

تشخیص خودکار فلفل دلمه‌ای مبتنی بر توصیف‌گر سه‌بعدی هیستوگرام سریع ویژگی نقطه (FPFH) و یادگیری ماشین

امید دوستی ایرانی^۱، محمودرضا گلزاریان^{۲*} و محمدحسین آق‌خانی^۳

چکیده

برداشت دستی محصول فلفل دلمه‌ای به عنوان یکی از محصولات گلخانه‌ای زمان‌بر و هزینه‌های کارگری بالایی به دنبال دارد. به منظور برداشت رباتیک این محصول سامانه‌های بینایی ماشینی دوبعدی مختلفی توسعه یافته است. به دلیل محیط پیچیده گلخانه، تراکم بالای شاخه و برگ، وجود آفات و بیماری‌ها و آفتاب سوختگی، شرایط نوری غیر یکنواخت و متغیر و بلوغ غیر هم‌زمان محصول منجر به غیریکنواختی در رنگ می‌شود. بنابراین علاوه بر فلفل دلمه‌ای سبز، برداشت فلفل‌های دلمه‌ای رنگی نیز با چالش‌هایی همراه است. لذا هدف از انجام این پژوهش تشخیص فلفل دلمه‌ای در مدل ابر نقاط مبتنی بر توصیف‌گر هیستوگرام سریع ویژگی نقطه (FPFH) و یادگیری ماشین است. جهت ثبت تصاویر عمق از حسگر Kinect v2 استفاده شد. پس از ایجاد مدل سه‌بعدی از ویژگی‌های هندسی (FPFH) جهت طبقه‌بندی و از کانال رنگی H جهت ایجاد نظارت در ۹ مدل طبقه‌بند استفاده شد. برای این منظور از ۱۵ مدل سه‌بعدی از فلفل‌های رنگی استفاده شد. با توجه به معیارهای F1-Score، سطح زیر منحنی و صحت الگوریتم، مدل طبقه‌بند KNN به عنوان بهترین مدل انتخاب شد. به منظور ارزیابی الگوریتم KNN بر روی ۱۵ مدل سه‌بعدی از فلفل قرمز، فلفل نارنجی و زرد اجرا و در نهایت مورد بازبینی انسانی قرار گرفت. نتایج نشان داد مقدار معیار F1-Score به جز یک مورد در همه موارد بالاتر از ۰/۷، سطح زیر منحنی Roc نیز در همه موارد بالاتر از ۰/۸ و صحت الگوریتم طبقه‌بندی در همه موارد بالاتر از ۰/۹ به دست آمد. علاوه بر این نتایج ارزیابی انسانی نیز نشان داد که حداقل دقت تشخیص برابر ۷۱/۴۲ درصد و در بعضی موارد نیز دقت ۱۰۰ درصد حاصل شده است.

واژه‌های کلیدی: ابر نقاط، برداشت رباتی، یادگیری ماشین، حسگر Kinect v2، FPFH.

ارجاع: دوستی ایرانی ا. گلزاریان م. ر. و آق‌خانی م. ح. ۱۴۰۱. تشخیص خودکار فلفل دلمه‌ای مبتنی بر توصیف‌گر سه‌بعدی هیستوگرام سریع ویژگی نقطه (FPFH) و یادگیری ماشین. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۶: ۲۷-۳۹. <https://dx.doi.org/10.22034/JRMAM.2023.13863.587>

۱- دانشجوی دکتری، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد.

۲- دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد.

۳- استاد گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد.

* نویسنده مسئول: m.golzarian@um.ac.ir

تاریخ دریافت: ۱۴۰۱/۰۳/۰۳ تاریخ پذیرش: ۱۴۰۱/۰۵/۲۹

مقدمه

کشاورزی هوشمند با تجزیه و ترکیب اطلاعات، سبب تصمیم‌سازی در حداقل زمان ممکن می‌شود (Chidambaranathan *et al.*, 2018). در یک نظام هوشمند از فناوری‌های مختلف هوش مصنوعی از جمله بینایی ماشین و رباتیک، استفاده می‌شود (Dharmaraj & Vijayanand, 2018). استفاده از ربات‌ها در باغبانی، گلخانه‌ها و مزارع به طور مؤثری در حال گسترش است. با افزایش جمعیت جهان، راه‌حل تأمین امنیت غذایی افزایش تولیدات کشاورزی است؛ بنابراین ضروری است که در ازای منابع کمتر، غذای بیشتری تولید شود (Foley *et al.*, 2011). پیش‌بینی شده است که طی سال‌های ۲۰۰۵ تا ۲۰۵۰ تقاضا برای محصولات کشاورزی تا ۱۰۰ درصد افزایش می‌یابد (Tilman *et al.*, 2011). از آنجا که هزینه تولیدات زراعی بالا است، بهینه‌سازی عملکرد گلخانه‌ها می‌تواند نقش اساسی در کاهش هزینه‌های تولید ایفا کند (Ball *et al.*, 2016). ایران با سطح زیر کشت محصولات کشاورزی حدود ۷۰۰ هزار هکتار و تولید بیش از ۱۷ میلیون تن در سال، شش درصد از سهم کل زیر کشت محصولات زراعی و بالغ بر ۲۹ درصد از تولید محصولات زراعی در جهان را به خود اختصاص داده است (Silspur, 2018). محصول فلفل دلمه سرشار از ویتامین‌های مختلف و مواد معدنی مانند فسفر، کلسیم و منیزیم است که جایگاه خاصی در سبد غذایی انسان‌ها پیدا کرده است (Bosland *et al.*, 2012). مطابق با آمار سازمان کشاورزی آمریکا تولید این محصول در جهان از حدود ده میلیون تن در سال ۱۹۹۰ به حدود بیست و شش میلیون تن در سال ۲۰۰۷ رسیده است (Moghimi *et al.*, 2015). همچنین بر اساس آمارنامه نامه‌های موجود تولید انواع فلفل دلمه‌ای در سال ۲۰۲۰ حدود ۳۶ میلیون تن است (Tridge, 2022). تولیدکنندگان با محدودیت‌هایی در برداشت محصولات گلخانه‌ای به‌خصوص فلفل دلمه که تا زمان برداشت تغییرات زیادی در رنگ دارد، مواجه هستند (Sarig, 2005). این محدودیت‌ها افزایش هزینه‌های کارگری در برداشت محصول را به دنبال دارد. بسیاری از فناوری‌ها به‌منظور به‌کارگیری در مزرعه شامل رباتیک (Billingsley *et al.*, 2008) و پردازش تصویر در عملیات برداشت، بیشتر مورد بررسی و تحقیق قرار گرفته‌اند (Moonrinta *et al.*,

2010). تحقیقات اخیر نیز با هدف جامعیت بخشیدن به صنعت رباتیک در این زمینه پیشرفت چشمگیری داشته‌اند (McCool *et al.*, 2016). سیستم‌های بینایی دوبعدی^۱ (2-D) بخش جدایی‌ناپذیر خودکارسازی فرآیندهای کشاورزی در تولید محصولات غذایی هستند. بینایی ماشین در نقطه عطفی قرار دارد که به زودی به سمت روش‌های سه‌بعدی^۲ (3-D) حرکت خواهد کرد؛ و به دنبال آن کاهش هزینه‌ها و افزایش کیفیت عملیات مورد نظر را به دنبال خواهد داشت (Vázquez-Arellano *et al.*, 2016). با توسعه فناوری روش لیزری^۳ و روش تطبیق تصویر^۴، اطلاعات سه‌بعدی به‌طور فزاینده‌ای توجه پژوهش‌گران را به خود جلب کرده است. سه‌بعدی‌سازی، کاربردهای گسترده‌ای دارد که از جمله آن می‌توان به باستان‌شناسی (De Reu *et al.*, 2013)، نظارت بر تغییرات پستی و بلندی زمین^۵ (Gonçalves & Henriques, 2015)، بیان حالات چهره (Tung & Matsuyama, 2014) و مدل‌سازی در منابع طبیعی و کشاورزی (Rose *et al.*, 2014; Tao, 2014; 2015) اشاره کرد. در سال‌های اخیر، با پیشرفت قابل‌توجهی از فوتوگرامتری و فناوری بینایی رایانه‌ای، بازسازی سه‌بعدی مبتنی بر تصویر به عنوان یک رقیب اصلی در مقابل روش اسکنر لیزری قرار گرفته است (Vosselman, 2012). در مقایسه با روش اسکنر لیزری، بازسازی سه‌بعدی بر اساس تصویر مزایایی دارد که از جمله آن‌ها می‌توان به عدم محدودیت در نوع دوربین (García-Gago, 2014) قابلیت استفاده از تصاویر واسنجی شده (Tanskanen *et al.*, 2013)، قابلیت استفاده از قاب‌های حاصل از فیلم‌برداری (Furukawa & Ponce, 2010)، کم‌هزینه بودن (Remondino *et al.*, 2014) و همراه داشتن اطلاعات رنگی و تولید نقاط پرتراکم از لحاظ تئوری اشاره کرد. در سال‌های اخیر مطالعه تشخیص میوه از پردازش تصاویر دودویی تا هوش مصنوعی^۶ و یادگیری ماشین^۷ افزایش یافته است (Zhao *et al.*, 2017). با توسعه اطلاعات عمق تصویر^۸، داده‌های سه‌بعدی از یک صحنه که به طور مستقیم و با دقت بالا توسط رادار

1- Two-Dimensional

2- Three-Dimensional

3- Laser Scanning

4- Image Matching Method

5- Topographic Monitoring

6- Artificial Intelligence

7- Machine Learning

8- Depth Information

که با استفاده از ویژگی‌های بافتی در ترکیب با ویژگی‌های رنگی تا ۹۲ درصد افزایش یافته است (Moghimi *et al.*, 2015). در پژوهشی ۱۴ موقعیت مختلف دوربین را برای تشخیص فلفل دلمه رنگی (قرمز و زرد) مورد بررسی قرار گرفت. بهترین حالت تشخیص دید مستقیم با زاویه ۶۰ درجه رو به بالا به دست آمد. در این حالت دقت تشخیص برابر با ۶۰ درصد محاسبه شد. برای افزایش دقت استفاده ترکیبی از چند دوربین و در شرایط مختلف تصویربرداری پیشنهاد شده است (Hemming *et al.*, 2014). پژوهشگران برای تشخیص خیار که رنگ مشابهی با برگ دارد از یک دوربین دارای یک درجه آزادی با حرکت خطی استفاده کرده‌اند. حرکت خطی دوربین منجر به افزایش دقت می‌شود ولی این افزایش دقت به دنبال خود افزایش در زمان تصویربرداری، پردازش تصاویر و پیچیدگی الگوریتم را به همراه دارد (Van-Henten *et al.*, 2003). همچنین برای تشخیص پرتقال سبز از تصویربرداری RGB تحت شرایط نور طبیعی استفاده شد. دقت تشخیص در این تحقیق برابر با ۷۵/۳ درصد به دست آمده است (Kurtulmus *et al.*, 2011).

در پژوهشی دیگر به تشخیص میوه سیب با استفاده از دوربین RGB-D پرداخته شد. دقت تشخیص سیب در نمونه مورد آزمایش برابر با ۱۰۰ درصد و در حالت واقعی برابر با ۸۵ درصد به دست آمد (Nguyen *et al.*, 2014). در پژوهشی دیگر، پژوهشگران جهت تشخیص سیب قرمز با استفاده از توصیف‌گر PPFH^۶ و طبقه‌بندی اطلاعات با روش ماشین بردار پشتیبان^۷ و ترکیب آن با الگوریتم ژنتیک^۸ به دقت تشخیص ۹۲٪ دست یافتند (Tao & Zhou, 2017 2014). همچنین محققین با استفاده از یک دوربین عمق‌سنج به تشخیص فلفل دلمه و دمگل آن به منظور تعیین محل برش پرداختند. در این پژوهش از توصیف‌گر محلی PFH^۹ و به منظور طبقه‌بندی اطلاعات از روش ماشین بردار پشتیبان (SVM) استفاده شد. سطح زیر منحنی^{۱۰} (AUC) به دست آمده در این روش برابر با ۰/۷۱ گزارش شده، که دقت قابل قبولی است (Sa *et al.*, 2017). در پژوهشی دیگر به تشخیص

لیزری یا دوربین عمق حاصل شده، سبب بهبود تشخیص و درک بهتر از محیط می‌شوند (Jiang *et al.*, 2016). فناوری بدست آوردن داده‌های ابر نقاط سه‌بعدی^۱ و بازسازی سه‌بعدی^۲ سبب می‌شود تا ویژگی‌های هندسی سه‌بعدی از میوه، شاخه و برگ با دقت بیشتری ایجاد شوند (Kumazakia & Kunii, 2016). از آنجایی که دوربین‌های عمق ارزان، کم‌حجم و کاربرد آسانی دارند، می‌توانند ابزار مناسبی جهت کاربردهای کشاورزی از جمله رباتیک باشند. با این حال اشکالاتی نیز دارند از جمله این‌که: ۱- تخمین عمق توسط این حسگر در فواصل محدود امکان‌پذیر نیست (معمولاً کمتر از ۵ متر)، ۲- تخمین عمق با نویز همراه است و زاویه دید آن‌ها (۶۰°) به مراتب محدودتر از دوربین‌های تخصصی و لیزر اسکنرها (۱۸۰°) است. رایج‌ترین حسگرهای عمق که به منظور تهیه مدل‌های سه‌بعدی مورد استفاده قرار می‌گیرد حسگرهای Kinect v1 و Kinect v2 است، که به ترتیب از فناوری نور ساختار یافته^۳ و مدت زمان پرواز^۴ استفاده می‌کنند (Nissimov *et al.*, 2015). تاکنون تحقیقات مختلفی در حوزه کشاورزی با استفاده از پردازش مدل‌های دوبعدی و سه‌بعدی به منظور تشخیص خودکار میوه انجام شده است که در ادامه به برخی از این تحقیقات اشاره شده است.

در قدیمی‌ترین منبع علمی که تشخیص خودکار میوه را مورد اشاره قرار می‌دهد، مشکلاتی که باید در تشخیص خودکار میوه مدنظر قرار گیرند عبارت بودند از: روشنایی غیریکنواخت (ناشی از سایه) و تراکم شاخه و برگ که آشکار بودن میوه‌ها را بین ۷۰ تا ۱۰۰ درصد محدود می‌کرد. بنابراین تحقیقات بیشتری در زمینه بهبود الگوریتم‌های موجود انجام شد (De-An *et al.*, 2011). در پژوهشی تشخیص فلفل دلمه‌ای سبز با استفاده از تصاویر دوبعدی در محیط گلخانه مورد بررسی قرار گرفت. یک شاخص جدید بافتی بر پایه تخمین چگالی لبه تعریف و در ترکیب با شاخص‌های رنگی شامل رنگ مایه، شدت اشباع رنگی و سبزیگی تشدید شده (EGD)^۵ برای شناسایی فلفل دلمه‌ای سبز استفاده شده است. دقت تشخیص الگوریتم برابر با ۸۶ درصد گزارش شده است؛

6- Fast Point Feature Histogram
7-Support Vector Machine
8- Genetic Algorithm
9- Point Features Histogram
10- Area-Under-the-Curve

1- 3D Point Cloud Data
2- 3D Reconstruction
3- Structured-light
4- Time of flight
5- Excessive green index

توجه به مطالب بیان شده هدف از این مطالعه ارائه یک سامانه بینایی سه‌بعدی با قابلیت و انعطاف پذیری بالا و ارزان است که وظیفه آن تشخیص خودکار فلفل دلمه‌ای رنگی (قرمز، زرد و نارنجی) جهت برداشت با ربات است.

مواد و روش‌ها

تهیه تصاویر عمق

در این پژوهش به منظور تهیه تصاویر عمق از حسگر Kinect v2 استفاده شد. این حسگر علاوه بر تصویر عمق یک تصویر رنگی از هدف ارائه می‌دهد. نسخه اولیه این حسگر Kinect v1 است و نسل بعدی آن پیشرفت‌های از جمله دقت بهتر در نقشه عمق، افزایش زاویه دید^۲، کاهش فاصله بین دوربین و انسان در اجرای بازی‌های رایانه‌ای از ۲/۴ متر به ۱/۳۷ متر، افزایش دقت تصویر دوربین رنگی و مفاصل اضافی برای ردیابی بدن را به همراه دارد (Pagliari & Pinto, 2015). در این حسگر تخمین عمق بر اساس مدت زمان پرواز یک اشعه نوری به هدف و بازگشت آن به حسگر محاسبه می‌شود. مشخصات این حسگر در جدول ۱ بیان شده است.

جدول ۱- مشخصات حسگر Kinect v2

مشخصات	عنوان
۴۲۴×۵۱۲	رزولوشن تصویر عمق (Depth)
۱۰۸۰×۱۹۲۰	رزولوشن تصویر (RGB)
۰/۵ - ۴/۵	دامنه کاری (متر)
۶۰×۷۰	حوزه دید (FOV) (درجه)

تصویربرداری در یک گلخانه زیر کشت فلفل دلمه با رنگ‌های سبز، قرمز، زرد و نارنجی، در روستای ابراهیم آباد واقع در خراسان رضوی انجام شد. در شکل ۱ حسگر Kinect v2 به همراه آداپتور و مبدل آن نشان داده شده است. پس از نصب حسگر Kinect v2 در نرم‌افزار متلب (Matlab R2021b) تصویربرداری با اجرای برنامه نوشته شده انجام و اطلاعات به صورت خودکار ذخیره شد. تصویربرداری در تمام ساعات روز و در شرایط نور طبیعی (روشنایی طبیعی گلخانه) انجام شد. یکی از چالش‌های تصاویر عمق اولیه وجود نویز با مقادیر صفر در لبه‌های تصویر بود. با توجه به اینکه نویزها می‌توانند دقت پردازش‌های بعدی را تحت تأثیر قرار دهند (Rusu et al.,

فلفل دلمه‌ای قرمز بر اساس تصاویر عمق حاصل از دوربین RGB-D پرداخته شد. در این پژوهش به منظور ایجاد ابر نقاط متراکم از محصول، ابر نقاط از نمای مختلف محصول ایجاد و با اسفاده از روش ترکیب Kinect^۱ مدل ابر نقاط نهایی حاصل شده است. در نهایت با استفاده از فیلتر رنگی R-G و کاهش حجم نمونه مدل نهایی ایجاد و سپس با استفاده از فاصله اقلیدسی نسبت به تعیین مراکز خوشه و خوشه‌بندی اقدام شد. نتایج این پژوهش نشان می‌دهد که دقت الگوریتم بر اساس بازبینی انسانی برابر با ۹۰/۶۹ درصد است (Zhao et al., 2020). در این پژوهش از ترکیب ابرنقاط استفاده شده است که برای کارهای بلادرنگ به خاطر حجم محاسبات بالا و زمان پردازش ممکن است کارایی خوبی نداشته باشد.

همانطور که از بررسی مطالعات پیشین مشخص است، اگر چه از حسگرهای مختلف (دوبعدی و سه‌بعدی) و توصیفگرهای مختلف (رنگ، بافت، هندسه) در تشخیص میوه‌ها استفاده شده است، اما تشخیص محصولات کشاورزی همواره با چالش‌های گسترده‌ای روبرو بوده، که عمدتاً ناشی از شرایط متغیر در محیط رشد گیاه است. در تشخیص و برداشت فلفل دلمه‌ای چالش‌هایی چون پس زمینه پیچیده و غیر یکنواخت از لحاظ شدت روشنایی، وجود اشیاء مختلف در تصویر، پوشش میوه و دمگل توسط برگ‌ها و شاخه‌ها، تغییر رنگ محصول در مراحل مختلف رسیدگی، آفتاب سوختگی، وجود میوه‌های خال‌دار، لکه‌دار شدن و کم رنگ شدن میوه‌ها موجب می‌شود تا فرایند تشخیص با پیچیدگی‌های زیادی روبرو باشد. بنابراین اگر چه فلفل‌های رنگی تضاد رنگی خوبی را در محیط برداشت از خود نشان می‌دهند ولی رنگ محصول یک متغیر وابسته به شرایط محیطی و بلوغ محصول است. بنابراین صرفاً استفاده از ویژگی‌های رنگی در تشخیص محصول در همه شرایط کارا نبوده و از دقت کافی برخوردار نیست. بنابراین محیط گلخانه‌ای زیر کشت محصول فلفل دلمه‌ای رنگی یک محیط پیچیده از دید ماشین برداشت و چشم انسان است. به همین دلیل به ویژگی‌هایی مستقل از رنگ جهت تشخیص آن نیاز است. بنابراین، این مسأله به وجود می‌آید که آیا ویژگی‌های هندسی محصول فلفل دلمه‌ای در مدل ابر نقاط قادر به ایجاد تمایز بین فلفل و شاخه و برگ هستند یا خیر؟ با

موقعیت x و y از نقطه $P(x, y, z)$ متناظر با هر پیکسل در نقشه عمق با استفاده از معادلات (۱) و (۲) محاسبه می‌شوند (Lachat et al., 2015).


$$X = \frac{j-Cx}{Fx} * Z \quad (1)$$

$$y = \frac{k-Cy}{Fy} * Z \quad (2)$$

در معادلات فوق، (Cx, Cy) و (Fx, Fy) بیان کننده ویژگی‌های درونی حسگر و به ترتیب نشان دهنده مرکز کانونی و فاصله کانونی هستند. مقادیر مرکز کانونی و فاصله کانونی با اتصال حسگر به نرم‌افزار متلب قابل استخراج بودند. پس از محاسبه مقادیر x و y مدل سه‌بعدی ایجاد شد.

استخراج ویژگی‌های هندسی و رنگی

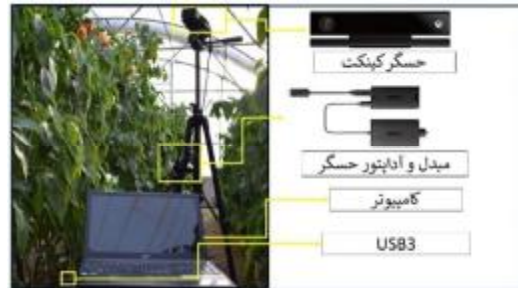
در سال‌های اخیر استفاده از توصیف‌گرهای سه‌بعدی محلی^۲ از جمله هیستوگرام سریع ویژگی نقطه (PFH) توسط (Rusu et al., 2008) و حالت سریع‌تر آن یعنی (FPFH) توسط (Rusu et al., 2009)، به منظور تشخیص اهداف و بازسازی در مدل‌های سه‌بعدی توسعه یافته است. در این پژوهش به منظور توصیف سطح اهداف موجود در تصویر عمق از توصیف‌گر FPFH استفاده شد. ویژگی‌های هندسی که در این پژوهش استخراج شده‌اند عبارت‌اند از: زوایای مربوط به بردار نرمال سطح (n) شامل (ϕ, θ, α) و فاصله اقلیدسی (d) . زوایای مربوط به بردار نرمال سطح در شکل ۳ در یک دستگاه مختصات UVW نمایش داده شده‌اند. در این شکل، p_1 نقطه جستجو و p_2 نقطه‌ای دیگر در همسایگی نقطه p_1 است.



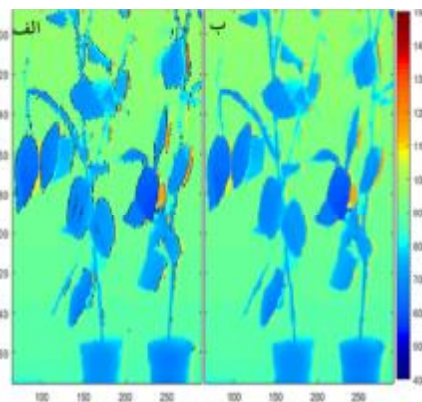
شکل ۳- دستگاه مختصات UVW

زوایای مربوط به بردار نرمال سطح، فاصله اقلیدسی و انحناء در دستگاه مختصات UVW به صورت معادلات (۳) تا (۷) تعریف می‌شوند (Tao & Zhou, 2017; Hana et al., 2018).

این نقاط با استفاده از فیلتر میانگین اصلاح شدند. (Shen et al., 2017; Nguyen et al., 2015). نمونه‌ای از این تصاویر در شکل ۲ نمایش داده شده است. شعاع همسایگی در این فیلتر برابر با ۲ پیکسل در نظر گرفته شد.



شکل ۱- نمایش اجزای سامانه تشخیص خودکار فلفل دلمه‌ای



شکل ۲- حذف و جایگزینی پیکسل‌های صفر در نقشه عمق گیاه فلفل دلمه‌ای با استفاده از فیلتر میانگین. الف) تصویر اولیه. ب) تصویر فیلتر شده

ساخت مدل سه‌بعدی

محاسبه مقادیر x و y برای هر مقدار عمق

خروجی تصویربرداری عمق^۱، یک تصویر دوبعدی است که تصویر عمق یا نقشه عمق نامیده می‌شود. مقدار هر پیکسل از این تصویر دوبعدی، فاصله آن نقطه در صحنه را تا مرکز دوربین نشان می‌دهد.

در هر تصویر عمق محور عمودی (y) بیانگر عرض و محور افقی (x) بیانگر طول نقاط است (Shen et al., 2017). هر پیکسل $P(j, k)$ در نقشه‌های عمق به یک موقعیت فیزیکی $P(x, y, z)$ در ابر نقاط سه‌بعدی با در نظر گرفتن موقعیت دوربین عمق در حسگر Kinect، تبدیل می‌شود.

2- Local 3d Descriptor

1- Range imaging

فاصله زیادی داشتند استفاده شد. با استفاده از معیار Z -Score هر داده‌ای که خارج از بازه $(\bar{X} - 3\sigma, \bar{X} + 3\sigma)$ قرار داشت، به عنوان داده دور افتاده شناسایی و حذف شد.

مجموعه داده

در این مطالعه داده‌ها شامل ۳۰ نمونه از مدل‌های سه‌بعدی در هر سه نوع فلفل است. ۱۵ نمونه جهت انتخاب بهترین الگوریتم و ۱۵ نمونه جهت ارزیابی الگوریتم مورد استفاده قرار گرفت.

طبقه‌بندی

در این پژوهش ۹ روش طبقه‌بندی با نظارت که در پژوهش‌های ارائه شده در جدول ۳ معرفی شده اند، بر روی مجموعه داده بررسی و در نهایت بهترین مدل جهت آزمون انتخاب شد. روش‌های مورد استفاده در جدول ۳ آورده شده است.

جدول ۱- معرفی روش‌های طبقه‌بندی مورد استفاده

منبع	روش
Berrar (2018)	Naive Bayes Classifier
Yu & Su (2019)	Bagging Classifier
Sandesh Kumar <i>et al.</i> , (2021)	Ada Boost Classifier
Jahanbakhshi & Kheiralipour (2020)	Quadratic Discriminant Analysis
Huang <i>et al.</i> , (2019)	Linear Discriminant Analysis
Zhao <i>et al.</i> , (2020)	SVM (Linear- Polynomial- Sigmoid- RBF)
Pomares <i>et al.</i> , (2018)	Logistic Regression
Becker <i>et al.</i> , (2018)	Gradient Boosting Classifier
Medina & Paffenroth, (2021).	KNN- Classifier

به منظور ارزیابی دقت الگوریتم از معیارهای $F1$ -Score، سطح زیرمنحنی Roc و صحت طبقه‌بندی استفاده شده است. همانطور که در شکل ۶ مشاهده می‌شود، در نهایت پس از بازسازی مدل سه‌بعدی کلاس مربوط به فلفل دلمه‌ای بر اساس بهترین مدل طبقه‌بندی بر روی ۱۵ مدل مورد بازیابی و شمارش انسانی قرار گرفته است. دقت حاصل در جدول ۵ بیان شده است.

به منظور تصویربرداری عمیق، ساخت مدل سه‌بعدی و استخراج ویژگی‌های هندسی و رنگی از نرم‌افزار Matlab R2018b و جهت پیش‌پردازش و طبقه‌بندی مدل‌های

$$\alpha = V \cdot n_2 \quad (۳)$$

$$\phi = U \cdot \frac{P_2 - P_1}{d} \quad (۴)$$

$$\theta = \arctan(W \cdot n_2, U \cdot n_2) \quad (۵)$$

$$d = \|p_2 - p_1\| \quad (۶)$$

$$\sigma_p = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2} \quad (۷)$$

در روابط فوق α, ϕ و θ توصیف‌کننده زوایای بین بردارهای نرمال هستند. فاصله اقلیدسی بین دو نقطه با d نشان داده شده است. λ بیانگر مقدار ویژه در ماتریس کوواریانس در یک همسایگی از نقطه جستجو و σ_p توصیف‌کننده انحنای سطح است که به منظور تخمین بردارهای نرمال سطح از آن استفاده می‌شود. جهت تعیین نظارت و ارزیابی الگوریتم خوشه‌بندی از ناظرهای رنگی برای هر فلفل دلمه‌ای در سه رنگ زرد، قرمز و نارنجی استفاده شد. برای این منظور از فضای رنگی HSV به دلیل تأثیر کمتر شرایط محیطی بر روی این فضای رنگی استفاده شد (Gonzalez & Wood, 2002). برای این منظور اختلاف در کانال رنگی H در هر سه نوع فلفل مورد بررسی قرار گرفت. پس از تبدیل مدل رنگی RGB به مدل HSV به صورت تصادفی از نواحی مربوط به فلفل دلمه‌ای و شاخه و برگ نمونه‌برداری و سپس مورد مقایسه قرار گرفت. مقادیر حد آستانه (تمایز رنگی بین فلفل و سایر اجزای گیاه) برای این سه ناظر در جدول ۲ بیان شده است.

جدول ۲- تعیین حد آستانه جهت تعیین نظارت به منظور

ارزیابی دقت الگوریتم خوشه‌بندی

نوع فلفل	کانال رنگی	بازه تغییرات
زرد	H	$0 < H < 0.17$
قرمز	H	$0.17 < H < 1$
نارنجی	H	$0 < H < 0.13$

پیش‌پردازش ویژگی‌های استخراج شده

حذف داده‌های دورافتاده

برای حذف داده‌های دور افتاده، از دو فیلتر عمق $(z < 1200)$ و معیار Z -Score استفاده شد (Nurunnabi *et al.*, 2015). از فیلتر عمیق جهت حذف داده‌هایی که مقدار عمق آن‌ها در فاصله‌ای خارج از ردیف کشت و دور از حسگر و ردیف کشت قرار داشت و از معیار Z -Score جهت حذف داده‌هایی که در هر ویژگی از میانگین کل

معیار ذکر شده بیشتر از ۷۰ درصد است. بنابراین مناسب‌ترین روش جهت تشخیص فلفل دلمه‌ای در ابر نقاط در مجموعه داده مورد استفاده الگوریتم KNN است. این نتیجه با توجه به اینکه برای طبقه‌بندی از ویژگی‌های هندسی استفاده شده، دور از انتظار نبود. چرا که انتظار می‌رود نقاطی که در همسایگی یکدیگر قرار دارند، متعلق به یک طبقه باشند و در نتیجه ویژگی‌های هندسی آن‌ها به هم نزدیک باشد.

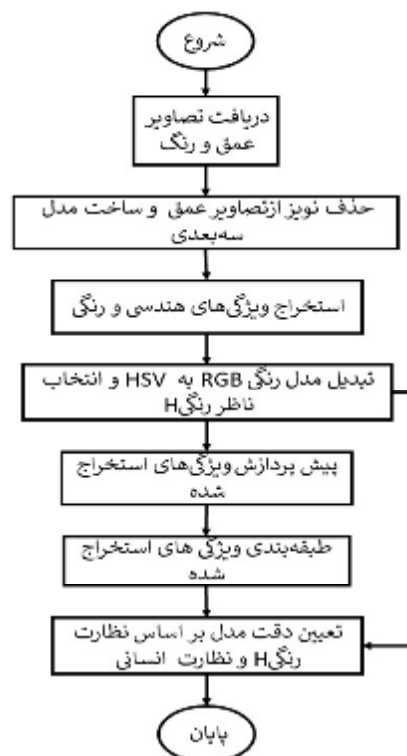
برای مقایسه بهتر الگوریتم‌های مورد بررسی نمودار جعبه‌ای معیار F1-Score در شکل ۵ رسم شده است (بالا بودن F1-Score، بالا بودن صحت الگوریتم و بالا بودن سطح زیرمنحنی Roc را نتیجه می‌دهد).

معیارهای ارزیابی دقت طبقه‌بندی در جدول ۵ آورده شده است. همانطور که مشاهده می‌شود معیار F1-Score به جز یک مورد در همه موارد بالاتر از ۰/۷ به دست آمده است. سطح زیر منحنی Roc نیز در همه موارد بالاتر از ۰/۸ و صحت الگوریتم طبقه‌بندی در همه موارد بالاتر از ۰/۹ به دست آمده است که نشان از دقت بالای الگوریتم در تشخیص اهداف است.

در شکل ۶ الگوریتم‌های طبقه‌بندی بر اساس مدت زمان اجرا نیز مورد آزمون قرار گرفته‌اند. همان‌طور که مشاهده می‌شود، روش ماشین بردار پشتیبان بیشترین زمان اجرا در هر سه حالت Linear, RBF, Polynomial و Sigmoid بیشترین زمان اجرا را داشته‌اند. همچنین کمترین زمان اجرا مربوط به روش رگرسیون لجستیک است. روش KNN به عنوان مناسب‌ترین روش معرفی شده در جدول ۵ با زمان ۹/۴۵ ثانیه عملیات طبقه‌بندی را انجام می‌دهد. با توجه به اینکه این زمان اجرا بر روی یک سیستم رایانه-ای معمولی به دست آمده است، با توجه به دقت این روش در مقایسه با سایر روش‌ها جهت استفاده در برداشت رباتیک مناسب به نظر می‌رسد.

نتایج حاصل از ارزیابی انسانی نشان داد که به جز یک مدل که دقت تشخیص فلفل در آن ۶۲/۵ به دست آمده، حداقل دقت ۷۱/۴۲ درصد و در بعضی موارد نیز دقت ۱۰۰ درصد حاصل شده است. با توجه به دامنه دید حسگر Kinect v2 در هر مدل سه‌بعدی یا تصویر عمق ممکن است یک تا چندین فلفل مشاهده شود که همه این‌ها با توجه به دلایلی چون در دسترس نبودن برای یک بازوی ربات و چندرنگی بودن فلفل‌ها، هدف تشخیص

سه‌بعدی از زبان برنامه‌نویسی Python 3.8 و محیط توسعه Jupyter استفاده شد. در نرم افزار پایتون از کتابخانه‌های numpy, pandas, collections, scipy, sklearn و timeit بهره گرفته شده است. در شکل ۴ مراحل انجام این تحقیق در قالب یک نمودار نمایش داده شده است.



شکل ۴- نمایش مراحل اجرای تحقیق

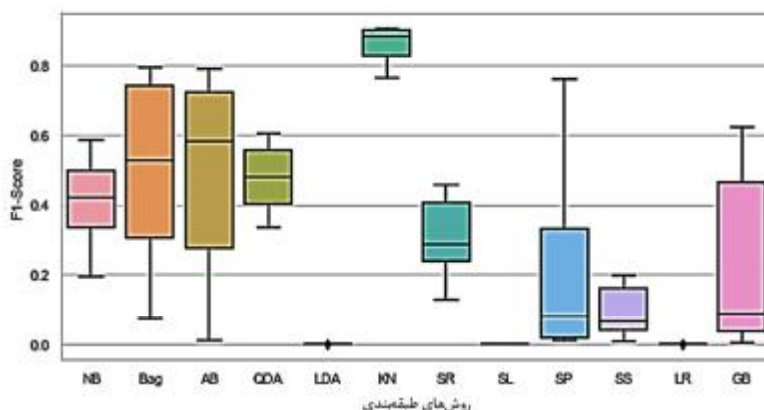
نتایج و بحث

در این قسمت نتایج حاصل از تشخیص و طبقه‌بندی ارائه شده است. در جدول ۴ کمینه، بیشینه و میانگین معیارهای دقت طبقه‌بندی شامل صحت طبقه‌بندی سطح زیر منحنی Roc و F1-Score بر اساس ۱۵ مدل سه‌بعدی از فلفل دلمه‌ای قرمز، آورده شده است. در تشخیص و طبقه‌بندی، روشی جهت طبقه‌بندی مناسب است که هر سه معیار صحت، سطح زیر منحنی Roc و F1-Score آن بالاتر از ۷۰ درصد باشد (Tao & Zhou, 2017; Hana et al., 2018). مطابق جدول ۲، در الگوریتم KNN، میانگین صحت طبقه‌بندی برابر با ۹۶/۴۴ درصد، میانگین سطح زیر منحنی Roc برابر با ۹۰/۶۷ درصد و میانگین F1-Score برابر با ۸۶ درصد است. همچنین کمینه هر سه

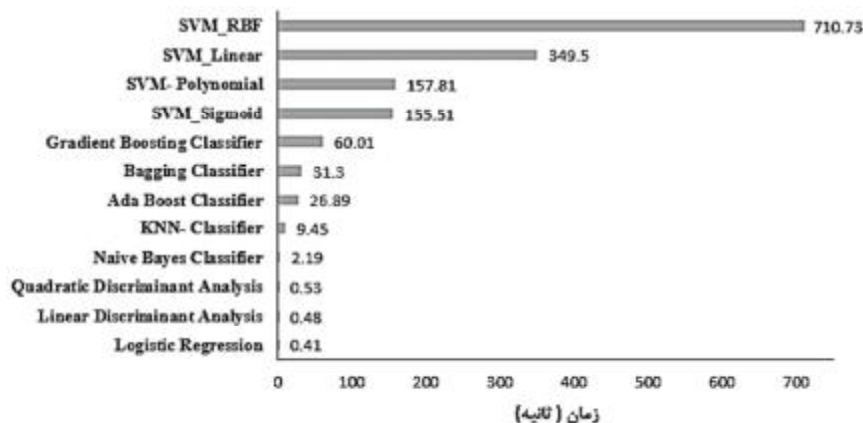
الگوریتم نبود. همانطور که در شکل ۷ مشاهده می‌شود با توجه به موقعیت مکانی خود قابلیت برداشت آن را فلغل‌هایی به عنوان فلغل هدف در نظر گرفته شده‌اند که اولاً مطابق با رنگ مورد نظر باشند و ثانیاً یک بازوی ربات داشته باشد.

جدول ۲- آماره‌های توصیفی جهت انتخاب بهترین روش طبقه‌بندی با نظارت بر اساس معیارهای صحت، سطح زیر منحنی Roc و F1-score

معیارهای ارزیابی دقت مدل									روش طبقه‌بندی
Accuracy			Roc			F1-score			
mean	max	min	mean	max	min	mean	max	min	
۷۱/۶۷	۸۴/۱۱	۶۴/۱۴	۷۰/۸۸	۷۳/۳۲	۶۶/۰۷	۴۰/۸۴	۵۸/۶۱	۱۹/۴۱	Naive Bayes Classifier
۹۱/۸۰	۹۵/۰۱	۹۰/۱۲	۶۸/۶۱	۸۳/۷۳	۵۱/۸۸	۴۹/۵۳	۷۹/۳۴	۷/۲۳	Bagging Classifier
۹۱/۴۶	۹۴/۷۵	۸۹/۵۶	۵۰/۲۲	۸۳/۷۴	۵۰/۲۲	۴۹/۶۵	۷۹/۰۳	۱/۰۳	Ada Boost Classifier
۷۹/۲۱	۹۰/۴۴	۷۲/۳۲	۷۴/۳۰	۷۷/۳۰	۷۰/۲۱	۴۷/۶۱	۶۰/۳۹	۳۳/۲۹	Quadratic Discriminant Analysis
۸۴/۹۴	۹۴/۷۷	۷۳/۱۶	۴۹/۹۵	۵۰/۰۰	۴۹/۹۹	۰/۰۰	۰/۰۲	۰/۰۰	Linear Discriminant Analysis
۸۴/۹۶	۹۴/۷۷	۷۳/۲۱	۵۰/۰۰	۵۰/۰۰	۵۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	SVM- Linear
۸۸/۳۸	۹۴/۸۰	۸۰/۱۴	۵۸/۴۹	۸۲/۵۸	۵۰/۲۶	۲۲/۶۲	۷۶/۱۶	۱/۰۴	SVM- Polynomial
۷۳/۸۹	۸۹/۸۷	۵۶/۷۳	۴۶/۶۶	۴۸/۶۰	۴۴/۷۲	۹/۲۲	۱۹/۶۳	۰/۸۲	SVM- Sigmoid
۶۴/۱۴	۵۳/۳۱	۳۶/۹۵	۶۱/۳۱	۶۴/۷۱	۵۸/۳۸	۳۰/۴۸	۴۵/۵۷	۱۲/۶۰	SVM-RBF
۸۸/۹۴	۹۴/۷۷	۷۳/۱۱	۴۹/۹۹	۵۰/۰۲	۴۹/۹۳	۰/۰۱	۰/۱۳	۰/۰۰	Logistic Regression
۸۸/۳۹	۹۴/۷۹	۸۴/۱۷	۵۸/۱۱	۷۲/۶۱	۵۰/۱۱	۲۴/۳۶	۶۲/۱۸	۰/۴۳	Gradient Boosting Classifier
۹۶/۴۴	۹۷/۹۱	۹۴/۸۵	۹۰/۶۷	۹۳/۹۸	۸۳/۶۴	۸۶/۰۰	۹۰/۴۰	۷۶/۶۱	KNN- Classifier



شکل ۵- نمودار جعبه‌ای F1-score برای روش‌های مختلف طبقه‌بندی



شکل ۶- مقایسه زمان اجرای روش‌های مختلف طبقه‌بندی

جدول ۳ - معیارهای ارزیابی دقت مدل و نتایج حاصل از بازبینی انسانی برای سه نوع فلفل قرمز، نارنجی و زرد


دقت	بازبینی انسانی			معیارهای ارزیابی دقت مدل				نوع فلفل
	تعداد فلفل شناسایی شده	تعداد فلفل هدف	تعداد کل فلفل در تصویر (سبز، زنگی)	Accuracy	Roc	F1-scor	شماره تصویر	
۸۷/۵۰	۷	۸	۱۰	۹۵/۶۸	۹۳/۱۶	۸۸/۳۰	۱	فلفل قرمز
۸۰/۰۰	۴	۵	۹	۹۶/۶۵	۹۱/۳۷	۸۵/۲۴	۲	
۸۰/۰۰	۴	۵	۱۱	۹۵/۱۰	۸۷/۳۸	۸۰/۷۱	۳	
۱۰۰	۳	۳	۸	۹۶/۴۰	۸۸/۳۸	۸۱/۵۲	۴	
۱۰۰	۳	۳	۶	۹۷/۷۷	۸۵/۲۱	۷۷/۷۴	۵	
۸۰	۸	۱۰	۱۲	۹۲/۷	۹۲/۲۶	۸۷/۷۹	۱	فلفل نارنجی
۸۰	۸	۱۰	۱۷	۹۲/۳۵	۹۲/۱۶	۸۸/۳۴	۲	
۶۲/۵۰	۵	۸	۱۳	۹۴/۵۲	۹/۷۸	۶۹/۸	۳	
۷۷/۷۷	۷	۹	۱۲	۹۵/۱۸	۸۰/۴۶	۷۲/۷۵	۴	
۷۱/۴۲	۵	۷	۱۱	۹۴/۸۹	۸۴/۹	۷۹/۵۳	۵	
۸۸/۸۸	۸	۹	۱۵	۹۲/۸۴	۹۲/۵۰	۸۹/۰۳	۱	فلفل زرد
۸۸/۸۸	۸	۹	۱۴	۹۲/۴۵	۹۲/۲۷	۸۸/۹۹	۲	
۸۰	۴	۵	۷	۹۳/۶۲	۹۱/۷۵	۸۶/۴۱	۳	
۸۳/۳۳	۵	۶	۱۱	۹۲/۵۷	۹۲/۳۳	۸۸/۹۵	۴	
۸۵/۷۱	۶	۷	۹	۹۴/۳۸	۸۲/۶	۷۵/۴۴	۵	

استفاده از شاخه و برگ و یا روی هم افتادن آنها است که این مورد سبب تشکیل بخشی از مدل ابر نقاط فلفل‌های تشخیص داده شده است. همانطور که در شکل ۸ مشاهده می‌شود، بعضی از نقاط تشخیص داده شده با دایره‌های قرمز رنگ نمایش داده شده است. این نقاط در واقع نقاطی هستند که به اشتباه به عنوان فلفل تشخیص داده شده‌اند. با توجه به اینکه ویژگی هیستوگرام سریع نقطه توصیف کننده انحنای سطح است. تشخیص این نقاط به عنوان فلفل به واسطه وجود تشابه در انحنای سطح برگ و ساقه در بعضی نواحی است. البته با توجه به اینکه این نقاط در مقابل نقاط تشخیص داده شده به عنوان فلفل ناچیز هستند. به عنوان نویز قابل حذف کردن هستند و البته این نقاط ویژگی‌های رنگی نقاط فلفل را ندارند که خود سبب تمایز است.

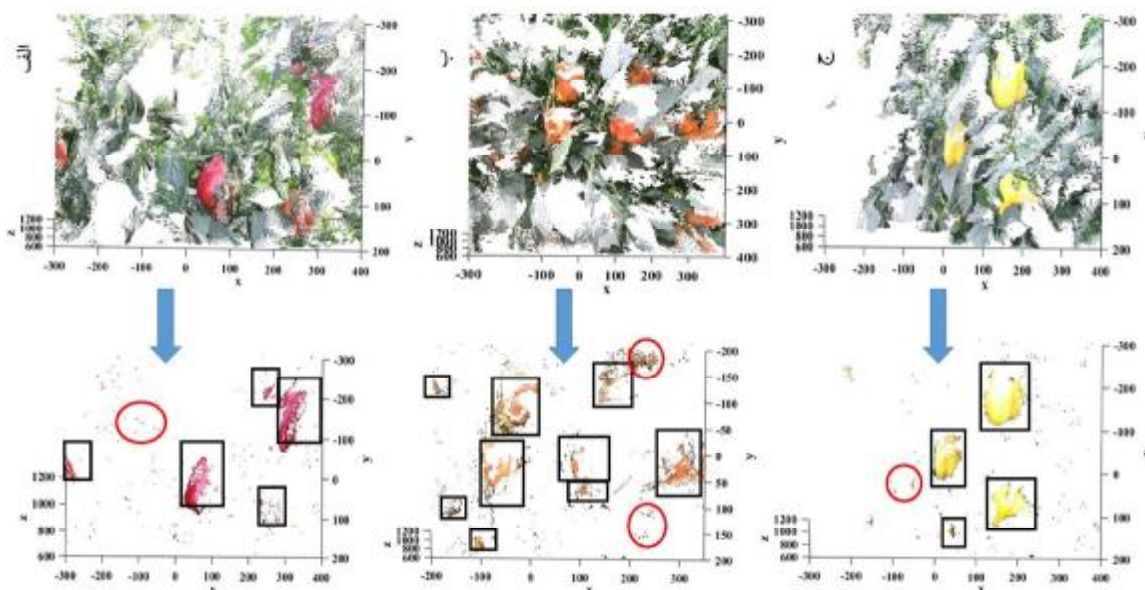
پس از طبقه‌بندی مدل سه‌بعدی به دو کلاس فلفل دلمه‌ای و شاخه و برگ گیاه، مدل سه‌بعدی مربوط به تشخیص فلفل دلمه‌ای قرمز، فلفل دلمه‌ای نارنجی و فلفل دلمه‌ای زرد در شکل ۸ نمایش داده شده است.

مطابق جدول ۵ معیارهای دقت طبقه‌بندی در هر سه نوع فلفل بیشتر از ۷۰ درصد است، بنابراین دقت طبقه‌بندی در هر سه نوع فلفل قابل قبول است. در بازبینی انسانی در ۱۴ مورد بیش از ۷۰ درصد فلفل‌های هدف تشخیص داده شده بودند و تنها در یک مورد ۶۲/۵ درصد فلفل‌ها تشخیص داده شدند.

همان‌طور که مشاهده می‌شود در ابر نقاط مربوط به فلفل‌های تشخیص داده شده، مدل کامل از فلفل دلمه برگردان نشده یا در مواردی حفره‌ای در آن شکل گرفته است. وجود این موارد به دلیل پوشیده شدن فلفل‌ها با



شکل ۷- نمایش وجود فلفل های غیر هدف در برداشت هر نوع فلفل. الف) فلفل دلمه نارنجی ب) فلفل دلمه قرمز ج) فلفل دلمه زرد



شکل ۸- نمایش تشخیص فلفل دلمه‌ای در سه رنگ قرمز (الف)، نارنجی (ب) و زرد (ج) از مدل های سه‌بعدی. ردیف اول مدل سه‌بعدی شامل شاخه و برگ و فلفل دلمه‌ای. ردیف دوم نمایش مدل سه‌بعدی فلفل‌های تشخیص داده شده

همان‌طور که در بخش مقدمه بیان شد، پژوهش‌های مشابهی نیز در این حوزه صورت گرفته است. این پژوهش‌ها هر دو بر روی محصول فلفل دلمه‌ای صورت گرفته است. در پژوهشی به تشخیص فلفل دلمه‌ای و دمگل آن با استفاده از الگوریتم ماشین بردار پشتیبان پرداخته شده است که دقت ۰/۷۱ حاصل شد (Sa et al., 2017). در مقابل در پژوهش حاضر ماشین بردار پشتیبان الگوریتم مناسبی نبود. دلیل این امر می‌تواند در نامتعادل بودن داده‌های مورد استفاده در پژوهش باشد. همچنین از ترکیب ابرنقاط در جهات مختلف استفاده شده، که منجر به ایجاد ابر نقاط کامل‌تر و متعادل‌تری شده است. اما این روش حجم محاسبات و زمان انجام را به شدت افزایش می‌دهد. در این حالت فاصله حسگر به بوته کم‌تر شده و دامنه دید محدودتری دارد. بنابراین پس‌زمینه ساده‌تری

نسبت به فلفل در مدل مشاهده می‌شود. در حالی که استفاده از یک تصویر عمق در پژوهش حاضر منجر به ایجاد حوزه دید وسیع‌تر و به دنبال آن پس‌زمینه پیچیده‌تری می‌شود که داده‌های نامتعادل‌تری ایجاد می‌کند. در پژوهش مشابه دیگری (Zhao et al., 2020) جهت تشخیص بدون نظارت فلفل دلمه‌ای رنگی در مدل‌های سه‌بعدی از یک الگوریتم خوشه‌بندی بر اساس فاصله اقلیدسی استفاده شده و دقت بازبینی انسانی برابر با ۹۰/۶۹ درصد حاصل شده است. به نظر می‌رسد استفاده از فیلتر رنگی R-G با توجه به رنگی بودن نمونه‌ها اثر زیادی در افزایش دقت داشته است. در حالی که در پژوهش حاضر از هیچ ویژگی رنگی استفاده نشده و صرفاً از ویژگی‌های هندسی جهت خوشه‌بندی استفاده شده است.

نتیجه‌گیری

هدف از انجام این پژوهش تشخیص فلفل دلمه‌ای رنگی در مدل‌های سه‌بعدی با استفاده از توصیف‌گر هندسی FPFH بود. جهت دریافت تصاویر عمق و رنگ و تشکیل مدل ابر نقاط از حسگر Kinect v2 استفاده شد. به منظور طبقه‌بندی مدل ابر نقاط ۹ الگوریتم طبقه‌بند بر روی ۱۵ ابر نقطه از فلفل دلمه رنگی مورد بررسی قرار گرفت و بر اساس معیارهای ارزیابی مدل طبقه‌بند مدل KNN به عنوان بهترین مدل بر اساس دقت، صحت، سطح زیر منحنی Roc و مدت زمان اجرا انتخاب شد. لازم به ذکر است در این مقاله جهت طبقه‌بندی تنها از ویژگی‌های هندسی استفاده شد و ویژگی‌های رنگی تنها برای ایجاد ناظر مورد استفاده قرار گرفتند. بدیهی است که چنانچه رنگ را به ویژگی‌ها اضافه کنیم تعداد فلفل‌هایی که تشخیص داده می‌شوند، بیشتر و مدل کامل‌تری به دست خواهد آمد. از طرفی هنگامی که از رنگ به عنوان ناظر استفاده شده است، ورود آن به مدل طبقه‌بندی موجب افزایش دقت به صورت کاذب خواهد شد. روش مورد استفاده در این پژوهش شامل ساخت مدل سه‌بعدی با استفاده از حسگر Kinect، استخراج ویژگی‌های هندسی و رنگی و طبقه‌بندی مدل‌های ابر نقاط علاوه بر اینکه می‌تواند در طراحی و ساخت ربات‌های برداشت کشاورزی مورد استفاده قرار بگیرد، می‌تواند در پژوهش‌های دیگر از جمله تشخیص موانع در مسیر حرکت ربات در محیط گلخانه، تشخیص خودکار سایر محصولات گلخانه‌ای از جمله خیار که رنگ مشابهی با شاخه و برگ دارد، تشخیص خودکار میوه خارج از محیط گلخانه، تخمین وزنی عملکرد باغات و سایر تحقیقات مشابه مورد استفاده قرار گیرد. نویسندگان در این مقاله بیشتر درصدد بررسی این موضوع بودند که آیا ویژگی‌های هندسی قادر به تشخیص فلفل‌های دلمه‌ای از برگ و ساقه هستند یا خیر، تا بتوانند راه‌کاری جهت تشخیص فلفل دلمه‌ای سبز برای مطالعات بعدی بیابند. با توجه به چالش‌های زیاد در تشخیص فلفل دلمه‌ای سبز به دلیل نزدیکی رنگ فلفل دلمه‌ای سبز به رنگ برگ و ساقه پیشنهاد می‌شود تشخیص فلفل دلمه‌ای سبز مبتنی بر توصیف‌گرهای سه‌بعدی محلی در یک مطالعه مستقل مورد بررسی قرار گیرد.

سپاسگزاری

بدینوسیله از پارک علم و فناوری خراسان به دلیل حمایت مالی این پروژه و دانشگاه فردوسی مشهد به خاطر در اختیار گذاشتن امکانات و تجهیزات تقدیر و تشکر می‌شود. همچنین از دکتر امیرحسین نایبی آستانه به خاطر نظرات ارزشمندشان در انجام این پروژه کمال تشکر را داریم.

منابع

- Ball, D., Upcroft, B., Wyeth, G., Corke, P., English, A., Ross, P., Patten, T., Fitch, R., Sukkarieh, S. & Bate, A. (2016). Vision-based Obstacle Detection and Navigation for an Agricultural Robot. *Journal of Field Robotics*, 33(8): 1107-1130.
- Becker, C., Rosinskaya, E., Häni, N., d'Angelo, E., & Strecha, C. (2018). Classification of aerial photogrammetric 3D point clouds. *Photogrammetric Engineering & Remote Sensing*, 84(5): 287-295.
- Berrar, D. (2018). Bayes' theorem and naive Bayes classifier. *Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics*, 4: 403-412.
- Billingsley, J., Visala, A. & Dunn, M. (2008). *Robotics in agriculture and forestry*. In Springer handbook of robotics. Springer Berlin Heidelberg, 1065-1077.
- Bosland, P. W., Votava, E. J. & Votava, E. M. (2012). Peppers: *vegetable and spice capsicums* (Vol. 22). Cabi.
- Chidambaranathan, C. M., Handa, S., & Ramanamurthy, M. (2018). Development of smart farming-a detailed study. *Int. J. Eng. Technol*, 7(2): 56-58.
- De Reu, J., Plets, G., Verhoeven, G., De Smedt, P., Bats, M., Cherretté, B., De Maeyer, W., Deconynck, J., Herremans, D., Laloo, P. & Van Meirvenne, M. (2013). Towards a three-dimensional cost-effective registration of the archaeological heritage. *Journal of Archaeological Science*, 40(2): 1108-1121.
- De-An, Z., Jidong, L., Wei, J., Ying, Z. & Yu, C. (2011). Design and control of an apple harvesting robot. *Biosystems engineering*, 110(2): 112-122.
- Dharmaraj, V., & Vijayanand, C. (2018). Artificial intelligence (AI) in agriculture. *International Journal of Current Microbiology and Applied Sciences*, 7(12): 2122-2128.
- Foley, J. A., Ramankutty, N., Brauman, K. A., Cassidy, E. S., Gerber, J. S., Johnston, M., Mueller, N. D., O'Connell, C., Ray, D. K., West, P. C. & Balzer, C. (2011). *Solutions*

- Sensing and Spatial Information Sciences*, 40(5): 93
- McCool, C., Sa, I., Dayoub, F., Lehnert, C., Perez, T. & Uperoft, B. (2016), May. Visual detection of occluded crop: For automated harvesting. *In Robotics and Automation (ICRA), 2016 IEEE International Conference on*. 2506-2512). IEEE.
- Medina, F. P., & Paffenroth, R. (2021). Machine Learning in LiDAR 3D point clouds. *In Advances in Data Science*. 113-133.
- Moghim, A., Aghkhani, M., & Golzarian, M. (2015). Designing of Computer Vision Algorithm to Detect Sweet Pepper for Robotic Harvesting Under Natural Light. *Journal of Agricultural Machinery*, 5(1): 82-91. (In Persian)
- Moonrinta, J., Chaivivatrakul, S., Dailey, M. N., & Ekpanyapong, M. (2010). Fruit detection, tracking, and 3D reconstruction for crop mapping and yield estimation. *In Control Automation Robotics & Vision (ICARCV), 2010 11th International Conference on*, 1181-1186.
- Nguyen, T.T., Vandevoorde, K., Kayacan, E., De Baerdemaeker, J. & Saeys, W. (2014). Apple detection algorithm for robotic harvesting using a RGB-D camera. *In International Conference of Agricultural Engineering, Zurich, Switzerland*.
- Nguyen, V. T., Vu, H., & Tran, T. H. (2015). An efficient combination of RGB and depth for background subtraction. *In Some Current Advanced Researches on Information and Computer Science in Vietnam*, 49-63.
- Nissimov, S., Goldberger, J. & Alchanatis, V. (2015). Obstacle detection in a greenhouse environment using the Kinect sensor. *Computers and Electronics in Agriculture*, 113: 104-115.
- Nurunnabi, A., West, G., & Belton, D. (2015). Outlier detection and robust normal-curvature estimation in mobile laser scanning 3D point cloud data. *Pattern Recognition*, 48(4): 1404-1419.
- Pagliari, D., & Pinto, L. (2015). Calibration of Kinect for Xbox one and comparison between the two generations of Microsoft sensors. *Sensors*, 15(11): 27569-27589.
- Pomares, A., Martínez, J. L., Mandow, A., Martínez, M. A., Morán, M., & Morales, J. (2018). Ground extraction from 3D lidar point clouds with the classification learner app. *In 2018 26th Mediterranean Conference on Control and Automation (MED)*, 1-9.
- Remondino, F., Spera, M.G., Nocerino, E., Menna, F. & Nex, F. (2014). State of the art for a cultivated planet. *Nature*, 478(7369): 337-342.
- Furukawa, Y. & Ponce, J. (2010). Dense 3D motion capture from synchronized video streams. *In Image and Geometry Processing for 3-D Cinematography*. Springer Berlin Heidelberg, 193-211.
- García-Gago, J., González-Aguilera, D., Gómez-Lahoz, J. & San José-Alonso, J. I. (2014). A photogrammetric and computer vision-based approach for automated 3D architectural modeling and its typological analysis. *Remote Sensing*, 6(6): 5671-5691.
- Gonçalves, J. A. & Henriques, R. (2015). UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104: 101-111.
- Gonzalez, R. C., & Woods, R. E. (2002). Digital image processing. upper saddle River. J.: Prentice Hall.
- Hana, X. F., Jin, J. S., Xie, J., Wang, M. J. & Jiang, W. (2018). A comprehensive review of 3D point cloud descriptors. *arXiv preprint arXiv:1802-02297*.
- Hemming, J., Ruizendaal, J., Hofstee, J. W. & van Henten, E. J. (2014). Fruit detectability analysis for different camera positions in sweet-pepper. *Sensors*, 14(4): 6032-6044.
- Huang, R., Hong, D., Xu, Y., Yao, W., & Stilla, U. (2019). Multi-scale local context embedding for LiDAR point cloud classification. *IEEE Geoscience and Remote Sensing Letters*, 17(4): 721-725.
- Jahanbakhshi, A., & Kheiralipour, K. (2020). Evaluation of image processing technique and discriminant analysis methods in postharvest processing of carrot fruit. *Food Science & Nutrition*, 8(7): 3346-3352.
- Jiang, L., Koch, A. & Zell, A. (2016). Object recognition and tracking for indoor robots using an rgb-d sensor. *In Intelligent Autonomous Systems*, 13: 859-871.
- Kumazakia, R. & Kunii, Y. (2016). 3D modeling of components of a garden by using point cloud data. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 5: 305-309.
- Kurtulmus, F., Lee, W.S. & Vardar, A. (2011). Green citrus detection using 'eigenfruit', color and circular Gabor texture features under natural outdoor conditions. *Computers and Electronics in Agriculture*, 78(2): 140-149.
- Lachat, E., Macher, H., Mittet, M. A., Landes, T., & Grussenmeyer, P. (2015). First experience with Kinect v2 sensor for close range 3D modeling. *The International Archives of Photogrammetry, Remote*

- Tilman, D., Balzer, C., Hill, J. and Befort, B.L. (2011). Global food demand & the sustainable intensification of agriculture. *Proceedings of the National Academy of Sciences*, 108(50): 20260-20264.
- Tridge. Bell pepper production. Retrieved 5 August 2022. Anonymous (2022)
- Tung, T. & Matsuyama, T (2014). Geodesic mapping for dynamic surface alignment. *IEEE transactions on pattern analysis and machine intelligence*, 36(5): 901-913.
- Van Henten, E.J., Van Tuijl, B.V., Hemming, J., Kornet, J.G., Bontsema, & Van Os, E.A. (2003). Field test of an autonomous cucumber picking robot. *Biosystems engineering*, 86(3): 305-313.
- Vázquez-Arellano, M., Griepentrog, H.W., Reiser, D. & Paraforos, D.S. (2016). 3-D Imaging Systems for Agricultural Applications—A Review. *Sensors*, 16(5): 618.
- Vosselman, G. (2012). Automated planimetric quality control in high accuracy airborne laser scanning surveys. *ISPRS Journal of photogrammetry and remote sensing*, 74: 90-100.
- Yu, Y., & Su, H. (2019). Collaborative representation ensemble using bagging for hyperspectral image classification. In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, 2738-2741.
- Zhao, Q., Brocks, S., Lenz-Wiedemann, V.I., Miao, Y., Zhang, F. & Bareth, G. (2017). Detecting spatial variability of paddy rice yield by combining the DNDC model with high resolution satellite images. *Agricultural Systems*, 152: 47-57.
- Zhao, Z., Song, Y., Cui, F., Zhu, J., Song, C., Xu, Z., & Ding, K. (2020). Point cloud features-based kernel SVM for human-vehicle classification in millimeter wave radar. *IEEE Access*, 8: 26012-26021.
- in high density image matching. *The Photogrammetric Record*, 29(146): 144-166.
- Rose, J.C., Paulus, S. & Kuhlmann, H. (2015). Accuracy analysis of a multi-view stereo approach for phenotyping of tomato plants at the organ level. *Sensors*, 15(5): 9651-9665.
- Rusu, R. B., Marton, Z. C., Blodow, N., & Beetz, M. (2008). Persistent point feature histograms for 3D point clouds. In *Proc 10th Int Conf Intel Autonomous Syst (IAS-10)*, Baden-Baden, Germany, 119-128.
- Rusu, R.B., Blodow, N. & Beetz, M. (2009), May. Fast point feature histograms (FPFH) for 3D registration. In *Robotics and Automation, 2009. ICRA'09. IEEE International Conference on robotics and automation*. 3212-3217. IEEE.
- Sa, I., Lehnert, C., English, A., McCool, C., Dayoub, F., Upcroft, B., & Perez, T. (2017). Peduncle detection of sweet pepper for autonomous crop harvesting-combined color and 3-D information. *IEEE Robotics and Automation Letters*, 2(2): 765-772.
- Sandesh Kumar, C., Sharma, V. K., Yadav, A. K., & Singh, A. (2021). Perception of plant diseases in color images through adaboost. In *Innovations in Computational Intelligence and Computer Vision*. 506-511). Springer, Singapore.
- Sarig, Y. (2005). Mechanized fruit harvesting-site specific solutions. *Information and technology for sustainable fruit and vegetable production, Frutic*, 5: 237-247.
- Shen, B., Yin, F., & Chou, W. (2017). A 3D Modeling Method of Indoor Objects Using Kinect Sensor. In *2017 10th International Symposium on Computational Intelligence and Design (ISCID)*, 1: 64-68.
- Silspur, M. (2018). Nutrition management of sweet pepper in greenhouses and farms with emphasis on reducing nitrate accumulation. *Soil and Water Research Institute*. Karaj. (In Persian).
- Tanskanen, P., Kolev, K., Meier, L., Camposeco, F., Saurer, O. & Pollefeys, M. (2013). Live metric 3d reconstruction on mobile phones. In *Proceedings of the IEEE International Conference on Computer Vision*, 65-72.
- Tao, W. (2014). Multi-view dense match for forest area. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(1): 397.
- Tao, Y., & Zhou, J. (2017). Automatic apple recognition based on the fusion of color and 3D feature for robotic fruit picking. *Computers and electronics in agriculture*, 142: 388-396.

