

## هم‌بخش بندی با استفاده از روش تجزیه ماتریس ساخت یافته دو مرحله‌ای

محمدجواد فدائی اسلام\*

### چکیده

در این مقاله روشی دو مرحله‌ای برای هم‌بخش‌بندی مبتنی بر تجزیه تصویر به ماتریس مرتبه کم و پراکنده ابداع شده است. در مرحله اول که مشابه روش SMD است ابرپیکسل‌های نقشه برجسته به عنوان ماتریس پراکنده در نظر گرفته می‌شوند و اجزای زمینه به عنوان ماتریس با رتبه کم. در این حالت ابرپیکسل‌هایی که با اطمینان بالا، زمینه خوشه‌بندی شده‌اند حذف می‌شوند. در مرحله بعد تمام ابرپیکسل‌های باقی مانده از تمام تصاویر باهم در نظر گرفته می‌شوند. پس از وزن دهی جدید به ساختار درخت و ادغام اطلاعات، روش SMD دوباره بر روی داده‌های جدید اعمال می‌شود. در این مرحله به علت کثرت ابرپیکسل‌های باقی مانده از قسمت نقشه برجسته تصاویر، اعمال روش تجربه ماتریسی باعث فرار گرفتن ابرپیکسل‌های نقشه برجسته در ماتریس با مرتبه کم خواهد شد. به عبارتی در روش پیشنهادی با وزن دهی مناسب به نمایش درختی ابرپیکسل‌ها، اطلاعات همسایگی و مشابهت درون یک تصویر و بین تصاویر در روش تجزیه ماتریسی نهاده شده، تا از طریق آن نتایج هم‌بخش‌بندی بهبود یابد. نتایج به دست آمده از به کارگیری روش پیشنهادی بر روی پایگاه تصاویر مرتبط با این حوزه، حاکی از توانمندی این روش هستند.

### کلید واژه‌ها

هم‌بخش‌بندی، شناسایی نقشه برجستگی، تجزیه ماتریس، درخت همسایگی

### ۱ مقدمه

در برخی از مقالات، محققین برای کاهش خطا از روش‌های تعاملی بهره برده‌اند، اما فرآیند تعاملی بسیار زمان‌بر است و با رهیافت کلی موجود در تمام عرصه‌های هوش مصنوعی یعنی خودکارسازی در تعارض است.

برخی از مقالات اخیر، از تزریق اطلاعات معنایی برای حل مشکل بهره برده‌اند [۱]. هم‌بخش‌بندی<sup>۱</sup> راه‌کار میانه‌ای است که در آن اطلاعات اضافه موجود در تصاویر مرتبط دیگر برای این هدف به کار گرفته می‌شود. این تکنیک برای اولین بار در مقاله [۲] مطرح شد.

بخش‌بندی یکی از مسایل پایه‌ای در فرآیند بینایی ماشین و پردازش تصویر است. تکنیک‌های متعددی برای بخش‌بندی از طریق یافتن تفاوت بین پیکسل‌ها و گنجاندن آنها در یک تابع هدف سراسری ابداع شده است. اما بخش‌بندی، تنها با استفاده از اطلاعات موجود در یک تصویر با خطای زیاد همراه خواهد بود.

این مقاله در اسفندماه سال ۱۳۹۶ دریافت، در آذرماه سال ۱۳۹۸ بازنگری و در بهمن‌ماه سال ۱۳۹۸ پذیرفته شد.

\* دانشکده برق و کامپیوتر، دانشگاه سمنان  
رایانامه: [fadaei@semnan.ac.ir](mailto:fadaei@semnan.ac.ir)

<sup>1</sup> Co-segmentation

همکارانش در مقاله [۲] فرض نموده‌اند که اندازه دو تصویر ورودی هم‌اندازه است و اندازه پیش‌زمینه در هر دو تقریباً یکسان است. یافتن جواب بهینه برای این تابع انرژی از درجه مسایل NP-hard است. از این‌رو هاجام<sup>۲</sup> و همکارانش در [۳] با هدف رسیدن به مساله بهینه‌سازی از درجه چندجمله‌ای، سازگاری دو هیستوگرام را به عنوان یک پاداش در نظر گرفته‌اند به جای آنکه تفاوت آنها را به عنوان جریمه در نظر داشته باشند. آنها این مساله بهینه‌سازی را در قالب گراف بیان نمودند که جواب بهینه در آن از طریق الگوریتم حداکثر جریان<sup>۳</sup> به دست می‌آید. در مقالات [۲] و [۳] فرآیند هم‌بخش‌بندی تنها با دو تصویر انجام می‌شود.

جولین<sup>۴</sup> و همکارانش از روش خوشه‌بندی تفکیک‌کننده<sup>۵</sup> برای هم‌بخش‌بندی استفاده نمودند [۵] و [۶]. آنها هم‌بخش‌بندی را در سطح ابرپیکسل<sup>۶</sup> اجرا نمودند. هم‌بخش‌بندی مطلوب دارای دو فاکتور مهم است: همبستگی فضایی<sup>۷</sup> در داخل یک تصویر و مشابهت نواحی پیش‌زمینه در بین تصاویر. جولین و همکارانش در این دو مقاله از خوشه‌بندی طیفی برای برقراری همبستگی فضایی در یک تصویر و از خوشه‌بندی تفکیک‌کننده برای یافتن تشابه بین تصاویر استفاده کرده‌اند.

روبیو و همکارانش در [۷] یک روش بدون ناظر ارایه داده‌اند که از یک مدل زایشی<sup>۸</sup> استفاده می‌کند و از انطباق نواحی<sup>۹</sup> هم بهره می‌برد. آنها نیز یک تابع انرژی جدید ارایه نمودند.

مقالات [۸] و [۹] از روش ترکیب خطی<sup>۱۰</sup> برای استخراج نواحی برجسته مشترک در دو یا چند تصویر استفاده نموده‌اند. آقای لی و همکارانش در [۸] از سه روش استخراج نقشه‌برجستگی ایتی<sup>۱۱</sup>، FTA<sup>۱۲</sup> و SRA<sup>۱۳</sup> سه مقدار اهمیت برای هر ناحیه یافته‌اند و سپس آنها را باهم به صورت وزن‌دار جمع نموده‌اند و آن را نقشه‌برجستگی یک تصویر تنها<sup>۱۴</sup> یا

هم‌بخش‌بندی کاربردهای گسترده‌ای در صنعت دارد؛ شناسایی جسم یا افراد در دوربین‌های متعدد نظارتی یکی از کاربردهای آن است. ردیابی اشیا با این تکنیک با توجه به تعداد بالای دوربین‌های نظارتی نصب شده در زوایای مختلف یک مکان، می‌تواند به سادگی صورت گیرد. دسته‌بندی تصاویر موجود در منابع اطلاعاتی و استخراج اطلاعات از آنها از دیگر کاربردهای آن است. در مقاله [۳] هم‌بخش‌بندی در شناسایی پاتولوژی در تصاویر مغزی به کار برده شده است.

بسیاری از روش‌های نوین هم‌بخش‌بندی، از استخراج نواحی نقشه‌برجسته<sup>۱</sup> در راستای افزایش سرعت و دقت بهره می‌برند؛ تجزیه ماتریسی از جمله رهیافت‌های مهم در حوزه استخراج نواحی نقشه‌برجسته است. با فرض مشابه بودن نواحی زمینه در فضای یک تصویر، پنگ و همکاران در مقاله [۴] روشی مبتنی بر تجزیه ماتریس ویژگی‌های نواحی، به ماتریس با رتبه کم (نواحی زمینه) و ماتریس پراکنده (نواحی نقشه‌برجسته) ابداع نموده‌اند. نوآوری آنها در این بوده است که توانسته‌اند به نحوی اطلاعات همسایگی را در فرآیند تجزیه وارد کنند. با الهام از روش آنها در این مقاله یک روش هم‌بخش‌بندی ابداع شد که تجزیه ماتریسی را در دو مرحله انجام می‌دهد. در مرحله اول اطلاعات همسایگی در یک تصویر مورد توجه قرار می‌گیرد و در مرحله دوم اطلاعات تصاویر مختلف به کار گرفته می‌شود تا ابرپیکسل‌ها به درستی به زمینه یا پیش‌زمینه بخش‌بندی شوند.

ساختار این مقاله به شرح ذیل است: در فصل دوم روش‌های هم‌بخش‌بندی توضیح داده شده است. در این بخش ابتدا روش‌های اولیه که در سطح پیکسل کار می‌کنند بررسی شده‌اند و سپس روش‌های مبتنی بر خوشه‌بندی تفکیک‌کننده و روش‌های تکرار شونده مورد مطالعه قرار گرفته‌اند. روش عمده دیگر که در مقالات استفاده شده نگاشت هم‌بخش‌بندی به یک مساله در حوزه گراف است.

اغلب روش‌های اخیر که در حوزه هم‌بخش‌بندی پیشنهاد شده‌اند، اهمیت (برجستگی) یک ابرپیکسل را محاسبه می‌نمایند. با توجه به گستردگی موضوع و رویکردهای موفق مختلف در این زمینه، اطلاعات جمع‌آوری شده در این زمینه در فصل سوم آورده شده است. فصل چهارم و پنجم به روش پیشنهادی و نتایج به کارگیری آن می‌پردازد، نتیجه‌گیری و ارایه پیشنهادات در بخش‌های آخر آمده‌اند.

## ۲ مروری بر کارهای گذشته

در مقاله [۲] موضوع هم‌بخش‌بندی برای اولین بار مطرح شد. در این مقاله تابع مولدی توصیف شد و در نهایت این موضوع به یک مساله کمینه‌سازی تابع انرژی تبدیل شد. رادر و

<sup>2</sup> Hochbaum

<sup>3</sup> Max-flow algorithm

<sup>4</sup> Joulin

<sup>5</sup> Discriminative clustering

<sup>6</sup> Superpixel

<sup>7</sup> Spatial coherence

<sup>8</sup> Generative model

<sup>9</sup> Region matching

<sup>10</sup> Linear combination

<sup>11</sup> Itti's method

<sup>12</sup> Frequency-tuned saliency

<sup>13</sup> Spectral residual saliency

<sup>1</sup> Single-image saliency map

<sup>1</sup> Salient

گرفته می‌شد تا اهمیت یک ناحیه از جهت زمینه یا پیش‌زمینه بودن را جدا از تصویر دیگر مورد ارزیابی قرار دهد. مقالاتی با عنوان نقشه‌برجستگی هم‌زمان<sup>۱</sup> نیز ارائه شده است که وظیفه آنها یافتن نواحی برجسته مشترک در دو یا چند تصویر است. می‌توان تفاوت‌هایی را برای این موضوع و هم‌بخش‌بندی در نظر گرفت. از جمله اینکه در نقشه‌برجستگی هم‌زمان دو موضوع برجسته بودن و مشترک بودن به صورت هم‌زمان بررسی می‌شود. اما در هم‌بخش‌بندی ممکن است ناحیه مشترک در قسمت زمینه باشد. اما با این وجود، ارتباط تنگاتنگی این دو موضوع باهم دارند و از نقشه‌برجستگی هم‌زمان می‌توان به عنوان یک روش استخراج اطلاعات اولیه برای یافتن نواحی مشترک استفاده کرد [۱۴]. با توجه به مطالب مطرح شده در این بخش تعدادی از روش‌هایی که استخراج نقشه‌برجستگی را در یک تصویر یا به طور مشترک در چند تصویر انجام داده‌اند را مورد بررسی قرار می‌دهیم.

آقای زو و همکارانش در مقاله خود [۱۵] برای یافتن نواحی نقشه‌برجسته از روشی مبتنی بر تجزیه ماتریس به یک ماتریس با مرتبه کم<sup>۲</sup> و یک ماتریس پراکنده<sup>۳</sup> یا خلوت استفاده نموده‌اند. این روش بر این فرض استوار است که نواحی متعلق به زمینه تصویر دارای مشخصات و ویژگی‌های یکسانی است. از این رو ستون‌هایی مشابه را در ماتریس ویژگی‌ها ایجاد می‌کند و در تجزیه ماتریسی در ماتریس با مرتبه پایین قرار می‌گیرند. در گام اول آنها با استفاده از روش انتقال میانگین<sup>۴</sup> تصویر ورودی را به صورت سلسله مراتبی به سه سطح ناحیه‌بندی نموده‌اند، که نام‌های آنها عبارتند از ناحیه‌بندی درشت (CG)<sup>۵</sup>، ناحیه‌بندی میانی (MG)<sup>۶</sup> و ناحیه‌بندی ریز (FG)<sup>۷</sup> که نواحی ریز را برای سادگی و تمایز ابرپیکسل نیز نام نهاده‌اند. نواحی درشت (CG) و ابرپیکسل در فرآیند استخراج مدل بازیابی ماتریس مرتبه پایین<sup>۸</sup> یا LRMR دخالت دارند و نواحی میانی (MG) در پس‌پردازش به کار برده شده‌اند تا اطلاعات فضایی و همسایگی هم در فرآیند الگوریتم لحاظ شود. در این مقاله از هر ابرپیکسل ۵۳ ویژگی استخراج شده است که الهام گرفته از روش [۱۶] می‌باشد. این ۵۳ ویژگی به صورت زیر هستند:

- مولفه‌های رنگ سبز، آبی و قرمز (۳ ویژگی)
- مولفه رنگ و اشباع<sup>۹</sup> (۲ ویژگی)

SISM نامیده‌اند. یافتن نقشه‌برجستگی چندتصویری<sup>۱</sup> یا MISM در چند گام انجام می‌شود. گام اول تجزیه هرمی دو تصویر به ابرپیکسل‌ها است. هر پیکسل در لایه بالاتر به چند ابرپیکسل در لایه پایین‌تر تبدیل می‌شود. در گام دوم دو نوع ویژگی از تصویر استخراج می‌شود: توصیف‌کننده مبتنی بر رنگ و مبتنی بر بافت. این بردارها با استفاده از روش kmeans به N خوشه تبدیل می‌شوند که مرکز آن یک کلمه کد<sup>۲</sup> تشکیل می‌دهد. گام سوم استخراج گراف چندلایه متناظر برای دو تصویر است. یک گره به همسایگانش در همان تصویر متصل است و به نواحی تصویر دیگر هم که با آن هم لایه هستند یا یک لایه اختلاف دارند متصل است. گام انتهایی یافتن ناحیه مشابه در تصویر دیگر برای آن ناحیه است. مشابهت بین دو ناحیه از معیار SimRank محاسبه می‌شود [۱۰]. روش به کار برده شده در مقاله [۹] به جای SimRank از درخت پوشای کمینه در محاسبه شباهت استفاده شده است.

منگ و همکارانش در [۱۱] مساله هم‌بخش‌بندی را به یک مساله یافتن کوتاهترین مسیر در گراف تبدیل نموده‌اند. مقاله [۱۲] روشی ابداع نموده است تا قالب یا طرح یک شی را از چند تصویر استخراج نماید (که به آن هم‌طرح<sup>۳</sup> گویند) و از به هم پیوستن آن با هم‌بخش‌بندی روند شناسایی اشیا را تسهیل نماید. در این روش بخش‌بندی مبتنی بر ناحیه و بخش‌بندی مبتنی بر طرح یکدیگر را تکمیل می‌نمایند و در شرایطی که بیش از یک شی مشترک در تصویر وجود دارد (گله حیوانات به طور مثال) نتایج خوبی به همراه داشته است. ممکن است در تصاویر مختلف اشیایی مشابه وجود داشته باشند که به لحاظ رنگ باهم متفاوت باشند، مانند تصویر چند اسب با رنگ‌های مختلف. در این شرایط روش‌های مبتنی بر شباهت رنگ کارا نیست. تائو و همکارانش در [۱۳] سعی نموده‌اند تا با استخراج شمای<sup>۴</sup> جسم، سازگاری آن را در تصاویر مختلف بررسی نمایند.

## ۳ نقشه‌برجستگی و کاربردهای آن در هم‌بخش‌بندی

هدف نقشه‌برجستگی<sup>۵</sup> یافتن نواحی مورد توجه و مهم برای انسان در تصویر است. این موضوع یکی از زمینه‌های جذاب و پرکاربرد پردازش تصویر در سال‌های اخیر بوده است. در کارهای این حوزه، پس از استخراج ابرپیکسل روش‌هایی به کار

<sup>7</sup> Co-saliency

<sup>8</sup> Low rank

<sup>9</sup> Sparse

<sup>10</sup> Mean-shift algorithm

<sup>11</sup> Coarse grained

<sup>12</sup> Medium grained

<sup>13</sup> Fine grained

<sup>14</sup> Low rank matrix recovery

<sup>1</sup> Hue and saturation

<sup>2</sup> Multi-image saliency map

<sup>3</sup> Codeword

<sup>4</sup> Cosketch

<sup>5</sup> Shape

<sup>6</sup> Saliency

می‌دهد. همان‌طور که ملاحظه می‌شود این درخت چهار لایه دارد. در لایه اول تمام ابرپیکسل‌ها که آنها را ناحیه هم نامیده‌ایم در یک دسته مجزا (خوشه مجزا) قرار دارند. در لایه‌های بالاتر خوشه‌های مشابه به هم متصل می‌شوند و تشکیل خوشه بزرگتر می‌دهند.

$i=1$	{1}	{2}	{3}	{4}	{5}	{6}	{7}	{8}	{9}	{10}
.		{3}	{1,2}	{4,7}	{8,9}	{5,6,10}				
.			{1,2,4,7}	{3,8,9}	{5,6,10}					
$i=4$				{3,8,9}	{1,2,4,5,6,7,10}					

شکل ۱ درخت فرضی ایجاد شده برای یک تصویر با چهار لایه که خوشه‌های هر لایه معین شده‌اند.

با توجه به مطالب بیان شده مقدار پارامتر تنظیم  $\Omega$ ، از روابط زیر استخراج می‌شود.

$$v_j^i = 1 - \max(\{\pi_k : k \in G_j^i\}) \quad (3)$$

$$\Omega(S) = \sum_{i=1}^d \sum_{j=1}^{n_i} v_j^i \|S_{G_j^i}\|_p \quad (4)$$

تابع  $V_j^i$  هرچه بیشتر باشد نشان دهنده آن است که این خوشه تمایل بیشتری به زمینه بودن دارد. اگر این مقدار در  $\|S_{G_j^i}\|_p$  ضرب شود باعث هماهنگی اطلاعات استخراج شده از روش‌های پایه تعیین نقشه‌برجستگی با روش تجزیه ماتریسی می‌شود. به عبارت دیگر اگر هر دو مقدار  $V_j^i$  و  $\|S_{G_j^i}\|_p$  بالا باشند ناهماهنگی دو روش را متبادر می‌سازد که در قالب هزینه  $\Omega$  در رابطه ۱ نشان داده شده است. این درخت در حقیقت ماتریس پراکنده‌گی را با شباهت ابر پیکسل‌های همسایه تلفیق نموده است. رابطه ۱ با استفاده از روش ADM<sup>۳</sup> کمینه می‌شود. تانگ و همکارانش در [۲۱] تجزیه به ماتریس با مرتبه پایین و ماتریس پراکنده را به صورت زیر نوشته‌اند:

$$\min_{L,S} L_* + \lambda \|S\|_1 \quad (5)$$

$$s.t. \quad W \circ F = W \circ L + S$$

مقدار  $W$  وزنی است که از سه نوع اطلاعات نقشه‌برجستگی مکان، رنگ و اتصال با حاشیه تصویر (مشابه آنچه در [۴] است) به دست می‌آید. البته در این مقاله همسایگی بین نواحی در نظر گرفته نشده است.

آقای چن و همکاران در مقاله [۲۲] از روش تجزیه ماتریس دو مرحله‌ای برای این کار استفاده نموده‌اند. آنها در گام اول تصاویر ورودی را با روش انتقال میانگین به ابرپیکسل تبدیل می‌نمایند. از ابرپیکسل‌ها ۵۳ ویژگی استخراج می‌شود.

• اعمال فیلتر گابور در ۱۲ جهت و سه مقیاس (۳۶ ویژگی)

• اعمال فیلتر هرمی قابل هدایت<sup>۱</sup> در چهار جهت و سه مقیاس (۱۲ ویژگی).

ویژگی‌های فوق موجب تشکیل ماتریس  $53 \times N$  می‌شود که در آن تعداد ابرپیکسل‌ها را نشان می‌دهد.

پنگ و همکاران در [۴] روش دیگری برای تجزیه ماتریس‌ها به منظور یافتن نواحی نقشه‌برجسته ابداع نموده‌اند. در ابتدا با توجه به روش SLIC تصویر را به ابرپیکسل تبدیل نمودند [۱۷]. سپس مشابه با روش زو و همکاران [۱۵] از هر ابرپیکسل ۵۳ ویژگی تشکیل شد و ماتریس  $F$  با ابعاد  $53 \times N$  (تعداد ابرپیکسل هاست) تشکیل شد. پنگ و همکاران در این مقاله سعی دارند مشابه با مقاله [۱۵] سه نوع اطلاعات ماتریس با رتبه پایین، اطلاعات مربوط به همسایگی و اطلاعات اولیه مربوط به نقشه‌برجستگی را به نوعی باهم ترکیب نمایند. آنها از رابطه ۱ برای انجام آن بهره گرفتند؛ در این مقاله  $F$  با استفاده از تجزیه ماتریسی به نحوی به  $L$  (ماتریس مرتبه پایین) و  $S$  (ماتریس پراکنده) شکسته می‌شود که رابطه زیر کمینه شود.

$$\min_{L,S} \Psi(L) + \alpha \Omega(S) + \beta \theta(L,S) \quad (1)$$

$$s.t. \quad F = L + S$$

در این رابطه  $\Psi$  نشان دهنده رتبه ماتریس  $L$  است [۱۸].  $\theta$  یا به عبارتی تنظیم لاپلاسی<sup>۲</sup> از رابطه ۲ به دست می‌آید.

$$\theta(L,S) = \frac{1}{2} \sum_{i,j} \|s_i - s_j\|_2^2 w_{ij} \quad (2)$$

مقدار  $w_{ij}$  شباهت دو ناحیه همسایه را نشان می‌دهد. هرچه شباهت بیشتر باشد میزان آن بیشتر است. اگر این دو ناحیه همسایه در فرآیند تجزیه در دو قسمت متمایز قرار گیرند باعث می‌شود با توجه به رابطه ۲ مقدار جریمه‌ای از طریق  $\theta$  به سیستم اعمال شود.

یک ساختار درختی در بردارنده اطلاعات اولیه‌ای از میزان نقشه‌برجستگی نواحی، به مساله، از طریق پارامتر تنظیم  $\Omega$  در رابطه ۱، اضافه شده است. این سه نوع اطلاعات نقشه‌برجستگی عبارتند از: مکان، رنگ و اتصال با حاشیه تصویر که با الهام از [۱۶] و [۱۹] به دست آمده‌اند. برای هر ابرپیکسل  $i$ ، این سه مقدار درهم ضرب می‌شوند و پارامتری به نام  $\pi_i$  را تشکیل می‌دهند که احتمال نقشه‌برجستگی این ابرپیکسل را نشان می‌دهد و مقداری بین صفر و یک دارد. با توجه به الگوریتم ارائه شده در [۲۰] یک ساختار سلسله مراتبی یا درخت ایجاد می‌شود. شکل ۱ درخت فرضی حاصل از این الگوریتم را نشان

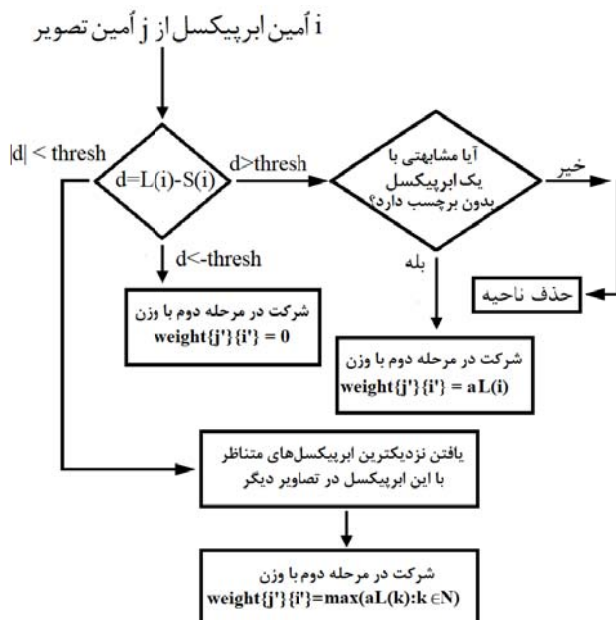
<sup>3</sup> Steerable pyramid filter

<sup>4</sup> Laplacian regularization

<sup>5</sup> Alternating direction method

#### ۴-۱ برچسب‌گذاری ابرپیکسل‌ها

شکل ۲ فلوجارت پیشنهادی برای یافتن وزن جدید برای ابرپیکسل‌ها را نشان می‌دهد. همان‌طور که در بخش (۳) مطرح شد، پس از اجرای الگوریتم SMD بر روی هر تصویر، ردیف متناظر با هر ابرپیکسل در ماتریس ویژگی  $F$  به دو بردار  $L$  و  $S$  تفکیک می‌شود که به ترتیب نشان‌دهنده تعلق آن ابرپیکسل به ماتریس با رتبه کم (زمینه) و ماتریس پراکنده (پیش‌زمینه) است. اندازه این دو بردار برای هر ابرپیکسل بین صفر و یک است. در الگوریتم پیشنهادی اختلاف بین دو مقدار  $L$  و  $S$  به عنوان معیاری برای دسته‌بندی ابرپیکسل‌ها در نظر گرفته شده است. اگر این اختلاف که  $d$  نامیده شده است از حد آستانه‌ای بیشتر باشد ابرپیکسل متعلق به زمینه است، اگر قدر مطلق آن از حد آستانه بیشتر باشد پیش‌زمینه است؛ در غیر این صورت به این ابرپیکسل برچسب نامعین زده می‌شود تا با استفاده از اطلاعات موجود در تصاویر دیگر تعیین برچسب شود.



شکل ۲ فلوجارت ساخت درخت جدید و نحوه وزن دهی به ابرپیکسل‌ها. ابرپیکسل در مرحله دوم اندیس جدیدی می‌یابد. لذا با  $i'$  و  $j'$  نمایش داده شده است.

#### ۴-۲ یافتن مشابه‌ترین ابرپیکسل و وزن دهی

شکل ۳ خروجی روش SMD را با توجه به تقسیم‌بندی صورت گرفته نشان می‌دهد. رنگ خاکستری در ستون سوم، ابرپیکسل با وضعیت نامعین را نشان می‌دهد. همان‌طور که در ستون چهارم ملاحظه می‌شود برای برچسب‌گذاری هر ابرپیکسل نامعین، شباهت آن با تمام ابرپیکسل‌های تصاویر دیگر سنجیده می‌شود. رابطه ۶ مجموعه‌ی  $\text{sim}_{\text{sup}}$  را نشان می‌دهد که شبیه‌ترین ابرپیکسل‌ها از هر تصویر به ابرپیکسل نامعین  $i_j$  در آن گردآوری شده است.  $i$  نشان‌دهنده شماره ابرپیکسل در تصویر  $Z$  است.

در روش‌های مرسوم که از نقشه‌برجستگی برای هم‌بخش‌بندی استفاده می‌شود، تنها یک روش برای رتبه‌بندی اولیه استفاده می‌شود اما مقاله [۲۳] سعی دارد روش‌های مختلف نقشه‌برجستگی را باهم ترکیب نماید تا از طریق آن به یک هم‌بخش‌بندی مناسب دست یابد. این ترکیب از طریق یافتن وزن‌های مناسب برای هر بخش‌بندی به دست می‌آید.

ظهور روش‌های عمیق تاثیر شگرفی در روش‌های شناسایی ایجاد نموده است. تسای و همکاران از شبکه عصبی کانولوشنی به عنوان یک روش استخراج ویژگی استفاده نموده‌اند [۲۴]. آنها سعی نموده‌اند تا هم‌بخش‌بندی و هم‌برجستگی را با استفاده یک تابع بهینه‌سازی و به صورت تکرار شونده بهبود دهند.

#### ۴ روش پیشنهادی

روش ارایه شده در [۴] که به صورت خلاصه SMD نام گرفته است، نتایج خوبی در یافتن نقاط برجسته به دست آورد. آنها در فرآیند تجزیه ماتریسی، اطلاعات مربوط به همسایگی و درخت سلسله مراتبی را گنجانده‌اند تا ضعف روش تجزیه که در آن اطلاعات همسایگی وجود ندارد برطرف شده باشد. با الهام از مقاله [۲۲] که یک روش تجزیه ماتریسی سلسله مراتبی را ابداع نموده است تلاش نمودیم تا روش پنگ و همکارانش [۴] را برای یافتن هم‌بخش‌بندی به صورت سلسله مراتبی توسعه دهیم. مراحل الگوریتم پیشنهادی به شرح ذیل است:

**گام اول:** اجرای الگوریتم SMD بر روی تمام تصاویر برای استخراج نقشه‌برجستگی اولیه.

**گام دوم:** برچسب‌گذاری ابرپیکسل‌ها به سه دسته زمینه، پیش‌زمینه و نامعین با توجه به یک مقدار آستانه

**گام سوم:** یافتن مشابه‌ترین ابرپیکسل در هر تصویر برای یک ابرپیکسل با برچسب نامعین و یافتن وزن مناسب برای ابرپیکسل‌های شرکت‌کننده در مرحله دوم SMD.

**گام چهارم:** ایجاد ماتریس و درخت همسایگی جدید بر اساس شباهت بین ابرپیکسل‌های تصاویر.

**گام پنجم:** اجرای دوباره SMD بر روی داده‌های جدید. در روش دو مرحله‌ای پیشنهادی، در مرحله اول که مشابه روش SMD است بردارهای ابرپیکسل‌های نقشه‌برجسته در ماتریس پراکنده وزن بیشتری دارند و اجزای زمینه در ماتریس با رتبه کم. در فرآیند الگوریتم، ابرپیکسل‌هایی که با اطمینان بالا، زمینه خوشه‌بندی شده‌اند حذف می‌شوند و در مرحله بعد تمام ابرپیکسل‌های باقی مانده از تمام تصاویر در معرض تجزیه قرار می‌گیرد. در این مرحله به علت کثرت ابرپیکسل‌های باقی مانده از قسمت نقشه‌برجسته تصویر، اعمال روش تجزیه ماتریسی باعث قرار گرفتن ابرپیکسل‌های نقشه‌برجسته در ماتریس با مرتبه کم خواهد شد. از این رو باید وزن‌ها در درخت جدید، متناسب با آن در نظر گرفته شود.

### ۴-۳ ماتریس و درخت همسایگی

هدف ماتریس همسایگی ایجاد پیوستگی در بخش بندی است که با نماد  $\theta$  در تابع هدف نام گذاری شده است (رابطه ۱). با در نظر گرفتن این ماتریس جریمه‌ای برای تفکیک دو ناحیه همسایه هم‌رنگ در یک تصویر در نظر گرفته می‌شود. این ماتریس در مرحله دوم اجرای SMD هم شرکت دارد؛ اما تعدادی از ابرپیکسل‌های زمینه حذف شده‌اند، بنابراین گرهی با شماره اندیس صفر در نظر گرفته شد تا جایگزین این اتصال باشد. به عبارت دیگر ابرپیکسل نامعین، در صورت اتصال با ابرپیکسل حذف شده، با همان وزن در مرحله دوم به این گره وصل می‌شود. برچسب این گره همواره زمینه است.

هدف درخت همسایگی در مقاله [۴] اضافه نمودن اطلاعات همسایگی در فرآیند تجزیه ماتریسی است. در مرحله دوم تجزیه ماتریسی سعی کردیم ابرپیکسل‌های مشابه در تصاویر مختلف در خوشه‌های یکسان در این درخت قرار گیرند تا از اطلاعات مشابهت بین تصویری یا به عبارتی بخش بندی هم‌زمان در فرآیند تجزیه دوم بهره‌برداری شود.

هر ابرپیکسل نامعین به مشابه‌ترین ابرپیکسل در تمام تصاویر دیگر متصل است. وزن این اتصال برابر میزان مشابهت بین این دو و عددی بین صفر و یک است. با استفاده از الگوریتم ارایه شده در مقاله [۲۰] خوشه بندی در سه سطح انجام می‌شود. پس از ایجاد درخت و خوشه بندی ابرپیکسل‌ها، مشابه با رابطه ۳ وزن هر خوشه به دست می‌آید. هرچه وزن ابرپیکسل‌های یک خوشه یا  $L(r_j^i)$  بالاتر باشد تمایل خوشه به زمینه بیشتر می‌شود پس  $V_j^i$  تناظر با خوشه کمتر می‌شود و در نتیجه کل خوشه تمایل بیشتری دارد تا در ماتریس S شرکت نماید.


در مرحله انتهایی پس از ایجاد ماتریس و درخت همسایگی SMD برای بار دوم اجرا می‌شود و ابرپیکسل‌های نامعین تعیین برچسب می‌شوند. روش پیشنهادی این مقاله را CoSMD نام نهادیم. روش پیشنهادی محدودیتی بر روی تعداد تصویر ورودی ندارد. برای پیاده‌سازی روش SMD و توسعه آن از کدی که نویسندگان مقاله [۴] انتشار داده‌اند و در دسترس محققین قرار دارد استفاده شد.

### ۵ نتایج پیاده‌سازی

برای ارزیابی روش پیشنهادی از مجموعه تصاویر پایگاه داده iCoseg که به همین منظور ایجاد شده است استفاده شد [۲۵]. این مجموعه در بردارنده ۳۸ گروه تصویر است که جمعا ۶۴۳ تصویر دارد. مشابه مقاله [۲۶] ده گروه از تصاویر این مجموعه برای ارزیابی مورد استفاده قرار گرفت که اطلاعات آن در جدول (۱) آمده است.

$$\text{sim sup}(r_j^i) = \{r_j^{i'} | j'' \in I_1, \dots, I_n, j'' \notin I_j\} \quad (6)$$

در روش [۴] ضرب سه معیار نقشه‌برجستگی اولیه در هم، مقدار  $\pi$  را برای هر ابرپیکسل تشکیل می‌دهد. وزن هر ابرپیکسل در لایه اول درخت برابر  $1 - \pi$  قرار گرفت. به عبارتی هر چه ابرپیکسل از منظر روش‌های پایه تعلق بیشتری به نواحی نقشه‌برجستگی داشته باشد دارای وزن کمتر می‌شود و این وزن کمتر اثر  $\|S\|$  را کاهش می‌دهد. از آنجا که در به کارگیری مجدد SMD نواحی زمینه در ماتریس پراکندگی S قرار می‌گیرند؛ پس موضوع معکوس می‌شود و  $\pi$  باید تعلق به زمینه بودن را مدنظر قرار دهد.



شکل ۳ از راست به چپ: ستون اول: تصویر شی، ستون دوم: درست زمینه، ستون سوم: خروجی SMD و برچسب گذاری ابرپیکسل‌ها به سه دسته زمینه، پیش‌زمینه و نامعین (خاکستری)، ستون چهارم: ابرپیکسل‌های نامعین و مشابه‌ترین به آنها در تصاویر دیگر. ابرپیکسل مشابه می‌تواند از ناحیه زمینه، درست زمینه یا نامعین باشد.

آنچنان که در فلوجارت نشان داده شده است، در مرحله اول اجرای SMD ابرپیکسل‌ها به سه دسته تقسیم می‌شوند؛ مقدار  $\pi$  در نواحی که پیش‌زمینه برچسب خورده‌اند برابر ۰ در نظر گرفته می‌شود. وزن ابرپیکسلی که برچسب نامعین دارد متناسب با بیشینه مقدار L ابرپیکسل‌های مشابه آن در تصاویر دیگر قرار داده شد (رابطه ۷).

$$\pi(r_j^i) = \max\{aL(r_j^{i'}) | j'' \in I_1, \dots, I_n, j'' \notin I_j\} \quad (7)$$
 ضریبی است که در دو حالت مورد بررسی قرار گرفت؛ یکبار مقدار آن ۱ در نظر گرفته شد و بار دیگر اندازه آن برابر میزان مشابهت بین این دو ابرپیکسل. اثرات این ضریب در بخش نتایج پیاده‌سازی بررسی شده است.

با توجه به روند در نظر گرفته شده در الگوریتم انتظار این است که ابرپیکسل‌های با برچسب زمینه از گردونه محاسبات حذف شوند. این حذف اتفاق خواهد افتاد مگر حالتی که ابرپیکسل با برچسب زمینه نزدیک‌ترین همسایه ابرپیکسل با برچسب نامعین قرار گیرد. در این حالت این ابرپیکسل با وزن  $\pi(r_j^i) = aL(r_j^i)$  در ادامه کار شرکت خواهد نمود.

جدول ۲ میزان معیار MAE برای روش‌های مختلف

شماره گروه	SMD	روش پیشنهادی با مقدار a برابر		روش پیشنهادی با مقدار a برابر	مشابهت بین دو ابرپیکسل
		d=0,2	d=0,4		
۱	۰,۱۶۶۴	۰,۱۶۱۵	۰,۱۹۵۳	۰,۱۶۲۹	۰,۱۹۵۲
۲	۰,۰۶۵۱	۰,۰۴۹۷	۰,۰۶۳۸	۰,۰۷۴۲	۰,۱۰۳۶
۳	۰,۰۹۶۲	۰,۰۸۰۸	۰,۰۸۰۸	۰,۰۸۶۶	۰,۰۹۲۵
۴	۰,۱۱۳۸	۰,۰۷۹۹	۰,۰۸۵۲	۰,۰۸۸۴	۰,۰۹۷۹
۵	۰,۱۶۱۶	۰,۱۴۲۵	۰,۱۴۲۱	۰,۱۹۲۹	۰,۲۲۴۲
۶	۰,۰۱۹۱	۰,۰۱۴۹	۰,۰۱۵۸	۰,۰۱۴۸	۰,۰۱۴۵
۷	۰,۰۳۳۸	۰,۰۱۹۷	۰,۰۲۲۳	۰,۰۲۱۲	۰,۰۲۲۹
۸	۰,۲۶۲۶	۰,۲۲۲۹	۰,۲۱۵۱	۰,۲۲۴۹	۰,۱۹۴۵
۹	۰,۲۰۳۵	۰,۱۶۳۵	۰,۱۵۹۲	۰,۱۶۵	۰,۱۶۲۹
۱۰	۰,۱۵۸	۰,۱۰۰۴	۰,۱۲۹۱	۰,۱۱۴۵	۰,۱۴۱۵
میانگین	۰,۱۲۸	۰,۱۰۳۶	۰,۱۱۰۹	۰,۱۱۴۵	۰,۱۲۵

حالت دیگری در نظر گرفته شده است که به جای یک

نزدیکترین ابرپیکسل در تصویر دیگر، دو نزدیکترین ابرپیکسل از هر تصویر دیگر انتخاب شد که نتایج آن در جدول (۳) آمده است. در برخی موارد بهبود ناچیزی ایجاد شده است که در مجموع قابل توجه نیست.

جدول ۳ میزان معیار MAE برای روش‌های مختلف با در نظر گرفتن دو نزدیکترین همسایه در تصاویر دیگر.

شماره گروه	SMD	روش پیشنهادی با مقدار a برابر		روش پیشنهادی با مقدار a برابر	مشابهت بین دو ابرپیکسل
		d=0,2	d=0,4		
۱	۰,۱۶۶۴	۰,۱۶۳۱	۰,۱۹۲۸	۰,۱۶۲۹	۰,۱۹۵۲
۲	۰,۰۶۵۱	۰,۰۴۱۸	۰,۰۴۹۲	۰,۰۷۴۲	۰,۱۰۳۶
۳	۰,۰۹۶۲	۰,۰۷۹۵	۰,۰۸۰۳	۰,۰۸۶۶	۰,۰۹۲۵
۴	۰,۱۱۳۸	۰,۰۷۹۸	۰,۰۸۴۷	۰,۰۸۸۴	۰,۰۹۷۹
۵	۰,۱۶۱۶	۰,۱۴۳۴	۰,۱۴۶۶	۰,۱۹۲۹	۰,۲۲۴۲
۶	۰,۰۱۹۱	۰,۰۱۴۹	۰,۰۱۵۱	۰,۰۱۴۸	۰,۰۱۴۵
۷	۰,۰۳۳۸	۰,۰۱۹۵	۰,۰۲۲۲	۰,۰۲۱۲	۰,۰۲۲۶
۸	۰,۲۶۲۶	۰,۲۱۹۴	۰,۲۰۸۸	۰,۲۲۳۷	۰,۲۰۰۴
۹	۰,۲۰۳۵	۰,۱۶۴	۰,۱۶۰۲	۰,۱۶۳۹	۰,۱۶۱۳
۱۰	۰,۱۵۸	۰,۱۰۸۹	۰,۱۳۲۷	۰,۱۰۹۷	۰,۱۳۶۳
میانگین	۰,۱۲۸	۰,۱۰۳۴	۰,۱۰۹۳	۰,۱۱۳۸	۰,۱۲۴۹

جدول (۴) نتایج معیار OR را با استفاده از روش‌های

مختلف نشان می‌دهد. همان‌طور که ملاحظه می‌شود روش پیشنهادی با  $a=1$  و اولین همسایه بهترین میانگین را داراست. روش ADLRR توسط لی و همکاران ابداع شد [۲۶]: این روش نیز از تجزیه ماتریسی استفاده می‌کند. تسای و همکاران نتایج حاصل از اعمال رهیافت خود را به صورت کلی ارایه نموده‌اند [۲۴]. برای مقایسه با روش آنها، مدل پیشنهادی را بر روی تمام گروه‌های مجموعه داده iCoseg اعمال کردیم که نتایج

جدول ۱ مشخصات گروه‌های مورد استفاده از پایگاه داده iCoseg

شماره	نام کلاس	تعداد تصاویر	شماره	نام کلاس	تعداد تصاویر
۱	Baseball	۲۵	۶	Skating	۱۱
۲	Football	۳۳	۷	Alaskan bear	۱۹
۳	Monk	۱۷	۸	Taj Mahal	۵
۴	Brown bear	۵	۹	Helicopter	۱۲
۵	Ferrari	۱۱	۱۰	Kite	۱۸

برای ارزیابی دو معیار پرکاربرد MAE و OR، مدنظر قرار

گرفت. معیار MAE از رابطه زیر محاسبه می‌شود:

$$MAE = \text{mean}|S - G| \quad (10)$$

در رابطه بالا  $G$  زمینه و  $S$  خروجی الگوریتم‌های مختلف است. MAE میانگین اختلاف پیکسل‌ها با زمینه است و هر چه به صفر نزدیک‌تر باشد بهتر است. معیار OR از رابطه زیر محاسبه می‌شود:

$$OR = \frac{|S' \cap G|}{|S \cup G|} \quad (11)$$

این معیار


$$S' = S > \text{mean}(S) \times 2$$

نسبت هم‌پوشانی نام دارد و  $S'$  باینری شده مقدار  $S$  است که با استفاده از یک آستانه به دست می‌آید. این معیار هرچه بیشتر باشد بهتر است. نام دیگر معیار OR اندیس جاکاردا<sup>۱</sup> یا نسبت "IoU"<sup>۲</sup> است. مقاله [۲۴] توضیحات جامعی در این خصوص ارایه داده است.

جدول ۲ نتایج معیار MAE را برای گروه‌های ده گانه مدنظر نشان می‌دهد. روش SMD خروجی مقاله [۴] را نشان می‌دهد. در رابطه ۷ که مخصوص محاسبه وزن ابرپیکسل است، ضریب  $a$  قرار دارد. این ضریب می‌تواند یک در نظر گرفته شود و یا میزان مشابهت ابرپیکسل با ابرپیکسل متناظر خود در تصویر دیگر باشد. هرچه آستانه  $d$  که در شکل ۲ و توضیحات مربوط به آن مطرح شد، بیشتر باشد تعداد ابرپیکسل با برجسب نامعین بیشتر می‌شود و بر پیچیدگی روش اضافه می‌کند. برای دو مقدار ۰,۲ و ۰,۴ دقت روش پیشنهادی بررسی گردید. همان‌طور که ملاحظه می‌شود روش پیشنهادی با  $d=0,2$  و  $a=1$  کمترین خطا را دارد.

<sup>1</sup> Jaccard index

<sup>2</sup> Intersection to the union



شکل ۴ خروجی روش پیشنهادی، از هر گروه یک تصویر نشان داده شده است.

جدول (۶) زمان لازم برای اجرای الگوریتم را بر روی یک سیستم با پردازنده Corei3 نشان می‌دهد. علاوه بر زمان با توجه به مقدار  $d$ ، متوسط تعداد ابرپیکسل نامعین در هر فریم آمده است. با نگاهی به ستون سوم جدول (۶) و ستون سوم جدول (۲) به نظر می‌رسد همبستگی بین دقت و تعداد ابرپیکسل با برچسب نامعین وجود داشته باشد.

آن در جدول (۵) آمده است. همان‌طور که ملاحظه می‌شود روش پیشنهادی نتایج قابل قبولی نسبت به رهیافت [۲۴] به دست داده است. شایان ذکر است تسای و همکاران از ویژگی‌های استخراج شده از شبکه‌های عصبی کانولوشنی بهره برده‌اند و از تکنیک‌های متنوع‌تری برای یافتن اطلاعات اولیه نقشه‌برجستگی استفاده می‌نمایند که مدل ارایه شده را پیچیده‌تر می‌کند

جدول ۴ میزان معیار OR برای روش‌های مختلف، آستانه  $d=0,2$  برای روش پیشنهادی مورد استفاده قرار گرفته است.

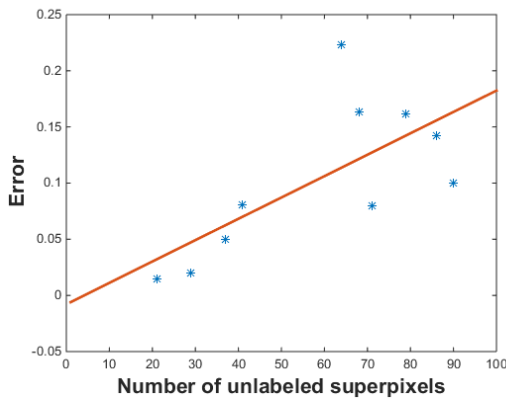
روش پیشنهادی با $a=1$ و دو اولین همسایه	روش پیشنهادی با $a=1$ اولین همسایه	ADLRR ۲۰۱۶	SMD	شماره گروه
۰,۵۳۱۵	۰,۵۳۴۱	۰,۵۲۱	۰,۶۱۳۲	۱
۰,۷۱۲۱	۰,۶۹۴۱	۰,۶۸۳	۰,۷۳۷۳	۲
۰,۵۲۱۸	۰,۵۲۵۹	۰,۳۸۶	۰,۵۳۱۵	۳
۰,۶۹۳۲	۰,۶۹۴۸	۰,۵۹۹	۰,۶۵۵۴	۴
۰,۵۶۲۶	۰,۵۶۴۸	۰,۶۴۳	۰,۵۸۵۱	۵
۰,۸۰۵۴	۰,۸۰۵۴	۰,۵۳۳	۰,۷۹۷۲	۶
۰,۸۶۱۶	۰,۸۶۰۱	۰,۴۶۵	۰,۸۵۶۵	۷
۰,۴۸	۰,۴۵۹۸	۰,۵۶۶	۰,۴۵۴	۸
۰,۶۰۵۲	۰,۶۰۴۱	۰,۴۴۸	۰,۵۸۷۶	۹
۰,۴۷۳	۰,۶۴۷۴	۰,۴۲۱	۰,۵۰۵۱	۱۰
۰,۶۲۴۷	۰,۶۳۹۱	۰,۵۲۷	۰,۶۳۲۳	میانگین

جدول ۵ ارزیابی جامع بر روی iCoseg

OR	Accuracy	روش
۰,۷۲۳	۰,۹۰۸	[۲۴] Tsai18
۰,۶۱۶	۰,۸۸۵	روش پیشنهادی با $d=0,2$ و $a=1$

به منظور ارزیابی کیفی روش پیشنهادی، تعدادی از آنها در شکل ۴ نمایش داده شده‌اند. در برخی تصاویر الگوریتم پیشنهادی با عدم موفقیت همراه بوده است که برخی از آنها در شکل ۵ نشان داده شده‌اند. از آنجا که یکی از روش‌های استخراج نقشه‌برجستگی به دور بودن ابرپیکسل‌ها از حاشیه تصویر است. از این رو در تصاویری که ناحیه نقشه‌برجسته با حاشیه تصویر متصل است نتایج مطلوبی حاصل نشده است. از سوی دیگر لباس بلند راهب باعث شده است نواحی مشابه زیادی ایجاد شود و تعداد زیاد آنها موجب قرار گرفتن در ماتریس با رتبه کم شده است.





شکل ۶ همبستگی بین متوسط تعداد ابرپیکسل نامعین در هر گروه و خطا.

## ۶ جمع بندی

با توجه به پیشرفت روزافزون بشری و فراهم آمدن امکانات تصویربرداری، حجم عظیمی از تصاویر ایجاد شده است که پردازش دستی آنها امکان پذیر نیست. هم‌بخش بندی یکی از تکنیک‌هایی است که می‌تواند در راستای استخراج خودکار اطلاعات از تصاویر به ما کمک کند. در کنار هم‌بخش بندی تکنیک استخراج نقشه برجستگی هم‌زمان هم وجود دارد که هدف آن یافتن اطلاعات مهم مشابه در چند تصویر است. هم‌بخش بندی مشابهت زیادی با نقشه برجستگی هم‌زمان دارد اما تفاوت‌هایی هم با آن دارد؛ ممکن است ناحیه مشترک بین دو تصویر جزو نواحی برجسته نباشد. خروجی هم‌بخش بندی معمولاً صفر و یک است اما در نقشه برجسته معمولاً خروجی در بازه صفر و یک است. اما با این وجود ارتباط تنگاتنگی بین آن دو وجود دارد و در بالا بردن کیفیت استخراج اطلاعات به هم کمک می‌کنند.

روش‌های اخیر از ابرپیکسل برای قطعه‌بندی اولیه تصویر استفاده نموده‌اند. اجرا در سطح پیکسل زمان را بالا می‌آورد در شرایطی که اطلاعات در سطح پیکسل چندان مفهوم نیست و همراه با نویز است.

اطلاعات همسایگی بین ابرپیکسل‌ها در روش‌های مختلف باید مورد توجه گیرد. روش‌های تجزیه ماتریسی به مرتبه پایین و پراکنده این اطلاعات را در حالت پایه در خود ندارد. روش SMD درختی می‌سازد و این اطلاعات را در آن قرار می‌دهد و در فرآیند تجزیه از آن بهره می‌گیرد. با توجه به این قابلیت در روش پیشنهادی در دو مرحله از این تکنیک استفاده شده است. در مرحله اول و بر روی تک‌تک تصاویر روش تجزیه ماتریسی SMD انجام شد. در این مرحله تعداد زیاد نواحی زمینه ایجاد می‌شود که در فرآیند تجزیه در ماتریس با رتبه کم قرار گرفت. با اطلاعات به دست آمده از این مرحله ابرپیکسل‌ها به سه دسته زمینه، نقشه برجسته و نامعین تقسیم شدند. در مرحله دوم با استفاده از تجمیع اطلاعات مشترک بین تصاویر در درخت همسایگی سعی شده است ابرپیکسل‌ها با برجسته نامعین به

جدول ۶ زمان اجرا برحسب ثانیه

زمان برای پردازش هر فریم به ثانیه	متوسط تعداد ابرپیکسل نامعین در هر فریم	تعداد تصاویر	شماره گروه	گام اول	گام دوم
				SMD	d=۰,۲
۱,۴	۱,۱	۷۹	۱۹	۱	۱,۴
۰,۸	۰,۷	۳۷	۲۵	۲	۰,۸
۱,۱	۱	۴۱	۳۳	۳	۱,۱
۰,۷	۰,۶	۷۱	۱۱	۴	۰,۷
۰,۶	۰,۵	۸۶	۵	۵	۰,۶
۰,۳	۰,۳	۲۱	۱۲	۶	۰,۳
۰,۵	۰,۵	۲۹	۱۸	۷	۰,۵
۰,۷	۰,۶	۶۴	۱۱	۸	۰,۷
۱	۰,۸	۶۸	۱۷	۹	۱
۰,۷	۰,۶	۹۰	۵	۱۰	۰,۷

هدف از ترسیم نمودار شکل ۶ بررسی میزان همبستگی بین متوسط تعداد ابرپیکسل نامعین و خطاست. همان‌طور که انتظار می‌رود این دو کمیت به هم وابستگی دارند. از این طریق می‌توان پیچیدگی ساختار تصاویر ورودی را هم ارزیابی نمود و بر اساس آن پارامترها را در یک فرآیند یادگیرنده به نحوی تنظیم نمود که دقت بر اساس آن افزایش یابد.



شکل ۵ برخی از تصاویری که روش پیشنهادی در هم‌بخش بندی نتیجه مطلوب به دست نیاورده است.

- [5] Joulin, A., Bach, F., Ponce, J., *Discriminative clustering for image cosegmentation*, Computer Vision and Pattern Recognition, 2010.
- [6] Joulin, A., Bach, F., Ponce, J., *Multi-class cosegmentation*, Computer Vision and Pattern Recognition, 2012.
- [7] Rubio, J. C., Serrat, J., Lopez, A., Paragios, N., *Unsupervised co-segmentation through region matching*, Computer Vision and Pattern Recognition, 2012.
- [8] Li, H., Ngan, K. N., *A co-saliency model of image pairs*, IEEE Trans. on image processing, vol. 20, no. 12, pp. 3365-3375, 2011.
- [9] Li, H., Meng, F., Ngan, K. N., *Co-salinet object detection from multiple images*, IEEE Trans. on Image Processing, vol. 15, no. 8, pp. 1896-1909, 2013.
- [10] Jeh, G., Widom, J., *SimRank: a measure of structured-context similarities*, eighth ACM SIGKDD international conference on Knowledge discovery and data mining, pp. 538-543, 2002.
- [11] Meng, F., Li, H., Liu, G., Ngan, K. N., *Object cosegmentation based on shortest path algorithm and saliency model*, IEEE Trans on Multimedia, vol. 14, no. 5, pp. 1429-1441, 2012.
- [12] Dai, J., Wu, Y. N., Zhou, J., Zhu, S.-C., *Cosegmentation and cosketch by unsupervised learning*, ICCV, 2013.
- [13] Tao, W., Li, K., Sun, K., *SaCoseg: object cosegmentation by shape conformability*, IEEE Trans. on Image Processing, vol. 24, no. 3, pp. 943-955, 2015.
- [14] Zhang, D., Fu, H., Han, J., Borji, A., *A Review of Cosaliency Detection Technique: Fundamentals, Applications, and Challenges*, archive:1604.07090v4, 2017.
- [15] Zou, W., Kpalma, K., Liu, Z., Ronsin, J., *Segmentation driven low-rank matrix recovery for saliency detection*, BMVC, 2013.
- [16] Shen, X., Wu, Y., *A Unified Approach to Salient Object Detection via Low Rank Matrix Recovery*, CVPR, 2012.
- [17] Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Susstrunk, S., *SLIC Superpixels Compared to State-of-the-Art Superpixel Methods*, IEEE Trans on PAMI, vol. 34, no. 11, p. 2274-2282, 2012.
- [18] Zhang, Z., Xu, Y., Yang, J., Li, X., Zhang, D., *A Survey of Sparse Representation: Algorithms and Applications*, IEEE Access, 2015.
- [19] Zhu, W., Liang, S., Wei, Y., Sun, J., *Saliency Optimization from Robust Background Detection*, CVPR, 2014, pp. 2814-2821.
- [20] Felzenszwalb, P. F., Huttenlocher, D. P. *Efficient graph-based image segmentation*, IJCV, vol. 59, no. 2, p. 167-181, 2004.

زمینه یا پیش‌زمینه دسته‌بندی شوند. در مرحله دوم ابرپیکسل‌های زمینه حضور ندارند و کثرت ابرپیکسل‌های پیش‌زمینه موجب می‌شود تا آنها در ماتریس با رتبه کم قرار گیرند. همان‌طور که نتایج نشان می‌دهد بهبودی قابل توجهی در نتایج نسبت به روشی که تنها از یک تصویر استفاده می‌کند و روش‌های دیگر ایجاد شده است.

## ۷ پیشنهادات

در زیر چهار پیشنهاد برای بهبود روش پیشنهادی ارائه شده است.

در مقالات محدودی از اطلاعات ساختاری به طور محدود استفاده شده است، اما در روش‌های مبتنی بر تجزیه ماتریس از این اطلاعات تا کنون استفاده نشده است. به کارگیری آنها در قالب یک تنظیم‌کننده در یک رابطه و فرمول‌بندی برای کمینه سازی آن می‌تواند مفید باشد.

تاری می‌تواند عامل مهمی در یافتن ناحیه برجسته باشد اما در روش پیشنهادی و مقالات مرجعی که از تجزیه ماتریسی استفاده نموده‌اند تنها از ویژگی‌های دوری از مرکز، اتصال به کناره تصویر و حساسیت رنگی چشم به عنوان روش‌های استخراج اولیه برجستگی استفاده شده است. اطلاعات دیگر نظیر تاری می‌تواند منجر به بهبودی نتایج شود.

جسم مشترک در بین چند تصویر دارای ابرپیکسل‌هایی است که با نظمی در کنار هم قرار گرفته‌اند. نمایش این نظم می‌تواند با استفاده از یک میدان تصادفی شرطی صورت پذیرد که ارتباط بین ابرپیکسل‌ها را به صورت آماری نشان می‌دهد. ادغام این اطلاعات در روش‌های موجود ارزنده است.

اخیرا در برخی مقالات از شبکه‌های از پیش آموزش دیده شده کانولوشنی عمیق برای استخراج ویژگی استفاده نموده‌اند. بررسی این موضوع و به کارگیری آنها در هم‌بخش‌بندی می‌تواند موثر باشد.

## مراجع

- [1] Malekijoo, A., Fadaeieslam, M. J., *Convolution-deconvolution architecture with the pyramid pooling module for semantic segmentation*, Multimedia Tools and Applications, vol. 78, no. 22, pp. 32379-32392, 2019.
- [2] Rother, C., Kolmogorov, V., Minka, T., Blake, A., *Cosegmentation of image pairs by histogram matching - incorporating a global constraint into MRFs*, Computer Vision and Pattern Recognition, 2006.
- [3] Hochbaum, D. S., Singh, V., *An efficient algorithm for co-segmentation*, International Conference on Computer Vision, 2009.
- [4] Peng, H., Li, B., Ling, H., Hu, W., Xiong, W., Maybank, S. J., *Salient object detection via structured matrix decomposition*, IEEE Trans. on PAMI, vol. 39, no. 4, pp. 818-832, 2016.



محمدجواد فدائی اسلام مدرک کارشناسی ارشد و دکترای خود را در رشته مهندسی کامپیوتر گرایش هوش مصنوعی در سال‌های ۱۳۸۴ و ۱۳۹۱ از دانشگاه علم و صنعت ایران دریافت کرد. از سال ۱۳۹۲ به عضویت هیئت علمی دانشگاه سمنان در آمد. زمینه‌های تحقیقاتی مورد علاقه ایشان پردازش تصویر و متن، پردازش ویدئو، شناسایی آماری الگو و یادگیری عمیق است.

- [21] Tang, C., Wu, J., Wang, P., Li, W., *Salient object detection via weighted low rank matrix recovery*, IEEE Signal Processing Letters, vol. 24, no. 4, pp. 490 - 494, 2016.
- [22] Chen, H., Wang, P., Liu, M., *From cosaliency detection to object cosegmentation: A unified multistage low rank matrix recovery approach*, IEEE conf. on robotics and biometrics, 2015.
- [23] Jerripothula, K. R., Cai, J., Yuan, J., *Image Co-segmentation via saliency co-fusion*, IEEE Trans. on Multimedia, vol. 18, no. 9, pp.1896-1909, 2016.
- [24] Tsai, C., Li, W., Hsu, K., Qian, X., Lin, Y., *Image co-saliency detection and co-segmentation via progressive joint optimization*, IEEE Trans. on Image Processing, vol. 28, no. 1, pp.56-71, 2019.
- [25] Batra, D., Kowdle, A., Parikh, D., Chen, T., *icoseg: Interactive co-segmentation with intelligent scribble guidance*, CVPR, 2010.
- [26] Li, Y., Liu, J., Li, Z., Lu, H., Ma, S., *Object co-segmentation via salient and common regions discovery*, Neurocomputing, vol. 172, pp.225-234, 2016.