

آشکارسازی نواحی موانع اطراف MAV با تکیه بر تکنیک انبساط - مبنا و در محیط بیرون با عوارض مختلف

سمیرا بدرلو^{۱*}، مسعود ورشوساز^۲

^۱ دانشجوی دکتری فتوگرامتری - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
badrloo.samira@email.kntu.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
varshosazm@kntu.ac.ir

(تاریخ دریافت اردیبهشت ۱۴۰۰، تاریخ تصویب آذر ۱۴۰۰)

چکیده

MAV ها (Micro-Aerial Vehicles) به دلیل اندازه کوچک، وزن کم و چابک بودن سکوی ایده آلی برای استفاده در محیط داخل و بیرون هستند. آن‌ها توانایی حرکت در جهت‌های مختلف را دارند؛ اما در هر جهت، موانع مختلفی است که امکان برخورد با آن‌ها وجود دارد. از این رو MAV ها به آشکارسازی و اجتناب از موانع در تمام جهات نیاز دارند. روش‌های انبساط - مبنا قابلیت آشکارسازی موانع را برای ناوبری MAV دارند. این روش‌ها تا حد زیادی درکی مشابه با درک انسان از موانع دارند و از میزان بزرگ شدن عارضه استفاده می‌کنند؛ اما بررسی الگوریتم‌های موجود برای روش انبساط - مبنا نشان می‌دهد که همه آن‌ها دارای مشکلاتی مانند آشکارسازی نقاط محدودی از موانع و آشکارسازی ناقص قسمتی از موانع هستند. دلیل این مشکلات اینست که الگوریتم‌های موجود نقطه - مبنا می‌باشند و پس از بررسی نقاط، نقاط مربوط به موانع و یا convex hull آن‌ها را به عنوان موانع ارائه می‌دهند. به طوری که نتایج ناقص سبب هدایت نادرست و برخورد MAV با موانع آشکار نشده می‌شود. هدف از این مقاله، آشکارسازی کامل نواحی موانع به منظور هدایت صحیح MAV و عدم برخورد آن با موانع اطراف در محیط بیرون با عوارض مختلف است. برای این منظور روش انبساط - مبنا جدیدی با استفاده از نواحی تصویر fisheye برای آشکارسازی موانع ارائه می‌شود. روش پیشنهادی از نواحی تصویر و افزایش مساحت آن‌ها در تصاویر متوالی استفاده می‌کند و در نهایت موانع را به صورت نواحی ارائه می‌دهد تا مشکلات موجود را حل نماید. نتایج به دست آمده بیانگر کارایی روش در محیط با عوارض مختلف می‌باشد، به طوری که ۶۷ و ۵۴ درصد از پیکسل‌های مربوط به موانع به طور میانگین و به ترتیب در دو حالت حرکت رو به جلو و حرکت به سمت راست آشکارسازی شده‌اند. علاوه بر این مقایسه روش پیشنهادی با روش Al-Kaff و همکاران (۲۰۱۷) بیانگر کارایی بالای آن نسبت به الگوریتم موجود است و نتایج آن را به طور میانگین به میزان ۴۰ و ۲۹ درصد، به ترتیب در دو حالت حرکت رو به جلو و حرکت به سمت راست بهبود داده است.

واژگان کلیدی: آشکارسازی موانع، روش‌های انبساط - مبنا، تصاویر fisheye، نواحی مربوط به موانع


* نویسنده رابط

۱- مقدمه

MAV ها به دلیل اندازه کوچک، وزن کم و چابک بودن سکوی ایده آلی برای استفاده در محیط داخل^۱ و بیرون^۲ هستند [۱، ۲]. آن‌ها در دهه اخیر کاربرد فراوانی در جستجو و نجات [۳، ۴]، بازرسی صنعتی [۵، ۶] و فیلم‌برداری [۷] داشته‌اند. MAV هایی از نوع Quadrotor توانایی حرکت در جهت‌های مختلف را دارند، در هر جهت موانع مختلفی وجود دارند که امکان برخورد با آن‌ها وجود دارد. ساختمان‌ها، درختان، انسان‌ها و سایر ساختارها نمونه‌هایی از این موانع هستند که در محیط بیرون وجود دارند. شاید اولین راه‌حل برای آشکارسازی موانع تهیه نقشه ۳ بعدی از محیط اطراف و آشکارسازی موانع با استفاده از آن باشد، اما تهیه نقشه سه‌بعدی onboard و آنلاین از محیط اطراف به دلیل محدودیت در توان محاسباتی رایانه نصب شده بر روی MAV چالش‌برانگیز است [۸، ۹]. از این‌رو نیاز به روشی برای آشکارسازی موانع می‌باشد که بتواند نواحی موانع اطراف MAV را بدون تهیه نقشه در محیط بیرون با عوارض مختلف آشکارسازی نماید.

امروزه روش‌های مختلفی برای آشکارسازی موانع پیشنهاد شده‌اند. این روش‌ها از سنسورهای فعال^۳ (مانند رادار، سونار) و غیر فعال^۴ (مانند دوربین‌های معمولی) برای آشکارسازی موانع استفاده می‌کنند. بر همین اساس، آن‌ها را می‌توان به دو دسته سنسور- مبنا [۱۰-۱۲] و تصویر- مبنا [۹، ۱۳، ۱۴] تقسیم‌بندی نمود [۱۵]. روش آشکارسازی موانع با استفاده از سنسورهای فعال، روش سنسور- مبنا نامیده می‌شود. در روش‌های سنسور- مبنا از سنسورهای فعال متنوعی مانند امواج لیزر [۱۱، ۱۶، ۱۷]، رادار [۱۱، ۱۲]، سونار [۱۸]، اولتراسونیک [۱۹]، کینکت [۲۰]، Time-of-Flight (TOF) [۲۱]، structured light، camera [۲۲] و RGB-D [۲۳] برای آشکارسازی موانع استفاده می‌شود. امواج لیزر بسیار دقیق می‌باشند، همچنین امواج سونار و اولتراسونیک قابلیت اندازه‌گیری جهت و موقعیت موانع را دارند و دارای قیمت مناسبی هستند؛ اما عوامل مختلفی همچون تراکم هوا می‌تواند

نتایج حاصل از این سنسورها را تحت تأثیر قرار دهد [۱۵]. علاوه بر این، امواج رادار می‌توانند گزینه مناسبی برای آشکارسازی موانع باشند، خصوصاً زمانی که اطلاعات تصویری کافی و مناسبی در دسترس نباشد؛ اما سنسورهای رادار معمولاً بزرگ و سنگین هستند و استفاده از آن‌ها در MAV ها با دشواری‌هایی همراه می‌باشد [۲۴]. به طور کلی، روش‌های سنسور- مبنا به دلیل وزن، اندازه، مصرف انرژی بالا، محاسبات قابل توجه [۲۵] و وابستگی به شرایط جوی [۲۶] و سایر مشکلات برای MAV ها که دارای محدودیت وزن و هزینه هستند مناسب نیستند [۱]. در مقایسه با سنسورها، دوربین‌ها اطلاعات غنی‌ای از محیط فراهم می‌کنند و وزن مناسبی دارند. روش آشکارسازی موانع با استفاده از دوربین‌ها یا سنسورهای غیر فعال، روش تصویر- مبنا نامیده می‌شود. در روش‌های تصویر- مبنا اطلاعات مربوط به موانع با استفاده از درجات خاکستری تصاویر [۲۷]، نقاط [۱۴]، لبه‌ها [۲۸] استخراج می‌شود [۲۹]. روش‌های تصویر- مبنای آشکارسازی موانع می‌توانند به دو دسته استفاده از تک تصویر [۱۳، ۱۴، ۳۰] و جفت تصویر [۸، ۹، ۳۱] تقسیم گردند. در شکل ۱ تقسیم‌بندی روش‌های تصویر- مبنا و زیرمجموعه‌های آن نمایش داده شده است. این روش‌ها در ادامه مورد بحث و بررسی قرار می‌گیرند.



شکل ۱- تقسیم‌بندی روش‌های تصویر- مبنا آشکارسازی موانع

۱-۱- روش‌های جفت تصویر

در این روش‌ها از جفت دوربین استفاده می‌شود. جفت دوربین در مقابل یا در اطراف ربات نصب می‌شود و جفت تصویر را اخذ می‌نماید. سپس با استفاده از جفت تصویر نقشه ۳ بعدی‌ای از محیط اطراف در حین حرکت ساخته می‌شود. نقشه ۳ بعدی به دست آمده برای آشکارسازی موانع استفاده می‌گردد. در تحقیقات مختلف از روش جفت تصویر آشکارسازی موانع برای هدایت افراد نابینا [۳۲]،

^۱ Indoor
^۲ Outdoor
^۳ Active
^۴ Passive

دوربین برای آشکارسازی مانع در مقابل پهباد استفاده کرده‌اند [۲۶-۲۸، ۴۱]. Ulrich و Nourbakhsh (۲۰۰۰) هر پیکسل از تصویر را برحسب درجه خاکستری‌اش به مانع و یا زمین دسته‌بندی کرده‌اند. Lee و همکاران (۲۰۱۶) از Markov random field segmentation برای آشکارسازی مانع در محیط داخل استفاده نموده‌اند. HUH و همکاران (۲۰۱۵) خط افق را برای جداسازی آسمان از زمین پیدا کرده‌اند. سپس با استفاده از الگوریتم particle filter مانع متحرک را در آسمان آشکارسازی کرده‌اند. در تحقیق Mashaly و همکاران (۲۰۱۶) پس از انجام پردازش‌ها، تصویر باینری‌ای به دست آمده است که در آن مانع از آسمان جدا شده‌اند. در تحقیق انجام شده توسط Croon و Wagter (۲۰۱۸) روش self-supervised learning برای پیدا نمودن خط افق پیشنهاد شده است و مانع به عنوان عوارضی که با خط افق تقاطع دارند آشکارسازی شده‌اند. به‌طور کلی، روش‌های ظاهر - مبنا به منظور آشکارسازی مانع، محدود به شرایط محیطی‌ای می‌باشند که جداسازی مانع از پس‌زمینه آسان می‌باشد. در حالی که فرض آشکارسازی مانع با استفاده از جداسازی مانع از پس‌زمینه، در برخی از اوقات فرض درستی نمی‌باشد [۱۵]. برای مثال، در محیط بیرون با عوارض مختلف مانند ساختمان‌ها، درختان، انسان‌ها و سایر ساختارها ممکن است مانع استخراج شده به این روش در فاصله دور قرار داشته باشد و مانع حرکت پهباد نباشد. به همین دلیل نمی‌توانند در محیط بیرون با عوارض مختلف کاربرد داشته باشند.

۱-۲-۲- روش‌های حرکت - مبنا

در این روش‌ها عمق با استفاده از اطلاعات حرکت به دست می‌آید. Optical flow متداول‌ترین روش حرکت - مبنا است [۴۲]. در این روش با استفاده از روش گرادیان Lukas-Kanade عمق به دست می‌آید [۴۳]. تحقیقات مختلفی در این زمینه انجام شده است [۳۹، ۴۴]. در تحقیق Karimi و Gharani (۲۰۱۷) روش آشکارسازی مانع شامل مراحل پردازش دو تصویر متوالی، محاسبه Optical flow و انتخاب نقاطی برای آشکارسازی مانع می‌باشد. حشرات از Optical flow برای آشکارسازی مانع استفاده می‌کنند که متناسب با الگوی پرواز آن‌ها است [۴۵، ۴۶]. برای مثال زنبورهای عسل هرگز در امتداد خط

اتومبیل [۳۳-۳۵]، UAV [۸، ۹، ۳۱] و MAV [۸، ۳۶] استفاده شده است. مشکل این روش‌ها حجم بالای محاسبات آن‌ها به دلیل تهیه نقشه سه‌بعدی به صورت آنلاین است [۸، ۹]. به طوری که استفاده از روش‌های جفت تصویر به منظور پردازش بر روی میکروپروسسور نصب شده بر روی MAV سنگین هستند [۸، ۹] و نیاز به Graphics processing unit (GPU) قوی دارند [۳۷]. به طور مثال، پهباد 2 skydio^۱ دارای ۶ دوربین fisheye است و با سیستم پردازش بسیار قوی و پرهزینه‌ای (256 Dual-Core NVIDIA Pascal™ GPU، 4GB 128-bit LPDDR4، Denver 2 64-bit CPU) این داده‌ها را پردازش می‌کند. درحالی‌که در آشکارسازی مانع نیاز به تهیه نقشه سه‌بعدی از محیط اطراف نیست و بهتر است مانع را بدون تهیه نقشه کامل از محیط اطراف آشکارسازی کرد. همچنین، در این روش‌ها کالیبراسیون دقیق سیستم تأثیرگذار می‌باشد. در صورتی‌که کالیبراسیون جفت دوربین به صورت صحیح انجام نشود و یا به مرور زمان و با توجه به ناپایداری سیستم از بین برود در دقت فاصله به دست آمده از مانع تأثیر خواهد داشت [۹].

۱-۲-۲- روش‌های تک تصویر

در روش‌های تک تصویر از یک دوربین استفاده می‌شود. به‌طوری‌که یک دوربین در مقابل یا در اطراف ربات برای آشکارسازی مانع نصب می‌شود. مطالعات مختلفی در خصوص آشکارسازی مانع با استفاده از تک تصویر انجام شده است [۲، ۱۴، ۱۵، ۳۸]. روش‌های آشکارسازی مانع با استفاده از تک تصویر می‌توانند به ۴ دسته ظاهر - مبنا [۲۶]، حرکت - مبنا [۳۹]، عمق - مبنا [۳۸] و انبساط - مبنا [۱۴] تقسیم‌بندی گردند [۴۰].

۱-۲-۱- روش‌های ظاهر - مبنا


این روش‌ها مانع را به عنوان عارضه‌ای در نظر می‌گیرند که بر روی زمینه یکنواختی قرار دارد، مانند هواپیما در آسمان، اتومبیل بر روی آسفالت. سپس از اطلاعات لبه [۲۴، ۲۸]، رنگ [۲۷، ۴۱]، بافت [۴۱] و شکل عارضه [۲۶، ۴۱] برای آشکارسازی مانع استفاده می‌گردد [۴۰]. تحقیقات مختلفی در این زمینه انجام شده است که از تک

^۱ <https://www.skydio.com/skydio-2>

راست حرکت نمی‌کنند، بلکه با الگوی زیگزاگ حرکت می‌کنند. حرکت زیگزاگ سبب تولید بردارهای حرکت می‌شود و این بردارها می‌توانند برای برآورد عمق و تشخیص موانع مورد استفاده قرار گیرند. به همین دلیل آشکارسازی موانع روبرو با استفاده از optical flow به دلیل تولید بردارهای محدود در حرکت مستقیم مشکل است [۴۷-۴۹].

۱-۲-۳- روش‌های عمق - مبنا

روش‌های عمق - مبنا با استفاده از تک تصویر اطلاعات سه‌بعدی کاملی از محیط اطراف تهیه نموده و سپس با استفاده از آن اطلاعات موانع اطراف را آشکارسازی می‌کنند [۱، ۳۸، ۵۰]. گروهی از این روش‌ها از motion stereo استفاده می‌نمایند [۱، ۲، ۳۸]. در تحقیق Hane و همکاران (۲۰۱۷) چهار دوربین fisheye نصب شده بر روی اتومبیل به اخذ تصویر می‌پردازند (مطابق با شکل ۲).



شکل ۲- دوربین‌های fisheye نصب شده در قسمت مقابل، عقب و اطراف ماشین [۳۸]

به طوری که هر کدام به صورت مستقل از دیگری به صورت تک دوربین (تصویر) به آشکارسازی موانع می‌پردازند. به همین دلیل در روش‌های تک تصویر مطرح شده‌اند. سپس برای تولید نقشه عمق^۱ از motion stereo استفاده می‌شود. Lin و همکاران (۲۰۱۸) از دوربین fisheye و Inertial measurement unit (IMU) به منظور نوابری مستقل MAV استفاده نموده‌اند. آن‌ها عمق را بر مبنای تصاویر کلیدی و با استفاده از motion stereo به دست آورده‌اند.

در سال‌های اخیر، برخی از محققان با استفاده از شبکه‌های عصبی مصنوعی عمق را به دست آورده‌اند [۵۱-۵۳]. به‌طور مثال Kumar و همکاران (۲۰۱۸) برای تخمین عمق در اطراف ماشین از ۴ دوربین fisheye و Convolutional Neural Network (CNN) استفاده کرده‌اند. Mancini و همکاران (۲۰۱۸) ساختار جدیدی برای شبکه CNN با نام Joint Monocular Obstacle Detection (J-MOD2) ارائه داده‌اند. سپس از آن برای برآورد عمق و آشکارسازی موانع استفاده کرده‌اند. هر چند طی چند سال گذشته برآورد عمق با استفاده از تک دوربین و بر اساس یادگیری عمیق به طور گسترده مورد تحقیق و توسعه قرار گرفته است، اما هنوز محدودیت‌هایی برای آن وجود دارد که باید برطرف شوند. یکی از این محدودیت‌ها در افزایش دقت است که برای این منظور محققان شبکه عصبی را عمیق‌تر می‌کنند، این امر سبب افزایش استفاده از حافظه و پیچیدگی فضا می‌شود. همچنین روش‌های یادگیری عمیق برای برآورد عمق یک چشمی همیشه از چندین شبکه استفاده می‌کنند که این امر میزان محاسبات و مصرف حافظه را افزایش می‌دهد. محدودیت دوم در تأمین داده‌های آموزشی متنوع، متعدد و باکیفیت است [۵۴]. هر چه تعداد داده‌های آموزشی در این روش‌ها بیشتر باشد سبب بهبود نتایج آن‌ها خواهد شد. به طوری که الگوریتم در فرآیند آموزش ویژگی‌های مختلف عوارض مدنظر را می‌آموزد و بر اساس این آموزش قادر به آشکارسازی آن‌ها می‌شود. پس نیاز به داده‌های آموزشی زیاد و باکیفیت (از لحاظ رادئومتریکی) ضعف اصلی این روش‌هاست [۵۵]. همچنین با توجه به این که در آشکارسازی موانع با مکان‌ها و عوارض متعدد و ناشناخته مواجه هستیم، تأمین داده‌های آموزشی مناسب در این کاربرد زمان‌بر و هزینه‌بر خواهد بود. علاوه بر این نحوه برآورد بهتر عمق صحنه‌های پیچیده برای برآوردن کاربردهای عملی هنوز یک کار بسیار چالش‌برانگیز است [۵۴].

به‌طور کلی، روش‌های عمق - مبنا به دلیل تهیه اطلاعات سه‌بعدی از محیط اطراف حجم محاسبات بالایی دارند [۱۴، ۵۰]. این مشکل در MAV ها به دلیل محدودیت در پردازش‌های سنگین و نیاز به GPU قوی بیشتر است [۳۷]. درحالی‌که در آشکارسازی موانع نیاز به تهیه نقشه عمق از محیط نیست و یافتن موقعیت موانع بدون تهیه نقشه عمق از محیط اطراف کافی است.

^۱ Depth map

۱-۲-۴- روش‌های انبساط - مبنا

در روش‌های انبساط - مبنا از نزدیک شدن و بزرگ شدن عارضه استفاده می‌شود. این روش‌ها تا حد زیادی درکی مشابه با درک انسان از مانع دارند. به‌طوری‌که عوارضی را در تصاویر جستجو می‌کنند که در تصاویر متوالی در حال بزرگ شدن هستند. تحقیقات مختلفی در این زمینه انجام شده است [۱۴، ۱۵، ۳۰، ۵۶-۵۹]. در این تحقیقات از تصاویر متوالی و معیارهای مختلف برای آشکارسازی مانع استفاده می‌شود. برای مثال Mori و Scherer (۲۰۱۳) از تغییرات مقیاس نقاط استخراج شده با استفاده از Speeded Up Robust Features (SURF) به منظور آشکارسازی مانع برای MAV استفاده کرده‌اند. Zeng و همکاران (۲۰۱۶) از بزرگ شدن مرز عارضه، Al-Kaff و همکاران (۲۰۱۷) از تغییرات مقیاس نقاط استخراج شده با الگوریتم Scale-Invariant Feature Transform (SIFT) و نسبت مساحت convex hull آن‌ها برای آشکارسازی مانع استفاده نموده‌اند. همچنین Badrloo و Varshosaz (۲۰۱۷) نسبت فواصل نقاط را در نظر گرفته‌اند. Aguilar و همکاران (۲۰۱۷) از الگوی اولیه‌ای از مانع و نقاط استخراج شده با SURF برای آشکارسازی مانع استفاده کرده‌اند. Padhy و همکاران (۲۰۱۹) از نسبت فواصل اقلیدسی نقاط متناظر برای آشکارسازی مانع استفاده کرده‌اند. Lee و همکاران (۲۰۲۱) از نسبت ارتفاع تصویری درخت به ارتفاع تصویر برای آشکارسازی درختان مانع استفاده کرده‌اند. روش‌های انبساط - مبنا مانع را بدون تهیه نقشه کامل از محیط آشکارسازی می‌نمایند. همچنین به دلیل استفاده از معیارهای هندسی مختلف مانند مقیاس نقاط SURF [۵۶]، SIFT [۱۴] و نسبت فواصل [۳۰، ۵۸] و سایر موارد قابلیت استفاده در محیط‌هایی با عوارض مختلف را دارند؛ اما الگوریتم‌های موجود برای روش انبساط - مبنا نقاط محدودی از مانع و قسمت ناقصی از مانع را آشکارسازی می‌کنند و به‌عنوان نتیجه نهایی ارائه می‌دهند. نتایج ناقص سبب هدایت نادرست و برخورد MAV با مانع آشکار نشده می‌شود.

در مباحث فوق روش‌های تصویر-مبنای آشکارسازی مانع مورد بررسی قرار گرفتند. همان‌طور که در مباحث فوق دیده می‌شود، روش‌های جفت تصویر به دنبال تهیه نقشه ۳

بعدی کاملی از محیط اطراف می‌باشند که در آشکارسازی مانع نیاز به تهیه نقشه از محیط اطراف نیست. از میان روش‌های تک تصویر روش ظاهر - مبنا از فرض ساده‌ای استفاده می‌کند و قابلیت استفاده در محیط بیرون با عوارض مختلف را ندارد. روش حرکت-مبنا برای آشکارسازی مانع مقابل کارایی ندارد [۱۴]. روش عمق-مبنا به دنبال تهیه نقشه کاملی از محیط اطراف است که در آشکارسازی مانع نیاز به تهیه نقشه از محیط اطراف نیست و یافتن موقعیت مانع نزدیک کافی است.

از بین روش‌های فوق، روش انبساط-مبنا درکی مشابه با درک انسان از مانع دارد و از آنجائی که از اطلاعات هندسی مانند فاصله [۵۸]، مقیاس نقاط [۵۶] و مساحت convex hull [۱۴] برای آشکارسازی مانع استفاده می‌کند در محیط‌هایی با عوارض مختلف قابل استفاده می‌باشد [۱۴، ۵۶، ۵۸]. همچنین به منظور آشکارسازی مانع نیاز به تهیه نقشه کاملی از محیط اطراف ندارد، به طوری که بدون تهیه نقشه از محیط اطراف مانع را آشکارسازی می‌نماید. علاوه بر این برخلاف روش حرکت - مبنا قابلیت آشکارسازی مانع مقابل را دارد. از طرفی در ناوبری MAV نیاز به روشی برای آشکارسازی مانع می‌باشد که بتواند مانع اطراف را بدون تهیه نقشه در محیط بیرون با عوارض مختلف آشکارسازی نماید. از این‌رو روش انبساط-مبنا می‌تواند قابلیت آشکارسازی مانع را برای ناوبری MAV داشته باشد؛ اما بررسی الگوریتم‌های موجود برای روش انبساط - مبنا نشان می‌دهد که همه آن‌ها از یک چالش اساسی رنج می‌برند که مربوط به آشکارسازی نقاط محدودی از مانع و آشکارسازی ناقص قسمتی از مانع است [۱۴، ۳۰، ۵۶-۵۸]. نتایج ناقص سبب هدایت نادرست و برخورد MAV با مانع آشکار نشده می‌شود. در شکل ۳ نمونه‌ای از آشکارسازی ناقص مانع در تحقیقات اخیر نمایش داده شده است. همان‌طور که از شکل ۳ قابل مشاهده است، convex hull قرمز رنگ به عنوان ناحیه‌ای از مانع آشکارسازی شده است. در صورتی که در واقعیت کل قفسه کتاب مانع هست، اما قسمت ناقصی از آن به صورت convex hull قرمز رنگ به‌عنوان مانع آشکارسازی شده است. مانع در واقعیت به صورت نواحی‌ای در محیط اطراف پهناد وجود دارند و استخراج نقاط پراکنده‌ای از مانع و آشکارسازی ناقص قسمتی از مانع اطلاعات کاملی از آن ارائه نمی‌دهد. به‌طوری‌که عدم آشکارسازی کامل نواحی مانع سبب

هدایت نادرست و برخورد MAV با موانع آشکار نشده می شود. بنابراین نیاز به روش جدیدی می باشد که بتواند این اشکالات را برطرف نماید.



شکل ۳- نمونه ای از آشکارسازی ناقص موانع به صورت convex hull قرمز رنگ [۱۴]

همان طور که بیان شد، الگوریتم های موجود برای روش های انبساط - مبنا دارای مشکلات آشکارسازی نقاط محدودی از موانع و آشکارسازی ناقص قسمتی از موانع هستند. علت این مشکل استفاده از نقاط در آشکارسازی موانع است. به طوری که این روش ها نقطه - مبنا می باشند و پس از بررسی نقاط، نقاط مربوط به موانع و با convex hull آن ها را به عنوان موانع ارائه می دهند. به همین دلیل مشکلات آشکارسازی نقاط محدودی از موانع و آشکارسازی ناقص قسمتی از موانع را دارند. در صورتی که موانع در واقعیت به صورت نواحی ای در محیط بیرون وجود دارند و بهتر است به صورت ناحیه آشکارسازی شوند. اگر به جای نقاط ناحیه موانع استخراج شود، شکل کلی ای از موانع به دست می آید و مشکل آشکارسازی نقاط محدودی از موانع و آشکارسازی ناقص قسمتی از موانع رفع می گردد. از این رو، در این مقاله روش انبساط - مبنا جدیدی با استفاده از نواحی تصویر برای آشکارسازی موانع ارائه می شود. هدف از ارائه روش پیشنهادی، آشکارسازی کامل نواحی موانع به منظور هدایت صحیح MAV و عدم برخورد آن با موانع اطراف در محیط بیرون با عوارض مختلف است. روش پیشنهادی از نواحی تصویر و افزایش مساحت آن ها در تصاویر متوالی استفاده می کند و در نهایت موانع را به صورت نواحی ارائه می دهد تا مشکلات آشکارسازی نقاط محدودی از موانع و آشکارسازی ناقص قسمتی از موانع را حل نماید. به طوری که نواحی تصویر استخراج شده و مساحت آن ها با استفاده از نقاط متناظر موجود در نواحی به دست می آید. سپس نسبت مساحت نواحی در دو تصویر متوالی مقایسه می شود. اگر این نسبت بزرگ تر از مقدار حد آستانه باشد ناحیه به عنوان موانع در نظر گرفته می شود. در نهایت نتایج نهایی به صورت تصویر باینری ای می باشد که نواحی مربوط به موانع را از غیر موانع

جدا می کند. بطوریکه نواحی مربوط به موانع در محیط بیرون با عوارض مختلف مانند ساختمان ها، درختان، انسان ها و سایر ساختارها آشکارسازی می شود.

علاوه بر این، اکثر تحقیقات موجود در هر دو روش جفت تصویر و تک تصویر از زوایای دید ۵۷ تا ۹۲ درجه استفاده کرده اند [۹، ۱۴، ۵۲]. این زاویه دید محدود، فقط قسمت مقابل پهپاد را پوشش می دهد. همچنین تعدادی از تحقیقات از دوربین های fisheye برای این منظور استفاده کرده اند [۲، ۳۸، ۶۱]. در این روش پیشنهادی نیز برای آشکارسازی موانع در اطراف پهپاد از یک دوربین fisheye نصب شده در مقابل پهپاد، استفاده می شود. دوربین های fisheye دارای زاویه دید مساوی یا بیشتر از ۱۸۰ درجه هستند و با اخذ یک تصویر علاوه بر قسمت مقابل، قسمت های بالا، پایین، چپ و راست را هم ثبت می کنند. به همین دلیل گزینه مناسبی برای آشکارسازی موانع اطراف می باشند.

این مقاله از ۴ بخش تشکیل شده است. این بخش شامل مقدمه و مروری بر روش های موجود است. بخش بعدی روند آشکارسازی موانع با استفاده از روش پیشنهادی را شرح می دهد. در بخش ۳، نحوه پیاده سازی الگوریتم شرح داده شده است. سپس نتایج مورد ارزیابی و مقایسه قرار گرفته اند. بخش آخر مربوط به نتیجه گیری مقاله است و توصیه هایی را برای کارهای آینده ارائه می دهد.

۲- روند آشکارسازی موانع با استفاده از روش پیشنهادی

همان طور که در بخش قبل بیان شد، هدف از این مقاله آشکارسازی کامل نواحی موانع به منظور هدایت صحیح MAV و عدم برخورد آن با موانع اطراف در محیط بیرون با عوارض مختلف است. برای انجام این کار از نواحی تصویر و افزایش مساحت آن ها در تصاویر متوالی استفاده می شود. به طوری که نواحی از تصویر استخراج می شود و اگر نسبت مساحت نواحی بزرگ تر از مقدار حد آستانه باشد آن ناحیه به عنوان موانع در نظر گرفته می شود. همان طور که از شکل ۴ قابل مشاهده است، روش پیشنهادی دارای ۳ مرحله اصلی اخذ و آماده سازی داده ها، استخراج نواحی و مساحت آن ها از تصاویر متوالی و سپس آشکارسازی موانع با استفاده از نسبت مساحت نواحی در تصاویر متوالی است.

سفید و غیر مانع‌ها به رنگ سیاه در آن نمایش داده می شوند. برخلاف روش‌های موجود که به دلیل نقطه- مبنا بودن دارای مشکلات آشکارسازی نقاط محدودی از مانع و آشکارسازی ناقص قسمتی از مانع هستند روش پیشنهادی نواحی را استخراج و آن‌ها را به عنوان مانع ارائه می‌دهد. این روند سبب آشکارسازی کامل مانع و بهبود مشکلات فوق می‌شود. تمامی این مراحل در ادامه با جزئیات کامل شرح داده شده‌اند.


۱-۲- اخذ و آماده‌سازی داده‌ها

همان‌طور که در قسمت بالا بیان شد، بخش اول مربوط به بدست آوردن پارامترهای کالیبراسیون دوربین و اخذ و آماده‌سازی تصاویر است. در روش پیشنهادی از تصاویر دوربین fisheye به منظور آشکارسازی موانع استفاده می‌شود. تصاویر fisheye اعوجاج زیادی (به خصوص در کناره‌های تصویر) دارند، این اعوجاج بر صحت اطلاعات هندسی (مانند مساحت) استخراج شده از این تصاویر تأثیر می‌گذارد. با توجه به این‌که در روند آشکارسازی مانع نیاز به محاسبه صحیح مساحت نواحی و نسبت آن‌ها است. به همین دلیل قبل از محاسبه مساحت نواحی باید پارامترهای کالیبراسیون به دست آیند و در مختصات نقاط اعمال شوند. کالیبراسیون تصاویر fisheye در محیط آزمایشگاه و قبل از پرواز انجام می‌شود. با اخذ تصاویر از test field و با استفاده از روش Scaramuzza و همکاران (۲۰۰۶) پارامترهای کالیبراسیون با استفاده از رابطه (۱) برای تصاویر fisheye محاسبه می‌گردد.

$$\lambda \cdot \begin{bmatrix} u'' \\ v'' \\ w'' \end{bmatrix} = \lambda \cdot g(\alpha, U') = \lambda \cdot \begin{bmatrix} (\alpha, u') \\ (\alpha, v') \\ f(\alpha, \rho') \end{bmatrix} \quad (1)$$

$$= \lambda \cdot \alpha \cdot \begin{bmatrix} u' \\ v' \\ a_0 + \dots + a_N \rho'^N \end{bmatrix} = P \cdot X \quad \lambda, \alpha > 0$$

(u', v') و (u'', v'') در رابطه (۱) به ترتیب تصویر نقطه زمینی X بر روی صفحه تصویر و صفحه سنسور می‌باشند. λ و α پارامتر مقیاس و ρ' فاصله اقلیدسی نقطه تا مرکز تصویر می‌باشد. همچنین X به عنوان مختصات homogeneous، P به عنوان ماتریس perspective projection بیان می‌گردد. فاکتور α می‌تواند با λ ترکیب شود و به طور کلی ضرایب a_i با در نظر گرفتن $i = 0, 1, 2$




شکل ۴- فلوچارت الگوریتم ارائه شده در این تحقیق

در این روش پیشنهادی، تصاویر با استفاده از دوربین fisheye اخذ می‌شوند. با توجه به اینکه استخراج اطلاعات هندسی مانند مساحت از تصاویر fisheye به دلیل وجود اعوجاج بالا در این تصاویر صحیح نیست، نیاز بدست آوردن پارامترهای کالیبراسیون و اعمال آن در مختصات نقاط می‌باشد. به همین دلیل در مرحله اول که اخذ و آماده‌سازی داده‌ها است، کالیبراسیون تصاویر fisheye انجام می‌شود و پارامترهای کالیبراسیون بدست می‌آیند. همچنین تصاویر در این مرحله اخذ می‌شوند. سپس در مرحله دوم نواحی از تصویر دوم استخراج شده و مساحت آن‌ها در هر دو تصویر با استفاده از نقاط متناظر بدست می‌آید. در نهایت در مرحله سوم نسبت مساحت نواحی به منظور آشکارسازی مانع محاسبه می‌شود، اگر نسبت مساحت‌ها از مقدار حد آستانه بیشتر باشد آن نواحی به عنوان مانع آشکارسازی می‌گردند. به‌طوری‌که نتیجه نهایی به صورت تصویر باینری‌ای است که نواحی مانع به رنگ

N ، ... همان تعداد $N+1$ پارامتر چندجمله‌ای هستند که باید در مرحله کالیبراسیون مشخص شوند. پس از به دست آوردن پارامترهای کالیبراسیون، نوبت به اخذ تصاویر می‌رسد. این تصاویر با فرض این‌که دوربین در قسمت مقابل MAV نصب شده است و در حال حرکت به سمت موانع است اخذ می‌شوند. به‌طوری‌که در ۳ جهت حرکت روبه‌جلو، حرکت به سمت راست و چپ تصاویر برای آشکارسازی موانع استفاده می‌شوند. هم‌زمان با اخذ تصاویر، تصویر اخذ شده در همان لحظه و تصویر قبل از آن به عنوان دو تصویر متوالی استفاده می‌شوند.

۲-۲- استخراج نواحی و مساحت آن‌ها از تصاویر

در این بخش پس از اخذ تصاویر، نواحی و مساحت آن‌ها از تصاویر متوالی استخراج می‌شود. با توجه به این‌که MAV در جهات مختلف مانند مقابل، چپ، راست، بالا، پایین و عقب آزادی حرکت دارد، در این راستاها نیز امکان برخورد با موانع ثابت وجود دارد. در نتیجه بررسی تمام قسمت‌های تصویر fisheye برای آشکارسازی موانع لازم نیست. به همین دلیل در ابتدا، با توجه به جهت حرکت MAV قسمت مدنظر از تصاویر برای آشکارسازی موانع انتخاب می‌گردد. در این راستا، تصویر fisheye به ۳ قسمت چپ و راست و مقابل تقسیم‌بندی می‌شود و متناسب با جهت حرکت قسمت مدنظر انتخاب می‌گردد. این کار سبب کاهش فضای جستجو و حجم محاسبات می‌گردد. محدوده این قسمت‌ها مطابق با شکل ۵ و با تقسیم تصویر به ۳ قسمت مساوی به دست آمده‌اند.



شکل ۵- ۳ قسمت مربوط به مقابل، چپ و راست MAV استخراج شده از تصویر Fisheye

پس از انتخاب قسمت مدنظر از تصویر، نواحی و مساحت‌های آن‌ها باید به دست آید. اولین روندی که برای انجام این کار به ذهن می‌رسد، استخراج نواحی از هر دو

تصویر، تناظریابی بین آن‌ها و به دست آوردن تغییرات مساحت آن‌ها است. در این روند نواحی متناظر باید به درستی استخراج و تناظریابی شوند. در صورتی‌که نواحی مشابه به درستی استخراج نشوند، قابل تناظریابی نخواهند بود [۶۳] و نمی‌توانند در آشکارسازی موانع استفاده شوند. همچنین، استخراج و تناظریابی دقیق نواحی در محیط‌هایی با عوارض مختلف مشکل است [۶۴]. هرچند در آشکارسازی موانع، استخراج نواحی نسبت به نقاط ارجحیت دارد، اما برای به دست آوردن میزان افزایش مساحت نواحی نیاز به استخراج دقیق نواحی و تناظریابی آن‌ها نیست. به همین دلیل در این روش پیشنهادی روندی ارائه می‌شود که نیاز به تناظریابی نواحی ندارد. این روند پیشنهادی شامل استخراج نواحی از تصویر دوم، یافتن نقاط متناظر بین تصویر دوم و اول و سپس به دست آوردن تغییرات مساحت نقاط متناظر محاط در نواحی است. برخلاف روند اول، در روند پیشنهادی نیاز به انجام تناظریابی نواحی نیست. در صورتی‌که بتوانیم نواحی متمایز را از تصویر دوم استخراج نماییم، این نواحی در تصویر اول نیز وجود خواهند داشت (به دلیل فاصله زمانی بسیار کم بین تصاویر). همچنین برای محاسبه مساحت نیاز به مساحت دقیق نواحی در هر دو تصویر نیست و به راحتی می‌توان مساحت به دست آمده از نقاط متناظر محاط در ناحیه را استفاده نمود. با توجه به توضیحات بیان شده در این مقاله روند پیشنهادی مورد استفاده قرار می‌گیرد و در محیط برنامه‌نویسی متلب^۱ پیاده‌سازی می‌شود.

مطابق با روند پیشنهادی، نواحی تصویر دوم با استفاده از الگوریتم seeded region growing [۶۵] استخراج می‌گردند. این الگوریتم قادر به جداسازی نواحی متمایز از هم دیگر می‌باشد. همچنین نیاز به اطلاعات اولیه‌ای مانند تعداد نواحی و رنگ آن‌ها ندارد. به‌طوری‌که از پیکسل‌های تصویر به عنوان نقاط seed استفاده می‌شود و نواحی استخراج می‌گردند. این روند تا زمانی ادامه می‌یابد که همه پیکسل‌ها متعلق به ناحیه مشخصی باشند. سپس نواحی کوچک‌تر حذف می‌گردند. در مرحله بعد نقاط متناظر از تصویر اول و دوم استخراج می‌شوند. به دلیل وجود تغییرات هندسی زیاد در دو تصویر متوالی fisheye، الگوریتم‌های شناخته شده مانند Scale-Invariant Feature

^۱ MATLAB

۳-۲- آشکارسازی مانع با استفاده از نسبت مساحت نواحی

در مرحله قبل نواحی مدنظر و مساحت آن‌ها در هر دو تصویر به دست آمد. با توجه به این‌که مساحت نواحی مربوط به مانع در تصاویر متوالی افزایش می‌یابد. در این مرحله از معیار آشکارسازی مانع که مقدار نسبت مساحت‌ها است استفاده می‌شود. نسبت مساحت‌ها در دو تصویر متوالی مطابق با رابطه (۲) محاسبه می‌شود.

$$\text{Ratio(Area)} = \frac{\text{Area}_2(i,j)}{\text{Area}_1(i,j)} \quad (2)$$

در رابطه (۲)، i و j موقعیت نقاط متناظر، $\text{Area}_1(i,j)$ و $\text{Area}_2(i,j)$ به ترتیب مساحت convex hull نقاط متناظر در تصویر اول و دوم می‌باشد. در صورتی‌که نسبت مساحت ناحیه از مقدار حد آستانه مشخصی بزرگ‌تر باشد یعنی آن ناحیه در حال نزدیک شدن است و به عنوان مانع در نظر گرفته می‌شود. در غیر این‌صورت مانع نیست. مطابق با روش Al-Kaff و همکاران (۲۰۱۷)، مقدار حد آستانه در محیط آزمایشگاه و با بررسی نسبت مساحت موانع در جهات و فواصل مختلف به دست می‌آید. در نهایت پس از تصمیم‌گیری در خصوص تمامی نواحی، تصویر نهایی به صورت تصویر باینری خواهد بود که موانع به رنگ سفید از غیر موانع به رنگ سیاه جدا شده‌اند. در تصویر نهایی حفره‌های کوچک سیاه رنگی وجود دارند که از الگوریتم closing [۷۵] برای بستن آن‌ها استفاده می‌شود.

۳- پیاده‌سازی و ارزیابی نتایج

در بخش دوم، روند کلی روش پیشنهادی آشکارسازی مانع در این مقاله بیان شد. این بخش در ابتدا پیاده‌سازی الگوریتم پیشنهادی را با جزئیات توضیح می‌دهد. از آنجائی که نوآوری این مقاله آشکارسازی نواحی مانع می‌باشد، در این بخش نشان خواهیم داد که چگونه می‌توان روش پیشنهادی را برای آشکارسازی نواحی مانع پیاده‌سازی کرد. سپس به منظور بررسی کارایی روش پیشنهادی در آشکارسازی مانع نتایج به دست آمده مورد ارزیابی و مقایسه قرار می‌گیرند.

SIFT Transform) [۶۶] قادر به تناظریابی تعداد نقاط محدودی بودند. به همین دلیل برای تناظریابی تصاویر متوالی از الگوریتم Affine-SIFT (ASIFT) [۶۷] استفاده شد. احتمال وجود نقاط متناظر اشتباه در بین این نقاط وجود دارد که این نقاط سبب محاسبه اشتباه مساحت و آشکارسازی نادرست مانع می‌شوند.

رایج‌ترین روش برای حذف نقاط متناظر نادرست، روشی است که بر اساس استفاده از ماتریس اساسی^۱ است [۶۸]؛ بنابراین در این تحقیق از ماتریس اساسی برای حذف نقاط متناظر نادرست استفاده می‌شود. روش‌های Random Sample Consensus (RANSAC) [۶۹]، M-estimator [۷۰] Least Median Squares (LMeds) Maximum Likelihood Estimation by Sample [۷۱] Consensus (MLEsac) [۷۲] و Universal RANSAC (USAC) [۷۳] می‌توانند برای شناسایی و حذف نقاط متناظر اشتباه به منظور تخمین دقیق ماتریس اساسی استفاده شوند. روش LMeds [۷۰] حساسیت کم‌تری به نقاط متناظر اشتباه دارد، به همین دلیل از این روش برای تخمین پارامترهای ماتریس F یا همان ماتریس اساسی استفاده می‌شود. برای هر انتخاب رندم پارامترهای ماتریس F و میانه مربعات باقیمانده برای مدل محاسبه می‌شوند. سپس پارامترهایی انتخاب می‌شوند که کم‌ترین میانه مربعات باقیمانده را دارند [۷۴]. با انتخاب پارامترها برای مدل نقاطی که خارج از مدل قرار می‌گیرند به عنوان نقاط اشتباه در نظر گرفته می‌شوند [۷۴]. در این الگوریتم تعداد انتخاب رندم نقاط توسط کاربر مشخص می‌شود. پس از استخراج نواحی و نقاط متناظر صحیح، نوبت به محاسبه مساحت نواحی برای آشکارسازی مانع می‌رسد. با حداقل سه نقطه غیر هم خط می‌توان یک صفحه را تشکیل داد و مساحت آن را محاسبه نمود. برای این منظور به صورت جداگانه برای هر ناحیه بررسی می‌گردد که آیا در آن ناحیه حداقل سه نقطه متناظر غیر هم خط برای محاسبه مساحت وجود دارد یا نه. اگر سه نقطه متناظر در آن ناحیه وجود نداشته باشد ناحیه مدنظر به رنگ سیاه ذخیره می‌شود. در غیر این‌صورت پارامترهای کالیبراسیون بر نقاط مدنظر اعمال و مساحت convex hull نقاط متناظر در هر دو تصویر به دست می‌آید.

^۱ Fundamental matrix

۳-۱- پیاده‌سازی

همان‌طور که در بخش دوم بیان شد، ساختار کلی الگوریتم روش پیشنهادی شامل مراحل اخذ و آماده‌سازی داده‌ها، استخراج نواحی و مساحت آن‌ها از تصویر و آشکارسازی موانع با استفاده از نسبت مساحت نواحی است. در مرحله اول که اخذ و آماده‌سازی داده‌ها می‌باشد، پارامترهای کالیبراسیون تعیین شده و تصاویر متوالی اخذ می‌گردند. در مرحله مذکور، در ابتدا به منظور تعیین دقیق پارامترهای کالیبراسیون دوربین از test field تصاویری در موقعیت‌های مختلف اخذ شد. در شکل ۶ تعدادی از این تصاویر نشان داده شده‌اند.



شکل ۶- نمایش تعدادی از تصاویر اخذ شده از test field

سپس از روش Scaramuzza و همکاران (۲۰۰۶) و OCamCalib toolbox [۷۶] که توسط آن‌ها ارائه شده است، برای محاسبه پارامترهای کالیبراسیون استفاده شد. همان‌طور که در بخش ۲ توضیح داده شد، در روش Scaramuzza و همکاران (۲۰۰۶) نیاز به تعیین $N+1$ پارامتر برای کالیبراسیون دوربین است که آن‌ها به صورت بهینه $N=4$ را در نظر می‌گیرند. با در نظر گرفتن عدد ۴ برای N ، ۵ پارامتر a_0, a_1, a_2, a_3, a_4 پس از انجام کالیبراسیون به دست آمدند. مقادیر پارامترهای به دست آمده در جدول ۱ ارائه شده است. همچنین مقدار میانگین reprojection error مساوی با $1/21$ پیکسل به دست آمد.


جدول ۱- مقادیر پارامترهای کالیبراسیون به دست آمده با روش

Scaramuzza و همکاران (۲۰۰۶) [۶۲]

a_0	a_1	a_2	a_3	a_4
-926.71	100	42×10^{-5}	-19.7×10^{-8}	19.6×10^{-11}

پس از کالیبراسیون دوربین نوبت به اخذ تصاویر می‌رسد. در اخذ تصاویر فرض بر اینست که دوربین در قسمت مقابل MAV نصب شده است (مطابق با شکل ۷) و تصاویر


به دست آمده از آن برای آشکارسازی موانع در این مقاله استفاده می‌شوند.



شکل ۷- زاویه دید دوربین fisheye در صورت نصب بر روی یک پهپاد

البته با توجه اینکه امکان نصب دوربین بر روی پهپاد و اخذ تصاویر برای نویسندگان وجود نداشت، در این تحقیق از ۴ داده تصویری که با استفاده از دوربین Fisheye از محیط بیرون اخذ شدند برای ارزیابی الگوریتم پیشنهادی استفاده شد. به منظور بررسی کارایی روش پیشنهادی در حرکت به سمت مقابل و راست (و یا چپ)، از ۴ داده اخذ شده ۲ داده در حالت حرکت مستقیم به سمت عارضه و ۲ داده دیگر در حالت حرکت از سمت راست (و یا چپ به دلیل متقارن بودن اعوجاج شعاعی در تصاویر fisheye فرقی ندارد) به سمت همان عارضه اخذ شدند. همچنین به منظور بررسی کارایی الگوریتم در محیط‌هایی با عوارض مختلف مانند ساختمان، دیوار، درخت و سایر ساختارها باشند. تصاویر با استفاده از دوربین LG 360 CAM و با ابعاد 1280×2560 پیکسل اخذ شدند. پس از اخذ تصاویر، تصویر اخذ شده در همان لحظه و تصویر قبل از آن به عنوان دو تصویر متوالی انتخاب شدند (مطابق با شکل‌های ۸ (الف و ب)). پس از اخذ و آماده‌سازی داده‌ها، متناسب با جهت حرکت پهپاد قسمت مدنظر از تصویر دوم انتخاب شد (مطابق با شکل‌های ۸ (ج)). سپس با در نظر گرفتن مقدار حد آستانه ۱۰ برای اختلاف درجات خاکستری، نواحی با استفاده از الگوریتم seeded region growing [۶۵] استخراج شدند. همچنین نواحی کوچک‌تر از ۳۰۰ پیکسل حذف شدند (این عدد با سعی و خطا به دست آمد).


نقطه متناظر ASIFT [۶۷] بودند. همچنین در شکل‌های ۹ (ج) نواحی دارای حداقل سه نقطه متناظر نمایش داده شدند.



شکل ۹- آشکارسازی مانع با استفاده از روش پیشنهادی برای ۴ داده اخذ شده، (الف) قسمت انتخاب شده، (ب) نواحی استخراج شده، (ج) نواحی دارای حداقل ۳ نقطه متناظر، (د) تصویر باینری بدست آمده از مانع به روش پیشنهادی

جدول ۲- نتایج به دست آمده از پیاده‌سازی الگوریتم پیشنهادی

	حرکت به سمت راست		حرکت به سمت مقابل	
	۹۸	۱۸۶	۱۲۲	۱۷۷
تعداد نواحی استخراج شده	۹۸	۸۵	۹۸	۸۴
درصد پیکسل‌های ناحیه بندی شده	۳۳۶۶	۱۳۷۰	۱۰۶۹	۲۱۴۵
تعداد نقاط متناظر	۲۴۷۰	۱۱۴۶	۸۹۵	۱۶۴۰
تعداد نقاط متناظر صحیح	۱۰	۳۷	۱۴	۴۸
تعداد نواحی دارای حداقل ۳ نقطه متناظر	۳۱	۴۱	۴۲	۶۲
درصد نواحی دارای حداقل ۳ نقطه متناظر	۸۸	۱۴۹	۱۰۸	۱۲۹
تعداد نواحی بدون ۳ نقطه متناظر	۶۹	۵۹	۵۸	۳۸
درصد نواحی بدون ۳ نقطه متناظر	۴	۱۶	۸	۱۹
تعداد نواحی انتخاب شده به عنوان مانع				




شکل ۸- نمایش داده اول و دوم برای حرکت به سمت مقابل و داده سوم و چهارم برای حرکت به سمت راست، (الف) تصویر اول، (ب) تصویر دوم، (ج) قسمت انتخاب شده از تصویر دوم متناسب با جهت حرکت

مطابق با شکل ۹ (ب) تصویر نواحی استخراج شده نمایش داده شده است. در جدول ۲ نتایج پیاده‌سازی مراحل مختلف الگوریتم پیشنهادی برای ۲ تصویر متوالی شکل ۸ (الف و ب) ارائه شده است. مطابق با سطر دوم جدول ۲ به منظور بررسی درصد پیکسل‌هایی از تصویر که ناحیه بندی شده‌اند، نسبت مجموع تعداد پیکسل‌های نواحی به مجموع تعداد پیکسل‌های آن قسمت از تصویر به دست آمد. این عدد به طور میانگین برای ۴ داده مساوی با ۹۱ درصد است و بیان‌گر اینست که ۹۱ درصد قسمت انتخاب شده از تصویر به نواحی مختلف تقسیم‌بندی شده است.

پس از استخراج نواحی از تصویر دوم، در مرحله بعد با استفاده از الگوریتم ASIFT [۶۷] نقاط متناظر برای محاسبه مساحت نواحی استخراج شدند. احتمال وجود نقاط متناظر اشتباه در بین این نقاط وجود داشت که سبب محاسبه اشتباه مساحت و آشکارسازی نادرست مانع می‌شدند.

به همین دلیل پس از اعمال ماتریس اساسی [۷۷] و انتخاب عدد ۲۰۰۰ به عنوان تعداد انتخاب رندم نقاط برای محاسبه پارامترهای ماتریس اساسی نقاط متناظر صحیح انتخاب شدند، تعداد نقاط متناظر به دست آمده برای هر مجموعه داده در سطر چهارم جدول ۲ نمایش داده شده است. پس از استخراج نواحی و تناظر یابی نقاط باید مساحت نواحی در هر دو تصویر به منظور آشکارسازی مانع محاسبه شوند. برای این منظور به حداقل ۳ نقطه متناظر غیر هم خط نیاز است. به همین دلیل وجود ۳ نقطه متناظر غیر هم خط در نواحی بررسی شد. مطابق با سطر ششم جدول ۲، به‌طور میانگین ۴۴ درصد از پیکسل‌های نواحی دارای حداقل ۳

۲/۵ متر یا کمتر از ۲/۵ متر از MAV قرار دارد و مانع محسوب می‌شود.



شکل ۱۰- ارتباط بین فاصله از عارضه و نسبت مساحت‌ها

در نهایت پس از مشخص شدن مقدار حد آستانه، نواحی مربوط به مانع با در نظر گرفتن حد آستانه ۱/۲۸۴ برای نسبت مساحت‌ها استخراج شدند. پس از بررسی تمام نواحی و آشکارسازی نواحی، حفره‌های تصویر با استفاده از الگوریتم closing و با انتخاب مقدار ۲۰ برای آن بسته می‌شوند. مطابق با شکل‌های ۹ (د) نتیجه نهایی به صورت تصویر باینری‌ای است که موانع را به رنگ سفید و غیر موانع را به رنگ سیاه نمایش می‌دهد. حال باید نتایج به دست آمده مورد ارزیابی قرار گیرند و با تحقیقات موجود در این زمینه مقایسه شوند که در بخش بعد نتایج به دست آمده مورد ارزیابی و مقایسه قرار خواهند گرفت.

۳-۲- ارزیابی و مقایسه روش پیشنهادی


هدف از این مقاله آشکارسازی کامل نواحی مانع به منظور هدایت صحیح MAV و عدم برخورد آن با موانع اطراف در محیط بیرون با عوارض مختلف است. برای این منظور، خروجی آن تصویر باینری‌ای است که عوارض موجود در تصویر را به دو نوع مانع (به رنگ سفید) و غیر مانع (به رنگ سیاه) طبقه‌بندی می‌نماید. به همین دلیل می‌توان از روش‌های ارزیابی طبقه‌بندی تصویر به منظور ارزیابی روش پیشنهادی در این تحقیق بهره برد. در ارزیابی روش‌های طبقه‌بندی از ماتریس confusion [۸۰] استفاده می‌گردد. این ماتریس شامل ۴ پارامتر FP ، TP ، FN و TN می‌باشد. به‌طوری‌که این پارامترها بیان‌گر تعداد پیکسل‌هایی هستند که در واقعیت مانع بوده و به عنوان مانع آشکارسازی شده‌اند (TP)، در واقعیت غیر مانع بوده و به عنوان مانع آشکارسازی شده‌اند (FP)، در واقعیت مانع

پس از استخراج نواحی و اطمینان از وجود حداقل ۳ نقطه متناظر در هر ناحیه، مساحت $convex hull$ نقاط متناظر در هر دو تصویر به دست آمد. سپس در مرحله سوم برای آشکارسازی مانع مقدار نسبت مساحت ناحیه در تصویر دوم به تصویر اول محاسبه شد، این مقدار اگر بیشتر از مقدار حد آستانه بود آن ناحیه به عنوان مانع انتخاب می‌شد. مقدار حد آستانه متناسب با فاصله لازم برای عکس‌العمل مشخص شد. همچنین فاصله لازم برای عکس‌العمل متناسب با زمان لازم برای انجام محاسبات به دست آمد. با توجه به این‌که پارامترهای کالیبراسیون در دفتر کار تهیه می‌شوند، در زمان آشکارسازی مانع نیاز به زمان محاسبه ندارند و آماده هستند. زمان لازم برای مراحل باقیمانده که مربوط به اخذ تصاویر، استخراج نواحی و نقاط متناظر، محاسبه مساحت و نسبت آن‌هاست با توجه به برقراری مشابهت با تحقیقات انجام شده [۹، ۳۲، ۷۸، ۷۹]، ۲۵۰ میلی‌ثانیه در نظر گرفته شد. به طور مثال Beul و همکاران (۲۰۱۷) با استفاده از برد کوچک مجهز به پردازنده چهار هسته‌ای Intel Core i7-4770R، ۱۶ گیگابایت حافظه DDR3 و ۴۸۰ گیگابایت SSD، در محدوده زمانی کمتر از ۲۵۰ میلی‌ثانیه آشکارسازی مانع را انجام داده‌اند. سپس با فرض سرعت ۱۰ متر بر ثانیه برای MAV عدد ۲/۵ متر به عنوان فاصله لازم برای عکس‌العمل به مانع از رابطه ۳ به دست آمد.

$$x = v \cdot t \quad (3)$$

در رابطه (۳)، x بیان‌گر فاصله، v سرعت پهباد و t زمان می‌باشد. با توجه به این محاسبات هر عارضه‌ای که در فاصله ۲/۵ متری قرار داشته باشد در محدوده خطر و برخورد پهباد قرار دارد و نسبت مساحت نواحی در این فاصله به عنوان حد آستانه در نظر گرفته می‌شود. برای یافتن نسبت مساحت معادل با فاصله ۲/۵ متری، مشابه با روش Al-Kaff و همکاران (۲۰۱۷)، با استفاده از حرکت دوربین به سمت عارضه (با سرعت ۱۰ متر بر ثانیه) و اندازه‌گیری فاصله تا عوارض و به دست آوردن نسبت مساحت برای نواحی نموداری همانند نمودار شکل ۱۰ به دست آمد. با توجه به نمودار شکل ۱۰ حد آستانه لازم برای تفکیک موانع از سایر عوارض در فاصله ۲/۵ متر، عدد ۱/۲۸۴ است. به‌طوری‌که اگر نسبت مساحت برای ناحیه‌ای مساوی یا بزرگ‌تر از عدد ۱/۲۸۴ باشد، آن ناحیه در فاصله

پیشنهادی با استفاده از ماتریس confusion، باید نواحی واقعی موانع در دسترس باشند، به همین دلیل تصویری باینری‌ای از موانع به صورت دستی تهیه شد. به طوری که فاصله عوارض نزدیک به دوربین که در مسیر حرکت آن هستند با استفاده از متر اندازه‌گیری شد. سپس مطابق با شکل‌های ۱۱ (الف-د) پیکسل‌های مربوط به موانع (عوارض موجود در فاصله کم‌تر از ۲/۵ متر) به صورت دستی و به رنگ سفید در تصویر باینری مشخص شد.



شکل ۱۱- تصاویر باینری واقعی به دست آمده از موانع، (الف) داده اول، (ب) داده دوم، (ج) داده سوم، (د) داده چهارم

در نهایت پس از مقایسه تصویر باینری واقعی از موانع با تصویر باینری به دست آمده از روش پیشنهادی، درصد دقت نتایج به دست آمده به صورت Recall، Precision و Overall accuracy به همراه زمان لازم برای پردازش در جدول ۳ برای دو حرکت به سمت مقابل و راست نمایش داده شدند.

جدول ۳- نتایج به دست آمده برای روش پیشنهادی آشکارسازی موانع و روش Al-Kaff و همکاران [۱۴]

	دقت	داده‌های حرکت به سمت مقابل		داده‌های حرکت به سمت راست	
		اول	دوم	سوم	چهارم
روش پیشنهادی	Recall (%)	۸۲	۵۲	۶۹	۳۹
	Precision (%)	۸۴	۹۹	۶۶	۹۹
	Overall accuracy (%)	۷۹	۵۶	۷۰	۴۹
	Time (s)	۲۳۰	۱۵۷	۱۷۸	۱۴۵
روش Al-Kaff و همکاران (۲۰۱۷)	Recall (%)	۳۰	۲۴	۳۹	۱۱
	Precision (%)	۶۱	۱۰۰	۵۷	۹۹
	Overall accuracy (%)	۴۵	۳۱	۶۷	۲۷
	Time (s)	۱۴۱	۴۰	۹۵	۵۳

با توجه به جدول ۳، در حالت حرکت به سمت مقابل دقت Recall برای داده اول و دوم به ترتیب ۸۲،۵۲ درصد به دست آمده است. به طوری که بخشی از ناحیه موانع با پیاده‌سازی روش پیشنهادی آشکارسازی شده است. عدم وجود حداقل ۳ نقطه متناظر در برخی از نواحی (مطابق با

بوده و به عنوان غیر موانع آشکارسازی شده‌اند (FN) و در واقعیت غیر موانع بوده و به عنوان غیر موانع آشکارسازی شده‌اند (TN).

با استفاده از ماتریس confusion پارامترهای Recall، Precision و Overall accuracy برای ارزیابی دقت به دست می‌آیند و در این تحقیق نیز از این پارامترها استفاده می‌شود. پارامتر Recall با استفاده از رابطه (۴) به دست می‌آید.

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

این پارامتر بیان‌گر کارایی الگوریتم در آشکارسازی موانع واقعی به عنوان موانع می‌باشد. با توجه به این که آشکارسازی کامل موانع و عدم برخورد با آن‌ها از اهداف اصلی این مقاله است، Recall مهم‌ترین پارامتر در ارزیابی دقت الگوریتم آشکارسازی موانع است. همچنین پارامتر Precision از رابطه (۵) به دست می‌آید.

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (5)$$

این پارامتر برای ارزیابی دقت الگوریتم در آشکارسازی غیر موانع به عنوان غیر موانع استفاده می‌شود. کم بودن مقدار درصد Precision بیان‌گر آشکارسازی غیر موانع به عنوان موانع می‌باشد و سبب محدودیت مانور MAV می‌شود. همچنین Overall accuracy به عنوان دقت کلی با استفاده از رابطه (۶) محاسبه می‌شود. در ادامه مطالب کارایی روش پیشنهادی با استفاده از این پارامترها مورد ارزیابی قرار می‌گیرد.

$$Overall\ accuracy = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (6)$$

همان‌طور که قبلاً در این مقاله بیان شد، از ۴ تصویر اخذ شده از دوربین Fisheye به منظور ارزیابی نتایج آشکارسازی موانع با روش پیشنهادی استفاده شد. پس از پیاده‌سازی روش پیشنهادی موانع آشکارسازی شده به صورت پیکسل‌های سفید رنگ در تصویر باینری به دست آمده نمایش داده شدند.

پس از استخراج نتایج نیاز به ارزیابی مطابقت آن‌ها با وضعیت واقعی موانع بود. برای این منظور از ماتریس confusion استفاده شد. برای ارزیابی کارایی روش

سطر هشتم جدول ۲) دلیل این مشکل است. در این راستا، در تحقیقات آینده مشکل عدم وجود نقاط متناظر کافی مورد بررسی قرار خواهد گرفت. همچنین دقت Precision نیز به ترتیب ۸۴ و ۹۹ درصد برای داده اول و دوم در حالت حرکت به سمت مقابل به دست آمده است. این دقت بیانگر موفقیت بالای روش پیشنهادی در آشکارسازی عوارض غیر مانع به عنوان غیر مانع است. هم‌رنگ بودن موانع نزدیک و عوارض دور و انتخاب آن‌ها به عنوان یک ناحیه کلی دلیل کم بودن این دقت برای داده اول در مقایسه با داده دوم است. در نهایت دقت کلی الگوریتم (Overall accuracy) به ترتیب برای داده اول و دوم ۷۹ و ۵۶ درصد به دست آمده است.

در حالت حرکت به سمت راست نیز، دقت Recall برای داده سوم و چهارم به ترتیب ۶۹ و ۳۹ درصد به دست آمده است. در داده چهارم این دقت نسبت به سایر داده‌ها کمتر است که با توجه به توضیحات بالا عدم وجود حداقل ۳ نقطه متناظر و همچنین احتمال وجود نقاط متناظر اشتباه به‌خصوص در لبه‌های تصویر Fisheye که کیفیت پایینی در این نواحی دارند سبب بروز چنین خطایی شده است. همچنین تشابه درجات خاکستری ناحیه مانع و نواحی عوارض دور سبب ترکیب این نواحی باهم دیگر شده است. به‌طوری‌که نقاط متناظر استخراج شده از آن‌ها ممکن است از ناحیه مانع یا غیر مانع یا ترکیبی از هر دو باشند و نسبت مساحت به دست آمده بیانگر وجود مانع نباشد. دقت Precision نیز در این حالت به ترتیب ۶۶ و ۹۹ درصد برای داده سوم و چهارم به دست آمده است. در داده سوم به دلیل تشابه درجات خاکستری مانع و عوارض دور و ترکیب آن‌ها باهم دیگر دقت به دست آمده کمتر است. در نهایت دقت کلی الگوریتم (Overall accuracy) به ترتیب برای داده سوم و چهارم ۷۰ و ۴۹ درصد به دست آمده است.


یکی از پارامترهای لازم برای ارزیابی روش پیشنهادی آشکارسازی مانع در کاربردهای آنلاین، زمان لازم برای انجام محاسبات می‌باشد. در سطر چهارم جدول ۳ زمان لازم برای انجام محاسبات روش پیشنهادی نمایش داده شده است. این زمان برای برنامه‌نویسی انجام شده در نرم‌افزار متلب و با سیستمی با مشخصات زیر ثبت شده است:

- CPU: Intel (R) Core (TM) i7-8550U CPU @ 1.80 GHz
- RAM: 12 GB
- Graphics card: NVIDIA GeForce MX130

همان‌طور که قبلاً بحث شد، زمان مدنظر برای پردازش داده‌ها بر روی MAV ۲۵۰ میلی‌ثانیه می‌باشد. درحالی‌که زمان‌های به دست آمده با توجه به استفاده از نرم‌افزار متلب و سیستم با ویژگی‌های فوق به مراتب بیشتر از زمان مدنظر ۲۵۰ میلی می‌باشد. از آنجائی که تمرکز روش پیشنهادی حاضر بر روی آشکارسازی کامل نواحی مانع به منظور هدایت صحیح MAV و عدم برخورد آن با موانع اطراف در محیط بیرون با عوارض مختلف است، میزان دقت آشکارسازی کامل نواحی مانع با استفاده از روش پیشنهادی بیشتر از زمان موردنیاز برای پردازش حائز اهمیت می‌باشد. هرچند زمان لازم برای انجام محاسبات نیز یکی از پارامترهای مهم در کاربردهای آنلاین می‌باشد به همین دلیل در تحقیقات آینده با استفاده از سیستم‌ها و زبان‌های برنامه‌نویسی دارای سرعت بالا زمان انجام محاسبات را کاهش خواهیم داد.

به منظور ارزیابی بهتر روش پیشنهادی، باید دقت روش پیشنهادی با الگوریتم‌های موجود در این زمینه مقایسه گردد. یکی از تحقیقات اخیر در روش‌های انبساط - مبنا، الگوریتم Al-kaff و همکاران (۲۰۱۷) است. برخلاف سایر الگوریتم‌ها که فقط نقاطی از مانع را ارائه داده‌اند [۳۰، ۵۶-۵۸] در الگوریتم آن‌ها علاوه بر نقاط مانع، convex hull نقاط نیز به عنوان ناحیه مانع در نظر گرفته شده است. به همین دلیل روش پیشنهادی با روش Al-Kaff و همکاران (۲۰۱۷) مقایسه شده است. برای این منظور مطابق با روش Al-Kaff و همکاران (۲۰۱۷)، نقاط متناظر با استفاده از الگوریتم SIFT [۶۶] و Brute-Force با تنظیم مقدار distance-ratio 0.28 از تصاویر متوالی داده اول، دوم، سوم و چهارم استخراج شدند. سپس نقاطی که مقدار پارامتر مقیاس SIFT در آن‌ها از تصویر اول به دوم افزایش داشته است، انتخاب شدند. در مرحله بعد مساحت convex hull نقاط باقیمانده در هر دو تصویر به دست آمد. مطابق با تحقیق Al-Kaff و همکاران (۲۰۱۷) در صورتی‌که عارضه در فاصله کمتر از ۲/۵ متر قرار داشته باشد، نسبت مجموع پارامتر مقیاس SIFT از تصویر دوم به اول بزرگ‌تر از عدد ۱ می‌باشد. همچنین نسبت مساحت convex hull از تصویر دوم به اول بزرگ‌تر از ۱/۴۵ باشد، نقاط و ناحیه convex hull به عنوان مانع شناسایی می‌شوند. نقاط مانع و ناحیه مربوط به آن در شکل ۱۲ نمایش داده شده است. همچنین نتایج به دست آمده در جدول ۳ ارائه شده است. با توجه به جدول ۳، در داده اول دقت Recall بیانگر اینست که ۳۰

درصد از مانع شناسایی شده است. همچنین دقت Precision بیان گر اینست که تنها ۶۱ درصد از عوارض غیر مانع به عنوان مانع شناسایی شده‌اند و بقیه به اشتباه به عنوان مانع آشکارسازی شده‌اند.



شکل ۱۲- مقایسه نتایج روش پیشنهادی با روش Al-Kaff و همکاران (۲۰۱۷) (الف) نتایج به دست آمده از روش Al-Kaff و همکاران به همراه نقاط مانع به رنگ قرمز و ناحیه مربوط به convex hull نقاط به رنگ سبز، (ب) نمایش نتایج به دست آمده از روش Al-Kaff و همکاران به صورت تصویر باینری (ج) نتایج به دست آمده از روش این تحقیق

همان‌طور که از شکل ۱۲ (ب) در داده اول قابل مشاهده است، نواحی آشکارسازی شده به عنوان مانع مربوط به عوارض دور بوده و به اشتباه به عنوان مانع آشکارسازی شده‌اند. دلیل آن اینست که الگوریتم Al-Kaff و همکاران [۱۴] عوارض دور و نزدیک را از هم دیگر تفکیک نمی‌نماید و آن‌ها را به صورت کلی به عنوان مانع آشکارسازی می‌کند. همچنین در داده دوم نیز تنها ۲۴ درصد از مانع شناسایی شده است. در خصوص داده‌های سوم و چهارم نیز درصد کمی از پیکسل‌های مانع آشکارسازی شده‌اند. به‌طورکلی، با مقایسه مقادیر دقت‌ها در جدول ۳ می‌توان نتیجه گرفت

که الگوریتم پیشنهادی عملکرد بهتری در آشکارسازی مانع و تفکیک مانع از عوارض دور داشته است، اما در خصوص زمان پردازش الگوریتم Al-Kaff و همکاران [۱۴] زمان کمتری را به خود اختصاص داده است. در این راستا و در تحقیقات آینده زمان لازم برای پردازش روش پیشنهادی کاهش و بهبود خواهد یافت.

۴- نتیجه‌گیری

روش‌های انبساط - مبنا می‌توانند قابلیت آشکارسازی مانع را برای ناوبری MAV داشته باشند؛ اما بررسی الگوریتم‌های موجود برای روش انبساط - مبنا نشان می‌دهد که همه آن‌ها دارای مشکلات آشکارسازی نقاط محدودی از مانع و آشکارسازی ناقص قسمتی از مانع هستند. هدف اصلی این تحقیق ارائه الگوریتمی برای غلبه بر این مشکلات بود. به‌طوری که الگوریتم ارائه شده نواحی‌ای از مانع نزدیک را در محیط بیرون و با مانع مختلف، از تصاویر fisheye آشکارسازی می‌کند. نتایج به دست آمده بیان گر کارایی روش در محیطی با عوارض مختلف می‌باشد. به‌طوری که ۶۰ درصد از پیکسل‌های مربوط به مانع به‌طور میانگین در دو حالت حرکت رو به جلو و حرکت به سمت راست آشکارسازی می‌شوند. همچنین، مقایسه روش پیشنهادی با روش Al-Kaff و همکاران (۲۰۱۷) بیان گر کارایی بالای آن نسبت به الگوریتم موجود است.

با این حال، الگوریتم پیشنهادی در آشکارسازی مانع با محدودیت‌هایی مواجه است. یکی از این محدودیت‌ها عدم وجود حداقل ۳ نقطه متناظر در برخی از نواحی است. این محدودیت سبب عدم بررسی مانع بودن یا نبودن برخی از نواحی می‌شود. همچنین وجود نقاط متناظر اشتباه، سبب آشکارسازی نادرست مانع می‌شود. از این رو در مطالعات آینده و با بررسی روش‌های تناظریابی مناسب برای تصاویر fisheye می‌توان تعداد نقاط متناظر صحیح را افزایش داد. محدودیت دوم هم‌رنگ بودن مانع با پس‌زمینه می‌باشد که سبب ایجاد اشتباه در آشکارسازی صحیح مانع می‌شوند. برای این منظور می‌توان در تحقیقات آینده از الگوریتم‌های مناسبی مانند ناحیه بندی معنایی^۱ برای ناحیه بندی تصویر و تفکیک درست عوارض از هم دیگر استفاده نمود.

^۱ Semantic Segmentation

تواند قابل حل باشد. به طوری که پس از رفع محدودیت زمان پردازش، می‌توان روش پیشنهادی را بر روی برد MAV با توان پردازش محدود پیاده‌سازی کرد.

محدودیت سوم زمان لازم برای پردازش روش پیشنهادی است. این محدودیت در تحقیقات آینده و با استفاده از الگوریتم‌های سریع‌تر خصوصاً برای ناحیه بندی تصویر می

مراجع

- [1] Gao, W., Wang, K., Ding, W., et al. (2020). "Autonomous aerial robot using dual fisheye cameras." *Journal of Field Robotics*. Vol.37, No.4, PP. 497-514.
- [2] Lin, Y., Gao, F., Qin, T., et al. (2018). "Autonomous aerial navigation using monocular visual-inertial fusion." *Journal of Field Robotics*. Vol. 35, No. 1, PP. 23-51.
- [3] Luo, C., Espinosa, A. P., Pranantha, D., et al. (2011). "Multi-robot search and rescue team." *IEEE International Symposium on Safety, Security, and Rescue Robotics*. 1-5 November. Kyoto, Japan.
- [4] Bi, Y., Lan, M., Li, J., et al. (2019). "A lightweight autonomous MAV for indoor search and rescue." *Asian Journal of Control*. Vol. 21, No. 4, PP. 1732-1744.
- [5] Nikolic, J., Burri, M., Rehder, J., et al. (2013). "A UAV system for inspection of industrial facilities." *IEEE Aerospace Conference*. 2-9 March 2013. Big Sky, MT, USA.
- [6] Chataigner, F., Cavestany, P., Soler, M., et al. (2020). "ARSI: An Aerial Robot for Sewer Inspection." in *Advances in Robotics Research: From Lab to Market: Springer*. Cham.
- [7] Hepp, B. (2018). "Planning for Autonomous Micro-Aerial Vehicles with Applications to Filming and 3D Modeling." PhD Thesis. ETH Zurich.
- [8] McGuire, K., de Croon, G., De Wagter, C., et al. (2017). "Efficient Optical Flow and Stereo Vision for Velocity Estimation and Obstacle Avoidance on an Autonomous Pocket Drone." *IEEE Robotics and Automation Letters*. Vol. 2, No. 2, PP. 1070-1076.
- [9] Barry, A. J., Florence, P. R., and Tedrake, R. (2018). "High-speed autonomous obstacle avoidance with pushbroom stereo." *Journal of Field Robotics*. Vol. 35, No. 1, PP. 52-68.
- [10] Heidarsson, H. K. and Sukhatme, G. S. (2011). "Obstacle detection and avoidance for an autonomous surface vehicle using a profiling sonar." *2011 IEEE International Conference on Robotics and Automation*. 9-13 May. Shanghai, China.
- [11] Giannì, C., Balsi, M., Esposito, S., et al. (2017). "Obstacle detection system involving fusion of multiple sensor technologies." *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. 42, PP. 127-134.
- [12] Ariyur, K. B., Lommel, P., and Enns, D. F. (2005). "Reactive inflight obstacle avoidance via radar feedback." *Proceedings of the 2005, American Control Conference*. 8-10 June. Portland, OR, USA.
- [13] Häne, C., Sattler, T., and Pollefeys, M. (2015). "Obstacle detection for self-driving cars using only monocular cameras and wheel odometry." *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 28 Sept.-2 October. Hamburg, Germany.
- [14] Al-Kaff, A., García, F., Martín, D. et al. (2017). "Obstacle detection and avoidance system based on monocular camera and size expansion algorithm for UAVs." *Sensors*. Vol. 17, No. 5: 1061.
- [15] Zeng, Y., Zhao, F., Wang, G., et al. (2016). "Brain-Inspired Obstacle Detection Based on the Biological Visual Pathway." *International Conference on Brain Informatics*. 13 October. Bosnia and Herzegovina.
- [16] Díaz-Vilariño, L., Boguslawski, P., Khoshelham, K., et al. (2016). "Indoor navigation from point clouds: 3D modelling and obstacle detection." *XXIII ISPRS Congress 2016*. 12 - 19 July, Prague, Czech republic.
- [17] Li, F., Wang, H., Akwensi, P. H., et al. (2019). "CONSTRUCTION OF OBSTACLE ELEMENT MAP BASED ON INDOOR SCENE RECOGNITION." *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* Vol. XLII-2/W13. 10-14 June. Enschede, Netherlands.
- [18] Qin, R., Zhao, X., Zhu, W., et al. (2021). "Multiple Receptive Field Network (MRF-Net) for Autonomous Underwater Vehicle Fishing Net Detection Using Forward-Looking Sonar Images." *Sensors*. Vol. 21, No. 6: 1933.
- [19] Singh, B. and Kapoor, M. (2021). "A Framework for the Generation of Obstacle Data for the Study of Obstacle Detection by Ultrasonic Sensors." *IEEE Sensors Journal*. Vol. 21, No. 7, PP. 9475-9483.
- [20] Kucukyildiz, G., Oca, H., Karakaya, S., et al. (2017). "Design and implementation of a multi sensor based brain computer interface for a robotic wheelchair." *Journal of Intelligent & Robotic Systems*. Vol. 87, No. 2, PP. 247-263.

- [21] Buck, S., Hanten, R., Bohlmann, K., et al. (2016), "Generic 3d obstacle detection for agvs using time-of-flight cameras." 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). 9-14 October. Daejeon, Korea (South).
- [22] Liu, Y., Fu, Y., Zhuan, Y. et al. (2021). "Large depth-of-field 3D measurement with a microscopic structured-light system." Optics Communications. Vol. 481: 126540.
- [23] Yuan, Z., Li, Y., Tang, S. et al. (2021). "A survey on indoor 3D modeling and applications via RGB-D devices." Frontiers of Information Technology & Electronic Engineering. Vol. 22, No. 6, PP. 815-826.
- [24] Huh, S., Cho, S., Jung, Y. et al. (2015). "Vision-based sense-and-avoid framework for unmanned aerial vehicles." IEEE Transactions on Aerospace and Electronic Systems. Vol. 51, No. 4, PP. 3427-3439.
- [25] Zahran, S., Moussa, A. M., Sesay, A. B. et al. (2018). "A new velocity meter based on Hall effect sensors for UAV indoor navigation." IEEE Sensors Journal. Vol. 19, No. 8, PP. 3067-3076.
- [26] Lee, T.-J., Yi, D.-H., and Cho, D.-I. (2016). "A monocular vision sensor-based obstacle detection algorithm for autonomous robots." Sensors. Vol. 16, No. 3: 311.
- [27] de Croon, G. and De Wagter, C. (2018). "Learning what is above and what is below: horizon approach to monocular obstacle detection." arXiv preprint arXiv:1806.08007.
- [28] Mashaly, A. S., Wang, Y., and Liu, Q. (2016). "Efficient sky segmentation approach for small UAV autonomous obstacles avoidance in cluttered environment." In 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). 10-15 July. Beijing, China.
- [29] Huh, K., Park, J., Hwang, J., et al. (2008). "A stereo vision-based obstacle detection system in vehicles." Optics and Lasers in Engineering. Vol. 46, No. 2, PP. 168-178.
- [30] Padhy, R. P., Choudhury, S. K., Sa, P. K., et al. (2019). "Obstacle Avoidance for Unmanned Aerial Vehicles: Using Visual Features in Unknown Environments." IEEE Consumer Electronics Magazine. Vol. 8, No. 3, PP. 74-80.
- [31] Ruf, B., Monka, S., Kollmann, M., et al. (2018). "REAL-TIME ON-BOARD OBSTACLE AVOIDANCE FOR UAVS BASED ON EMBEDDED STEREO VISION." arXiv preprint arXiv: 1807.06271.
- [32] Huang, H.-C., Hsieh, C.-T., and Yeh, C.-H. (2015). "An indoor obstacle detection system using depth information and region growth." Sensors. Vol. 15, No. 10, PP. 27116-27141.
- [33] Ball, D., Ross, P., English, A., et al. (2017). "Farm Workers of the Future: Vision-Based Robotics for Broad-Acre Agriculture." IEEE Robotics Automation Magazine. Vol. 24, No. 3, PP. 97-107.
- [34] Kim, D., Choi, J., Yoo, H., et al. (2015). "Rear obstacle detection system with fisheye stereo camera using HCT." Expert Systems with Applications. Vol. 42, No. 17-18, PP. 6295-6305.
- [35] Jung, H., Lee, Y., Kim, B., et al. (2007). "Stereo vision-based forward obstacle detection." International journal of automotive technology. Vol. 8, No. 4, PP. 493-504.
- [36] Tijmons, S., de Croon, G. C., Remes, B. D., et al. (2017). "Obstacle avoidance strategy using onboard stereo vision on a flapping wing mav." IEEE Transactions on Robotics. Vol. 33, No. 4, PP. 858-874.
- [37] Pestana, J., Maurer, M., Muschick, D., et al. (2019). "Overview obstacle maps for obstacle-aware navigation of autonomous drones." Journal of field robotics. Vol. 36, No. 4, PP. 734-762.
- [38] Häne, C., Heng, L., Lee, G. H., et al. (2017). "3D visual perception for self-driving cars using a multi-camera system: Calibration, mapping, localization, and obstacle detection." Image and Vision Computing. Vol. 68, PP. 14-27.
- [39] Gharani, P. and Karimi, H. A. (2017). "Context-aware obstacle detection for navigation by visually impaired." Image and Vision Computing. Vol. 64, PP. 103-115.
- [40] Singh, Y. and Kaur, L. (2017). "Obstacle Detection Techniques in Outdoor Environment: Process, Study and Analysis." International Journal of Image, Graphics & Signal Processing. Vol. 9, No. 5: 35.
- [41] Ulrich, I. and Nourbakhsh, I. (2000). "Appearance-based obstacle detection with monocular color vision." Proceedings of the Seventeenth National Conference on Artificial Intelligence and Twelfth Conference on Innovative Applications of Artificial Intelligence. 30 July - 3 August.
- [42] Ho, H. W., De Wagter, C., Remes, B. D. W., et al. (2018). "Optical-flow based self-supervised learning of obstacle appearance applied to MAV landing." Robotics and Autonomous Systems. Vol. 100, PP. 78-94.
- [43] Gosiewski, Z., Ciesluk, J., and Ambroziak, L. (2011). "Vision-based obstacle avoidance for unmanned aerial vehicles." 2011 4th International Congress on Image and Signal Processing. 15-17 October. Shanghai, China.
- [44] Tsai, C.-C., Chang, C.-W., and Tao, C.-W. (2018). "Vision-Based Obstacle Detection for Mobile Robot in Outdoor Environment." Journal of Information Science & Engineering. Vol. 34, No. 1.

- [45] Mueller, Z. and Diamantas, S. (2021). "Modeling a priori Unknown Environments: Place Recognition with Optical Flow Fingerprints." In Proceedings of the 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications. 8-10 February.
- [46] Zhou, Y., Ho, H. W., and Chu, Q. (2021). "Extended incremental nonlinear dynamic inversion for optical flow control of micro air vehicles." *Aerospace Science and Technology*. Vol. 116, No. 14: 106889.
- [47] Low, T. and Wyeth, G. (2007). "Learning to avoid indoor obstacles from optical flow." Proceedings of the 2007 Australasian Conference on Robotics and Automation. 10-12 December. Brisbane, Australia.
- [48] Oh, P. Y., Green, W. E., and Barrows, G. (2004). "Neural nets and optic flow for autonomous micro-air-vehicle navigation." ASME International Mechanical Engineering Congress and Exposition.
- [49] Green, W. E. and Oh, P. Y. (2008). "Optic-flow-based collision avoidance." *IEEE Robotics & Automation Magazine*. Vol. 15, No. 1, PP. 96-103.
- [50] Silva, A., Mendonça, R., and Santana, P. (2020). "Monocular Trail Detection and Tracking Aided by Visual SLAM for Small Unmanned Aerial Vehicles," *Journal of Intelligent & Robotic Systems*. Vol. 97, No. 3, PP. 531-551.
- [51] Kumar, V. R., Milz, S., Simon, M., et al. (2018). "Monocular Fisheye Camera Depth Estimation Using Semi-supervised Sparse Velodyne Data." *arXiv preprint arXiv:1803.06192*.
- [52] Mancini, M., Costante, G., Valigi, P. et al. (2018). "J-MOD 2: Joint Monocular Obstacle Detection and Depth Estimation." *IEEE Robotics and Automation Letters*. Vol. 3, No. 3, PP. 1490-1497.
- [53] Gunethilake, W. (2021). "Blind Navigation using Deep Learning-Based Obstacle Detection." PhD Thesis.
- [54] Ming, Y., Meng, X., Fan, C., et al. (2021). "Deep learning for monocular depth estimation: A review." *Neurocomputing*. Vol. 438, PP. 14-33.
- [55] Lee, H., Ho, H., and Zhou, Y. (2021). "Deep Learning-based Monocular Obstacle Avoidance for Unmanned Aerial Vehicle Navigation in Tree Plantations." *Journal of Intelligent & Robotic Systems*. Vol. 101, No. 1, PP. 1-18.
- [56] Mori, T. and Scherer, S. (2013). "First results in detecting and avoiding frontal obstacles from a monocular camera for micro unmanned aerial vehicles." *IEEE International Conference on Robotics and Automation (ICRA)*. 6-10 May. Kongresszentrum Karlsruhe - Karlsruhe, Germany.
- [57] Aguilar, W. G., Casaliglla, V. P., and Pólit, J. L. (2017). "Obstacle avoidance based-visual navigation for micro aerial vehicles." *Electronics*. Vol. 6, No. 1:10.
- [58] Badrloo, S. and Varshosaz, M. (2017). "Monocular vision based obstacle detection." *Earth Observation and Geomatics Engineering*. Vol. 1, No. 2, PP. 122-130.
- [59] Escobar-Alvarez, H. D., Johnson, N., Hebble, T., et al. (2018). "R-ADVANCE: Rapid Adaptive Prediction for Vision-based Autonomous Navigation, Control, and Evasion." *Journal of Field Robotics*. Vol. 35, No. 1, PP. 91-100.
- [60] Badrloo, S., Varshosaz, M. (2017). "Monocular vision based obstacle detection. " *Earth Obs. Geomatics Engg*. Vol. 1, No. 2, PP. 122-130.
- [61] Nieuwenhuisen, M., Droeschel, D., Schneider, J., et al. (2013). "Multimodal obstacle detection and collision avoidance for micro aerial vehicles." *European Conference on Mobile Robots*. 25-27 September. Barcelona, Spain.
- [62] Scaramuzza, D., Martinelli, A., and Siegwart, R. (2006). "A flexible technique for accurate omnidirectional camera calibration and structure from motion." *Fourth IEEE International Conference on Computer Vision Systems*. 4 - 7 January. New York, NY, USA.
- [63] Memon, M. H., Memon, I., Li, J.-P., et al. (2019). "IMRBS: image matching for location determination through a region-based similarity technique for CBIR." *International Journal of Computers and Applications*. Vol. 41, No. 6, PP. 449-462.
- [64] Chen, Y.-C., Lin, Y.-Y., Yang, M.-H., et al. (2020). "Show, Match and Segment: Joint Weakly Supervised Learning of Semantic Matching and Object Co-segmentation." *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 43, PP. 3632-3647.
- [65] Adams, R. and Bischof, L. (1994). "Seeded region growing." *IEEE Transactions on pattern analysis and machine intelligence*. Vol. 16, No. 6, PP. 641-647.
- [66] Lowe, D. G. (2004). "Distinctive image features from scale-invariant keypoints." *International journal of computer vision*. Vol. 60, No. 2, PP. 91-110.
- [67] Morel, J.-M. and Yu, G. (2009). "ASIFT: A new framework for fully affine invariant image comparison." *SIAM journal on imaging sciences*. Vol. 2, No. 2, PP. 438-469.

- [68] Valgaerts, L., Bruhn, A., Mainberger, M., et al. (2012). "Dense versus sparse approaches for estimating the fundamental matrix." *International Journal of Computer Vision*. Vol. 96, No. 2, PP. 212-234.
- [69] Derpanis, K. G. (2010). "Overview of the RANSAC Algorithm." *Image Rochester NY*. Vol. 4, No. 1, PP. 2-3.
- [70] Rusiecki, A. (2012). "Robust learning algorithm based on iterative least median of squares." *Neural processing letters*. Vol. 36, No. 2, PP. 145-160.
- [71] Mittal, S., Anand, S., and Meer, P. (2012). "Generalized projection-based M-estimator." *IEEE transactions on Pattern analysis and machine intelligence*. Vol. 34, No. 12, PP. 2351-2364.
- [72] Li, J., Yang, Y.-M., and Zhang, X.-X. (2012). "An Improved MLESAC Algorithm for Estimating Fundamental Matrix." *Computer Engineering*. Vol. 38, No. 19, PP. 215-217.
- [73] Raguram, R., Chum, O., Pollefeys, M., et al. (2012). "USAC: A universal framework for random sample consensus." *IEEE transactions on pattern analysis and machine intelligence*. Vol. 35, No. 8, PP. 2022-2038.
- [74] Massart, D. L., Kaufman, L., Rousseeuw, P. J., et al. (1986). "Least median of squares: a robust method for outlier and model error detection in regression and calibration." *Analytica Chimica Acta*. Vol. 187, PP. 171-179.
- [75] Serra, J. (1983). "Image analysis and mathematical morphology." Academic Press, Inc. 6277 Sea Harbor Drive Orlando, FL, United States.
- [76] Scaramuzza, D., Martinelli, A., and Siegwart, R. (2006). "A toolbox for easily calibrating omnidirectional cameras." *IEEE/RSJ International Conference on Intelligent Robots and Systems*. 9-15 october. Beijing, China.
- [77] Luong, Q.-T. and Faugeras, O. D. (1996). "The fundamental matrix: Theory, algorithms, and stability analysis." *International journal of computer vision*. Vol. 17, No. 1, PP. 43-75.
- [78] Kim, J. and Suga, Y. (2007). "An omnidirectional vision-based moving obstacle detection in mobile robot." *International Journal of Control, Automation, and Systems*. Vol. 5, No. 6, PP. 663-673.
- [79] Beul, M., Krombach, N., Nieuwenhuisen, M. et al. (2017). "Autonomous navigation in a warehouse with a cognitive micro aerial vehicle." in *Robot Operating System (ROS)*: Springer. Cham.
- [80] Canters, F. (1997). "Evaluating the uncertainty of area estimates derived from fuuy land-cover classification." *Photogrammetric Engineering & Remote Sensing*. Vol. 63, No. 4, PP. 403-414.