاهش می‌دهد [24]. در $FPFH$ تنها ارتباط مستقیم بین نقطه کلیدی و همسایگان در نظر گرفته می‌شود.

روش RSD^9 در سال ۲۰۱۰ ارائه شد که در آن برای هر جفت نقطه کلیدی با یک همسایه، فاصله و زاویه بین نرمال‌ها اندازه‌گیری می‌شود [17]. پس از آن، توصیف‌گر توسط نقاطی با بیشینه و کمینه شعاع تعریف می‌شود. در روش $SHOT^{10}$ ، یک شبکه کروی ایزوتروپیک به ازای هر نقطه کلیدی تشکیل می‌گردد [28]. در هر انبارک، یک هیستوگرام با توجه به زاویه بین نرمال‌ها به دست آمده و سپس تمامی هیستوگرام‌های موضعی به منظور تشکیل توصیف‌گر نهایی ادغام می‌شوند.

در سال ۲۰۱۳، روش $RoPS^{11}$ پیشنهاد داده شد که در آن ابتدا LRF^{12} با استفاده از بردارهای ویژه به دست آمده از ماتریس کواریانس تمامی نقاط همسایگی، نه تنها نقاط مش، محاسبه می‌شود [10]. LRF به دست آمده از این روش نسبت به نوفه و تغییرات وضوح مقاوم‌تر است؛ زیرا از تمامی نقاط همسایگی استفاده می‌کند؛ سپس $RoPS$ توسط نگاشت چرخشی نقاط همسایه بر روی محورهای این LRF محاسبه و مجموعه‌ای از ویژگی‌های آماری را ایجاد می‌کنند.

در سال ۲۰۱۶، روشی به نام $LFSH^{13}$ مطرح شد که توصیف کاملی از هندسه موضعی با کدگذاری از خصوصیات آماری‌شان در عمق موضعی، چگالی نقطه، و زاویه بین نرمال‌ها ایجاد می‌کند [30]. در این روش نرمال سطح به عنوان LRA^{14} در نظر گرفته و سپس اطراف هر نقطه‌ی کلیدی p یک کره به شعاع r در نظر گرفته شده و صفحه مماس به این کره در محل تلاقی LRA با کره L نامیده می‌شود. حال فاصله عمودی هر نقطه با تصویر آن در صفحه L ، به عنوان عمق موضعی، زاویه بین نرمال‌ها به عنوان ویژگی دوم و فاصله تصویر هر نقطه با تصویر نقطه

⁸ Fast point Features Histograms (FPFH)

⁹ Radius based Surface Descriptor (RSD)

¹⁰ Signature of Histograms of Orientations

¹¹ Rotational Projection Statistics (RoPS)

¹² Local Reference Frame (LRF)

¹³ Local Feature Statistics Histogram (LFSH)

¹⁴ Local Reference Axis (LRA)

¹ Recall versus 1-Precision Curve (RPC)

² Root Mean Square Error (RMSE)

³ Rotation error


⁴ Translation Error

⁵ Correct Registration

⁶ 3D Shape Context (3DSC)

⁷ Point Features Histograms (PFH)

نگاشت مرکاتور این نقطه در مدل را نشان می‌دهد. در قسمت ۱- (ج) نقطه کلیدی متناظر این نقطه در صحنه و همچنین کره همسایگی و LRF به دست آمده و در قسمت ۱- (د) نگاشت مرکاتور مربوط به این نقطه نشان داده شده است. همان‌طور که انتظار می‌رود نگاشت مرکاتور برای دو نقطه متناظر به‌طور تقریبی یکسان است؛ زیرا آن‌ها اطلاعات هندسی اطراف دو نقطه را نشان می‌دهند که به‌صورت صلب باهم برابرند، به عبارت دیگر با اعمال یک تبدیل اقلیدسی بر هم منطبق‌اند. سپس به‌ازای هر نگاشت مرکاتور یک هیستوگرام 30×30 در نظر گرفته می‌شود.



(شکل ۱): نگاشت مرکاتور به دست آمده با استفاده از روش پیشنهادی برای دو نقطه متناظر، (الف) نقطه کلیدی در مدل و (ب) نگاشت مرکاتور مربوط به نقطه کلیدی در مدل، (ج) نقطه کلیدی در صحنه و (د) نگاشت مرکاتور نقطه کلیدی در صحنه

(Figure-1): Mercator projections of two corresponding points, a keypoint in the model (a) and its Mercator projection (b) a keypoint in the scene (c) and its Mercator projection (d)

برای به دست آوردن هیستوگرام به بازه x و y نیاز است. متغیر x در بازه $[-\pi, \pi]$ است، اما بازه y به‌ازای هر نقطه کلیدی متفاوت است. کمینه و بیشینه y در تمامی نقاط همسایه به‌عنوان بازه y در نظر گرفته می‌شود. در نهایت تعداد نقاط در هر انبارک شمرده شده و بر تعداد کل نقاط تقسیم می‌شود. این عمل باعث می‌شود که روش پیشنهادی حساسیت کمتری نسبت به نوفه و تغییرات وضوح مش داشته باشد. در نهایت این هیستوگرام برداری شده و یک ویژگی نه‌صد بعدی به‌عنوان توصیف‌گر در نظر گرفته می‌شود. (شکل ۲)، نمودار جعبه‌ای مربوط به روش پیشنهادی را نشان می‌دهد.

p در صفحه L ، به‌عنوان فاصله افقی نگاشت محاسبه می‌شود. به‌ازای هر کدام از این‌ها یک هیستوگرام رسم شده و در نهایت توصیف‌گر از ادغام این هیستوگرام‌ها به دست می‌آید.

روش LSAH^۱ در سال ۲۰۱۸ ارائه شد [16]. توصیف‌گر LSAH با استفاده از الحاق پنج هیستوگرام نرمال به دست می‌آید. این هیستوگرام‌ها روابط بین نقطه کلیدی و نقاط همسایه و نرمال‌های آن‌ها را نشان می‌دهند.

۳- روش پیشنهادی

در تمامی توصیف‌گرهای موضعی، ویژگی نقطه با توجه به اطلاعات موضعی آن تعیین می‌شود، در این مقاله برای توصیف موضعی یک نقطه، نگاشت مرکاتور پیشنهاد داده شده است. نگاشت مرکاتور یکی از معروف‌ترین نگاشت‌های سه‌بعدی به دوبعدی است که از آن برای نقشه زمین نیز استفاده می‌شود. این نگاشت توسط گرادوس مرکاتور پیشنهاد داده شده و در حقیقت نگاشت همدیس سطح کره به روی استوانه است که همه اشکال، فاصله واقعی، زاویه، جهت و طول و عرض جغرافیایی نسبی را حفظ می‌کند [5]؛ بنابراین این نگاشت می‌تواند در ابرهای نقاط نیز تمامی این ویژگی‌ها را بین هر دو نقطه حفظ کند. معادلات تبدیل در این نگاشت به‌صورت زیر است (برای جزئیات بیشتر در مورد نگاشت مرکاتور به [26] مراجعه شود):

$$\begin{aligned} x &= \lambda \\ y &= \ln\left(\tan\left(\frac{\phi}{2} + \frac{\pi}{4}\right)\right) \end{aligned} \quad (1)$$

که در آن λ طول جغرافیایی و ϕ عرض جغرافیایی هستند. در روش پیشنهادی ابتدا کره‌ای به شعاع r برای تعیین همسایگی در نظر گرفته می‌شود، سپس برای به دست آوردن نگاشت مرکاتور، به یک LRF نیاز است. در این مقاله از LRF پیشنهادی در [28] استفاده شده که در آن برای به دست آوردن محورهای مختصات از ماتریس کواریانس وزن‌دار استفاده می‌شود؛ به این صورت که نقاط دورتر وزن کمتری می‌گیرند.

بعد از محاسبه LRF، برای هر نقطه در سطح کره همسایگی، نگاشت مرکاتور را تعیین می‌کنیم. در شکل ۱- (الف) نقطه کلیدی در مدل همراه با کره همسایگی و LRF به دست آمده نشان داده شده است، قسمت ۱- (ب)

^۱ Local Surface Angles Histogram (LSAH)

مجموعه داده جان بورکارت نیز از تعدادی اشیای ساده تشکیل شده که تعدادی از آن‌ها در شکل (۳-ب) نشان داده شده است. در این بخش روش پیشنهادی با روش‌های LSAH, RoPS, SHOT, FPFH, PFH, 3DSC, LFSH و RSD مقایسه شده است. تمامی روش‌ها به‌غیر از روش LFSH و LSAH در کتابخانه PCL در دسترس عموم قرار دارند. این دو روش را نیز با کد C++ پیاده‌سازی کرده‌ایم.

۴-۱- مقایسه روش‌های مختلف بر اساس ثبت کردن دوگانه

در این آزمایش ابتدا ۲۴ جفت مدل و صحنه از مجموعه داده بولوگنا تولید شد، به این صورت که ماتریس‌های تبدیل اقلیدسی تصادفی که شامل چرخش و انتقال است، ایجاد شد؛ سپس به‌ازای هر مدل و صحنه، صد نقطه کلیدی تصادفی انتخاب شد. گفتنی است که نقاط کلیدی و شعاع پشتیبانی برای تمامی روش‌ها یکسان است؛ شعاع پشتیبانی پانزده برابر وضوح مش^۴ (mr) تنظیم شد؛ سپس ویژگی‌های نقاط کلیدی مطابق آنچه در بخش ۳ بیان شد محاسبه شده و روش RANSAC به‌منظور ثبت کردن درشت استفاده شده است. نتایج ابتدا به‌صورت کیفی و سپس به‌صورت کمی نشان داده می‌شود. نتایج کیفی روش پیشنهادی برای سه جفت مدل و صحنه در شکل (۴) آمده است، در تصاویر سمت راست (الف) مدل با رنگ آبی و صحنه با رنگ بنفش ارائه شده است؛ سپس نقاط متناظر استخراج شده با استفاده از روش پیشنهادی، در قسمت (ب) نشان داده شده که در آن خطوط سبز بیانگر تناظر درست و خطوط قرمز بیانگر تناظر نادرست است و در تصاویر سمت چپ (ج) نتایج نهایی ثبت کردن درشت نشان داده شده است. همان‌طور که تصاویر نشان می‌دهند تمامی تناظرهای تخمین زده به‌وسیله روش پیشنهادی درست هستند و تمامی خطوط با رنگ سبز نشان داده شده، همچنین تصاویر سمت چپ نشان می‌دهند که با استفاده از روش پیشنهادی؛ حتی بدون استفاده از ثبت کردن ظریف، دو شیء به‌طور کامل بر هم منطبق شده و ثبت کردن به‌صورت ایده‌آل انجام شده است.

برای بررسی کمی روش پیشنهادی و همچنین مقایسه با روش‌های دیگر، از معیارهای خطای جذر میانگین مربعات، خطای چرخش θ_r ، خطای انتقال d_t و

^۴ Mesh Resolution (mr)



(شکل-۲): بلوک دیاگرام مربوط به روش پیشنهادی
(Figure-2): The block diagram of the proposed method

۴- نتایج و بحث

برای پیاده‌سازی ایده‌ی پیشنهادی از کتابخانه^۱ PCL کمک گرفته شده است، این کتابخانه به‌صورت منبع باز و به زبان C++ پیاده‌سازی شده و شامل توابعی برای محاسبه بردار نرمال، خواندن و نمایش ابرهای نقطه‌ای، محاسبه نقاط همسایگی و غیره است. از مجموعه داده بولوگنا^۲ [28] و جان بورکارت^۳ برای آزمایش و مقایسه روش پیشنهادی با روش‌های قبلی استفاده شد. مجموعه داده بولوگنا شامل شش مدل و ۴۵ صحنه است که هر صحنه به‌وسیله سه تا پنج مدل که تبدیل اقلیدسی داشته‌اند، تولید شده است. تعدادی مثال از ابرهای نقطه‌ای این مجموعه داده در شکل (۳-الف) نشان داده شده است.

^۱ <http://pointclouds.org/>

^۲ Bologna

^۳ <https://people.sc.fsu.edu/~jburkardt/>

معیار ثبت کردن صحیح ۱۰۰٪ برسد. در روش RoPS و روش LSAH نیز این معیار یک به دست آمده است. روش پیشنهادی بهترین نتیجه را در خطای دوران داشته و در معیارهای خطای جذر میانگین مربعات و خطای انتقال در جایگاه دوم بعد از روش LSAH قرار دارد. روش SHOT توانست ۶۶٪ ثبت صحیح انجام دهد، اما روشهای دیگر کارایی خوبی نشان ندادند.

این آزمایش به طریق مشابه برای ۳۰ جفت مدل و صحنه در مجموعه داده جان بورکارت نیز انجام شده است. در اینجا نیز به ازای هر مدل و صحنه، صد نقطه کلیدی به صورت تصادفی انتخاب شده و شعاع پشتیبانی پانزده برابر وضوح مش در نظر گرفته شده است. نتایج در جدول (۲) نشان داده شده است. هر سه روش LSAH، RoPS و روش پیشنهادی توانستند برای تمامی جفت ها ثبت کردن صحیح انجام دهند. نتایج نشان می دهد روش پیشنهادی در معیارهای خطای جذر میانگین مربعات و خطای انتقال، دومین بهترین بعد از روش LSAH و در معیارهای خطای دوران، سومین بهترین بعد از روش های LSAH و RoPS است، اگرچه این مقادیر برای هر سه روش نزدیک به صفر است. این نتایج ثابت می کند که روش پیشنهادی نسبت به تبدیل اقلیدسی پایداری خوبی از خود نشان می دهد.

همچنین میزان ثبت کردن صحیح استفاده شد که این معیارها به صورت زیر محاسبه می شوند [11]:


$$RMSE = \sqrt{\frac{\sum_{k=1}^N \|R_e p_k + t_e - q_k\|^2}{N}} \quad (2)$$

$$\theta_r = \cos^{-1} \left(\frac{\text{trace}(R_{GT} R_e^T) - 1}{2} \right) \frac{180}{\pi} \quad (3)$$


$$d_t = \|T_{GT} - T_e\| \quad (4)$$


که در آن p_k و q_k نقاط متناظر، N تعداد نقاط متناظر، R_{GT} ماتریس چرخش واقعی، R_e ماتریس چرخش تخمین زده شده، T_{GT} بردار انتقال واقعی و T_e بردار انتقال تخمین زده شده هستند. اگر خطای چرخش یک ثبت کردن کمتر از مقدار آستانه τ_r و خطای انتقال آن کمتر از مقدار آستانه τ_t باشد، به عنوان ثبت کردن صحیح تخمین زده می شود، بنابراین معیار ثبت کردن صحیح برابر است با تعداد ثبت کردن صحیح تقسیم بر تعداد کل ثبت کردن ها. در این آزمایش اگر خطای چرخش کمتر از پنج درجه و خطای انتقال کمتر از پنج برابر وضوح مش باشد، ثبت کردن، صحیح در نظر گرفته می شود.

نتایج کمی برای ۲۴ جفت مدل و صحنه در جدول (۱) نشان داده شده است. نتایج نشان می دهد که الگوریتم پیشنهادی کارایی خوبی نشان داده و توانسته است به



(شکل-۳): تعدادی از ابرهای نقطه ای متعلق به مجموعه داده بولوگنا [28] و جان بورکارت (Figure-3): Some point clouds of the Bologna dataset [28] (a) and the dataset of John Burkardt (b)





(شکل-۴): مراحل ثبت کردن سه جفت مدل و صحنه با استفاده از روش پیشنهادی
(Figure-4): Registration steps for three pairs of model and scene

(جدول-۱): نتایج ثبت کردن دوگانه در مجموعه داده بولوگنا

(Table-1): Pairwise registration results on the Bologna dataset

روش‌ها	خطای جذر میانگین مربعات	خطای انتقال	خطای چرخش	ثبت کردن صحیح
روش پیشنهادی	$2/2812 \times 10^{-7}$	$1/2650 \times 10^{-7}$	$0/0270$	۱
[23] FPFH	$2/2498$	$2/2502$	$92/0649$	$0/2500$
[17] RSD	$0/8852$	$0/8756$	$97/1618$	$0/0417$
[8] 3DSC	$1/6754$	$1/6756$	$96/5474$	۰
[29] LFSH	$1/7327$	$1/7208$	$77/3431$	$0/1667$
[22] PFH	$1/2975$	$1/2992$	$98/8903$	$0/2500$
[27] SHOT	$0/6092$	$0/6196$	$44/2603$	$0/6667$
[10] RoPS	$2/2976 \times 10^{-7}$	$1/2526 \times 10^{-7}$	$0/0279$	۱
[16] LSAH	$2/8770 \times 10^{-8}$	$2/1930 \times 10^{-8}$	$0/0282$	۱

(جدول-۲): نتایج ثبت کردن دوگانه در مجموعه داده جان بورکارت

(Table-2): Pairwise registration results on the dataset of John Burkardt

روش‌ها	خطای جذر میانگین مربعات	خطای انتقال	خطای چرخش	ثبت کردن صحیح
روش پیشنهادی	$5/8153 \times 10^{-5}$	$1/1472 \times 10^{-4}$	$0/0354$	۱
[23] FPFH	$25/4150$	$22/4934$	$9/3470$	$0/8966$
[17] RSD	$106/9108$	$65/0830$	$86/4222$	$0/1000$
[8] 3DSC	$61/5034$	$44/3833$	$77/3581$	$0/2333$
[29] LFSH	$96/9788$	$50/5206$	$67/7520$	$0/2667$
[22] PFH	$28/5319$	$25/5098$	$30/9807$	$0/6330$
[27] SHOT	$0/1046$	$0/2889$	$6/6811$	$0/9620$
[10] RoPS	$4/8228 \times 10^{-5}$	$1/0325 \times 10^{-4}$	$0/0311$	۱
[16] LSAH	$3/0240 \times 10^{-4}$	$8/0747 \times 10^{-4}$	$0/0344$	۱

استفاده شد. برای تمام توصیف‌گرهای انتخاب‌شده، پارامترهای پیش‌فرض در پیاده‌سازی PCL اعمال شده است. در این قسمت، به منظور مقایسه بهتر و بررسی تأثیر نداشت مرکاتور، در این آزمایش نتایج روش پیشنهاد شده

۲-۴- مقایسه روش‌های مختلف بر اساس ویژگی توصیفی

از منحنی بازخوانی در برابر دقت (RPC) برای مقایسه توصیفی روش پیشنهادی با توصیف‌گرهای یادشده،

۳-۴- مقایسه روش‌های مختلف بر اساس

پایداری در برابر نویز

در این بخش روش پیشنهادی با توصیف‌گرهای یادشده در سطوح مختلف نوفه مقایسه شده که به این منظور نوفه گاوسی با انحراف معیار استاندارد ۰/۱، ۰/۳ و ۰/۵ وضوح مش به صحنه اضافه شده است. در شکل (۷) تصاویر به ترتیب از سمت راست، ویژگی به دست آمده مربوط به یک نقطه در صحنه بدون نوفه و ویژگی‌های مربوط به همان نقطه در صحنه با نوفه با انحراف معیار ۰/۱، ۰/۳ و ۰/۵ وضوح مش هستند. همچنین شکل (۸)، نتایج RPC مربوط به سطوح مختلف نویز گاوسی را نشان می‌دهد. توجه داشته باشید روش RoPS به نوع داده مش نیاز دارد؛ بنابراین پس از اضافه کردن نوفه، با استفاده از روشی که توسط مارتون و دیگران مطرح شده [19] و در PCL پیاده‌سازی شده، برای صحنه نوفه‌ای مش ایجاد و سپس RoPS اعمال شده است.

همان‌طور که در شکل (۸) نشان داده شده، روش پیشنهادی در جایگاه نخست قرار دارد و پس از آن، روش پیشنهادی در [22]، دومین بهترین نتیجه را در نوفه با انحراف معیار ۰/۱ وضوح مش به دست آورده است. بالاترین مقدار بازخوانی برای روش پیشنهادی در نوفه با انحراف معیار ۰/۱ وضوح مش برابر با ۰/۹۷۷۵ است که نشان می‌دهد این سطح نوفه در روش پیشنهادی به‌طور تقریبی بی‌تأثیر است.

روش پیشنهادی، در نوفه با انحراف معیار ۰/۳ و ۰/۵ وضوح مش نیز بهترین عملکرد را از خود نشان داده است. روش [2] دومین بهترین عملکرد را در نوفه با انحراف معیار ۰/۳ وضوح مش از خود نشان داد و پس از آن بهترین نتیجه مربوط به روش LSAH است. در بالاترین سطح نوفه نیز بعد از روش پیشنهادی، روش پیشنهادی در [22] بهترین نتیجه را دارد و پس از آن روش SHOT قرار گرفته است. روش LSAH در این سطح نویز حساسیت بیشتری نشان داده و به‌طور تقریبی با روش LFSH هم‌سطح تلقی می‌شود، در مقادیر آستانه کوچک روش LFSH بهتر عمل کرده ولی در مقادیر آستانه بزرگ‌تر روش LSAH نتایج بهتری ارائه داده است.

در [22] نیز آورده شده است. در ابتدا، پانصد نقطه کلیدی به صورت تصادفی برای همه مدل‌ها در هر مرحله انتخاب، سپس، نقاط کلیدی صحنه مربوطه تعیین شد. نقاط کلیدی و شعاع پشتیبانی برای تمام روش‌ها یکسان است؛ شعاع پشتیبانی پانزده برابر وضوح مش در نظر گرفته شده است.

برای رسم منحنی RPC به این صورت عمل می‌شود که ابتدا برای هر نقطه کلیدی در صحنه، نسبت بین نزدیک‌ترین و دومین نزدیک‌ترین ویژگی در مدل به ویژگی این نقطه، محاسبه می‌شود. اگر این نسبت کمتر از یک مقدار آستانه τ باشد، زوج نقطه کلیدی در صحنه و نزدیک‌ترین نقطه در مدل، به عنوان یک تطابق^۱ در نظر گرفته می‌شوند. اگر فاصله بین نقطه کلیدی صحنه و نقطه کلیدی مدل تبدیل شده در یک تطابق به اندازه کافی کوچک باشد، این تطابق به عنوان یک تطابق صحیح در نظر گرفته می‌شود. دقت، تعداد تطابق صحیح تقسیم بر تعداد کل تطابق‌ها و بازخوانی تعداد تطابق صحیح بر تعداد کل زوج‌ها است. منحنی RPC با تغییر آستانه τ ایجاد می‌شود [28].

شکل (۵) دو ویژگی به دست آمده مربوط به دو نقطه متناظر توسط روش پیشنهادی را نشان می‌دهد که همان‌طور که مشاهده می‌شود، ویژگی‌های به دست آمده برای دو نقطه متناظر شبیه هم هستند. شکل (۶) نتایج RPC را در مجموعه داده بولوگنا نشان می‌دهد. نتایج به دست آمده، متوسط مقادیر دقت و بازخوانی برای تمامی ۴۵ صحنه است. همان‌طور که مشاهده می‌کنید، روش پیشنهادی بعد از روش ارائه شده در [22]، به نتیجه بسیار خوبی رسیده، تا آنجا که بازخوانی در همان تکرارهای اولیه نزدیک به یک به دست آمده است. LSAH در جایگاه سوم و RoPS در جایگاه چهارم قرار گرفته که تفاوت زیادی با روش‌های دیگر دارند. بالاترین مقدار بازخوانی در روش پیشنهادی ۰/۹۸۵۰ در روش LSAH ۰/۹۶ و در روش RoPS ۰/۹۴۳۴ است. طبق نمودار پس از RoPS به ترتیب روش‌های SHOT، LFSH، FPFH، PFH و RSD در نهایت 3DSC قرار دارند. SHOT و LFSH نتایج منطقی دارند؛ اما نتایج روش‌های دیگر خوب نیست. همان‌طور که انتظار می‌رفت، PFH و FPFH عملکرد مشابهی از خود نشان داده‌اند.

¹ Match

پایداری در برابر تغییر وضوح مش

به‌منظور ارزیابی پایداری روش‌های مختلف در برابر تغییرات وضوح مش، مش‌های صحنه با فاکتورهای کاهش $\frac{1}{8}$ ، $\frac{1}{4}$ و $\frac{1}{2}$ ساده‌سازی شده‌اند. در شکل (۹) به ترتیب از سمت راست، ویژگی به‌دست‌آمده مربوط به یک نقطه در صحنه، و ویژگی‌های مربوط به همان نقطه در صحنه ساده‌شده با فاکتورهای کاهش $\frac{1}{8}$ ، $\frac{1}{4}$ و $\frac{1}{2}$ نشان داده شده است. همچنین شکل (۱۰)، نتایج RPC تحت فاکتورهای کاهش مختلف را نشان می‌دهد.


همان‌طور که در تصویر مشخص است، روش پیشنهاد شده در [22] در مش‌هایی با فاکتور کاهش $\frac{1}{8}$ از سایر روش‌ها بهتر عمل کرده است و پس از آن روش پیشنهادی به‌ترتیب روش‌های SHOT، LFSH، PFH، 3DSC، RoPS و درنهایت RSD قرار دارند. در حالت فاکتور کاهش $\frac{1}{2}$ ، ابتدا روش [34] و سپس روش SHOT بهترین نتایج را ارائه می‌دهند. روش پیشنهادی به‌عنوان سومین بهترین روش در مقادیر آستانه کم قرار گرفته است، اگرچه بالاترین مقدار بازخوانی در روش PFH از بالاترین مقدار بازخوانی در روش پیشنهادی بهتر است.

در حالت ساده‌سازی فاکتور کاهش $\frac{1}{2}$ ، روش RoPS بهترین عملکرد را دارد و روش [22] در جایگاه دوم قرار دارد. روش SHOT و روش پیشنهادی رقابت تنگاتنگی دارند، در مقادیر آستانه کم SHOT بهتر از روش


پیشنهادی عمل می‌کند؛ اما بالاترین مقدار بازخوانی در روش پیشنهادی از بالاترین مقدار بازخوانی در روش SHOT بهتر است. RSD به تغییرات وضوح مش بسیار حساس بوده، اما عملکرد روش‌های دیگر منطقی‌تر است.

۵- نتیجه‌گیری

در این مقاله، یک توصیف‌گر موضعی بر مبنای نگاشت مرکاتور ارائه شد که اطلاعات غنی و دقیق هندسی از محیط موضعی اطراف نقاط فراهم کرده و به‌صورت مستقیم از ابر نقطه استفاده می‌کند. با استفاده از نگاشت مرکاتور فاصله، زاویه، جهت، طول و عرض جغرافیایی نسبی حفظ می‌شود؛ بنابراین این نگاشت می‌تواند در ابرهای نقطه‌ای نیز تمامی این ویژگی‌ها را بین هر دو نقطه همسایگی حفظ کند. رویکرد پیشنهادی با تعدادی از روش‌های مطرح مقایسه شد و نتایج برتری این روش را نسبت به روش‌های دیگر بر اساس معیارهای خطای جذر میانگین مربعات، خطای چرخش و انتقال، خطای ثبت‌کردن و RPC نشان داد که اثبات می‌کند این روش نسبت به تبدیل اقلیدسی مقاوم بوده و همچنین خاصیت توصیفی خوبی ارائه می‌کند. همچنین این روش، نتایج قابل قبولی در پایداری نسبت به نوفه و تغییر وضوح مش نسبت به روش‌های دیگر ارائه کرد. با این حال این روش در بعضی مسائل پاسخ مناسبی ارائه نخواهد کرد. به‌عنوان مثال زمانی که قسمتی از شیء به‌وسیله اشیای دیگر پوشیده شده است؛ به عبارت دیگر درهم ریختگی و انسداد وجود دارد، روش‌های یادگیری عمیق نتایج بهتری ارائه خواهند داد.




(ب)




(الف)


(شکل-۵): ویژگی‌های به‌دست‌آمده برای یک نقطه در مدل (الف) و نقطه متناظر آن در صحنه (ب)
(Figure-5): The achieved features for a point in the model (a) and its corresponding point in the scene (b)



(شکل-۶): الف) نتایج RPC مربوط به تمامی توصیف گرها، ب) شکل بزرگ شده الف) برای وضوح بیشتر
(Figure-6): The RPC-based evaluation of the descriptors




(شکل-۷): ویژگی‌های به دست آمده برای یک نقطه، الف) در صحنه بدون نویز و صحنه‌های با نویز گوسی با انحراف معیار
(ب) ۰/۱ وضوح مش، (ج) ۰/۳ وضوح مش، و (د) ۰/۵ وضوح مش
(Figure-7): Achieved features for a point in (a) the noise-free scene, the scenes with standard deviation
(b) 0.1 mr, (c) 0.3 mr, and (d) 0.5 mr




(شکل-۸): نتایج RPC مربوط به تمامی توصیف گرها در سطوح مختلف نویز گوسی با انحراف معیار الف) ۰/۱ وضوح مش، (ب) ۰/۳ وضوح مش، و (ج) ۰/۵ وضوح مش

(Figure-8): RPC based evaluation of the descriptors with respect to different levels of Gaussian noise (a) noise deviation 0.1 mr (b)



(شکل-۹): ویژگی‌های به‌دست‌آمده برای یک نقطه در صحنه (الف) و در صحنه ساده‌شده با فاکتورهای کاهش $\frac{1}{8}$ (ب) $\frac{1}{4}$ (ج) $\frac{1}{2}$ (د)

(Figure-9): Achieved features for a point in the scene (a) and the simplified scenes with reduction factors 1/8 (b), 1/4 (c) and $\frac{1}{2}$ (d)



(شکل-۱۰): نتایج RPC مربوط به تمامی توصیف‌گرها در سطوح مختلف مش رزولوشن با فاکتورهای کاهش $\frac{1}{8}$ (الف) $\frac{1}{4}$ (ب) $\frac{1}{2}$ (ج)

(Figure-10): RPC based evaluation of the descriptors with respect to different mesh resolutions (a) reduction factor 1/8 (b) reduction factor 1/4 (c) reduction factor 1/2.

- [3] P. J. Besl and N. D. McKay, "Method for registration of 3-D shapes," in *Sensor fusion IV: control paradigms and data structures*, vol. 1611: International Society for Optics and Photonics, pp. 586-606, 1992.
- [4] S. Bu, L. Wang, P. Han, Z. Liu, and K. Li, "3D shape recognition and retrieval based on multi-modality deep learning," *Neurocomputing*, vol. 259, pp. 183-193, 2017.

6- References

۶- مراجع

- [1] A. Aldoma et al., "CAD-model recognition and 6DOF pose estimation using 3D cues," in *2011 IEEE international conference on computer vision workshops (ICCV workshops)*, 2011: IEEE, pp. 585-592 .
- [2] N. Bayramoglu, A. A. Alatan, "Shape index SIFT: Range image recognition using local features", In *2010 20th International Conference on Pattern Recognition*, pp. 352-355, 2010.

- [15] O. Kechagias-Stamatis and N. Aouf, "Histogram of distances for local surface description," in 2016 IEEE international conference on robotics and automation (ICRA), 2016: IEEE, pp. 2487-2493 .
- [16] R. Lu, F. Zhu, Q. Wu, and Y. Kong, "LSAH: a fast and efficient local surface feature for point cloud registration," in *Ninth International Conference on Graphic and Image Processing (ICGIP 2017)*, vol. 10615: International Society for Optics and Photonics, pp. 106151G , 2018.
- [17] Z.-C. Marton, D. Pangercic, N. Blodow, J. Kleinhellefort, and M. Beetz, "General 3D modelling of novel objects from a single view," in *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*,: IEEE, pp. 3700-3705, 2010 .
- [18] Z.-C. Marton, D. Pangercic, N. Blodow, and M. Beetz, "Combined 2D-3D categorization and classification for multimodal perception systems," *The International Journal of Robotics Research*, vol. 30, no. 11, pp. 1378-1402, 2011.
- [19] Z. C. Marton, R. B. Rusu, and M. Beetz, "On fast surface reconstruction methods for large and noisy point clouds," in *2009 IEEE international conference on robotics and automation*, pp. 3218-3223, 2009.
- [20] S. Quan, J. Ma, F. Hu, B. Fang, T. Ma, "Local voxelized structure for 3D binary feature representation and robust registration of point clouds from low-cost sensors", *Information Sciences*, vol. 444, pp. 153-171, 2018.
- [21] J. C. Rangel, J. Martinez-Gomez, C. Romero-González, I. Garcia-Varea, and M. Cazorla, "Semi-supervised 3D object recognition through CNN labeling," *Applied Soft Computing*, vol. 65, pp. 603-613, 2018.
- [22] M. Rezaei, M. Rezaeian, V. Derhami, F. Sohel, M. Bennamoun, "Deep learning-based 3D local feature descriptor from Mercator projections", *Computer Aided Geometric Design*, Vol. 74, pp. 101771, 2019.
- [23] R. B. Rusu, N. Blodow, Z. C. Marton, and M. Beetz, "Aligning point cloud views using persistent feature histograms," in 2008 IEEE/RSJ international conference on intelligent robots and systems, 2008: IEEE, pp. 3384-3391 .
- [24] R. B. Rusu, N. Blodow, and M. Beetz, "Fast point feature histograms (FPFH) for 3D registration," in 2009 IEEE international
- [5] E. L. Eisenstein and E. Elizabeth Lewisohn, *The printing revolution in early modern Europe*. Cambridge University Press, 2005.
- [6] D. Fehr, W. J. Beksi, D. Zermas, and N. Papanikolopoulos, "Covariance based point cloud descriptors for object detection and recognition," *Computer Vision and Image Understanding*, vol. 142, pp. 80-93, 2016.
- [7] M. A. Fischler and R. C. Bolles, "Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography," *Communications of the ACM*, vol. 24, no. 6, pp. 381-395, 1981.
- [8] A. Frome, D. Huber, R. Kolluri, T. Bülow, and J. Malik, "Recognizing objects in range data using regional point descriptors," in *European conference on computer vision*, 2004: Springer, pp. 224-237 .
- [9] G. Georgakis, S. Karanam, Z. Wu, J. Ernst, and J. Košecká, "End-to-end learning of keypoint detector and descriptor for pose invariant 3D matching," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 1965-1973 .
- [10] Y. Guo, F. Sohel, M. Bennamoun, M. Lu, and J. Wan, "Rotational projection statistics for 3D local surface description and object recognition," *International journal of computer vision*, vol. 105, no. 1, pp. 63-86, 2013.
- [11] Y. Guo, F. Sohel, M. Bennamoun, M. Lu, and J. Wan, "An Accurate and Robust Range Image Registration Algorithm for 3D Object Modeling," *IEEE transactions on multimedia*, vol. 16, no. 5, pp. 1377-1390, 2014.
- [12] Y. Guo, F. Sohel, M. Bennamoun, M. Lu, and J. Wan, "3D object recognition in cluttered scenes with local surface features: A survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 36, no. 11, pp. 2270-2287, 2014.
- [13] A. E. Johnson and M. Hebert, "Using spin images for efficient object recognition in cluttered 3D scenes," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 21, no. 5, pp. 433-449, 1999.
- [14] S .H. Kasaei, A. M. Tomé, L. S. Lopes, and M. Oliveira, "GOOD: A global orthographic object descriptor for 3D object recognition and manipulation," *Pattern Recognition Letters*, vol. 83, pp. 312-320, 2016.

کارشناسی ارشد و دکترای خود را از دانشگاه شیراز و دانشگاه یزد در رشته مهندسی کامپیوتر (هوش مصنوعی) دریافت کرده است. وی هم‌اکنون استادیار گروه مهندسی کامپیوتر دانشگاه سیستان و بلوچستان است. زمینه پژوهشی مورد علاقه ایشان، یادگیری ماشین، بینایی ماشین و پردازش تصویر است.

نشانی رایانامه ایشان عبارت است از:

mrezaei@ece.usb.ac.ir



مهدی رضائیان دارای دکترای فتوگرامتری از دانشگاه ETH سوئیس بوده و مدرک کارشناسی ارشد خود را در رشته مهندسی پزشکی (بیوالکتریک) از دانشگاه تهران و کارشناسی خود را در رشته مهندسی برق (الکترونیک) از دانشگاه صنعتی خواجه نصیرالدین طوسی اخذ کرده است. وی هم‌اکنون عضو هیأت علمی دانشگاه یزد است. زمینه پژوهشی ایشان شامل بینایی ماشین، پردازش تصویر و تشخیص الگو است.

نشانی رایانامه ایشان عبارت است از:

mrezaeian@yazd.ac.ir



ولی درهمی دوره کارشناسی خود را در رشته مهندسی برق (سامانه‌های کنترل هوشمند) از دانشگاه صنعتی اصفهان در سال ۱۳۷۵ به اتمام رسانیده و در سال ۱۳۷۷ و ۱۳۸۶ به ترتیب مدرک کارشناسی ارشد و دکترای خود را از دانشگاه تربیت مدرس در رشته مهندسی برق (سیستم‌های کنترل هوشمند) دریافت کرده است. وی هم‌اکنون دانشیار گروه مهندسی کامپیوتر و عضو هیأت علمی دانشگاه یزد است. زمینه پژوهشی مورد علاقه ایشان سامانه‌های فازی عصبی، کنترل هوشمند، یادگیری تقویتی، رباتیک، موتور جستجو و فناوری اطلاعات است. ایشان بیش از ۱۵۰ مقاله چاپ‌شده در نشریات کنفرانس‌های معتبر دارند.

نشانی رایانامه ایشان عبارت است از:

vderhami@yazd.ac.ir

conference on robotics and automation, 2009: IEEE, pp. 3212-3217 .

- [25] R. B. Rusu, G. Bradski, R. Thibaux, and J. Hsu, "Fast 3d recognition and pose using the viewpoint feature histogram," in 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2010: IEEE, pp. 2155-2162 .
- [26] D. Salomon, Transformations and projections in computer graphics. Springer Science & Business Media, 2007.
- [27] F. Tombari, S. Salti, and L. Di Stefano, "Unique shape context for 3D data description," in Proceedings of the ACM workshop on 3D object retrieval, 2010, pp. 57-62 .
- [28] F. Tombari, S. Salti, and L. Di Stefano, "Unique signatures of histograms for local surface description," in European conference on computer vision, 2010: Springer, pp. 356-369 .
- [29] W. Wohlkinger and M. Vincze, "Ensemble of shape functions for 3d object classification," in 2011 IEEE international conference on robotics and biomimetics, 2011: IEEE, pp. 2987-2992 .
- [30] J. Yang, Z. Cao, and Q. Zhang, "A fast and robust local descriptor for 3D point cloud registration," *Information Sciences*, vol. 346, pp. 163-179, 2016.
- [31] J. Yang, Q. Zhang, and Z. Cao, "Multi-attribute statistics histograms for accurate and robust pairwise registration of range images," *Neurocomputing*, vol. 251, pp. 54-67, 2017.
- [32] J. Yang, Q. Zhang, Y. Xiao, and Z. Cao, "TOLDI: An effective and robust approach for 3D local shape description," *Pattern Recognition*, vol. 65, pp. 175-187, 2017.
- [33] D. Zai et al., "Pairwise registration of TLS point clouds using covariance descriptors and a non-cooperative game," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 134, pp. 15-29, 2017.
- [34] "What are Point Clouds". Tech27.



معصومه رضائی دوره کارشناسی را در رشته مهندسی کامپیوتر (نرم‌افزار) از دانشگاه شهید باهنر کرمان در سال ۱۳۸۵ به اتمام رسانده و در سال ۱۳۸۹ و ۱۳۹۸ به ترتیب مدرک