



تشخیص نقاط برجسته تصاویر با استفاده از

نمونه برداری فشرده در حوزه موجک

مهدی بنی طالبی دهکردی^۱، عباس ابراهیمی مقدم^{۲*}، مرتضی خادمی^۳، هادی هادی زاده^۴

^۱ و ^۲ دانشکده مهندسی، گروه مهندسی برق، دانشگاه فردوسی مشهد، مشهد، ایران

^۴ دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی قوچان، قوچان، ایران

چکیده

امروزه پژوهشگران، از مزایای بسیار زیاد استفاده از مدل سازی توجه بصری انسان، در زمینه های مختلف، به صورت گسترده استفاده می کنند. در روش های مختلف ارائه شده در این راستا، نقشه هایی دو بُعدی موسوم به "نقشه نقاط برجسته" استخراج می شود که مقادیر نقاط مختلف در آن، بیان گر میزان جلب توجه بیننده به نقاط متناظر در تصویر است. در این مقاله نیز برای به دست آوردن نقشه برجستگی از ضرایب موجک تصاویر، بر اساس روش نمونه برداری فشرده، نمونه های تصادفی انتخاب می شوند. در ادامه، از نمونه های انتخاب شده نقشه های ویژگی تولید می شود. با استفاده از نقشه های ویژگی به دست آمده، نقشه برجستگی محلی و نقشه برجستگی کلی محاسبه می شود. در نهایت، با ترکیب خطی نقشه برجستگی محلی و کلی به دست آمده، نقشه برجستگی نهایی محاسبه می شود. ارزیابی های تجربی حاکی از نتایج امیدوارکننده ای از برتری روش ارائه شده نسبت به سایر مدل های تشخیص برجستگی، در آشکارسازی نواحی برجسته و در عین حال در کاهش حجم محاسباتی است.

واژگان کلیدی: نقشه نقاط برجسته، توجه بصری، تبدیل موجک، تُنکی، نمونه برداری فشرده

Compressed-Sampling-Based Image Saliency Detection in the Wavelet Domain

Mehdi Banitalebi-Dehkordi¹, Abbas Ebrahimi-Moghadam^{2*}, Morteza Khademi³, Hadi Hadizadeh⁴

^{1,2,3}Faculty of Engineering, Department of Electrical Engineering, University of Mashhad, Mashhad, Iran

⁴Faculty of Electrical and Computer Engineering, Quchan University of Technology, Quchan, Iran

Abstract

When watching natural scenes, an overwhelming amount of information is delivered to the Human Visual System (HVS). The optic nerve is estimated to receive around 10^8 bits of information a second. This large amount of information can't be processed right away through our neural system. Visual attention mechanism enables HVS to spend neural resources efficiently, only on the selected parts of the scene at order. This results in a better and faster perception of events.

In order to perform saliency measurement on visual data, subjective eye-tracking experiments may be carried out. These experiments involve using devices to track eye movements of a number of subjects while they watch images or videos on a screen.

That being said, such devices are not very suitable in practice due to hardship involved with carrying out experiments, such as need to have restricted test environment, being time consuming as well as expensive.

* Corresponding author

* نویسنده عهده دار مکاتبات

Instead, researchers developed Computational Visual Attention Models (VAMs) in attempts to mimic the HVS saliency prediction process.

Visual Attention Modelling has widely been used in various areas of image processing and understanding. Computational models of visual attention aim to predict the most interesting areas of an image to the observers. To this end, these models produce saliency maps, in which each pixel is assigned a likelihood value of being looked at. In other words, saliency maps highlight where the most likely for viewers to look at in an image is. Knowing the Regions of Interests (ROIs) can be helpful in applications such as image and video compression, object recognition and detection, visual search, retargeting, retrieval, image matching, and segmentation.

Saliency prediction is generally done in a bottom-up, top-down, or hybrid fashion. Bottom-up approaches exploit low-level attributes such as brightness, color, edges, texture, etc. Top-down approaches focus on context-dependent information from the scene such as appearance of humans, animals, text, etc. Hybrid methods combine the two streams.

This paper proposes a new method of saliency prediction using sparse wavelet coefficients selected from low-level bottom-up saliency features. Wavelet based image methods are used widely in image processing algorithms as they are especially powerful in decomposing images into several scales of resolutions. In our method, first random compressive sampling is performed on wavelet coefficients in the Lab color space. Random sampling enables a reduction in computational complexity and provides a sparse representation of the coefficients. The number of decomposition levels is chosen based on the information diffusion property of the signal. In the proposed method, the sampling can be done at a rate different than the Nyquist rate, and based on the sparsity degree of the signal. It is shown that having the basis vectors of a sparse representation of the signal, can result in an accurate signal reconstruction. In this work, the sparsity degree and thus the sampling rate is computed empirically. Next, local and global saliency maps are generated from these random samples to account for small-scale and large-scale (scene-wide) saliency attributes. These maps are then combined to form an overall saliency map. The overall saliency map therefore includes both local, and global saliency attributes. The main contribution of this paper is the use of compressive sampling in creating a novel wavelet domain representation for image saliency prediction.

Extensive performance evaluations show that the proposed method provides a promising saliency prediction performance while the computation complexity remains reasonable, thanks to the dimensionality reduction of compressive sampling. In particular, the proposed method demonstrated favorable precision, recall, and F-measure, when compared to state-of-the-art saliency detection methods, over large-scale datasets. We hope the proposed approach brings ideas to the saliency analysis research community.

Keywords: Saliency map, visual attention, wavelet transform, sparsity, compressive sampling

پژوهش‌های فراوانی جهت مطالعه و درک این سازوکار صورت گرفته است و مدل‌های محاسباتی مختلفی برای پیش‌بینی نقاط برجسته در تصاویر دیجیتال طراحی و توسعه یافته‌اند [5-8].

در حالت کلی می‌توان روش‌های موجود برای پیش‌بینی نقاط برجسته در یک تصویر را به دو دسته روش‌های پایین به بالا⁴ و روش‌های بالا به پایین⁵ تقسیم کرد. روش‌های پایین به بالا که محرک محور⁶ هم خوانده می‌شوند، بیش‌تر از ویژگی‌های سطح پایین مانند روشنایی، تباين (کنتراست)⁷، رنگ و غیره، استفاده می‌کنند [8]، [9] و [10]. در روش‌های بالا به پایین، که هدف محور⁸ هستند، از پردازش‌های معنایی و سطح بالا همانند تشخیص شیء و متن برای پیش‌بینی نقاط برجسته استفاده می‌کنند [11]، [12]. به‌طورکلی روش‌های پایین به بالا در مقایسه با

۱- مقدمه

در هر ثانیه در حدود 10^8 بیت اطلاعات از چشم‌ها به مغز انسان ارسال می‌شود. از آنجایی‌که مغز انسان مانند هر دستگاه فیزیکی دیگر دارای محدودیت‌های پردازشی است، نیاز است تا اطلاعات ورودی به مغز بر اساس اهمیت حیاتی و یا کاربردی آنها انتخاب و پردازش شوند. این امر توسط سازوکاری موسوم به سازوکار توجه‌بصری¹ در دستگاه بینایی انسان (HVS)² انجام می‌شود [1-4]. با استفاده از این سازوکار، مکان جلب توجه انسان در هنگام مشاهده یک تصویر یا یک صحنه تصویری مشخص می‌شود. درک سازوکار توجه بصری، کاربردهای گوناگونی در حوزه‌های مختلف علوم کاربردی و مهندسی دارد. درحقیقت، پیش‌بینی نقاط جلب‌توجه انسان در یک تصویر که به آن "پیش‌بینی نقاط برجسته"³ گفته می‌شود، کاربردهای زیادی در بینایی رایانه، رباتیک و علوم اعصاب دارد؛ لذا در دهه‌های گذشته،

¹ Visual Attention Mechanism

² Human Visual System

³ Saliency Prediction

⁴ Bottom-Up

⁵ Top-Down

⁶ Stimulus-Driven

⁷ Contrast

⁸ Goal-Driven

در روش پیشنهادی *Achenta* و همکاران [17]، برای محاسبه نقشه برجستگی بصری یک تصویر، ابتدا آن تصویر توسط یک فیلتر گاوسی هموار شده و سپس تصویر حاصله به فضای رنگی $CIE-LAB^9$ انتقال داده می‌شود؛ سپس مؤلفه‌های رنگی هر پیکسل به‌عنوان یک بردار ویژگی در نظر گرفته و پس از آن میانگین حسابی کلیه بردارهای ویژگی کلیه پیکسل‌های تصویر محاسبه می‌شود؛ درنهایت، میزان برجستگی بصری هر پیکسل از تصویر با محاسبه قدر مطلق تفاوت بردار ویژگی آن پیکسل با بردار میانگین حاصله به دست می‌آید.

به‌طور کلی، مدل‌هایی همانند مدل *Itti* و *GBVS* از اطلاعات محلی تصویر برای پیش‌بینی برجستگی بصری استفاده می‌کنند، درحالی‌که مدل‌هایی نظیر مدل ارائه‌شده توسط *Hou* و همکاران و همچنین مدل ارائه‌شده توسط *Achenta* و همکاران، تنها از اطلاعات کلی (سراسری) برای این منظور استفاده می‌کنند؛ اما در دسته‌ای دیگر از روش‌ها، علاوه بر اطلاعات محلی، از اطلاعات کلی نیز به‌همراه اطلاعات محلی استفاده شده است. از جمله این روش‌ها می‌توان به روش ارائه‌شده توسط *Ye* و همکاران اشاره کرد [18]. در این روش، مشابه با روش ارائه‌شده در [14]، بعد از تقسیم‌بندی تصویر به آبر پیکسل‌ها¹⁰، تصویر با یک گراف مدل می‌شود؛ به‌طوری‌که گره‌های گراف را ابرپیکسل‌های حاصله تشکیل می‌دهند و وزن یال متصل‌کننده دو گره از گراف بر اساس تفاوت بین ویژگی‌های دو ابر پیکسل متناظر تعریف می‌شود. ویژگی‌های در نظر گرفته‌شده برای هر آبر پیکسل در این روش عبارتند از: برجستگی محلی آن آبر پیکسل، میزان تشابه آن آبر پیکسل به یک شیء¹¹ و میزان ظهور¹² آن آبر پیکسل. در ادامه، با استفاده از گراف به‌دست‌آمده، یک نقشه موسوم به نقشه احتمال شیء¹³ به دست می‌آید که با قطع‌بندی¹⁴ آن، اشیا و نقاط برجسته در تصویر از زمینه تفکیک و شناسایی می‌شوند.

در مدل‌هایی که تاکنون در این بخش در مورد آنها صحبت شد، از ویژگی‌های استخراج شده از تصویر در حوزه پیکسل برای مدل‌سازی سازوکار توجه بصری استفاده می‌شود. در دسته‌ای دیگر از مدل‌ها، از ویژگی‌های استخراج‌شده در حوزه تبدیل یا فرکانس برای استخراج نقشه نقاط برجسته استفاده می‌شود [19-22]. برای مثال، *Guo* و

روش‌های بالا به پایین ساده‌تر بوده و از سرعت پردازش بالاتری برخوردار هستند؛ به این دلیل، تعداد مدل‌های توسعه‌یافته در این دسته به‌مراتب بیشتر از تعداد مدل‌های موجود بالا به پایین است. در این مدل‌ها، نقشه‌هایی دوبعدی موسوم به "نقشه نقاط برجسته"¹⁵ محاسبه می‌شود که مقادیر نقاط مختلف در آن، بیان‌گر میزان جلب توجه بیننده به نقاط متناظر در تصویر ورودی است.

بیش‌تر مدل‌های پایین به بالا که از ویژگی‌های سطح پایین برای محاسبه نقشه نقاط برجسته استفاده می‌کنند، مبتنی بر اصولی هستند که نخستین بار توسط *Itti* و همکاران او پیشنهاد شده است [12]، [13]. در مدل ارائه‌شده توسط *Itti*، فرض می‌شود که نقاط برجسته در یک تصویر نقاطی هستند که در حوالی آن نقاط، تضاد ویژگی‌های سطح پایین (همانند رنگ، جهت‌گیری و شدت روشنایی) در مقایسه با سایر نقاط بیشتر است؛ لذا در این مدل، نقاط برجسته با اندازه‌گیری تضادهای محلی در کانال‌های ویژگی مختلف، در یک چهارچوب چند سطحی¹⁶ آشکارسازی می‌شوند [12].

در [14]، *Harel* و همکاران یک مدل پیش‌بینی نقاط برجسته، موسوم به *GBVS*¹⁷ بر مبنای گراف پیشنهاد کردند که در آن فرض می‌شود تکه‌هایی¹⁸ از تصویر که عدم تشابه بیشتری با سایر تکه‌ها دارند، از برجستگی بصری بالاتری برخوردارند و برعکس؛ لذا، هر یک از تکه‌های تصویر در غالب گره‌های یک گراف در نظر گرفته می‌شود، به‌نحوی که وزن هر یال بین دو گره از گراف، برابر با میزان عدم تشابه دو تکه متناظر در تصویر ورودی است. برای اندازه‌گیری عدم تشابه دو تکه نیز، از یک زنجیره مارکف استفاده می‌شود. مشابه با این مدل، *Liu* و همکاران با بهره‌گیری از میدان‌های تصادفی شرطی (CRF)¹⁹ و استخراج ویژگی‌های تباین چندسطحی²⁰، هیستوگرام اختلاف مرکز با اطراف²¹ و چگونگی توزیع مکانی رنگ، روشی برای آشکارسازی نقاط برجسته ارائه کردند [15]. *Hou* و همکاران نیز با استفاده از این فرضیه که توجه انسان به سمت نقاط با بیشترین حجم اطلاعات، جلب شود، روشی برای پیش‌بینی نقاط برجسته با استفاده از مفهوم نمایش تنگ²² تصاویر ارائه کردند [16].

¹ Visual Saliency Map

² Multiscale

³ Graph-Based Visual Saliency

⁴ Patch

⁵ Conditional Random Fields

⁶ Multi-Scale Contrast

⁷ Center-Surround Histogram

⁸ Sparse Representation

⁹ Commission internationale de l'éclairage

¹⁰ Super-Pixels

¹¹ Objectness

¹² Appearance

¹³ Object Probability Map

¹⁴ Segmentation

همکاران، مدلی جهت تولید نقشه نقاط برجسته در قاب‌های ویدئو با بهره‌گیری از چهار ویژگی اندازه بردارهای حرکتی، تضاد در شدت روشنایی و دو طیف از طیف‌های رنگ، ارایه کردند. در این مدل، با محاسبه تبدیل فوریه چهارگانه (QFT)¹ و ویژگی‌های استخراج‌شده از قاب‌های ویدئو و اعمال عکس تبدیل QFT بر روی مرحله طیف نرمالیزه‌شده، نقشه نقاط برجسته استخراج می‌شود [22].

در دسته‌ای دیگر از مدل‌های موجود، از تبدیل موجک (WT)² برای تولید نقشه نقاط برجسته استفاده شده است. با توجه به اینکه تبدیل موجک قادر به ارائه اطلاعات مکان-فرکانسی است، استفاده از این تبدیل در مدل‌های استخراج نقشه نقاط برجسته، به صورت گسترده‌ای مورد توجه پژوهش‌گران قرار گرفته است [23-27]. به‌عنوان نمونه، *Libao* و همکاران، روشی جهت آشکارسازی نقاط برجسته با استفاده از تبدیل موجک ارائه کردند که در آن از بررسی تغییرات ویژگی‌های محلی و کلی به‌دست‌آمده از ضرایب موجک در مقیاس‌های مختلف، برای آشکارسازی نقاط برجسته استفاده می‌شود. ایده اصلی برای استخراج ویژگی‌های محلی و کلی در فضای WT ، انتخاب نقاط با تغییرات بیشتر (براساس قدر مطلق اندازه ضرایب موجک) و دنبال کردن آنها در راستای آشکارسازی نقاط برجسته است [23].

مشابه با [23]، *Murry* و همکاران نیز روشی ارائه کردند که در آن برای تولید نقشه نقاط برجسته از ضرایب موجک فرکانس بالا استفاده می‌شود. در این روش با بهره‌گیری از بردارهای ویژگی استخراج‌شده از ضرایب موجک، میزان تأثیر نقاط در جلب توجه بیننده در قالب یک ماتریس وزن نمایش داده می‌شود [25]. در نظر گرفتن حساسیت انسان به تباین محلی و قابلیت جلب توجه نقاط مرکزی نسبت به اطراف، ایده‌های استفاده‌شده در استخراج نقشه نقاط برجسته در این روش هستند.

İmamoğlu و همکاران نیز روشی مبتنی بر ضرایب موجک برای آشکارسازی نقاط برجسته ارائه کردند [28]. در این روش نیز مانند [17]، با توجه به نزدیکی فضای رنگ CIE-Lab به ادراک انسان، ابتدا تصاویر به این فضا انتقال پیدا می‌کنند؛ در ادامه، تبدیل موجک بر روی هر یک از کانال‌های رنگی تصویر اعمال می‌شود تا نمایش چندسطحی تصویر در باندهای فرکانسی مختلف به‌دست آید؛ پس از آن، تبدیل عکس موجک (IWT) بر روی هر یک از زیر باندهای

میانی به‌دست آمده، اعمال می‌شود تا یک نقشه ویژگی برای هر زیرباند میانی به‌دست آید. بدین ترتیب، هر نقشه ویژگی حاوی اطلاعات محلی تصویر در یک باند فرکانسی میانی است که در آن جزئیات مختلفی از لبه‌ها تا بافت‌ها ظاهر می‌شود. این امر به آشکارسازی ساختارها و بی‌نظمی‌های مختلف در فرکانس‌های متفاوت کمک می‌کند؛ سپس، با استفاده از نقشه‌های ویژگی به‌دست‌آمده، یک نقشه برجستگی بصری محلی و یک نقشه برجستگی کلی محاسبه می‌شود. برای محاسبه نقشه برجستگی محلی، ابتدا بیشینه مقدار ویژگی در هر نقطه بر روی هر سه کانال رنگی محاسبه می‌شود؛ سپس مقادیر به‌دست‌آمده بر روی کلیه مقیاس‌ها با یکدیگر جمع و نتیجه حاصله به عنوان برجستگی بصری محلی در آن نقطه در نظر گرفته می‌شود. برای محاسبه نقشه برجستگی کلی نیز، ابتدا توزیع ویژگی‌های محاسبه‌شده به‌صورت یک توزیع گاوسی مدل می‌شود؛ سپس، میزان برجستگی کلی هر نقطه در تصویر بر اساس تابعی از میزان احتمال مشاهده آن مقدار ویژگی در آن نقطه محاسبه می‌شود؛ در نهایت، با ترکیب خطی نقشه برجستگی محلی و کلی به‌دست‌آمده، نقشه برجستگی نهایی تصویر ورودی محاسبه می‌شود. نتایج آزمایش‌های گزارش‌شده در [28]، نشان می‌دهند که برخلاف پیچیدگی محاسباتی بالای روش یادشده، این روش از کارایی و دقت خوبی در مقایسه با سایر روش‌های موجود برخوردار است.

در این مقاله، قصد داریم تا روش [28] را به‌گونه‌ای تغییر دهیم تا از پیچیدگی محاسباتی آن کاسته شود. برای این منظور از مفهوم نمایش T_{nk} ³ تصاویر در حوزه موجک [29] استفاده می‌کنیم. درحقیقت، ایده اصلی در روش پیشنهادی این است که تصاویر طبیعی در حوزه موجک T_{nk} هستند. این بدین معنی است که بیش‌تر ضرایب موجک تصاویر طبیعی دامنه بسیار کوچکی دارند و لذا می‌توان یک تصویر دلخواه را فقط با تعداد محدودی از ضرایب غیرصفر بازسازی با خطای کم کرد. از طرف دیگر، مطالعات مختلفی نشان داده‌اند که تصاویر در دستگاه بینایی مغز انسان به‌صورت T_{nk} پردازش می‌شوند [30]؛ لذا به نظر می‌رسد که در روشی همچون روش ارائه‌شده در [28]، نیازی به استفاده از کلیه ضرایب موجک هر زیرباند جهت تولید نقشه ویژگی آن زیرباند نیست و به‌احتمال تعداد محدودی از ضرایب برای حصول به یک دقت مشخص در پیش‌بینی نقاط برجسته، کفایت می‌کند.

³ Sparse Representation

¹ Quaternion Fourier Transform

² Wavelet Transform

امین کانال تصویر حاصله در فضای رنگی CIE-Lab باشد که $c \in \{L, a, b\}$. برای حذف و یا کاهش نوفه احتمالی در J^c ، ابتدا آن را با یک فیلتر پایین گذر 3×3 (h) به صورت زیر بالایش می‌کنیم تا تصویر \hat{J}^c به دست آید:

$$\hat{J}^c = J^c * h. \quad (1)$$

سیس هریک از کانال‌های \hat{J}^c را بین [۰ و ۲۵۵] نرمالیزه می‌کنیم تا \hat{J}_n^c به دست آید. پس از آن تبدیل موجک دو بُعدی گسسته با N سطح تجزیه را بر روی \hat{J}_n^c اعمال می‌کنیم تا ضرایب موجک $[A_N^c, H_s^c, V_s^c, D_s^c]$ را به صورت زیر به دست آوریم:

$$[A_N^c, H_s^c, V_s^c, D_s^c] = WT_N(\hat{J}_n^c), \quad (2)$$

که در آن $WT_N(\cdot)$ بیانگر تبدیل موجک گسسته با N سطح تجزیه است و $A_N^c, H_s^c, V_s^c, D_s^c$ به ترتیب بیانگر ضرایب تقریب در سطح تفکیک N ، ضرایب جزئیات در سطح تفکیک s در راستاهای افقی، عمودی و مورب در c -امین کانال \hat{J}_n^c است. در این مقاله با توجه به تصاویر موجود در پایگاه داده مورد استفاده در شبیه‌سازی‌ها، به صورت تجربی $N = 15$ تعیین شد.

حال برای استخراج ویژگی‌های مورد نظر از ضرایب جزئیات به دست آمده $[H_s^c, V_s^c, D_s^c]$ به صورت تصادفی N_{Sparse} نمونه انتخاب می‌کنیم. فرض کنید $[\hat{H}_s^c, \hat{V}_s^c, \hat{D}_s^c]$ بیانگر نمونه‌های به دست آمده باشد. از این نمونه‌ها به عنوان ویژگی‌های مورد نظر استفاده می‌کنیم. مقدار N_{Sparse} در شبیه‌سازی‌های انجام شده در این مقاله به صورت تجربی و برای دستیابی به جواب بهینه بر روی پایگاه داده مورد استفاده، $N_{Sparse} = 4$ انتخاب شد.

۲-۳- تولید نقشه‌های ویژگی

در این مرحله، از نمونه‌های حاصله در بخش قبل برای تولید نقشه‌هایی موسوم به نقشه‌های ویژگی استفاده می‌کنیم. برای این منظور عکس تبدیل موجک در سطح s (IWT_s) را بر روی $(\hat{H}_s^c, \hat{V}_s^c, \hat{D}_s^c)$ به صورت زیر اعمال می‌کنیم تا یک نقشه ویژگی $\text{Map}_s^c(x, y)$ در سطح s برای کانال c تصویر \hat{J}^c به دست آید:

$$\text{Map}_s^c(x, y) = \frac{(IWT_s(\hat{H}_s^c, \hat{V}_s^c, \hat{D}_s^c))^2}{\eta}, \quad (3)$$

در روشی موسوم به نمونه برداری فشرده (CS^1) از ویژگی‌های سیگنال‌ها در حوزه مورد نظر جهت کاهش نرخ نمونه برداری لازم برای بازسازی کامل و بدون خطای سیگنال مورد نظر استفاده می‌شود [31]. درحقیقت، با بهره‌گیری از این روش، می‌توان یک سیگنال T را با تعداد محدودی از نمونه‌های تصادفی با دقت بسیار بالایی بازسازی کرد. بر این اساس، در این مقاله، جهت کاهش پیچیدگی محاسباتی روش [28]، به جای استفاده از کلیه ضرایب موجک هر زیرباند جهت تولید نقشه‌های ویژگی، از تعداد محدودی از ضرایب موجک که به صورت تصادفی انتخاب می‌شوند، استفاده می‌کنیم. نتایج تجربی به دست آمده در این مقاله نشان می‌دهند که روش پیشنهادی در این مقاله، ضمن کاهش حجم محاسباتی روش ارائه شده در [28]، قادر است تا دقت و عملکرد آن را نیز تا حدی بهبود دهد.

طرح و سازمان کلی این مقاله بدین شرح است: در بخش بعد، روش پیشنهادی شرح داده می‌شود. آزمایش‌های انجام شده و نتایج به دست آمده در بخش ۳ ارائه خواهند شد و در پایان، در بخش ۴، نتیجه‌گیری مطالب ارائه می‌شود.

۲- روش پیشنهادی

۲-۱- معرفی کلی

همان‌طور که در بخش قبل اشاره شد، در این مقاله روشی جهت آشکارسازی نقاط برجسته در یک تصویر با استفاده از نمونه برداری تصادفی از ضرایب موجک در زیرباندهای تصویر ارائه می‌کنیم. در شکل (۱)، نمودار گردش کار روش پیشنهادی نشان داده شده است. همان‌طور که از این نمودار مشاهده می‌شود، روش پیشنهادی از سه مرحله (۱) استخراج ویژگی، (۲) تولید نقشه‌های ویژگی و (۳) ترکیب نقشه‌های ویژگی جهت محاسبه نقشه نقاط برجسته، تشکیل شده است. عملکرد هریک از این مراحل در ادامه به تفصیل شرح داده خواهد شد.

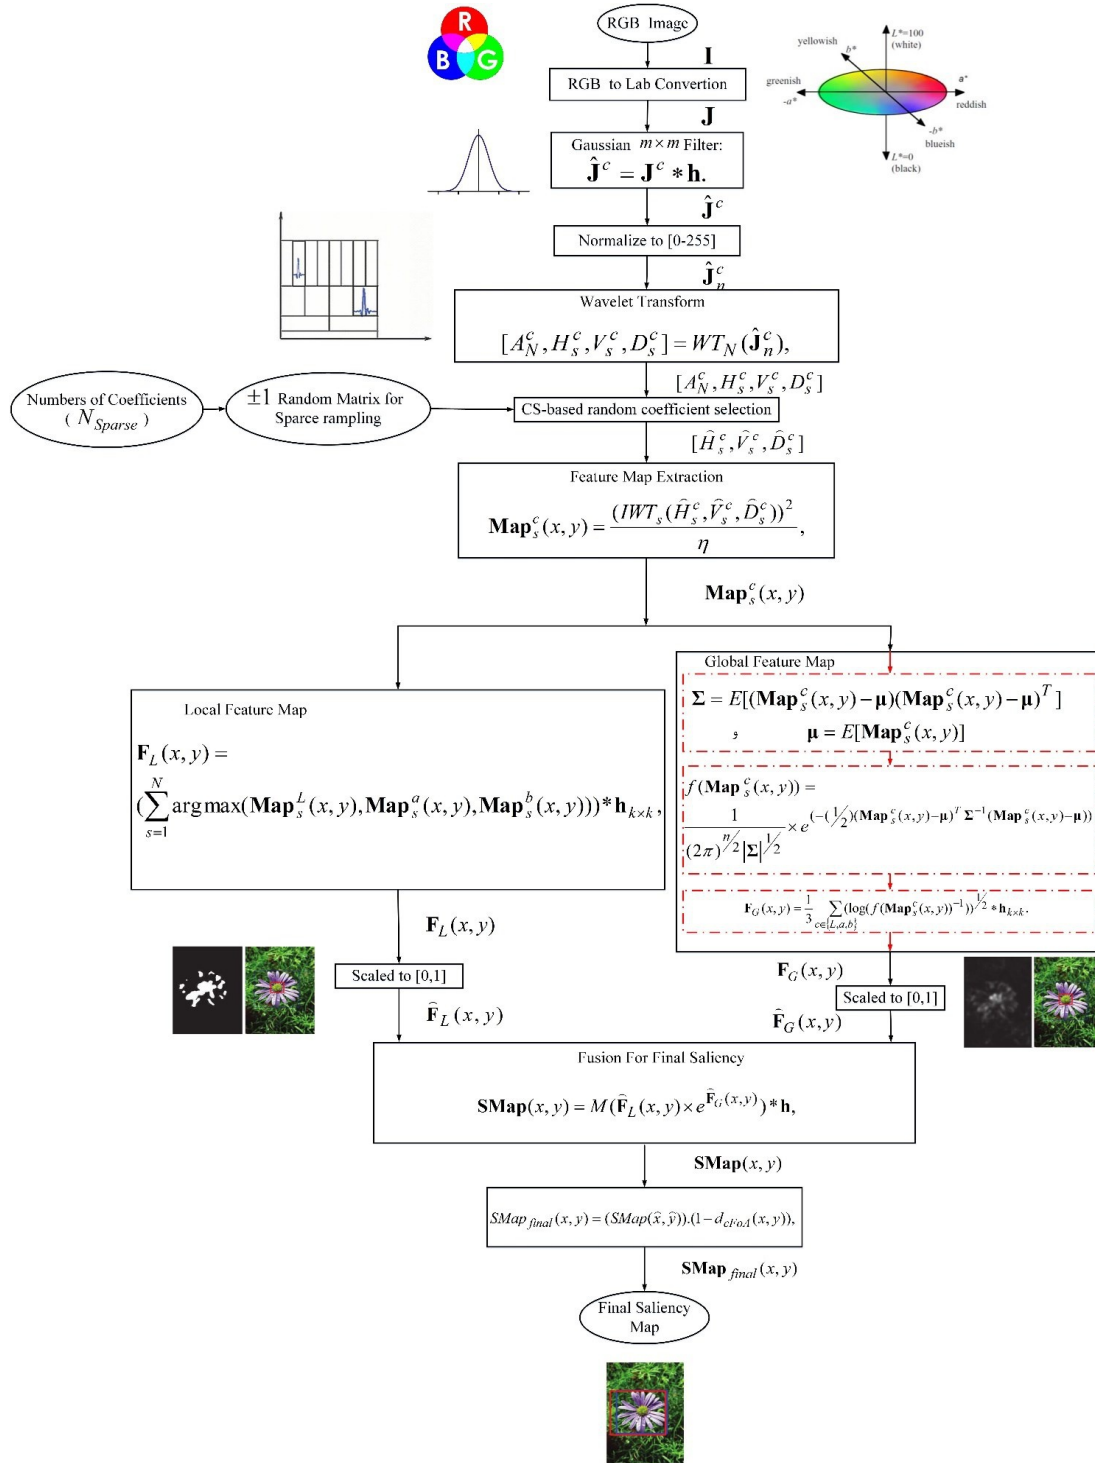
۲-۲- مرحله استخراج ویژگی

فرض کنید یک تصویر RGB (ورودی I) در اختیار داریم و می‌خواهیم نقشه نقاط برجسته آن را محاسبه کنیم. از آنجایی که مطالعات پیشین نشان داده‌اند که فضای رنگی CIE-Lab تطابق زیادی با ساختار ادراکی انسان دارد [11]، ابتدا تصویر ورودی را به فضای رنگی CIE-Lab انتقال می‌دهیم تا تصویر J حاصل شود. فرض کنید J^c بیانگر c -

¹ Compressive Sampling

مقیاس‌گذاری و جلوگیری از ایجاد تغییرات بزرگ در محاسبات مربوط به نقشه‌های ویژگی به صورت تجربی و با آزمون و خطا برابر با $\eta = 10^4$ انتخاب شد.

که در آن η یک ثابت نرمالیزه کردن است. با توجه به اینکه گستره مقادیر برای تصویر ورودی در فضای Lab ، برای هر کانال [۰ و ۲۵۵] است، طیف وسیعی از مقادیر ویژگی در $\mathbf{Map}_s^c(x,y)$ وجود دارد. مقدار η در (۳) برای



شکل-۱: نمودار گردش کار روش پیشنهادی (Figure-1): Flowchart of the proposed method

مقادیر ممکن برای خروجی رابطه (۸)، با توجه به انتخاب پارامترها، بین صفر و یک است.

از رابطه (۸)، نقشه نقاط برجسته‌ای مبتنی بر نقشه‌های برجستگی محلی و کلی به دست می‌آید. در ایجاد نقشه برجستگی نهایی از روشی مشابه با روش شرح داده شده در [28] استفاده می‌کنیم که توسط آن میزان برجستگی مناطق اطراف نقطه‌ای که بیشترین میزان برجستگی را دارد (FoA)، افزایش می‌یابد و برعکس میزان برجستگی نقاط دورتر کاهش می‌یابد. برای این منظور از رابطه زیر استفاده می‌کنیم:

$$SMap_{final}(x, y) = (SMap(\bar{x}, \bar{y})) \cdot (1 - d_{FoA}(x, y)), \quad (9)$$

که در این رابطه $SMap_{final}(x, y)$ مقدار برجستگی در نقطه (x, y) است، $SMap(\bar{x}, \bar{y})$ نیز برابر با بیشترین مقدار برجستگی به دست آمده از نقشه نقاط برجسته استخراج شده از مکان $((\bar{x}, \bar{y}))$ است، و $d_{FoA}(x, y)$ نیز فاصله بین محل (x, y) و نزدیک‌ترین FoA را نشان می‌دهد.

۳- نتایج آزمایش‌های انجام شده

نتایج شبیه‌سازی‌های انجام شده در این مقاله، بر روی پایگاه داده میکروسافت به دست آمده است [33]. این پایگاه داده شامل پنج هزار تصویر رنگی و نتایج قابل اطمینان حاصل از داده‌های تعقیب چشم انسان در راستای آشکارسازی نواحی برجسته است. به منظور ارزیابی کمی روش پیشنهادی بر روی پایگاه داده یادشده، از معیارهای "میزان دقت P"، "نرخ فراخوان R" و "معیار F_α "، که به صورت زیر تعریف می‌شوند، استفاده می‌کنیم:

$$P = \frac{\sum_x \sum_y (t(x, y) \times s(x, y))}{\sum_x \sum_y (s(x, y))} \quad (10)$$

$$R = \frac{\sum_x \sum_y (t(x, y) \times s(x, y))}{\sum_x \sum_y (t(x, y))} \quad (11)$$

$$F_\alpha = \frac{(1 + \alpha) \times P \times R}{\alpha \times P + R} \quad (12)$$

در این روابط، $t(x, y)$ نقشه نقاط برجسته مبتنی به دست آمده با استفاده از دستگاه دنبال کننده حرکات چشم، و $s(x, y)$ نقشه نقاط برجستگی به دست آمده از مدل

در ادامه از نقشه به دست آمده در رابطه (۳)، برای تولید یک نقشه ویژگی محلی و یک نقشه ویژگی کلی استفاده می‌کنیم. جهت تولید نقشه ویژگی محلی در هر کانال از رابطه زیر استفاده می‌کنیم:

$$F_L(x, y) = \left(\sum_{s=1}^S \arg \max (\text{Map}_s^L(x, y), \text{Map}_s^G(x, y), \text{Map}_s^B(x, y)) \right) * \mathbf{h}_{k \times k}, \quad (4)$$

که در آن $\mathbf{h}_{k \times k}$ یک فیلتر پایین‌گذر $k \times k$ است که از آن برای به دست آوردن یک نقشه هموار استفاده شده است. در اینجا برای رسیدن به جواب بهینه در شبیه‌سازی‌ها با آزمون و خطا مقدار $k = 5$ در نظر گرفته شده است.

به منظور تولید نقشه ویژگی کلی ابتدا مطابق با [28]، توزیع ویژگی‌های به دست آمده در هر نقشه را با تابع چگالی احتمال نرمال $f(\text{Map}_s^C(x, y))$ تعریف می‌کنیم. به بیان ریاضی، توزیع احتمال $\text{Map}_s^C(x, y)$ به صورت زیر محاسبه می‌شود:

$$f(\text{Map}_s^C(x, y)) = \frac{1}{(2\pi)^{D/2} |\Sigma|^{1/2}} \times e^{-\frac{1}{2} (\text{Map}_s^C(x, y) - \mu)^T \Sigma^{-1} (\text{Map}_s^C(x, y) - \mu)} \quad (5)$$

که در آن:

$$\Sigma = E[(\text{Map}_s^C(x, y) - \mu)(\text{Map}_s^C(x, y) - \mu)^T] \quad (6)$$

$$\mu = E[\text{Map}_s^C(x, y)]$$

سپس همانند روش [28] از رابطه زیر برای محاسبه نقشه ویژگی کلی استفاده می‌شود:

$$F_G(x, y) = \frac{1}{3} \sum_{c \in \{L, a, b\}} (\log(f(\text{Map}_s^C(x, y))^{-1}))^{1/2} * \mathbf{h}_{k \times k}. \quad (7)$$

۴-۲- ترکیب نقشه‌های ویژگی جهت محاسبه نقشه نقاط برجسته

برای تولید نقشه نقاط برجسته تصویر ورودی، ابتدا هریک از دو نقشه ویژگی محلی و کلی به دست آمده در مرحله قبل را بین صفر تا یک نرمالیزه می‌کنیم و سپس از رابطه زیر برای محاسبه نقشه نقاط برجسته استفاده می‌کنیم:

$$SMap(x, y) = M(\hat{F}_L(x, y) \times e^{F_G(x, y)}) * \mathbf{h}, \quad (8)$$

در این رابطه $\hat{F}_L(x, y)$ و $F_G(x, y)$ به ترتیب نرمالیزه شده نقشه‌های ویژگی محلی و کلی به بازه [۰ و ۱] هستند. همچنین $M(\cdot)$ تابع نرمال‌ساز غیرخطی به صورت $M(\cdot) = \frac{\ln \sqrt{2} / \sqrt{2}}{\cdot}$ است که برای کاهش اثر تقویت دامنه بر روی نقشه نقاط برجسته نهایی استفاده می‌شود [28].

¹ Focus of Attention
² Ground-Truth Map

محاسباتی است. α در رابطه (۱۲)، پارامتری مثبت برای تنظیم میزان دقت ارزیابی است. مقادیر بیشتر از α نشان‌دهنده اهمیت بیشتر در دقت است. در این مقاله بر اساس شبیه‌سازی‌های صورت گرفته، مقدار $\alpha = 0.3$ انتخاب شده است.

در شبیه‌سازی‌ها، P نشانگر میزان کیفیت روش پیشنهادی جهت پیش‌بینی برجستگی بصری، R نسبت مناطق برجسته صحیح تشخیص داده‌شده به اطلاعات مینا است و F'_{α} بیانگر عملکرد کلی روش مورد نظر است. برای انجام ارزیابی عملکرد مناسب از طریق به‌دست‌آوردن P ، R و F'_{α} ، با انتخاب یک آستانه مناسب، نقشه‌های $s(x, y)$ و $s(x, y)$ که در روابط (۱۰) و (۱۱) محاسبه شده‌اند، تبدیل به نقشه‌های دودویی می‌شوند. این مقادیر آستانه توسط روش آستانه‌گذاری خودکار *Otsu* [34] به‌دست می‌آیند. علاوه بر موارد بالا، در شبیه‌سازی‌ها، عملکرد مدل پیشنهادی بر اساس مشخصه عملکرد گیرنده (ROC^1) نیز مورد بررسی قرار می‌گیرد. نقشه برجستگی دربرگیرنده دو ناحیه برجسته و غیر برجسته است.

درصدی از مناطق برجسته که منطبق با نقشه برجستگی به‌دست‌آمده از نتایج قابل اطمینان است، نرخ اعلام درست (TPR^2) نامیده می‌شود. درصدی از مناطق غیر برجسته که توسط الگوریتم، منطبق با نقشه برجستگی به‌دست‌آمده از نتایج قابل اطمینان تشخیص داده می‌شود، نرخ اعلام درست کاذب (FPR^3) نامیده می‌شود. نمودار ROC تغییرات TPR نسبت به FPR را نمایش می‌دهد.

در نخستین قسمت از آزمایش‌ها، عملکرد روش پیشنهادی در استخراج نقشه‌های برجستگی به‌صورت کیفی مورد بررسی قرار می‌گیرد. در این راستا در شکل (۲)، نقشه نقاط برجسته کلی، محلی و نهایی به‌دست‌آمده از تصویر "کیمیا" نمایش داده شده است. برای تسهیل در مقایسه شهودی نتایج به‌دست‌آمده، در سطر نخست از این شکل، تصویر اصلی (۲-الف) در کنار نقشه برجستگی نهایی (۲-ب) و در سطر دوم نقشه برجستگی محلی (۲-ج) و کلی (۲-د) در کنار یکدیگر آورده شده‌اند. نقشه نقاط برجسته نهایی به‌دست‌آمده در شکل (۲)، شباهت زیادی به نقشه نقاط برجسته محلی (محاسبه‌شده از (۷)) دارد. این نتیجه زمانی ایجاد می‌شود که توزیع ویژگی‌های محلی برای مناطق برجسته هم سطح با تباین محلی برای برجستگی‌های داده شده باشد.

در ادامه شبیه‌سازی‌های انجام‌شده کیفیت عملکرد روش پیشنهادی به‌صورت کمی مورد بررسی قرار می‌گیرد. برای این منظور نقشه‌های برجستگی کلی و محلی و نهایی به‌دست‌آمده، با استفاده از اندازه‌گیری P ، R و F'_{α} ، در شکل (۳) نمایش داده شده است. از این شکل به‌وضوح می‌توان دریافت که با وجود شباهت زیاد در پیاده‌سازی، نقشه برجستگی محلی نسبت به نقشه برجستگی کلی، عملکرد مناسب‌تری دارد.

همچنین از این شکل می‌توان دریافت که نقشه برجستگی به‌دست‌آمده از ترکیب نقشه‌های محلی و کلی عملکرد بهتری نسبت به نقشه برجستگی محلی و یا کلی به صورت جداگانه دارد، چرا که نقشه برجستگی کلی و نقشه برجستگی محلی دربرگیرنده اطلاعات مهم از مناطق مختلف یک تصویر هستند و با وجود هم‌پوشانی اطلاعات آنها، نقشه ترکیبی نهایی اطلاعات بیشتری نسبت به تک‌تک آنها دارد.

همان‌طور که در بخش‌های قبل بیان شد، روش‌های ارائه‌شده توسط *Itti* و همکاران [13]، *Achanta* و همکاران [17]، *Hou* و همکاران [16]، *Murray* و همکاران [25] و *Imamoglu* و همکاران [28] برای مقایسه در شبیه‌سازی‌ها انتخاب شده‌اند. این روش‌ها به ترتیب مبتنی بر مدل مکانی، مبتنی بر تبدیل فوری و مبتنی بر تبدیل موجک هستند.

شکل‌های (۴ و ۵)، عملکرد کلی مدل‌های مورد بررسی را بر اساس مقادیر آستانه به‌دست‌آمده از روش *Otsu* و مقدار متوسط نقشه نقاط برجسته، نشان می‌دهند. همانگونه که از این دو شکل می‌توان دریافت، برای هر دو روش انتخاب آستانه، مدل ارائه‌شده در این مقاله برای معیار F و P عملکرد مناسب‌تری نسبت به روش‌های مورد بررسی از خود نشان می‌دهد. همچنین از این دو شکل می‌توان دریافت که روش ارائه‌شده در [25] از دید معیار R نسبت به روش پیشنهادی در این مقاله اندکی بهتر عمل می‌کند این در حالی است که از دید معیارهای F و P ، روش پیشنهادی عملکرد مناسب‌تری دارد.

همان‌گونه که در مقدمه نیز بیان شد، مدل ارائه‌شده در این مقاله شباهت زیادی به مدل ارائه‌شده در [28]، در فرآیند تولید نقشه‌های برجستگی محلی و کلی دارد. تفاوت این دو مدل در چگونگی انتخاب ضرایب موجک برای تولید نقشه‌های ویژگی است. نتایج ارائه‌شده در شکل‌های (۴ و ۵) برتری نسبی روش پیشنهادی را نسبت به [28] نشان می‌دهد.


¹ Receiver Operating Characteristic

² True Positive Rate

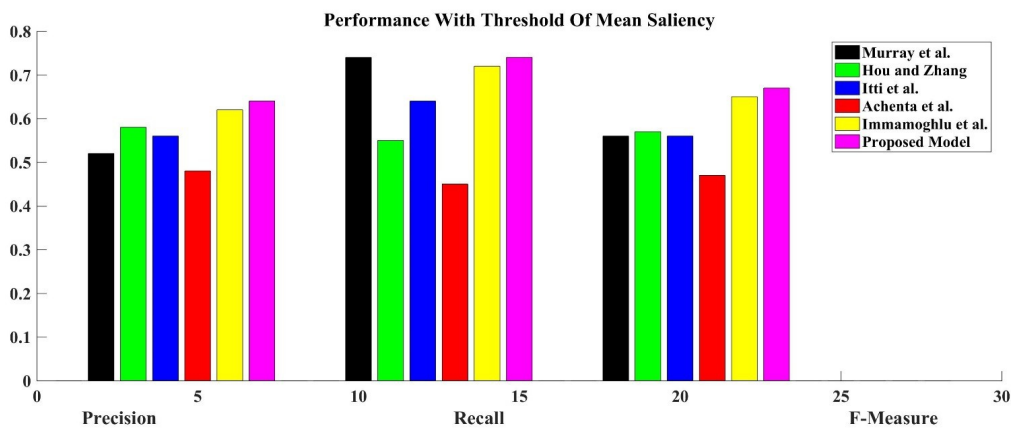
³ False Positive Rate



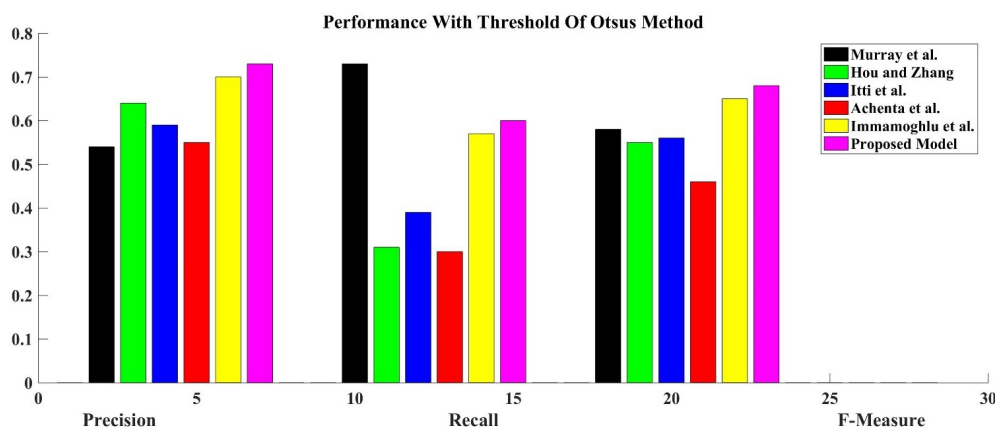
(شکل-۲): مقایسه نقشه نقاط برجسته محلی و کلی و نقشه نقاط برجسته به دست آمده از روش پیشنهادی برای تصویر کیمیا. الف- تصویر کیمیا، ب- نقشه برجستگی نهایی، ج- نقشه برجستگی محلی و د- نقشه برجستگی کلی
(Figure 2): An example showing local and global saliency maps from the proposed method. A) Input image, B) Final saliency map, C) Local saliency map, and D) Global saliency map



(شکل-۳): مقایسه عملکرد روش پیشنهادی برای نقشه های برجستگی محلی، کلی و نهایی با استفاده از پایگاه داده مایکروسافت (Figure-3): performance evaluation of the proposed method for local, global, and final Saliency maps using Microsoft's saliency dataset



(شکل-۴): مقایسه عملکرد روش پیشنهادی با سایر روش های مطرح شده بر حسب سه معیار P ، R و F (آستانه گذاری متوسط نقشه برجستگی)
(Figure-4): performance evaluation of various saliency prediction methods in terms of precision, recall, and F-measure (middle threshold of the saliency map)




(شکل-۵): مقایسه عملکرد روش پیشنهادی با سایر روش‌های مطرح شده بر حسب سه معیار F و R ، P

(آستانه‌گذاری اتوماتیک اوتسو)

(Figure-5): performance evaluation of various saliency prediction methods in terms of precision, recall, and F-measure (Otsu's Auto-thresholding)


نشان می‌دهد. در مقایسه عملکرد این روش با [28]، در نمودار ROC رقابت تنگاتنگی مشاهده می‌شود. با این وجود در یک جمع‌بندی کلی در این نمودار نیز مدل پیشنهادی عملکرد مناسب‌تری را از خود نشان می‌دهد.

منحنی ROC در شکل (۶) نمایش داده شده است. در نمودار ROC مقادیر بزرگتر نشان‌دهنده عملکرد مناسب‌تر الگوریتم آشکارسازی مناطق برجسته است. در این نمودار روش پیشنهادی در این مقاله نسبت به روش‌های ارائه‌شده در [13, 17, 16, 25] به وضوح کیفیت عملکرد بالایی از خود



(شکل-۶): مقایسه روش پیشنهادی و سایر روش‌ها توسط نمودار ROC

(Figure-6): evaluating ROC diagrams for various saliency prediction models.



(شکل-۷): مقایسه نقشه نقاط برجسته به دست آمده از روش پیشنهادی و دو روش دیگر برای تصویر کیمیا. الف- تصویر کیمیا، ب- روش

پیشنهادی، ج- روش GVBS و د- روش Image Signature

(Figure-7): A demonstration of saliency maps generated from different approaches: A) Input image, B) Proposed algorithm, C) GVBS method, D) Image Signature method.

(جدول-1): مقایسه نقشه نقاط برجسته به دست آمده از روش پیشنهادی و دو روش دیگر برای تصویر کیمیا بر اساس متوسط زمان اجرا.

(Table-1): Comparison of the proposed method with other classic methods in terms of average computational time.

نام روش	روش پیشنهادی	روش آرایه شده در [14]	روش آرایه شده در [16]	روش آرایه شده در [28]	روش آرایه شده در [17]	روش آرایه شده در [13]	روش آرایه شده در [21]	روش آرایه شده در [25]
مدت زمان اجرا (ثانیه)	0.1801	0.3801	0.4015	0.5249	0.2152	0.4102	0.3109	0.2913

در شکل (۷)، روش پیشنهادی در مقایسه با روش GVBS [14] و روش Image Signature [16] مورد بررسی قرار می‌گیرد. نتایج به دست آمده ارائه شده است. در این شکل برتری روش پیشنهادی قابل مشاهده است.

در قسمت آخر از شبیه‌سازی‌های انجام شده مدت زمان اجرای متوسط روش پیشنهادی، به‌عنوان یک تخمین از میزان پیچیدگی، مورد بررسی قرار گرفته است. نتایج آرایه شده در جدول (۱) برای تصویر استاندارد از "کیمیا" با ابعاد 480×720 و با استفاده از یک دستگاه رایانه با پردازنده Core i7 6700HQ و فرکانس پردازش ۲٫۶ GHz، در محیط ۲۰۱۷ Matlab با ۱۶ GB RAM به دست آمده‌اند.

نتایج به دست آمده نشان دهنده سرعت بالای روش پیشنهادی در استخراج نقشه نقاط برجسته هستند. دلیل سرعت بالای روش پیشنهادی، مدل‌سازی تنگ تصویر در فضای موجک و استفاده از خواص تکنیک نمونه برداری تصادفی است.

۴- نتیجه گیری

در این مقاله، روشی برای پیش بینی نقاط برجسته در تصاویر با استفاده از نمونه برداری تصادفی از ضرایب موجک آرایه شد. در روش پیشنهادی برای به دست آوردن نقشه برجستگی از ضرایب موجک تصاویر، براساس روش نمونه برداری فشرده، نمونه‌های تصادفی انتخاب می‌شود؛ سپس از نمونه‌های تصادفی انتخاب شده در هر زیرباند میانی، معکوس تبدیل موجک گرفته شده تا نقشه‌هایی موسوم به نقشه های ویژگی به دست آیند. نقشه‌های ویژگی به دست آمده حاوی اطلاعات محلی تصویر در یک باند فرکانسی میانی است که در آن جزئیات مختلفی از لبه‌ها تا بافت‌ها ظاهر می‌شود. در ادامه، با استفاده از نقشه‌های ویژگی به دست آمده، نقشه برجستگی بصری محلی و نقشه برجستگی کلی محاسبه می‌شود؛ در نهایت، با ترکیب خطی نقشه برجستگی محلی و کلی به دست آمده، نقشه برجستگی نهایی تصویر ورودی محاسبه می‌شود. نتایج آزمایش‌های

انجام شده نشان می‌دهند که این روش از کارایی و دقت خوبی در مقایسه با سایر روش‌های موجود برخوردار و در عین حال زمان اجرای کمتری دارد.

5- References

۵- مراجع

- [1] Y. Fang, W. Lin, Zh. Chen, Chia-Ming Tsai, and Chia-Wen Lin, "A Video Saliency Detection Model in Compressed Domain", *IEEE Trans. Circuits and Systems for Video Technology*, vol. 24, no. 1, Jan. 2014.
- [2] S. Mathe and C. Sminchisescu, "Actions in the Eye: Dynamic Gaze Datasets and Learnt Saliency Models for Visual Recognition", *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 37, no. 7, Jul 2015.
- [3] S. H. Khatoonabadi, I. V. Bajc, Yufeng Shan, "Comparison of visual saliency models for compressed video", in Proc. IEEE International Conference on Image Processing (ICIP), Jan 2015.
- [4] M. Xu, L. Jiang, X. Sun, Zhaoting Ye, and Z. Wang, "Learning to Detect Video Saliency with HEVC Features", *IEEE Trans. Image Processing*, vol. 26, no. 1, Jan 2017.
- [5] C. Li, Q. Tu, M. Zhao, J. Xu and A. Men, "A multiscale compressed video saliency detection model based on ant colony optimization", in Proc. IEEE CIC/ICCC 2015 Symposium on Signal Processing for Communications, Nov. 2015.
- [6] M. Jiang, X. Boix, G. Roig, J. Xu, L. V. Gool and Q. Zhao, "Learning to Predict Sequences of Human Visual Fixations", *IEEE Trans. Neural Networks and Learning Systems*, vol 27, no.6, Jun 2016.

[۷] حسین فیاضی، حمید دهقانی، مجتبی حسینی، "تجزیه تنگ تصاویر ابرطیفی با استفاده از یک کتابخانه طیفی هرس شده"، فصل‌نامه پردازش علائم و داده‌ها، سال سیزدهم شماره ۳ (پیاپی ۲۹، ۱۳۹۵). ۱۵۵-۱۶۹، ۱۳۹۵.

[7] H.Fayazi, H.Dehqani, and M.Hosseini, "sparse unmixing of hyper-spectral images using a pruned

IEEE Trans. Multimedia, vol. 19, no. 8, pp. 1742 - 1756, Apr 2017.

- [19] L. Zhang, X. Li, L. Nie, Y. Yang, and Y. Xia, "Weakly Supervised Human Fixations Prediction", *IEEE Trans. Cybernetics*, vol. 46, no. 1, pp. 258 - 269, Jan. 2016.
- [20] J. Li, L. Duan, X. Chen, T. Huang, and Y. Tian, "Finding the Secret of Image Saliency in the Frequency Domain", *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 37, no. 12, pp. 2428-2440, Apr 2015.
- [21] X. Hou and L. Zhang, "Saliency detection: A spectral residual approach," in *Proc. IEEE Int. Conf. Comput. Vision and Pattern Recognition*, pp. 1-8, Nov. 2007.
- [22] C. Guo, Q. Ma, and L. Zhang, "Spatio-temporal saliency detection using phase spectrum of quaternion Fourier transform," in *Proc. IEEE Int. Conf. Comput. Vision and Pattern Recognition*, pp. 1-8, 2008.
- [23] L. Zhang, J. Chen, and B. Qiu, "Region-of-Interest Coding Based on Saliency Detection and Directional Wavelet for Remote Sensing Images", *IEEE Trans. Geoscience and Remote Sensing Letters*, vol. 14, no. 1, pp. 23-27, Jan 2017.
- [24] Y. Yang, Y. Quc, Sh. Huang, and P. Lin, "Multiple Visual Features Measurement with Gradient Domain Guided Filtering for Multi-sensor Image Fusion", *IEEE Trans. Instrumentation and Measurement*, vol. 66, no. 4, Apr 2017.
- [25] N. Murray, M. Vanrell, X. Otazu, and C. A. Parraga, "Saliency estimation using a non-parametric low-level vision model," in *Proc. IEEE Int. Conf. Comput. Vision and Pattern Recognition*, 2011.
- [26] X. Liu, D. Zhai, J. Zhou, X. Zhang, D. Zhao, and Wen Gao, "Compressive Sampling-Based Image Coding for Resource-Deficient Visual Communication", *IEEE Trans. Image Processing*, vol. 25, no. 6, Jun 2016.
- [27] M. Aghagolzadeh, H. Radha, "Joint Estimation of Dictionary and Image from Compressive Samples", *IEEE Trans. Computational Imaging*, vol. pp, no. 99, Feb 2017.
- [28] N. İmamoğlu, W. Lin, Y. Fang, "A Saliency Detection Model Using Low-Level Features Based on Wavelet Transform", *IEEE Trans. Multimedia*, vol. 15, no. 1, pp. 96-106, Jan 2013.
- [29] S. A. Raza Naqvi, "Image compression using haar wavelet based tetrolet transform", in *Proc. IEEE Int. Conf. Open Source Systems and Technologies (ICOSST)*, pp. 50-54, Jan 2014.
- spectral library", *signal and data processing*, no.13, pp.155-169, 1395.
- [۸] مهدی بنی طالبی دهکردی، محمد تقی صادقی، حمید رضا ابوطالبی، "راهکار جدید استخراج ویژگی مبتنی بر نمونه برداری فشرده در پردازش سیگنال های صوتی"، فصل نامه پردازش علائم و داده ها، سال دهم شماره ۱ (پیاپی ۱۰، ۱۳۹۲)، ۵۷-۶۸، ۱۳۹۲.
- [8] M.Bani Talcbi.D, M.T.Sadeqi, and H.R. Aboutalebi, "New comprehensive sampling based feature extraction method and its APPLICATION in audio signal processing", *signal and data processing*, no.01,pp.57-68,1392.
- [9] N. Li, J. Yc, Y. Ji, H. Ling and J. Yu, "Saliency Detection on Light Field", *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 39, no. 8, Aug 2017.
- [10] S. Tajima and K. Komine, "Saliency-Based Color Accessibility", *IEEE Trans. Image Procesing*, vol. 24, no. 3, Mur 2015.
- [11] S. Frintrop, "VOCUS: A visual attention system for object detection and goal directed search," Ph.D. dissertation, Rheinische Friedrich-Wilhelms-Universität Bonn, Bonn, Germany, 2005.
- [12] L. Itti, "Models of bottom-up and top-down visual attention," Ph.D. dissertation, Dept. Computat. Neur. Syst., California Inst. Technol, Pasadena, 2000.
- [13] L. Itti, C. Koch, and E. Niebur, "Model of saliency-based visual attention for rapid scene analysis," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 20, no. 11, pp. 1254-1259, Nov. 1998.
- [14] J. Harel, Ch. Koch, P. Perona, "Graph-Based Visual Saliency", *Advances in Neural Information Processing Systems*, No.19. MIT Press, Cambridge, MA, pp. 545-552, 2007.
- [15] T. Liu, J. Sun, N.-N. Zheng, X. Tang, and H.-Y. Shum, "Learning to detect a salient object," in *Proc. IEEE Int. Conf. Comput. Vision and Pattern Recognition*, pp. 1-8, Apr. 2007.
- [16] X. Hou, J. Harel, and Ch. Koch, "Image Signature: Hlghlighting sparse salient regions", *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 34, no. 1, pp. 194-201, Jan 2012.
- [17] R. Achanta, S. Hemami, F. Estrada, and S. Susstrunk, "Frequencytuned salient region detection", in *Proc. IEEE Int. Conf. Comput. Vision and Pattern Recognition*, pp. 1597-1604, 2009.
- [18] L. Ye, Z. Liu, L. Li, L. Shen, C. Bai, and Yang Wang, "Salient Object Segmentation via Effective Integration of Saliency and Objectness",

کانادا دریافت کرده‌اند و از سال ۱۳۹۰ به‌عنوان استادیار در دانشگاه فردوسی مشهد فعالیت علمی می‌کنند. زمینه‌های پژوهشی مورد علاقه ایشان پردازش گفتار، پردازش تصویر و ویدیو، بینایی ماشین و پردازش سیگنال‌های حیاتی است. نشانی رایانامه ایشان عبارت است از:

a.ebrahimi@um.ac.ir



مرتضی خادمی تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق به ترتیب در سال‌های ۱۳۶۴ و ۱۳۶۶ در دانشگاه صنعتی اصفهان به پایان رسانده است. نامبرده از

سال ۱۳۶۶ الی ۱۳۷۰ به‌عنوان عضو هیأت علمی (مربی) در دانشگاه فردوسی مشهد به کار مشغول بود. پس از آن به دوره دکترای مهندسی برق در دانشگاه ولونگونگ (استرالیا) وارد گردیده و در سال ۱۳۷۴ موفق به اخذ درجه دکترا در مهندسی برق از دانشگاه یادشده شد. دکتر خادمی از سال ۱۳۷۴ دوباره در دانشکده مهندسی دانشگاه فردوسی مشهد مشغول به فعالیت شد و اینک نیز استاد این دانشکده است. زمینه‌های علمی مورد علاقه نامبرده شامل موضوعاتی مانند مخابرات ویدئویی، فشرده‌سازی ویدئو، پردازش تصویر، پردازش سیگنال‌های پزشکی و پنهان‌سازی اطلاعات در ویدئو است.

نشانی رایانامه ایشان عبارت است از:

khademi@um.ac.ir



هادی هادی‌زاده مدرک کارشناسی و کارشناسی ارشد برق در گرایش الکترونیک خود را به ترتیب از دانشگاه صنعتی شاهرود در سال ۱۳۸۴ و دانشگاه علم و صنعت ایران در سال ۱۳۸۷ اخذ

کرده است. وی مدرک دکترای خود را در رشته برق گرایش مخابرات از دانشگاه Simon Fraser کانادا در سال ۱۳۹۲ دریافت کرده و از همان سال به‌عنوان استادیار در دانشگاه صنعتی قوچان فعالیت می‌کند. زمینه‌های پژوهشی مورد علاقه ایشان پردازش و فشرده‌سازی تصاویر و ویدیوهای دیجیتال، شبکه‌های مخابراتی، بینایی و آموزش ماشین، بازشناسی الگو و مدل‌سازی دستگاه بینایی مغز انسان

[30] N. D. B. Bruce, Sh. Rahman, D. Carrier, "Sparse Coding in Early Visual Representation: From Specific Properties to General Principles", *Neurocomputing*, vol. 2, no. 1, pp. 1085–1098, Aug 2015.

[31] M. Banitalebi-Dehkordi, A. Banitalebi-Dehkordi, J. Abouei, K. N. Plataniotis, "Face recognition using a new compressive sensing-based feature extraction method", *Multimedia Tools and Applications*, vol. 1, no.2, pp.1-21, Jul. 2017.

[32] S. Goferman, L. Zelnik-Manor, and A. Tal, "Context-aware saliency detection," in Proc. *IEEE Int. Conf. Comput. Vision and Pattern Recognition*, pp. 2376–2383, 2010.

[33] Microsoft Research Cambridge-12 database, available in: <https://www.microsoft.com/en-us/download/details.aspx?id=52283&from=http%3A%2F%2Fresearch.microsoft.com%2Fenu%2Fum%2Fcambridge%2Fprojects%2Fmsrc12%2F>, April, 2012.

[34] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed. London, U.K.: Academic-Elsevier, pp. 20–24, 2009.



مهدی بنی‌طالبی دهکردی دوره کارشناسی خود را در رشته مهندسی برق گرایش الکترونیک در دانشگاه شهرکرد در سال ۱۳۸۶ به پایان رسانده و در سال ۱۳۹۱ مدرک کارشناسی‌ارشد خود را در

رشته مهندسی برق گرایش مخابرات سیستم از دانشگاه یزد اخذ کرده است. وی از سال ۱۳۹۳ دانشجوی دکترا برق گرایش مخابرات سیستم در دانشگاه فردوسی مشهد است. زمینه‌های پژوهشی مورد علاقه ایشان پردازش گفتار، پردازش تصویر و ویدیو و به‌صورت خاص تعیین کیفیت ویدیو است.

نشانی رایانامه ایشان عبارت است از:

Mehdi.banitalebidehkordi@mail.um.ac.ir



عباس ابراهیمی‌مقدم مدرک کارشناسی برق گرایش الکترونیک خود را از دانشگاه صنعتی شریف در سال ۱۳۷۰ و در سال ۱۳۷۴ مدرک کارشناسی‌ارشد را از دانشگاه صنعتی خواجه‌نصیر اخذ کرده

است. ایشان مدرک دکترای خود را از دانشگاه McMaster



می‌باشد. دکتر هادی‌زاده از سال ۲۰۰۹ تاکنون، موفق به کسب ۲۲ عنوان و افتخار علمی مختلف از دانشگاه‌های داخلی و بین‌المللی شده است. از جمله آنها می‌توان به کسب عنوان بهترین مقاله در کنفرانس بین‌المللی IEEE-ICME2012 در ملبورن استرالیا، اخذ گرنت Microsoft Research و Canon Information Systems Research Australia (CiSRA) و اخذ عنوان بهترین مقاله کنفرانس بین‌المللی مهندسی برق در دانشگاه تهران اشاره کرد. در سال ۲۰۱۳ نیز به‌عنوان دبیر اجرایی IEEE Signal Processing Society در حوزه ونکوور کانادا فعالیت کرده‌اند. ایشان تجربه کاری در شرکت‌های بین‌المللی همچون Dolby Laboratories و Icron Technologies را دارد.

نشانی رایانامه ایشان عبارت است از:

h.hadizadeh@qiet.ac.ir