

قطعه‌بندی تصاویر بافت‌دار به کمک برش گراف کرنل مبتنی بر آنتروپی و شبکه عصبی عمیق VGG16

مهرناز نیازی^۱، دانشجوی دکتری، کامبیز رهبر^۲، استادیار، منصور شیخان^۳، استاد، مریم خادمی^۴، دانشیار

۱- گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران، st_m_niazi@azad.ac.ir

۲- گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران، k_rahbar@azad.ac.ir

۳- گروه مهندسی برق، دانشکده فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران، msheikh@azad.ac.ir

۴- گروه ریاضیات کاربردی، دانشکده علوم پایه، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران، khademi@azad.ac.ir

چکیده: اخیراً قطعه‌بندی تصویر بر پایه روش‌های برش گراف کارایی چشمگیری را روی مجموعه‌ای از داده‌های تصویری به نمایش گذاشته‌اند. اگرچه که روش برش گراف کرنل کارایی مناسبی را تأمین می‌کند ولی کارایی آن به شدت به نگاشت داده‌ها به فضای تبدیل و ویژگی‌های تصویر وابسته است. روش برش گراف کرنل مبتنی بر آنتروپی برای قطعه‌بندی تصاویر بافت‌دار مناسب می‌باشد. با این حال کیفیت قطعه‌بندی آن متأثر از کیفیت استخراج مراکز کرنل است. این مقاله به بررسی قطعه‌بندی تصاویر بافت‌دار با استفاده از روش برش گراف کرنل مبتنی بر آنتروپی و VGG۱۶ بر اساس k-means وزن‌دار می‌پردازد. با بهره‌گیری از مزایای فضای کرنل، تابع هدف از دو مولفه داده جهت انتقال انحراف معیار داده هر ناحیه در تصویر قطعه‌بندی شده و مولفه تنظیم تشکیل می‌گردد. روش پیشنهادی درحالی‌که از مزیت‌های بار محاسباتی مناسب روش‌های مبتنی بر برش گراف بهره می‌برد، جایگزین مناسبی برای قطعه‌بندی تصاویر بافت‌دار خواهد بود. نتایج آزمایشگاهی بر روی مجموعه‌ای از دیتاست‌های معروف که شامل اشکال بافت‌دار هستند گرفته شده است تا کارایی الگوریتم در مقایسه با سایر روش‌های معروف در حوزه برش گراف کرنل مورد ارزیابی قرار گیرد.

واژه‌های کلیدی: قطعه‌بندی تصاویر، برش گراف کرنل، کرنل تابع پایه شعاعی، تصاویر بافت‌دار، خوشه‌بندی وزن‌دار.

Textural Image Segmentation based on Entropy and VGG16 Deep Neural Network Kernel Graph Cut

Mehrnaz Niazi, Ph.D. Student¹, Kambiz Rahbar, Assistant Professor², Mansour Sheikhan, Professor³, Maryam Khademi, Associate Professor⁴

1- Faculty of Computer Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran, Email: st_m_niazi@azad.ac.ir

2- Faculty of Computer Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran, Email: k_rahbar@azad.ac.ir

3- Faculty of Electrical Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran, Email: msheikh@azad.ac.ir

4- Faculty of Applied Mathematics, South Tehran Branch, Islamic Azad University, Tehran, Iran, Email: khademi@azad.ac.ir

Abstract: Recently, image segmentation based on graph cut methods has shown remarkable performance on a set of image data. Although the kernel graph cut method provides good performance, its performance is highly dependent on the mapping of data to the transform space and image features. Entropy-based kernel graph cut method is suitable for segmentation of textured images. However, the quality of its segmentation is affected by the extracting kernel centers quality. This article examines the segmentation of textural images using the proposed weighted entropy and VGG16-based kernel graph cut method. Using the advantages of kernel space, the objective function consists of two data components to transfer the data standard deviation of each area in the segmented image and the adjustment component. The proposed method, while taking advantage of the appropriate computational load of graph-based methods, will be a suitable alternative for textural image segmentation. Experimental results have been taken on a set of well-known datasets that include textural shapes in order to evaluate the effectiveness of the algorithm in compared to state-of-the-art methods in the field of kernel graph cut.

Keywords: Image Segmentation, Kernel Graph Cut, Radial Based Function Kernel, Textural Image, Weighted Clustering.

تاریخ ارسال مقاله: ۱۴۰۱/۰۵/۰۲

تاریخ اصلاح مقاله: ۱۴۰۲/۰۱/۱۶

تاریخ پذیرش مقاله: ۱۴۰۲/۰۲/۳۱

نام نویسنده مسئول: کامبیز رهبر

نشانی نویسنده مسئول: گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

۱- مقدمه

هدف از قطعه‌بندی تصویر، ساده‌سازی و تغییر نمایش یک تصویر است به گونه‌ای که تصویر معنادارتر و جهت تحلیل ساده‌تر گردد [۱]. به عبارتی دیگر، در قطعه‌بندی تصویر به هر پیکسل در تصویر یک برچسب تعلق می‌گیرد و پیکسل‌ها با ویژگی‌های مشترک در یک دسته قرار می‌گیرند.

قطعه‌بندی تصویر در زمینه‌های بسیاری مانند تصاویر پزشکی [۲]، پردازش ویدیو [۳] و بازیابی تصویر [۴، ۵] کاربرد دارد. به عنوان مثال، در زمینه پزشکی، با توجه به ساختار پیچیده بدن انسان، تشخیص دقیق بسیاری از مشکلات پزشکی از جمله تومورها و ضایعات بافت امری بسیار دشوار است و قطعه‌بندی تصویر می‌تواند کمک موثری باشد [۶]. در پردازش ویدیو، اشیاء متحرک معمولاً اطلاعات بسیار مهمی را برای نظارت ویدیویی و کنترل ترافیک و ضبط حرکات انسان و غیره دارد. در اکثر موارد حذف پس‌زمینه جهت تشخیص ویژگی‌های متفاوت در اشیاء متحرک الزامی است. این مسئله باعث ورود بحث قطعه‌بندی در این زمینه شده است [۷، ۸]. در علوم کشاورزی، تشخیص خودکار بیماری گیاهان یک شاخه بسیار پر طرف دار در این حیطه است. استفاده از قطعه‌بندی تصویر جهت تشخیص نواحی بیمار در گیاهان بسیار متداول است و مقالات بسیاری در این زمینه ارائه گردیده است [۹، ۱۰].

همچنین قطعه‌بندی تصویر در سنجش از دور جهت تشخیص تغییرات محیطی نیز بسیار پرکاربرد است. در این راستا قطعه‌بندی تصویر جهت تقسیم‌بندی پوشش سطح زمین استفاده می‌گردد [۱۱]. در سال‌های اخیر روش‌های مختلفی جهت قطعه‌بندی در تصویر ارائه گردیده است که می‌توان به روش‌های مبتنی بر جایابی میانگین [۱۲-۱۵] و روش‌های مبتنی بر برش گراف اشاره نمود. در مقاله فوق، سعی بر آن است که با بهبود قطعه‌بندی اولیه در الگوریتم برش گراف کرنل، کیفیت قطعه‌بندی در تصویر افزایش یابد و نتایج تحت شرایط مختلف نوفه‌ای با دیگر الگوریتم‌ها مقایسه گردند.

به طور کلی پژوهش‌های حوزه برش گراف کرنل به ۴ رویکرد اصلی تقسیم می‌شوند که عبارتند از: (۱) تعیین نوع نوفه و حذف نوفه جهت بهبود قطعه‌بندی، (۲) استخراج ویژگی‌های مناسب جهت قطعه‌بندی، (۳) انتخاب کرنل مناسب و یا ترکیب کرنل‌های مختلف جهت نگاشت داده‌ها، (۴) نگاشت داده‌ها با استفاده از کرنل انتخابی در رویکرد تعیین نوع نوفه و حذف نوفه، پس از دریافت تصویر ورودی در صورتی که تصویر نوفه‌ای باشد، ابتدا نوع و شدت نوفه مدل و در نهایت به حذف نوفه‌ی مربوطه از تصویر پرداخته می‌شود.

در این راستا، در مقاله ان‌گوک و همکاران در سال ۲۰۲۳، یک روش برای ترکیب فاصله مسیر دهی با اطلاعات لبه در یک چارچوب بهینه‌سازی گراف-کات ارائه شده است. اکثر روش‌های تبدیل فاصله، به نوبت در تصویر و همچنین موقعیت شروع اشتراک حساس هستند. فاصله مسیر دهی مصنوعی یا Dahu pseudo-distance که نسخه

پیوسته فاصله حداقل مانع است، در تصاویر نویزی و مبهم از فاصله ژئودزیک قدرتمندتر عمل می‌کنند.

لذا مقاله فوق، یک روش برای ترکیب Dahu pseudo-distance با اطلاعات لبه در یک چارچوب بهینه‌سازی گراف-کات ارائه نمود که از قابلیت‌های تکمیلی هر دو روش بهره می‌برد. با این حال، روش فوق پیچیدگی محاسباتی بالایی دارد. همچنین، به دلیل ترکیب اطلاعات لبه، این روش بهبود قابل توجهی در مواردی مانند تصاویر با لبه‌های ضعیف ارائه نمی‌دهد [۱۶].

در تصاویر CT، تضاد رنگ پایین، حاشیه‌های مات، و مرزهای نامنظم اعضایی مانند کبد، کلیه و طحال، استخراج خودکار مناطق خاصی از هر ارگان مورد نظر را سخت می‌کند. در مقاله چن و همکاران در سال ۲۰۲۰، یک الگوریتم بهبود یافته برش گراف با محدودیت شکلی انعطاف پذیر برای حل این مشکل پیشنهاد شده است.

در این روش، ابتدا تصویر اولیه با استفاده از ثبت چند اطللس قطعه بندی شده و سپس نتیجه حاصل به عنوان یک پیشینه شکلی برای محدود کردن شکل نهایی برش گراف با افزودن یک انرژی محدودیت شکلی به تابع انرژی گراف اعمال می‌شود.

در نهایت، تصاویر هر ارگان مورد نظر در تصاویر CT با کمینه کردن تابع انرژی با استفاده از الگوریتم جریان پیشینه برش کمینه استخراج می‌شود. روش فوق، می‌تواند به طور موثر از برش گراف معمولی که موجب بیش برش یا کم برش شدن مناطق می‌شود، جلوگیری کند. با این حال، روش به دلیل نیاز به ثبت اطللس زمان‌بر و پرهزینه است [۱۷].

پانگیری و همکاران نیز در سال ۲۰۱۹، بیان نمودند که تصاویر سونوگرافی یکی از معروف‌ترین ابزارهای مورد استفاده جهت غربالگری سرطان سینه است. مرحله قطعه‌بندی به دلیل وجود نوفه‌های لکه‌ای و اثر سایه، یکی از مراحل پر چالش در تشخیص سرطان در سیستم‌های کامپیوتری مبتنی بر تصاویر سونوگرافی است. هدف مقاله فوق، ارائه یک روش قطعه‌بندی خودکار با دقت بالا در تشخیص سرطان در تصاویر سونوگرافی حتی با وجود نوفه و مصنوعات دیگر است. در این راستا، ابتدا، تصاویر با استفاده از روش انتشار غیرهم‌سان کاهش لکه فیلتر می‌شوند و سپس مراحل دیگر قطعه‌بندی انجام می‌گیرد [۱۸].

در رویکرد استخراج ویژگی‌های مناسب، ابتدا در صورت نیاز، سوپر پیکسل‌های تصویر ورودی فیلتر شده از مرحله قبل، مشخص می‌گردد و ویژگی‌های مناسب مانند رنگ، بافت، موقعیت مکانی، و ابعاد تعیین می‌گردد. سپس در صورت نیاز به تجمع ویژگی‌ها، تعدادی از ویژگی‌ها جهت بهبود کیفیت قطعه‌بندی با یکدیگر تجمع می‌شود. در نهایت از بین ویژگی‌های تجمع‌شده در مرحله قبل، مجموعه ویژگی‌هایی که جهت قطعه‌بندی مفیدتر هستند انتخاب می‌گردند.

چندین مقاله با استفاده از انتخاب ویژگی‌های مناسب‌تر به بهبود قطعه‌بندی تصویر پرداخته‌اند که از جمله این مقالات، در مقاله نیازی و همکاران در سال ۲۰۲۲، بردار ویژگی به صورت دو لایه (یک لایه سطح

با نگاشت داده‌های تصویر با کرنل، برای بخش‌بندی اجزای اشباع شده در تصاویر استفاده می‌شود. توابع کرنل هیبرید برای بخش‌بندی به کار گرفته شده و با استفاده از تکرار برش گراف و محاسبه پارامترهای ناحیه‌ای از طریق محاسبه نقطه ثابت، عملیات بخش‌بندی انجام می‌شود. این روش عملکرد توابع کرنل عمومی و محلی را ترکیب می‌کند که باعث می‌شود بخش‌بندی دقیق و قوی باشد. با این حال روش فوق به دلیل پیچیدگی الگوریتم، نیاز به منابع محاسباتی بالا دارد و ممکن است زمان اجرای الگوریتم طولانی شود [۲۳].

در رویکرد نگاشت کرنل در برش گراف کرنل، با توجه به اینکه می‌خواهیم الگوریتم برش گراف کرنل بدون تعامل کاربر انجام پذیرد در ابتدا بایستی یک قطعه‌بندی اولیه به وسیله الگوریتم‌های خوشه‌بندی انجام گیرد. اولین گام در خوشه‌بندی، تعیین تعداد دسته‌ها است که می‌تواند به صورت ثابت و یا از طریق الگوریتم‌های مناسب، مشخص گردد. پس از تعیین تعداد دسته‌ها و البته نوع خوشه‌بندی، به استخراج مراکز اولیه می‌پردازیم.

هر تابع انرژی در برش گراف کرنل از دو بخش داده و تنظیم تشکیل می‌شود که در بخش داده میزان انحراف داده‌ها در هر ناحیه پس از نگاشت مشخص و در بخش تنظیم به یکسان‌سازی و نرم‌کنندگی مرزها پرداخته می‌شود. پس از تعیین دو بخش داده و تنظیم با توجه به کرنل انتخابی، تابع انرژی قطعه‌بندی با استفاده از جمع آن‌ها بدست می‌آید. پس از تعیین تابع انرژی بایستی به بهینه‌سازی قطعه‌بندی با کمینه نمودن تابع انرژی آن پرداخت که این کار می‌تواند از طریق الگوریتم برش گراف نیز انجام پذیرد. برای این منظور، بهبود قطعه‌بندی تا عدم تغییر نواحی و همگرایی تکرار می‌شود.

شایان ذکر است، بعضی از مقالات نیز در زمینه برش گراف کرنل با بزرگنمایی‌های مختلف و حتی ترکیب نتایج حاصل از آن‌ها به ارائه نوآوری در این زمینه پرداخته‌اند. در این راستا، بن‌صالح در سال ۲۰۱۱ یک روش چند ناحیه‌ای برش گراف کرنل ارائه دادند که در آن از نگاشت کرنل به عنوان یک مدل برش گراف بدون نظارت جهت قطعه‌بندی تصویر استفاده شد. در مقاله فوق، ابتدا با استفاده از روش k -means مراکز تعیین و سپس فاصله داده‌ها تا مرکز خوشه‌ای آن‌ها، به کرنل گوسی داده می‌شود. در نهایت برش گراف کرنل، بر اساس آن‌ها صورت می‌گیرد. در حقیقت، تصویر به صورت ضمنی از طریق تابع کرنل به داده‌هایی با ابعاد بالاتر نگاشت می‌گردد و داده‌ها از طریق تابع کرنل نمایش داده می‌شوند. در این راستا، دو بخش اصلی در نگاشت کرنل تعریف می‌گردد. یکی بخش داده، که نشان‌دهنده میزان انحراف داده‌ها بعد از انتقال است و دیگری بخش تنظیم، که جهت نرم‌کنندگی و بهبود مرزها استفاده می‌گردد [۲۴].

در این مقاله، مشابه مقاله نیازی و همکاران، از الگوریتم برش گراف کرنل مبتنی بر آنتروپی به عنوان یک مدل بدون نظارت جهت استخراج دولا به ویژگی (یک لایه سطح خاکستری و یک لایه آنتروپی) استفاده می‌گردد. به منظور ارتقا الگوریتم یک لایه فضای ویژگی

خاکستری و یک لایه آنتروپی) پیشنهاد شده است. این پیشنهاد نتایج خوبی را در قطعه‌بندی تصاویر ناهمگن و بافت‌دار ارائه داده است. با این حال الگوریتم فوق نمی‌تواند تصاویر با سایز کوچک و بافت پیچیده را به خوبی تفکیک نماید [۱۹].

مقاله چن و همکاران در سال ۲۰۲۲، یک چارچوب خوشه‌بندی نرم افزاری برای تقسیم‌بندی سریع تصاویر رنگی طراحی نموده است. در این چارچوب ابتدا یک روش تولید سوپریکسل جدید طراحی شده است که از نگاشت فوریه تصادفی برای تقریب کرنل‌های گوسی استفاده می‌کند و ویژگی‌های بعد بالایی پیکسل‌ها را به طور صریح نمایش می‌دهد.

خوشه‌بندی سوپریکسل‌ها به جای پیکسل‌های بزرگ، فرآیند تقسیم‌بندی تصویر رنگی را به طور قابل توجهی سریعتر می‌کند. به علاوه، سوپریکسل‌ها که توسط خوشه‌بندی نرم افزار استفاده می‌شود، نیز در فضای کرنل محاسبه می‌شود و روابط محلی بین سوپریکسل‌ها به عنوان پیش‌نیاز گرافیکی ترسیم می‌شود. در ادامه، به عنوان یک عبارت تفاضل کولبک-لیبل در تابع هدف خوشه‌بندی نرم افزار اضافه می‌شود.

در روش فوق، با توجه به استفاده از نگاشت فوریه تصادفی، نیازی به محاسبه مستقیم ماتریس کرنل گوسی نیست و این موجب کاهش بار محاسباتی می‌شود. با این حال، روش فوق نیاز به تعیین تعداد سوپریکسل‌ها قبل از شروع خوشه‌بندی دارد و این ممکن است باعث ایجاد خطایی در تعیین نتایج خوشه‌بندی شود. [۲۰].

مقاله رهبر در سال ۲۰۱۹، از چند جمله‌ای کراتچاک جهت مدل‌سازی تابع توزیع احتمال مقادیر روشنایی استفاده کرده است و مولفه‌های چندجمله‌ای کراتچاک به عنوان توابع ویژه عبارات مختلف در نظر گرفته شده است. این مقاله به بهبود تخمین مقادیر روشنایی و لذا بهبود قطعه‌بندی تصویر پرداخته است [۲۱].

در رویکرد انتخاب کرنل مناسب و یا ترکیب کرنل‌های مختلف، جهت بهبود عملکرد قطعه‌بندی، از کرنل‌هایی که از قانون مرسر تبعیت می‌کنند. همچنین می‌توان کرنل مناسب را از ترکیب خطی کرنل‌های پیشین حاصل نمود.

در این راستا، در مقاله کیو و همکاران، در سال ۲۰۲۲ از یک فاصله مکانی جدید و جهت کانتور (contour direction) در تابع انرژی استفاده شده است. به عبارتی در مقاله فوق، با استفاده از محدودیت اولیه ساختار گراف انرژی تغییر یافته است. در نهایت با استفاده از الگوریتم pseudoflow ماکزیمم جریان در گراف انرژی محاسبه می‌شود. در نتیجه، قطعه‌بندی در تصاویر با ویژگی‌های ظاهری پیش‌زمینه و پس‌زمینه نزدیک به هم ارتقا می‌یابد. با این حال همچنان در تفکیک تصاویر با مرزهای ضعیف چالش دارد [۲۲].

در مقاله جبا و همکاران در سال ۲۰۱۹، به منظور تقسیم‌بندی اتوماتیک نواحی در تصاویر PET/CT، بخش‌های اشباع رنگ تصاویر همجوشی شده، فیلتر و تقویت می‌شوند. در روش فوق، از برش گراف

سطح پایین و سطح بالای تصویر را از طریق لایه های کانولوشن استخراج می کند [25]. مولفه تنظیم نیز به صورت معادله ۳ تعریف می شود.

$$\Re(\lambda) = \sum_{\{p,q\} \in N} r(\lambda(p), \lambda(q)) \quad (3)$$

که N مجموعه همسایه‌های پیکسل p, q جفت پیکسل‌های همسایه و $r(\lambda(p), \lambda(q))$ تابع تنظیم مبتنی بر مربعات اختلاف میانگین ناحیه پیکسل‌های همسایه است. تابع تنظیم با استفاده از ثابت T مطابق با معادله ۴ محدود شده است.

$$r(\lambda(p), \lambda(q)) = \min(T, |\mu_{\lambda(p)} - \mu_{\lambda(q)}|^2), T > 0 \quad (4)$$

جهت بهینه سازی تابع انرژی در الگوریتم برش گراف کرنل، در گام نخست برچسب‌های ناحیه به عنوان پارامترهای ثابت تعیین می‌گردد. تابع هدف با توجه به پارامترهای آماری میانگین هر ناحیه کمینه سازی می شود. در گام دوم برچسب‌های بهینه تصویر با توجه به پارامترهای استخراج شده در گام اول با استفاده از الگوریتم برش گراف تعیین می شود. گام‌های فوق تا زمان رسیدن به مینیمم محلی تکرار می‌گردد.

در الگوریتم برش گراف کرنل مبتنی بر آنتروپی و VGG16 مراکز استفاده از الگوریتم k-means تعیین می شود. در الگوریتم k-means خوشه‌بندی به نحوی انجام می‌گیرد که تابع مجموع مربعات درون خوشه‌ها کمترین مقدار ممکن شود. معادله ۵، تابع هدف S در الگوریتم k-means را نمایش می‌دهد.

$$S = \min \sum_{l=1}^{N_{reg}} \sum_{p=1}^{n_l} z_{pl} |F_p - \mu_l|^2 \quad (5)$$

که N_{reg} تعداد خوشه‌ها، n_l تعداد داده ها در هر خوشه، μ_l میانگین خوشه l ام و z_{pl} مولفه عضویت داده F_p در خوشه l ام می‌باشد که با صفر یا یک مشخص می‌گردد. به منظور کمینه‌سازی تابع هدف بایستی مربع فاصله بین نقاط در خوشه‌های متفاوت بیشینه گردد. در این راستا، معیار فاصله می‌تواند بر اساس فاصله اقلیدسی به صورت معادله ۶ محاسبه گردد.

$$d = \sqrt{\sum_{i=1}^f (x_i - y_i)^2} \quad (6)$$

که f تعداد ویژگی‌ها و x_i و y_i ویژگی i ام از دو نمونه داده x و y می‌باشند. الگوریتم k-means در چهار مرحله به صورت زیر تعریف می‌گردد.

الگوریتم k-means	
۱-	انتخاب k مرکز اولیه به صورت تصادفی
۲-	محاسبه فاصله هر داده از مراکز خوشه با استفاده از معیار فاصله مناسب و خوشه‌بندی داده‌ها در نزدیکترین مرکز
۳-	به روزرسانی مراکز خوشه‌ها
۴-	تکرار مراحل ۲ و ۳ تا میانگین‌ها به یک ثبات کافی برسند و یا مجموع واریانس‌های خوشه‌ها تغییر چندانی نکنند.

مستخرج از شبکه عصبی عمیق VGG16 نیز به ان اضافه می‌گردد. این فضای ویژگی، باعث کارامدی هر چه بیشتر الگوریتم برش گراف کرنل جهت قطعه‌بندی پیکسل‌ها می‌گردد.

در مقاله فوق، در فضای ویژگی سه لایه ابتدا با استفاده روش k-means مراکز تعیین و سپس فاصله داده‌ها تا مرکز خوشه‌ای آن به کرنل مبتنی بر شعاع داده می‌شود و در نهایت، بر اساس آن برش گراف کرنل صورت می‌گیرد. در حقیقت، تصویر به صورت ضمنی از طریق تابع کرنل به داده‌هایی با ابعاد بالاتر نگاشت می‌گردد و داده‌ها از طریق تابع کرنل نمایش داده می‌شوند [۲۴]. با این حال، الگوریتم k-means به نقاط ابتدایی، به عنوان مراکز خوشه، حساس است. این الگوریتم خوشه‌بندی مناسبی را در تصاویر بافت‌دار تضمین نمی‌کند چرا که با انتخاب مراکز اولیه تصادفی و احتمال انتخاب مراکز بر روی مرزها، ممکن است به مراکز مناسبی دست نیابد.

از آنجایی که تعیین مراکز تاثیر به سزایی در کیفیت قطعه‌بندی با استفاده از برش گراف کرنل بدون نظارت خواهد داشت. در این مقاله سعی بر آن است تا با ارتقا فضای ویژگی و بهبود الگوریتم خوشه‌بندی مبتنی بر تصویر وزن‌دار، دقت و پایداری نتایج حاصل از الگوریتم برش گراف کرنل بدون نظارت را افزایش داد. در ادامه در بخش ۲، به مرور روش برش گراف کرنل مبتنی بر آنتروپی و VGG16، در بخش ۳، به بررسی الگوریتم برش گراف کرنل مبتنی بر آنتروپی بر اساس k-means وزن‌دار پرداخته می‌شود، در بخش ۴، نتایج آزمایشگاهی و در انتها در بخش ۵، نتیجه‌گیری مقاله مطرح می‌گردد.

۲- مروری بر روش برش گراف کرنل مبتنی بر آنتروپی و VGG16

با فرض اینکه I ماتریس شدت روشنایی تصویر است. تصویر I به N_{reg} ناحیه همگن $\{R_l\}_{l=1}^{N_{reg}}$ تقسیم می‌شود. l برچسب هر پیکسل می‌باشد که از مجموعه L انتخاب می‌گردد. R_l ناحیه ای است که مجموعه پیکسل‌ها با برچسب l در آن قرار می‌گیرد. به منظور قطعه بندی تصویر تابع هدف بایستی تعیین و کمینه گردد. تابع هدف از دو مولفه داده به منظور تطبیق مدل آماری و مولفه تنظیم جهت هموار سازی مرز ها تشکیل می‌گردد. تابع هدف $\mathcal{F}$ به صورت معادله ۱ تعریف می‌شود.


$$\mathcal{F}(\lambda) = D(\lambda) + \alpha \Re(\lambda) \quad (1)$$

که D مولفه داده، R مولفه تنظیم، λ یک تابع ایندکس گذاری جهت تعیین ناحیه هر پیکسل و α ضریب مثبت است. بخش داده به صورت معادله ۲ تعریف می‌گردد.

$$D(\lambda) = \sum_{p \in \Omega} D_p(\lambda(p)) = \sum_{l \in L} \sum_{p \in R_l} (F_p - \mu_l)^2 \quad (2)$$

که p پیکسل از مجموعه پیکسل های Ω میانگین ناحیه l ، F_p بردار ویژگی دو لایه (یک لایه سطح خاکستری و یک لایه آنتروپی) و یک لایه VGG16 پیکسل p می‌باشد. بردار ویژگی دو لایه (یک لایه سطح خاکستری و یک لایه آنتروپی) شدت روشنایی و ارتباط بین شدت روشنایی ها را در بر دارد. شبکه عصبی عمیق VGG16 ویژگی های

غیر لبه محاسبه می‌گردد. شکل ۱ نشان‌دهنده‌ی تصویر وزن دار مبتنی بر تبدیل فاصله اقلیدسی است.



شکل ۱: تصویر وزن دار مبتنی بر خروجی فیلتر بالاگذر

در تصویر وزن دار پیکسل‌های درون مرزی و برون مرزی وزن بیشتر و پیکسل روی مرز وزن کمتری دارند. پس از استخراج وزن پیکسل‌ها در تصویر، این تصویر جهت استخراج مراکز مبتنی بر اهمیت پیکسل‌ها در الگوریتم k-means وزن دار استفاده می‌گردد. بدین صورت که پس از تعیین مراکز، داده‌ها با توجه به درجه عضویت آن‌ها به نزدیک‌ترین مرکز خوشه اختصاص داده می‌شوند. معادله ۱۰ درجه عضویت داده F_p در خوشه λ_m را نشان می‌دهد.

$$m(\mu_l | F_p) = \frac{\|F_p - \mu_l\|^2}{\sum_{l=1:N_{reg}} \|F_p - \mu_l\|^2} \quad (10)$$

سیس به ازای هر مرکز خوشه، مراکز خوشه مجدد بر اساس درجه عضویت و وزن پیکسل‌ها محاسبه می‌شود. معادله ۱۱ نحوه محاسبه مراکز در الگوریتم k-means وزن دار را نشان می‌دهد.

$$\mu_l = \frac{\sum_{p=1:n_l} m(\mu_l | F_p) F'_p F_p}{\sum_{p=1:n_l} m(\mu_l | F_p) F'_p} \quad (11)$$

که در آن F'_p وزنی است که به هر پیکسل داده شده است و n_l تعداد نمونه‌ها در هر خوشه می‌باشد. به عبارتی در این الگوریتم داده‌ها متناسب با اهمیت آن‌ها بر روی مراکز تاثیر می‌گذارند. انتخاب مراکز بهینه‌تر باعث بهبود خروجی کرنل می‌گردد چراکه هر چه بردار ویژگی به مرکز کرنل نزدیک‌تر باشد ضریب بیشتری به آن اختصاص داده می‌شود. پس از دریافت خروجی کرنل بخش داده مبتنی بر کرنل و بخش تنظیم مبتنی بر میانگین‌های بدست آمده محاسبه می‌گردد. تابع انرژی مبتنی بر دو بخش داده و تنظیم تعیین می‌گردد و مبتنی بر آن گراف تصویر ساخته می‌شود.

در نهایت با استفاده از الگوریتم برش کمینه گراف به بخش پس زمینه و پیش‌زمینه تقسیم می‌گردد. جهت بهینه‌سازی تابع انرژی در الگوریتم برش گراف کرنل، در هر مرحله برچسب‌های ناحیه به عنوان پارامترهای ثابت تعیین می‌گردد. تابع هدف با توجه به پارامترهای آماری میانگین هر ناحیه کمینه‌سازی می‌شود. سپس برچسب‌های بهینه تصویر با توجه به پارامترهای استخراج شده در گام اول با استفاده از الگوریتم برش گراف تعیین می‌شود. گام‌های فوق تا زمان رسیدن به کمینه محلی تکرار می‌گردد. شکل ۲ نشان‌دهنده‌ی فلوچارت الگوریتم برش گراف آنتروپی و VGG16 وزن دار می‌باشد.

در الگوریتم k-means به منظور بهبود کیفیت خوشه‌بندی از شاخص ارزیابی درونی (ضریب سیلوئت) جهت ارزیابی خوشه‌بندی با محاسبه مشابه بودن داخل خوشه و یا نامشابه بودن و یا اندازه بین خوشه استفاده می‌گردد که مطابق با معادله ۷ محاسبه می‌گردد [26].

$$b(i) = \begin{cases} \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} & \text{if } n_l > 1 \\ 0 & \text{if } n_l = 0 \end{cases} \quad (7)$$

که در آن $a(i)$ متوسط فاصله یک نمونه از خوشه λ_m با سایر نمونه‌های همان خوشه می‌باشد و مطابق با معادله ۸ محاسبه می‌گردد.

$$a(i) = \frac{1}{n_l - 1} \sum_{j \in R_l, i \neq j} d_{ij} \quad (8)$$

که در آن n_l نشان‌دهنده‌ی تعداد اعضای خوشه λ_m ، R_l نشان دهنده‌ی خوشه λ_m و d_{ij} مقدار فاصله بین دو داده λ_m و λ_m می‌باشد. $b(i)$ نیز حداقل مقدار متوسط فاصله نمونه λ_m با تمامی نقاط در سایر خوشه‌ها را اندازه‌گیری می‌نماید و مطابق با معادله ۹ محاسبه می‌گردد.


$$b(i) = \min \frac{1}{n_l} \sum_{j \in R_l, i \notin R_l} d_{ij} \quad (9)$$

که در آن n_l تعداد اعضای خوشه λ_m می‌باشد. الگوریتم k-means در تصاویر با بافت‌های پیچیده به دلیل امکان انتخاب تصادفی مراکز اولیه بر روی مرزها و تنوع بافت نمی‌تواند مراکز را به خوبی تعیین نماید. لذا تعیین دقیق‌تر مراکز می‌تواند در بهبود عملکرد قطعه‌بندی بسیار موثر باشد.


۳- برش گراف کرنل مبتنی بر آنتروپی و VGG16 بر اساس k-means وزن دار

پارامتر اصلی در قطعه‌بندی الگوریتم برش گراف کرنل مبتنی بر آنتروپی و VGG16، مراکز تصویر است. چراکه نگاشت داده‌ها به فضای جدید مبتنی بر تنظیم کرنل RBF بر روی مراکز فوق انجام می‌گیرد. در الگوریتم برش گراف کرنل مبتنی بر آنتروپی و VGG16 وزن دار مراکز دو ناحیه پس زمینه و پیش زمینه بر اساس الگوریتم k-means وزن دار مشخص می‌گردد و کرنل RBF جهت نگاشت ضمنی داده‌ها به فضای بالاتر بر روی مراکز فوق تنظیم می‌گردد.

در این الگوریتم ارزش پیکسل‌ها مبتنی بر لبه‌های تصویر تعیین می‌گردد. با این فرضیه که مراکز مناسب، مراکزی هستند که در نواحی همگن با فرکانس پایین قرار می‌گیرند یا به عبارتی از لبه‌های اصلی تصویر دورتر باشند. لذا، پس از حذف لبه‌های ضعیف در تصویر با استفاده از فیلتر مات‌کننده گوسی، لبه‌های قوی در تصویر مبتنی بر یک فیلتر بالاگذر کنی استخراج می‌گردد. در نهایت تصویر وزن دار F' مبتنی بر تبدیل فاصله اقلیدسی بر اساس فاصله پیکسل تا نزدیک‌ترین پیکسل



شکل ۲: فلوچارت الگوریتم برش گراف کرنل آنتروپی وزن دار



شکل ۳: تصاویر نمونه دیتاست Brodatz

جدول ۱: مقایسه روش‌های مبتنی بر انرژی با معیارهای ارزیابی

مختلف بر روی تصاویر Brodatz


روش	معیارهای ارزیابی					
	Dice	Jaccard	Accuracy	PSNR	MSSD	E-time
روش پیشنهادی	۹۹.۱۴	۹۸.۳۰	۹۵.۴۹	۶۷.۰۷	۰.۰۱	۰.۰۴
Entropy	۹۸.۴۰	۹۶.۸۷	۹۲.۴۵	۶۴.۷۹	۰.۰۲	۱.۷۲
RBF Kernel	۷۵.۳۶	۶۲.۷۷	۵۳.۹۲	۵۴.۲۵	۰.۲۹	۲.۳۰
Krawtchouk	۴۵.۰۶	۲۹.۴۱	۲۹.۳۹	۵۶.۱۸	۰.۱۶	۲.۳۰
L2S	۷۲.۴۰	۵۸.۱۷	۵۸.۳۴	۵۸.۶۹	۰.۰۹	۱.۹۵
C-Maxflow	۸۸.۰۷	۷۸.۸۳	۳۱.۲۲	۵۵.۴۴	۰.۲۰	۱.۸۲
LoGRSF	۶۱.۵۳	۴۴.۷۸	۷.۶۰	۵۱.۲۳	۰.۴۹	۲.۷۸
LocalPrefitting	۶۴.۴۳	۴۷.۹۳	۹.۱۹	۵۱.۴۹	۰.۴۷	۴.۸۴
AMOE	۹۵.۹۱	۹۲.۲۸	۷۰.۰۹	۶۲.۰۶	۰.۰۷	۱۰.۳۵

۴- نتایج آزمایشگاهی

به منظور بررسی کامل عملکرد الگوریتم پیشنهادی، دو مجموعه دیتاست از تصاویر بافت‌دار Brodatz و DTD در نظر گرفته شده است. نتایج روش پیشنهادی با هشت روش برش گراف نماینده مقایسه شده است: Entropy [۱۹]، RBF [۲۴]، Krawtchouk [۲۱]، L2S [۲۷]، C-AMOE [۲۸]، LoGRSF [۲۹]، LocalPrefitting [۳۰] و MaxflowCut [۲۲]. ارزیابی با استفاده از پنج مجموعه داده زیر انجام شده است: (۱) تصاویر دیتاست Brodatz، (۲) تصاویر دیتاست DTD و تصاویر دیتاست مصنوعی بایستی ذکر گردد که دیتاست‌های فوق در مجموع شامل ۱۲۰ تصویر می‌باشند. جهت ارزیابی عملکرد روش‌های قطعه‌بندی، شش معیار اتخاذ شده است. معیار شباهت دایس (Dice) [۳۱]، معیار شباهت جاکارد (Jaccard) [۳۲]، دقت (Accuracy) [۳۳]، اوج نسبت سیگنال به نویز (PSNR) [۳۴]، میانگین مجموع مربعات فاصله (MSSD) [۳۵] و معیار زمان سپری‌شده (Elapsed Time). محیط آزمایش مطالعه فوق intel® Core™i7 CPU@ 2.20 GHz, memory 8.00 GB است و با متلب ۲۰۱۸ الف برنامه نویسی شده است.

۴-۱- نتایج آماری بر روی دیتاست Brodatz

به منظور ارزیابی الگوریتم پیشنهادی، مطالعه آزمایشگاهی روی یک شکل هندسی مصنوعی که با مجموعه داده‌های رنگی Brodatz الگوبرداری شده است، انجام شده است. دیتاست بافت Brodatz به طور گسترده‌ای استفاده می‌شود و از ۱۰۵ تصویر بافت‌دار تشکیل شده است. این مجموعه داده به دلیل تنوع بافت آن انتخاب شده است. مجموعه‌ای از تصاویر نمونه در شکل ۳ نشان داده شده است.



شکل ۴: شامل ارزیابی مختلف از تصاویر Brodatz، و هر ردیف شامل تصویر اصلی، تصویر مرجع، روش پیشنهادی، Entropy [۱۹]، RBF [۲۴]، Krawtchouk [۲۱]، L2S [۲۷]، C-MaxflowCut [۲۸]، LoGRSF [۲۹]، LocalPrefitting [۳۰] و AMOE [۲۲] است.

های دیگر افزایش ۱۰۷۹ در معیار دایس، ۳۰۱۲ در معیار جاکارد، ۲۴۰۲۵ در دقت، کاهش ۰۰۷ در نسبت اوج سیگنال به نویز و ۰۰۵ در مقدار میانگین مجموع مربعات فاصله را دارد. تفاوت زیاد در معیار دقت نسبت به معیار دایس و جاکارد به این دلیل است که معیار دایس و جاکارد تنها به پیش‌زمینه اهمیت می‌دهند در حالی که معیار دقت به صورت همزمان پس‌زمینه و پیش‌زمینه را ارزیابی می‌کند. لذا با توجه به اینکه هیچ یک از الگوریتم‌ها نتوانسته‌اند پس‌زمینه را به خوبی قطعه‌بندی نمایند، معیار دقت بهبود زیادی را نشان می‌دهد. همچنین با توجه به اینکه الگوریتم مرکز بهینه‌تری را انتخاب می‌کند در تعداد تکرارهای کمتری همگرا می‌شود و لذا زمان سپری‌شده در الگوریتم نسبت به سایر الگوریتم‌ها بسیار پایین‌تر می‌باشد.

جدول ۲: مقایسه روش‌های مبتنی بر انرژی با معیارهای ارزیابی مختلف

روش	معیارهای ارزیابی					
	Dice	Jaccard	Accuracy	PSNR	MSSD	E-time
روش پیشنهادی	۹۳.۵۶	۸۸.۴۱	۸۷.۶۳	۶۰.۰۷	۰.۰۹	۰.۰۵
Entropy	۸۳.۳۴	۷۲.۸۹	۶۳.۳۸	۵۶.۲۴	۰.۲۲	۲.۰۹
RBF Kernel	۷۶.۴۴	۶۳.۷۰	۵۱.۲۶	۵۴.۶۹	۰.۳۰	۲.۲۶
Krawtchouk	۳۳.۲۵	۲۱.۱۲	۲۰.۶۳	۵۵.۶۳	۰.۱۸	۲.۲۸
L2S	۵۱.۲۲	۳۷.۶۰	۳۷.۵۶	۵۶.۸۵	۰.۱۴	۲.۰۰
C-Maxflow	۶۰.۵۲	۴۶.۱۴	۳۴.۵۶	۵۱.۹۵	۰.۴۵	۱.۶۲
LoGRSF	۶۸.۳۶	۵۲.۴۰	۱۸.۰۱	۵۱.۹۵	۰.۴۲	۲.۶۳
LocalPrefitting	۷۰.۹۱	۵۵.۶۰	۱۷.۳۲	۵۲.۲۳	۰.۴۰	۴.۷۰
AMOE	۹۱.۷۷	۸۵.۲۹	۳۵.۰۹	۶۰.۰۰	۰.۱۵	۱۰.۴۸

مطالعات کیفی در شکل ۶ نیز که نتایج قطعه‌بندی نمونه‌های دیتاست DTD را نشان می‌دهد، برتری روش پیشنهادی را نسبت به سایر روش‌ها اثبات می‌کند. الگوریتم پیشنهادی در تمامی تصاویر با وجود تنوع و پیچیدگی بافت پس‌زمینه و پیش‌زمینه توانسته است شکل هندسی را نسبت به سایر روش‌ها به خوبی قطعه‌بندی نماید. در حالی که در الگوریتم Entropy، RBF، c-Maxflow، LoGRSF و LocalPrefitting نتوانسته‌اند پیش‌زمینه را به خوبی قطعه‌بندی نمایند و پیکسل‌های بسیاری از پس‌زمینه به عنوان پیش‌زمینه قطعه‌بندی شده‌اند. در سایر الگوریتم‌ها با وجودی که پس‌زمینه به خوبی قطعه‌بندی شده است ولی در اکثر موارد نتوانسته است شکل هندسی را به خوبی قطعه‌بندی نماید.

جدول ۱ نشان‌دهنده نتایج حاصل از دیتاست Brodatz در مقایسه با سایر الگوریتم‌های به نام این حوزه می‌باشد. روش پیشنهادی در مقایسه با بهترین روش‌های دیگر با اختلاف ۰.۷۴ در شباهت دایس، ۱.۴۳ در شباهت جاکارد، ۳۰۴ در دقت، ۲.۲۸ در نسبت اوج سیگنال به نویز برتر است و کمترین مقدار میانگین مجموع مربعات فاصله را دارد. همچنین با توجه به اینکه الگوریتم مرکز بهینه‌تری را انتخاب می‌کند در تعداد تکرارهای کمتری همگرا می‌شود و لذا زمان سپری‌شده در الگوریتم نسبت به سایر الگوریتم‌ها بسیار پایین‌تر می‌باشد.

مطالعات کیفی نیز برتری روش پیشنهادی را نسبت به سایر روش‌ها اثبات می‌کند. تصویر ۴ نیز نتایج قطعه‌بندی نمونه‌های دیتاست Brodatz را نشان می‌دهد. همانطور که مشاهده می‌شود، الگوریتم پیشنهادی در تمامی تصاویر با بافت پس‌زمینه و پیش‌زمینه متفاوت توانسته است شکل هندسی و پس‌زمینه را به خوبی قطعه‌بندی نماید. در حالی که در الگوریتم Entropy، RBF با وجودی که شکل هندسی پیش‌زمینه به خوبی قطعه‌بندی شده است پیکسل‌های پس‌زمینه که به عنوان پیش‌زمینه انتخاب شده‌اند، باعث افت کیفیت الگوریتم شده است. متقابل با آن در الگوریتم L2s، Krawtchouk و c-Maxflow و AMOE با وجودی که پس‌زمینه به خوبی قطعه‌بندی شده است ولی در اکثر موارد نتوانسته است پیش‌زمینه را به خوبی قطعه‌بندی نماید. دو الگوریتم LocalPrefitting و LoGRSF اصلاً نتوانسته‌اند پس‌زمینه و پیش‌زمینه را از یکدیگر تفکیک نمایند و نتایج ضعیفی را ارائه داده‌اند.


۴-۲- نتایج آماری بر روی دیتاست DTD

به منظور ارزیابی الگوریتم پیشنهادی، مطالعه آزمایشگاهی بر روی تصاویر دیجیتال دیتاست DTD گرفته شده است. این دیتاست شامل مجموعه تصاویر با بافت توصیفی پیچیده است که الگوهای طبیعی و مصنوعی در بافت‌های مذکور به طور همزمان وجود دارند. مجموعه ای از تصاویر نمونه در شکل ۵ نشان داده شده است.



شکل ۵: نمونه تصاویر دیتاست DTD

جدول ۲ نشان‌دهنده نتایج حاصل از دیتاست DTD در مقایسه با سایر الگوریتم‌ها می‌باشد. روش پیشنهادی در مقایسه با بهترین روش



شکل ۶: شامل ارزیابی مختلف از تصاویر DTD، و هر ردیف شامل تصویر اصلی، تصویر مرجع، روش پیشنهادی، Entropy [۱۹]، RBF [۲۴]، Krawtchouk [۲۱]، L2S [۲۷]، C-MaxflowCut [۲۸]، LoGRSF [۲۹]، LocalPrefitting [۳۰] و AMOE [۲۲] است.

مرزهای باریک پرداخت، چراکه الگوریتم فوق به دلیل خاصیت مات-کندگی کرنل RBF در تصاویر ظریف با مرزهای باریک خوب عمل نمی‌کند.

مراجع

- [1]. Kaur, D., & Kaur, Y. (2014). Various Image Segmentation Techniques: A Review. *International Journal of Computer Science and Mobile Computing*, 3(5), 809–814.
- [2]. Adla, D., Reddy, G. V. R., Nayak, P., & Karuna, G. (2023). A full-resolution convolutional network with a dynamic graph cut algorithm for skin cancer classification and detection. *Healthcare Analytics*, 100154. doi:10.1016/J.HEALTH.2023.100154
- [3]. Farhand, S., & Tsechpenakis, G. (2023). Foreground discovery in streaming videos with dynamic construction of content graphs. *Computer Vision and Image Understanding*, 227, 103620. doi:10.1016/J.CVIU.2022.103620
- [4]. Zhang, L., & Wu, X. (2022). Multi-task framework based on feature separation and reconstruction for cross-modal retrieval. *Pattern Recognition*, 122, 108217. doi:10.1016/J.PATCOG.2021.108217
- [5]. Mallick, A. K., & Mukhopadhyay, S. (2022). Video retrieval framework based on color co-occurrence feature of adaptive low rank extracted keyframes and graph pattern matching. *Information Processing & Management*, 59(2), 102870. doi:10.1016/J.IPM.2022.102870
- [6]. Yang, Z., Zhao, Y., qian, Liao, M., Di, S. hu, & Zeng, Y. zhan. (2021). Semi-automatic liver tumor segmentation with adaptive region growing and graph cuts. *Biomedical Signal Processing and Control*, 68, 102670. doi:10.1016/J.BSPC.2021.102670
- [7]. You, M., Luo, C., Zhou, H., & Zhu, S. (2023). Dynamic dense CRF inference for video segmentation and semantic SLAM. *Pattern Recognition*, 133, 109023. doi:10.1016/J.PATCOG.2022.109023
- [8]. Awan, M., & Shin, J. (2023). Weakly supervised multi-class semantic video segmentation for road scenes. *Computer Vision and Image Understanding*, 230, 103664. doi:10.1016/J.CVIU.2023.103664
- [9]. Duvvuri, S., & Kambhammettu, B. P. (2023). HS-FRAG: An open source hybrid segmentation tool to delineate agricultural fields in fragmented landscapes. *Computers and Electronics in Agriculture*, 204, 107523. doi:10.1016/J.COMPAG.2022.107523
- [10]. Luo, Z., Yang, W., Yuan, Y., Gou, R., & Li, X. (2023). Semantic segmentation of agricultural images: A survey. *Information Processing in Agriculture*. doi:10.1016/J.INPA.2023.02.001

۵- نتیجه گیری

در فرآیند قطعه‌بندی برش گراف کرنل RBF مبتنی بر آنتروپی و VGG16 بر اساس k-means وزن‌دار فیلتر مات‌کننده و سپس فیلتر بالاگذر جهت استخراج لبه‌های قوی استفاده و تصویر وزن‌دار مبتنی بر تبدیل فاصله اقلیدسی محاسبه می‌گردد. سپس تصویر وزن‌دار به همراه مولفه درجه عضویت جهت استخراج مراکز دقیق‌تر استفاده می‌گردد. استفاده از الگوریتم k-means وزن‌دار جهت استخراج نواحی باعث می‌شود الگوریتم پیشنهادی در تصاویر مختلف عملکرد مناسبی داشته باشد. چراکه داده‌ها متناسب با اهمیت آن‌ها بر روی مراکز تأثیر می‌گذارند. با توجه به اینکه هر چه بردار ویژگی به مرکز کرنل نزدیک‌تر باشد ضریب بیشتری به آن اختصاص داده می‌شود، انتخاب مراکز بهینه‌تر باعث بهبود خروجی کرنل می‌گردد. پس از دریافت خروجی کرنل، تابع انرژی مبتنی بر دو بخش داده و تنظیم جهت ساخت گراف تصویر تعیین می‌گردد. در نهایت با استفاده از الگوریتم برش کمینه گراف، تصویر به دو بخش پس زمینه و پیش‌زمینه تقسیم می‌گردد. تا زمان همگرایی الگوریتم، بهینه سازی تابع انرژی در الگوریتم برش گراف کرنل، با توجه به پارامترهای میانگین تعیین‌شده در هر مرحله ادامه می‌یابد. در این مطالعه، دو مجموعه دیتاست از تصاویر Brodatz و DTD به منظور بررسی عملکرد الگوریتم پیشنهادی، مورد بررسی قرار گرفت. با توجه به نتایج کیفی و کمی حاصل از دو مجموعه دیتاست، الگوریتم برش گراف کرنل ضمن ارائه مراکز دقیق‌تر توانسته است کارایی بالاتر و منعطف‌تری را در قطعه‌بندی تصاویر ارائه نماید. در کارهای آینده می‌توان به بهبود الگوریتم برش گراف کرنل مبتنی بر آنتروپی برای قطعه‌بندی تصاویر ظریف با

- fused PET/CT images. *Applied Soft Computing*, 85, 105815. doi:10.1016/J.ASOC.2019.105815
- [24]. Salah, M. Ben, Mitiche, A., & Ayed, I. Ben. (2011). Multiregion image segmentation by parametric kernel graph cuts. *IEEE Transactions on Image Processing*, 20(2), 545–557. doi:10.1109/TIP.2010.2066982
- [25]. Sharma, S., Guleria, K., Tiwari, S., & Kumar, S. (2022). A deep learning based convolutional neural network model with VGG16 feature extractor for the detection of Alzheimer Disease using MRI scans. *Measurement: Sensors*, 24, 100506. doi:10.1016/J.MEASEN.2022.100506
- [26]. Punhani, A., Faujdar, N., Mishra, K. K., & Subramanian, M. (2022). Binning-Based Silhouette Approach to Find the Optimal Cluster Using K-Means. *IEEE Access*, 10, 115025–115032. doi:10.1109/ACCESS.2022.3215568
- [27]. Mukherjee, S., & Acton, S. T. (2015). Region based segmentation in presence of intensity inhomogeneity using legendre polynomials. *IEEE Signal Processing Letters*, 22(3), 298–302. doi:10.1109/LSP.2014.2346538
- [28]. Kaba, D., Wang, Y., Wang, C., Liu, X., Zhu, H., Salazar-Gonzalez, A. G., & Li, Y. (2015). Retina layer segmentation using kernel graph cuts and continuous max-flow. *Optics Express*, 23(6), 7366. doi:10.1364/OE.23.007366
- [29]. Ding, K., Xiao, L., & Weng, G. (2017). Active contours driven by region-scalable fitting and optimized Laplacian of Gaussian energy for image segmentation. *Signal Processing*, 134, 224–233. doi:10.1016/j.sigpro.2016.12.021
- [30]. Ding, K., Xiao, L., & Weng, G. (2018). Active contours driven by local pre-fitting energy for fast image segmentation. *Pattern Recognition Letters*, 104, 29–36. doi:10.1016/j.patrec.2018.01.019
- [31]. Alidoost, M., Ghodrati, V., Ahmadian, A., Shafiee, A., Hassani, C. H., Bedayat, A., & Wilson, J. L. (2023). Model utility of a deep learning-based segmentation is not Dice coefficient dependent: A case study in volumetric brain blood vessel segmentation. *Intelligence-Based Medicine*, 7, 100092. doi:10.1016/J.IBMED.2023.100092
- [32]. Keelson, B., Buzzatti, L., Van Gompel, G., Scheerlinck, T., Hereus, S., de Mey, J., ... Buis, N. (2022). The use of cardiac CT acquisition mode for dynamic musculoskeletal imaging. *Physica Medica*, 104, 75–84. doi:10.1016/J.EJMP.2022.10.028
- [33]. Loke, S. C., MacDonald, B. A., Parsons, M., & Wünsche, B. C. (2020). Testing dataset for head segmentation accuracy for the algorithms in the 'BGSLibrary' v3.0.0 developed by Andrews Sobral. *Data in Brief*, 33, 106385. doi:10.1016/J.DIB.2020.106385
- [34]. Gajera, B. V., Kapil, S. R., Ziaei, D., Mangalagiri, J., Siegel, E., & Chapman, D. (2021). CT-Scan Denoising Using a Charbonnier Loss Generative Adversarial Network. *IEEE Access*, 9, 84093–84109. doi:10.1109/ACCESS.2021.3087424
- [35]. Liao, X., Yuan, Z., Zheng, Q., Yin, Q., Zhang, D., & Zhao, J. (2014). Multi-Scale and Shape Constrained Localized Region-Based Active Contour Segmentation of Uterine Fibroid Ultrasound Images in HIFU Therapy. (J. Tian, Ed.) *PLoS ONE*, 9(7), e103334. doi:10.1371/journal.pone.0103334
- [11]. He, Q., Sun, X., Diao, W., Yan, Z., Yin, D., & Fu, K. (2022). Transformer-induced graph reasoning for multimodal semantic segmentation in remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 193, 90–103. doi:10.1016/J.ISPRSJPRS.2022.08.010
- [12]. Liu, X., Zhang, Y., Zou, H., Wang, F., Cheng, X., Wu, W., ... Li, Y. (2023). Multi-source knowledge graph reasoning for ocean oil spill detection from satellite SAR images. *International Journal of Applied Earth Observation and Geoinformation*, 116, 103153. doi:10.1016/J.JAG.2022.103153
- [13]. Park, H. (2021). α -MeanShift++: Improving MeanShift++ for Image Segmentation. *IEEE Access*, 9, 131430–131439. doi:10.1109/ACCESS.2021.3114223
- [14]. Iswanto, I. A., Choa, T. W., & Li, B. (2019). Object Tracking Based on MeanShift and Particle-Kalman Filter Algorithm with Multi Features. *Procedia Computer Science*, 157, 521–529. doi:10.1016/J.PROCS.2019.09.009
- [15]. Wang, Q., Du, W., Ma, C., & Gu, Z. (2021). Gradient Color Leaf Image Segmentation Algorithm Based on Meanshift and Kmeans. *IEEE Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 1609–1614. doi:10.1109/IAEAC50856.2021.9391029
- [16]. Ôn Vũ Ngọc, M., Carlinet, E., Fabrizio, J., & Géraud, T. (2023). The Dahu graph-cut for interactive segmentation on 2D/3D images. *Pattern Recognition*, 136, 109207. doi:10.1016/J.PATCOG.2022.109207
- [17]. Chen, H., Pan, X., Lu, X., & Xie, Q. (2020). A modified graph cuts image segmentation algorithm with adaptive shape constraints and its application to computed tomography images. *Biomedical Signal Processing and Control*, 62, 102092. doi:10.1016/J.BSPC.2020.102092
- [18]. Panigrahi, L., Verma, K., & Kumar, B. (2019). Ultrasound image segmentation using a novel multi-scale Gaussian kernel fuzzy clustering and multi-scale vector field convolution. *Expert Systems With Applications*, 115, 486–498. doi:10.1016/j.eswa.2018.08.013
- [19]. Niazi, M., Rahbar, K., Sheikhan, M., & Khademi, M. (2022). Entropy-based kernel graph cut for textural image region segmentation. *Multimedia Tools and Applications* 2022, 1–21. doi:10.1007/S11042-022-12005-Z
- [20]. Chen, L., Zhao, Y. P., & Zhang, C. (2022). Efficient kernel fuzzy clustering via random Fourier superpixel and graph prior for color image segmentation. *Engineering Applications of Artificial Intelligence*, 116, 105335. doi:10.1016/J.ENGAPPAI.2022.105335
- [21]. Rahbar, K. (2019). Image segmentation through modeling the illumination probability distribution function using the Krawtchouk polynomial. *Signal Processing*, 164, 1–9. doi:10.1016/j.sigpro.2019.05.033
- [22]. Qu, S., Tan, H., Li, Q., & Peng, Z. (2022). Interactive image segmentation based on the appearance model and orientation energy. *Computer Vision and Image Understanding*, 217, 103371. doi:10.1016/J.CVIU.2022.103371
- [23]. Jeba, J. A., & Devi, S. N. (2019). Efficient graph cut optimization using hybrid kernel functions for segmentation of FDG uptakes in