

فرا تفکیک پذیری تصویر با انتخاب حوزه‌ی تنک مبتنی بر پایه‌ی گروه به شکل و فقی

الهامه میکاییلی^۱ علی آقاگل زاده^۲ معصومه آذغانی^۳

۱- دانشجوی دکتری- دانشکده مهندسی برق و کامپیوتر- گروه مخابرات- دانشگاه صنعتی نوشیروانی بابل- بابل- ایران
e.mikaiili@stu.nit.ac.ir

۲- استاد- دانشکده مهندسی برق و کامپیوتر- گروه مخابرات- دانشگاه صنعتی نوشیروانی بابل- بابل- ایران
aghagol@nit.ac.ir

۳- استادیار- دانشکده مهندسی برق- گروه مخابرات- دانشگاه صنعتی سهند- تبریز- ایران
mazghani@sut.ac.ir

چکیده: همواری محلی و خودشباهتی غیرمحلی، دو تا از مهم‌ترین پیش فرض‌ها برای حل مساله فرا تفکیک پذیری تصویر می‌باشند. با وجود اینکه نمایش تنک به خوبی برای توصیف همواری محلی در تصویرهای طبیعی استفاده می‌شود، نادیده گرفتن همبستگی بین ضرایب نمایش تنک بلوک‌های مشابه هم می‌تواند منجر به ضرایب تنک غیر دقیق گردد. در این مقاله مدلی برای نمایش تنک بلوک‌ها پیشنهاد می‌کنیم که از تلفیق همواری محلی و خودشباهتی غیرمحلی در یک چارچوب یکپارچه به دست می‌آید. این مدل، انتخاب حوزه‌ی تنک مبتنی بر پایه‌ی گروه به شکل و فقی نامیده می‌شود. بلوک‌های غیرمحلی با ساختار مشابه به صورت ماتریس، به عنوان واحد پایه نمایش تنک، به نام گروه، استخراج می‌شوند. برای نمایش تنک این گروه‌ها، آنها را به بردارهای ستونی تبدیل کرده و هر ستون، بهترین واژه‌نامه‌ای را که از اعمال تبدیل PCA برای گروه‌های داده‌های آموزشی به دست آمده‌اند، انتخاب می‌کند. فرآیند نمایش تنک هر ستون در حوزه‌ی گروه به یافتن بردارهای تنکی منجر می‌شود که با انتخاب واژه‌نامه‌های متعامد می‌توانند به سادگی تخمین زده شوند. برای بهبود بیشتر کارایی نمایش تنک مبتنی بر گروه، از عبارت تنظیم غیرمحلی نیز استفاده می‌شود. نتایج آزمایشها بر روی تصویرهای آزمایشی استاندارد، برتری روش پیشنهادی را نسبت به برخی از مهم‌ترین روشهای متعارف با معیارهای PSNR و SSIM نشان می‌دهد.

واژه‌های کلیدی: فراتفکیک پذیری تصویر، نمایش تنک، خود شباهتی غیرمحلی، آموزش واژه‌نامه

تاریخ ارسال مقاله : ۱۳۹۷/۰۷/۹

تاریخ پذیرش مشروط مقاله: ۱۳۹۶/۱۰/۲۷

تاریخ پذیرش مقاله: ۱۳۹۸/۰۹/۳

نام نویسنده‌ی مسئول: دکتر علی آقاگل زاده

نشانی نویسنده‌ی مسئول: بابل- خیابان شریعتی- دانشگاه صنعتی نوشیروانی بابل

بارتکرار شود [۷]. این پیش‌فرض برای اولین بار به شکل بهینه‌ای با به‌کارگیری روش NLM^۱ در حذف نویز تصویر مورد استفاده قرار گرفت [۸] و به دنبال آن به‌کارگیری همبستگی‌های غیرمحملی در تصویرهای طبیعی منجر به نتایج چشمگیری در بازیابی تصویر و SISR گردیده است. اگرچه روش‌های مبتنی بر بازسازی می‌توانند لبه‌ها را به خوبی حفظ کرده و مانع ایجاد مصنوعات گردند، ولی جزئیات ظریف یعنی اطلاعات فرکانس بالا در آنها، به ویژه برای عوامل بزرگنمایی بزرگ، اغلب هموار شده و در نهایت منجر به تصویر HR غیرطبیعی می‌گردند.

روش‌های مبتنی بر آموزش نتایج چشمگیری را در سال‌های اخیر به دست آورده‌اند. این دسته از روش‌ها را می‌توان به سه گروه تقسیم بندی کرد: ۱- روش‌های مبتنی بر آموزش واژه‌نامه (DL^۲) ۲- روش‌های سریع مبتنی بر تعبیه همسایه ها (NE^۳) ۳- روش‌های مبتنی بر یادگیری عمیق.

با توجه به این حقیقت که تصویرهای طبیعی می‌توانند به وسیله اتم‌های یک واژه‌نامه به شکل تنک نمایش داده شوند، الگوریتم‌هایی برای آموزش واژه‌نامه و به‌دست آوردن نمایش متراکم زوج‌های بلوک LR-HR پیشنهاد شده است. ابتدا در [۹] روش فراتفکیک پذیری به‌وسیله نمایش تنک (SCSR^۴) پیشنهاد شد. در [۹] دو واژه‌نامه‌ی LR-HR بسیار-کامل آموزش داده می‌شود که اتم‌های آنها بلوک‌های تصویرهای آموزشی هستند. ضرایب تنک بلوک LR و بلوک HR معادل آن با نمایش تنک یکسان، فرض می‌شوند. در [۱۰] به جای به‌کارگیری بلوک‌های تصویرهای آموزشی به عنوان اتم‌های واژه‌نامه، واژه‌نامه‌ها با به‌کارگیری محدودیت تنکی آموزش داده می‌شوند. در سالهای اخیر روش‌های زیادی برای بهبود روش SCSR انجام گرفته است.

تجزیه تنک روی واژه‌نامه‌های بسیار-کامل به شکل بالقوه ناپایدار بوده و تمایل به تولید مصنوعات دیداری دارند. در مرجع [۱۱] یک روش SISR بر مبنای نمایش تنک با به‌کارگیری انتخاب حوزه‌ی تنک به شکل وفقی (ASDS^۵) و تنظیم‌کننده‌های وفقی پیشنهاد شده است. در فاز آموزش به منظور کدکردن ساختارهای محلی متفاوت تصویر، از الگوریتم خوشه‌بندی K-means بر روی مشخصات بلوک‌های آموزشی HR استفاده شده است. از آنجایی که هر خوشه شامل بلوک‌هایی با مشخصات مشابه است، آموزش واژه‌نامه‌ی فشرده به جای واژه‌نامه‌ی بسیار-کامل برای آن کفایت می‌کند. بنابراین توسط تبدیل PCA^{۱۱} برای هر خوشه یک واژه‌نامه‌ی فشرده آموزش داده می‌شود. برای افزایش کارایی روش پیشنهادی، مدل خود بازگشتی برای مشخص کردن ساختارهای محلی و عبارت تنظیم‌کننده NLM برای مدل کردن قید شباهت غیرمحملی استفاده شده است. مشابه [۱۱]، در [۱۲] نیز از خوشه بندی K-means و تبدیل PCA برای آموزش واژه‌نامه‌های بهینه برای هر خوشه استفاده شده است با این تفاوت که، از خود تصویر ورودی به جای تصویرهای آموزشی استفاده می‌کند. در [۱۲] عبارت تنظیم‌کننده‌ای بر مبنای مفهوم نویز رمزگذاری تنک (

بهبود کیفیت تصویر و افزایش فراتفکیک پذیری در بسیاری از کاربردها، نظیر تصویربرداری پزشکی و نظارت‌های ویدیویی مساله‌ی مهمی است [۲-۱]. مساله فراتفکیک پذیری تک تصویره (SISR^۱) یکی از مسائل مهم در پردازش تصویر و بینایی ماشین است. هدف این مساله، تخمین یک تصویر با تفکیک‌پذیری بالا (HR^۲) از روی یک تصویر معادل آن با تفکیک پذیری پایین (LR^۳) است به گونه‌ای که تصویر تخمین زده شده به تصویر اصلی نزدیک باشد. مساله SISR می‌تواند با رابطه (۱) مدل شود:

$$y = HDx + n \quad (1)$$

که در آن x تصویر اصلی، H ماتریس مات‌کنندگی، D ماتریس زیر-نمونه برداری و n نویز است. SISR یک مساله‌ی معکوس به شدت بدحالت است، چرا که تعداد پیکسل‌های تصویر هدف از تعداد پیکسل‌های تصویر ورودی بسیار بیشتر است. اولین روش‌ها برای حل این مساله، روش‌های درونیایی هستند [۳]. نتایج حاصل از این روش‌ها به دلیل لحاظ نکردن فرآیند تخریب تصویر، ماتی و زیر-نمونه برداری، مناسب نیست. موثرترین الگوریتم‌ها برای حل این مساله در حالت کلی، روش‌های مبتنی بر آموزش و روش‌های مبتنی بر بازسازی هستند [۴-۵].

روش‌های مبتنی بر بازسازی، بر به‌کارگیری اطلاعات پیش‌فرض روی تصویر HR هدف، قیدهای بازسازی و نزدیک بودن تصویر LR ورودی به تصویر HR تخمین زده شده‌ای که به‌وسیله عمل‌گرهای مات-کنندگی و زیر-نمونه برداری تخریب شده است، تمرکز دارند. از اینرو این روش‌ها برای اعمال پیش‌فرض‌های مناسب بر روی تصویرهای طبیعی از چارچوب MAP^۴ با عبارت تنظیم‌کننده $R(x)$ استفاده می‌کنند [۵]:

$$x = \arg \min_x \frac{1}{2} \|y - DHx\|_2^2 + \lambda R(x) \quad (2)$$

که λ پارامتر تنظیم‌کننده برای میزان مشارکت دو عبارت هماندهی و عبارت تنظیم است. از جمله مهم‌ترین پیش‌فرض‌ها، پیش‌فرض همواری محلی، پیش‌فرض حفظ لبه، پیش‌فرض مشخصات گرادیان و پیش‌فرض مبتنی بر غیرمحملی‌ها هستند. در پیش‌فرض همواری محلی، فرض بر این است که تصویرها به استثنای لبه‌ها هموار می‌باشند. تنظیم‌کننده تغییر کلی (TV^۵) از جمله‌ی مهم‌ترین این تنظیم‌کننده‌ها است که منجر به صاف شدن تصویر تخمین زده شده و نادیده گرفتن جزئیات آن می‌شود [۶]. علاوه بر تعریف همسایگی یک پیکسل به شکل محلی، در پیش‌فرض‌های مبتنی بر غیرمحملی‌ها، پیکسل‌ها را در یک ناحیه جستجوی بزرگ در نظر گرفته و بر حسب شباهت بین بلوک‌های مستطیلی به آنها وزن می‌دهند. به‌کارگیری مدل‌های غیرمحملی در تنظیم‌کننده‌ها رایج بوده و بر اساس این فرض استوار است که هر مشخصه‌ای در یک تصویر طبیعی می‌تواند چندین

¹⁷(NCSR) معرفی شده است که منجر به عمل کرد قابل توجه این روش شده است. در [۱۳] یک مدل پیشگویی آماری بر مبنای نمایش تنک بلوک‌های LR و HR برای SISR پیشنهاد شده است. این روش پیشنهادی در ازای حجم محاسباتی بسیار بالا، منجر به نتایج مناسبی برای SISR شده است.

به استناد روش‌های آموزشی منیفلد، در [۱۴] یک روش مبتنی بر تعبیه همسایه برای مساله‌ی SISR پیشنهاد داده است. عمل کرد روش‌های مبتنی بر تعبیه همسایه به تعداد بلوک‌های آموزشی بستگی دارد. برخی از روش‌های سریع مبتنی بر تعبیه همسایه در [۱۶-۱۵] پیشنهاد شده است. در [۱۵] رگرسیون همسایگی اتکا یافته (¹²ANR) پیشنهاد شده است که در آن از تلفیق دو روش آموزش واژه‌نامه و تعبیه همسایه استفاده شده است. برای هر اتم واژه‌نامه‌ی LR، یک ماتریس نگاشت بین دو فضای LR و HR آموزش داده می‌شود. این ماتریس با پیدا کردن همسایگی‌هایی از سایر اتم‌های واژه‌نامه‌ی LR و اتم‌های معادلشان از واژه‌نامه‌ی HR، با رگرسیون و به صورت برون-خطی^{۱۴} به دست می‌آید. هر بلوک از تصویر ورودی، نزدیکترین اتم از واژه‌نامه‌ی LR را یافته و با استفاده از ماتریس برون‌خطی منطبق بر اتم انتخاب شده به فضای HR نگاشت می‌شود. برای بهبود روش ANR در [۱۶] روش A+ پیشنهاد شده است. در A+، برای یافتن ماتریس نگاشت، به جای دسته‌ای از اتم‌های نزدیک به اتم انتخابی، از نزدیکترین بلوک‌های آموزش به اتم انتخابی، استفاده می‌شود. در [۱۷] یکسان در نظر گرفته شدن اتم‌های همسایه‌ی اختصاص یافته به هر اتم واژه‌نامه‌ی LR در [۱۵] (برای آموزش ماتریس نگاشت برون خطی بین دو فضای LR و HR) به عنوان نقطه ضعف این روش ذکر شده است. برای حل این مشکل و بهبود روش ANR، در [۱۷] روش ¹⁵LANR پیشنهاد شده است. در این روش، اتم‌های اختصاص یافته به هر اتم واژه‌نامه‌ی LR، با در نظر گرفتن وزن شباهتشان به اتم مدنظر و پیش فرض شباهت غیر محلی برای آموزش ماتریس نگاشت برون خطی استفاده می‌شوند.

در [۱۸] یک روش مبتنی بر یادگیری عمیق با شبکه عصبی (¹¹SRCNN) برای SISR پیشنهاد شده است که با سه لایه، نگاشتی بین تصویرهای LR و HR را یاد می‌گیرد. در [۱۹] از یک شبکه عمیق تر با بیست لایه برای یادگیری استفاده شده است. اگر چه روش‌های مبتنی بر شبکه‌های عصبی عمیق عمل کرد بهتری دارند ولی فرآیند یادگیری آنها با حجم محاسباتی بالا، بسیار پیچیده است.

در روش‌های متعارف برای نمایش تنک، هر بلوک به شکل مستقل در فرآیند یادگیری واژه‌نامه و کدینگ تنک در نظر گرفته می‌شود. در واقع رابطه بین بلوک‌ها نادیده گرفته می‌شود که منجر به ضرایب تنک غیر دقیق می‌شود. ترکیب تنکی و خود-شباهتی غیرمحلی و فرمول‌بندی آنها به منظور حل مسائل معکوس در بازیابی تصویر، می‌تواند به نتایج متفاوتی در پردازش تصویر منجر شود. اخیراً در برخی از کارها [۲۲-۲۰] به کارگیری این ویژگی منجر به مدل کدینگ تنک دقیق تر شده

است. در [۲۰-۲۱] برای نمایش تنک بلوک‌های مشابه، اتم‌های مشابهی از واژه‌نامه انتخاب شده است که نتایج نزدیکتر به بهینه نسبت به حالتی که بلوک‌های مشابه به شکل مجزا کد می‌شوند، به دست آمده است. در [۲۱] با معرفی مفهوم گروه به عنوان واحد پایه برای نمایش تنک، روشی جامع برای انواع متفاوت بازیابی تصویر اعم از حذف نویز، حذف مات‌شدگی و سنجش فشرده ارائه شده است. [۲۲] یک روش برای بازیابی تصویر در حوزه سنجش فشرده ارائه داده است. به کارگیری قید تنکی محلی و تنکی ضرایب تبدیل به دست آمده از آرایه سه بعدی بلوک‌های مشابه، منجر به الگوریتم اندازه‌گیری توام تنکی وفقی گردیده است.

برگرفته از روش‌های ذکر شده، در این مقاله یک روش جدید با ترکیب روش‌های مبتنی بر بازسازی و آموزش پیشنهاد شده است که تنکی و خود-شباهتی غیرمحلی را در یک روش واحد به کار می‌گیرد و آنرا در روش مبتنی بر MAP برای SISR استفاده می‌کند. نوآوری‌های این مقاله در ادامه ذکر شده است:

۱- ما گروهی از بلوک‌های مشابه را به فرم بردار، به عنوان واحد پایه‌ی نمایش تنک به کار می‌گیریم که بهترین واژه‌نامه برای کد کردن آن با پیچیدگی کم و به صورت وفقی انتخاب می‌شود. بنابراین مدل جدید نمایش تنک، نمایش تنک با به کارگیری انتخاب حوزه‌ی تنک مبتنی بر پایه گروه به شکل وفقی (-A) ¹⁷GSDS نامیده می‌شود.

۲- یک مجموعه از واژه‌نامه‌های فشرده برای گروه‌های آموزشی با تفکیک پذیری بالا آموزش داده می‌شود. برای این منظور در ابتدا بلوک‌های آموزشی، با به کارگیری الگوریتم K-medoids، در K گروه خوشه بندی می‌شوند. از آنجایی که بلوک‌های هر خوشه دارای ساختار مشابه هستند، برای هر بلوک، گروهی از بلوک‌های مشابه آن تشکیل داده می‌شود. با در نظر گرفتن گروه‌ها به عنوان واحد پایه، از تبدیل PCA برای آموزش واژه-نامه‌ی متناظر گروه‌های تشکیل شده در خوشه استفاده می‌شود.

۳- از آنجایی که A-GSDS همواری محلی و خودشباهتی غیرمحلی را به وسیله نمایش تنک در یک روش واحد به کار می‌برد، می‌تواند تنکی‌های ساختار یافته‌ی تصویرهای طبیعی را به نحو موثری مشخص نماید. در واقع بلوک‌های یک گروه، اتم‌های یکسانی از واژه‌نامه‌ی آموزش یافته را به کار می‌برند.

۴- مدل پیشنهادی A-GSDS و روش NLM، در SISR استفاده شده و منجر به نتایج چشمگیری می‌شود.

در ادامه‌ی مقاله بخش‌های زیر آمده است: در بخش ۲ مروری بر نمایش تنک و آموزش واژه‌نامه، در بخش ۳ روش پیشنهادی برای حل مساله‌ی SISR با استفاده از A_GSDS، در بخش ۴ نتایج آزمایش‌ها و مقایسه با برخی از روش‌های مهم و در بخش ۵ نتیجه‌گیری مقاله ارائه شده اند.

۲- نمایش تنک و آموزش واژه‌نامه

ایده اصلی در الگوریتم‌های بازیابی تصویر بر مبنای پردازش بلوک‌ها، عبارتست از تجزیه تصویر هدف x به تعداد زیادی از بلوک‌ها با همپوشانی. بلوک x_i با اندازه $\sqrt{\beta} \times \sqrt{\beta}$ در موقعیت i ام به وسیله ماتریس استخراج بلوک، R_i ، به دست می‌آید: $x_i = R_i x$. نمایش تنک x_i می‌تواند به شکل زیر مدل شود [۲۳]:

$$\alpha_i = \arg \min_{\alpha_i} \|x_i - \phi \alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \quad (3)$$

که ϕ ، α_i به ترتیب واژه‌نامه و ضرایب تنک هستند. محاسبه α_i ، x_i از رابطه زیر به دست می‌آید:

$$x_i = \phi \alpha_i \quad (4)$$

با میانگین‌گیری از تمام بلوک‌های تخمین زده شده، تصویر نهایی از رابطه زیر به دست می‌آید [۲۳]:

$$x \approx (\phi \circ \alpha) \approx \left(\sum_{i=1}^N R_i^T R_i \right)^{-1} \sum_{i=1}^N (R_i^T \phi \alpha_i) \quad (5)$$

انتخاب واژه‌نامه، ارتباط مستقیمی با نمایش تنک بهینه دارد. استفاده از واژه‌نامه‌های از پیش تعیین شده در حوزه تبدیل و واژه‌نامه‌های آموزش یافته، دو روش معمول برای به دست آوردن واژه‌نامه‌های بسیار-کامل می‌باشند [۲۳].

روش‌های حوزه تبدیل، گروهی از توابع تبدیل ثابت را برای نمایش نمونه‌های تصویر به کار می‌برند. در حالیکه در روش‌های مبتنی بر آموزش واژه‌نامه، نمایش‌های تنک را روی یک واژه‌نامه بسیار-کامل با اطلاعات اضافی استفاده می‌کنند. با اینکه به کارگیری ماتریس‌های از قبل مشخص شده در روش‌های مبتنی بر حوزه تبدیل به دلیل سرعت و سادگی‌شان مناسب هستند، ولی آموزش واژه‌نامه برای دستیابی به نتایج بهتر و نزدیک به بهینه، در تکنیک نمایش تنک مهم بوده و در بهبود نتایج بازیابی بسیار موثر است. هدف آموزش واژه‌نامه، بهینه‌سازی توام واژه‌نامه و ضرایب نمایش می‌باشد. با فرض مجموعه‌ای از بلوک‌های آموزشی $X = \{x_1, \dots, x_n\}$ و ماتریس ضرایب نمایش تنک متناظر آنها $\Lambda = \{\alpha_1, \dots, \alpha_n\}$ ، به دست آوردن واژه‌نامه بهینه ϕ در حالت کلی می‌تواند به شکل زیر فرمول‌بندی شود [۲۴]:

$$\begin{aligned} (\phi, \Lambda) &\approx \arg \min_{\phi, \Lambda} \|X - \phi \Lambda\|_2^2 + \lambda \sum_{i=1}^n \|\alpha_i\|_p \\ &= \left(\sum_{i=1}^n \|x_i - \phi \alpha_i\|_2^2 + \lambda \|\alpha_i\|_p \right) \end{aligned} \quad (6)$$

از مهم‌ترین روش‌ها برای حل مساله فوق، الگوریتم K-svd [۲۴] است. اگر چه واژه‌نامه بسیار-کامل در بسیاری از روش‌های آموزش واژه‌نامه برای نمایش ساختارهای مختلف تصویر به کار می‌روند، ولی بسیاری از اتم‌ها در واژه‌نامه آموزش یافته با بلوک تصویر داده شده نامربوط هستند که منجر به کاهش دقت نمایش تنک و ایجاد مصنوعات

دیداری می‌گردند. اخیراً در برخی از مقالات برای کاهش نقاط ضعفی واژه‌نامه بسیار-کامل، مجموعه‌ای از واژه‌نامه‌های کامل آموزش داده می‌شود. برای این منظور، بلوک‌های آموزشی خوشه‌بندی می‌شوند و از آنجایی که بلوک‌های هر خوشه دارای ساختار مشابهی هستند، برای هر یک از خوشه‌ها یک واژه‌نامه کامل آموزش داده می‌شود. برای سادگی از تبدیل PCA برای آموزش این واژه‌نامه‌ها استفاده می‌شود [۱۲-۱۱].

۳- روش پیشنهادی

در این مقاله فرض بر این است که تصویر هدف دارای N بلوک با همپوشانی و با اندازه‌های $\sqrt{\beta} \times \sqrt{\beta}$ است. این بلوک‌ها به شکل برداری به طول β تبدیل شده و با $\{x_i\}_{i=1}^N$ نشان داده می‌شوند. x_{Gi} با ابعاد $(\beta \times c)$ ، از c تا بردار مشابه بردار x_i با طول β (متناظر با بلوک i ام) تشکیل شده است و x_{gi} معادل برداری ماتریس x_{Gi} با طول $1 \times (\beta c)$ ، به عنوان واحد پردازش در روش پیشنهادی است. $\phi_{gi} = [\phi_{gi1}, \dots, \phi_{gim}]$ واژه‌نامه‌ی متناظر با بردار x_{gi} با ابعاد $(\beta c) \times m$ است و $\phi_{Gi} = [\phi_{Gi1}, \dots, \phi_{Gim}]$ واژه‌نامه‌ی متناظر با گروه x_{Gi} با ابعاد $(\beta c) \times m$ است که از تغییر هر اتم ϕ_{gi} به دست می‌آید. اتم‌های این واژه‌نامه، ϕ_{Gij} ، ماتریسی با اندازه‌ی $(\beta \times c)$ و هم اندازه با گروه x_{Gi} هستند. همانگونه که قبلاً ذکر شد استخراج همبستگی بین ضرایب کدینگ تنک بلوک‌های مشابه می‌تواند منجر به مدل کدینگ تنک دقیق‌تر گردد. برای این منظور، ما مدل نمایش تنک با به کارگیری انتخاب حوزه تنک مبتنی بر پایه‌ی گروه به شکل وقتی را پیشنهاد می‌دهیم. در روش پیشنهادی نشان می‌دهیم که هر بردار $x_{gi} \in R^{\beta c \times 1}$ می‌تواند به شکل دقیقی به وسیله بردار تنک $\alpha_{Gi} = [\alpha_{Gi1}, \dots, \alpha_{Gim}]^T$ با اندازه‌ی $(m \times 1)$ ، که درایه‌های آن اسکالر هستند، که از واژه‌نامه‌ی آموزش یافته‌ی خود-وقتی ϕ_{gi} به دست آمده است نمایش داده شود. x_{Gi} نیز می‌تواند به وسیله‌ی بردار تنک α_{Gi} و واژه‌نامه‌ی آموزش یافته‌ی خود-وقتی ϕ_{Gi} نمایش داده شود:

$$x_{gi} = \phi_{gi} \alpha_{Gi} = \sum_{k=1}^m \alpha_{Gik} \phi_{gik} \quad (7)$$

$$x_{Gi} = \sum_{k=1}^m \alpha_{Gik} \phi_{Gik}$$

ϕ_{gi} به شکل برون خطی برای گروه‌های آموزشی HR آموزش داده شده و به شکل وقتی برای هر x_{gi} ، به عنوان واحد پایه‌ی نمایش تنک، انتخاب می‌شود. مزایای روش پیشنهادی می‌تواند اینگونه خلاصه شود: ۱- از معادله (۷) واضح است که تمام بلوک‌های هر گروه علاوه بر اینکه واژه‌نامه‌ی یکسانی را به کار می‌برند، اتم‌های یکسانی را از واژه‌نامه

برای نمایش تنک اتخاذ می‌کنند که این ویژگی منجر به نتایج نزدیک به بهینه و کدینگ دقیق‌تر بلوک‌های مشابه موجود در هر گروه می‌شود. در واقع رابطه‌ی (۷) نشان می‌دهد که هر گروه، متشکل از بلوک‌های مشابه هم، توسط اتم‌های یک واژه‌نامه به صورت همزمان کد می‌شوند و با این روش، بلوک‌های مشابه هم به‌طور مستقل کد نشده و رابطه‌ی بین آنها نادیده گرفته نمی‌شود. ۲- برای هر گروه یک واژه-نامه‌ی کامل به شکل وقفی تخصیص داده می‌شود که مناسب‌تر از واژه-نامه‌ی بسیار-کامل است.

۳-۱- نمایش تنک مبتنی بر گروه

در روش پیشنهادی برای هر بردار x_i به طول β ، متناسب با بلوک i ام، ماتریس x_{Gi} با اندازه $(\beta \times c)$ تشکیل می‌شود. برای تشکیل این ماتریس، c بلوک از بین بلوک‌های مشابه بلوک x_i ، x_j را در یک پنجره‌ی جستجوی بزرگ به عنوان ستون‌های ماتریس x_{Gi} انتخاب می‌کنیم. این بلوک‌ها با محاسبه‌ی وزن شباهت‌شان با بلوک x_i از رابطه‌ی زیر انتخاب می‌شوند:

$$w_{ij} = \exp\left(-\frac{\|x_i - x_j\|^2}{h}\right) \quad (8)$$

w_{ij} میزان شباهت بلوک j ام با بلوک i ام را نشان می‌دهد، هرچه فاصله‌ی اقلیدسی بین x_i و x_j کمتر باشد، w_{ij} بزرگتر خواهد بود. h در رابطه‌ی فوق پارامتر کنترل وزن است. ماتریس‌های $x_{Gi} \}_{i=1}^N$ به بردارهای ستونی $x_{gi} \}_{i=1}^N$ با اندازه $(\beta \times c) \times 1$ تبدیل شده و به عنوان واحد پایه پردازش به جای بلوک در نظر گرفته می‌شوند. با این تعریف، تنکی تصویرهای طبیعی در واحد گروه، پیشنهاد شده و نمایش تنک بر مبنای گروه نامیده می‌شود که به شکل زیر قابل بیان کردن است:

$$\alpha_{Gi} = \arg \min_{\alpha_{Gi}} \|x_{gi} - \phi_{gi} \alpha_{Gi}\|_2^2 + \lambda \|\alpha_{Gi}\|_1 \quad (9)$$

که ϕ_{gi} و α_{Gi} به ترتیب واژه‌نامه و ضرایب نمایش تنک گروه x_{gi} هستند. از آنجایی که انتخاب واژه‌نامه، ϕ_{gi} ، برای حل بهینه‌ی مساله (۹) مهم است، از به‌کارگیری آموزش مجموعه‌ای از واژه‌نامه‌های کامل برای گروه‌های آموزشی استفاده می‌کنیم که در بخش بعدی توضیح داده شده است.

۳-۲- آموزش واژه‌نامه کامل

بلوک‌های به‌دست آمده از تصویرهای آموزشی HR را داخل K دسته $\{C_1, \dots, C_K\}$ خوشه‌بندی می‌کنیم و μ_i را به عنوان مرکز خوشه‌ی C_i تعریف می‌کنیم. از آنجایی که در این مقاله گروه‌های حاصل از بلوک‌های مشابه به عنوان واحد پایه برای نمایش تنک در

نظر گرفته شده‌اند، از بلوک‌های مشابه موجود در هر خوشه، که مشابه هم هستند، برای تشکیل گروه‌ها استفاده می‌کنیم. به این ترتیب که برای هر بلوک خوشه‌ی C_i یک ماتریس از مشابه‌ترین بلوک‌ها را با استفاده از رابطه‌ی (۸) تشکیل داده و بعد از تبدیل این گروه‌ها به شکل برداری، خوشه C_i را با C_{gi} نمایش می‌دهیم. با در نظر گرفتن این بردارها به عنوان واحد پایه‌ی پردازش، از تبدیل PCA برای آموزش واژه‌نامه کامل متناظر این گروه‌ها استفاده می‌شود. با اعمال تبدیل PCA به C_{gi} ، واژه‌نامه‌ی متناظر آن $\phi_{gi} = [\phi_{gi1}, \dots, \phi_{gim}]$ ساخته می‌شود که اتم‌هایش از بین m بردار ویژه متناسب با بزرگترین مقادیر ویژه‌ی ماتریس کوواریانس C_{gi} انتخاب می‌شوند. اگر چه اندازه‌ی ϕ_{gi} برابر $(\beta \times c) \times m$ است، با تغییر هر اتم آن $(\phi_{gij} \in R^{(\beta \times c) \times 1})$ به شکل ماتریس $(\phi_{Gij} \in R^{(\beta \times c) \times m})$ واژه‌نامه-ی $\phi_{Gi} = [\phi_{Gi1}, \dots, \phi_{Gim}]$ با اندازه $(\beta \times c) \times m$ خواهد بود. در واقع هر اتم ϕ_{Gi} یک ماتریس هم اندازه‌ی گروه x_{Gi} است. برای هر گروه x_{Gi} از تصویر ورودی، واژه‌نامه متناظر آن بر حسب معیار حداقل فاصله اقلیدسی بین اولین ستون از x_{Gi} ، x_{Gi}^1 ، و مراکز خوشه‌ها $(\mu_k)_{k=1}^K$ انتخاب می‌شود:

$$k = \arg \min_k \frac{1}{2} \|x_{Gi}^1 - \mu_k\|_2^2 \quad (10)$$

از آنجایی که گروه‌های حاصل از بلوک‌های مشابه از معیار فاصله اقلیدسی بین بلوک‌ها برای تشکیل آنها استفاده می‌کنند، برای خوشه-بندی بلوک‌های آموزشی از خوشه بندی K-medoids [۲۵] استفاده می‌کنیم. در تحقیقات قبلی از خوشه بندی K-means برای خوشه بندی بلوک‌های آموزشی استفاده کرده‌ایم [۲۷]. در بخش ۴ نشان داده شده است که خوشه بندی با روش K-medoids به نتایج بهتری نسبت به خوشه بندی با روش K-means منجر می‌شود. از آنجایی که واژه‌نامه هر گروه به شکل وقفی انتخاب می‌شود، این روش A-GSDS نامیده شده است.

۳-۳- فرا تفکیک پذیری تصویر با A-GSDS

با وارد کردن NLM به عنوان عبارت تنظیم کننده در (۲)، SISR در نمایش تنک مبتنی بر A-GSDS به شکل زیر بیان می‌شود:

$$\alpha_G, x = \arg \min_{\alpha_G, x} \frac{1}{2} \|y - DHx\|_2^2 + \lambda_1 \|\alpha_G\|_1 + \lambda_2 \sum_{i=1}^N \left\| x_i - \sum_{j \in \Omega(x_i)} w_{ij} x_j \right\|_2^2 \quad (11)$$

$$s.t. \quad x = \Phi_g \circ \alpha_G$$

عبارت اول، عبارت هماندهی است. این عبارت برای محدود کردن تفاضل بین تصویر LR ورودی (y) و تصویر LR شبیه ساخته (DHx) استفاده می‌شود. عبارت دوم با شرط مساله $(x = \Phi_g \circ \alpha_G)$ به نمایش تنک گروه‌ها، مبتنی بر روش پیشنهادی A-GSDS دلالت

دارد. در این عبارت، α_{Gi} بردار نمایش تنک گروهی بلوک‌های مشابه بلوک x_i ، (x_{gi}) ، α_G الحاق تمام α_{Gi} ها، ϕ_{gi} واژه‌نامه‌ی متناظر با گروه x_{gi} و Φg الحاق تمام ϕ_{gi} را نشان می‌دهد. برای نشان دادن اعمال نمایش تنک مبتنی بر A-GSDS به طور همزمان بر روی تمام گروه‌های متشکل از بلوک‌های مشابه، برای سادگی از اپراتور \circ استفاده شده است. عبارت سوم، عبارت تنظیم است که پیش فرض

$$x_i = \arg \min_{x_i} \left\| x_i - \sum_{j \in \Omega(x_i)} w_{ij} x_j \right\| \quad (15)$$

$$\alpha_{Gi} = \phi_{gi}^T R_{Gi} x \quad (14)$$

$$x \left(\frac{t+1}{2} \right) = x(t) + \sigma (DH)^T (y - DHx(t))$$

شباهت غیرمحلّی را نشان می‌دهد. در این عبارت، x_j بلوک مشابه بلوک x_i ، $\Omega(x_i)$ مجموعه‌ی تمام بلوک‌های مشابه x_i و w_{ij} وزن شباهت بلوک‌های x_i و x_j است. مساله (11) با استفاده از روش تکراری¹⁸، یعنی با ثابت نگه داشتن α_G و به‌روز رسانی x و سپس با ثابت نگه داشتن x و به‌روز رسانی α_G ، حل می‌شود.

$$x_i = [(\lambda_2 + 1)I]^{-1} \cdot [W_i (x_{Gi})^T + \lambda_2 (\phi_{Gi} \alpha_{Gi})^1] \quad (16)$$

۳-۳-۱: تخمین α_{Gi}

در ابتدا ($t = 0$) با به‌کارگیری درونیایی دو مکعبی روی تصویر ورودی y ، تصویر هدف x تخمین زده می‌شود. با ثابت فرض کردن x ، مساله (11) برای هر گروه $\{x_{Gi}\}_{i=1}^N$ به شکل زیر تبدیل می‌شود:

$$\alpha_{Gi} = \arg \min_{\alpha_{Gi}} \left\| \frac{1}{2} y_{gi} - DH \phi_{gi} \alpha_{Gi} \right\|_2^2 + \lambda_1 \|\alpha_{Gi}\|_1 \quad (12)$$

y_{gi} بلوک‌های متناظر با x_{gi} از تصویر LR ورودی هستند. واژه‌نامه-ی مناسب هر گروه (ϕ_{gi}) با استفاده از رابطه‌ی (10) انتخاب می‌شود. در تکرار $(t+1)$ ام المان λ م بردار α_{Gi} ($\alpha_{Gi,j}$) به شکل بهینه با روش انقباض تکراری¹⁹ [26] به دست می‌آید:

$$\alpha_{Gi,j}^{(t+1)} = \text{soft} \left(\alpha_{Gi,j}^{(t)}, \tau \right) \quad (13)$$

τ پارامتر آستانه گذاری برای تابع آستانه‌گذاری نرم است. به دلیل به-

کارگیری تبدیل PCA در آموزش واژه‌نامه‌ها، $\alpha_{Gi}^{(t+\frac{1}{2})}$ به سادگی از روی ϕ_{gi}^T و $x \left(\frac{t+1}{2} \right)$ از رابطه‌ی زیر محاسبه می‌شود:

R_{Gi} ماتریس استخراج گروه در موقعیت i هستند به گونه‌ای که:

$$x_{gi} = R_{Gi} x \left(\frac{t+1}{2} \right) \quad (11)$$

دست آمده است که با روش گردانیدن نزولی حل می‌شود و δ در به-روزرسانی آن، گام حرکت است.

۳-۳-۲: تخمین x_i

با ثابت فرض کردن α_G ، مساله (11) برای تخمین هریک از بلوک‌های تصویر x (x_i) به شکل زیر تبدیل می‌شود:

$\phi_{Gi} \alpha_{Gi}$ با ابعاد $(\beta \times c)$ معادل ماتریسی گروه بازیابی شده $\hat{x}_{gi} = \phi_{gi} \alpha_{Gi}$ با ابعاد $(\beta c) \times 1$ است. $(\phi_{Gi} \alpha_{Gi})^1$ اولین بلوک از گروه بازیابی شده است. از آنجایی که اولین بلوک در گروه مربوط به x_i خود x_i است، عبارت دوم در (15) تضمین می‌کند که اولین بلوک در گروه بازیابی شده با x_i برابر است. مساله تخمین x_i در (15) یک تابع درجه دوم اکیدا محدب است، شکل بسته حل آن می‌تواند از (16) به دست آید:

که $W_i = [w_{i1}, \dots, w_{ic}]$ بردار وزن شباهت C بلوک مشابه x_i است. با میانگین‌گیری تمام بلوک‌های تخمین زده شده در نواحی دارای همپوشانی، تصویر x در تکرار $(t+1)$ ام به دست می‌آید:

$$x^{(t+1)} = \left(\sum_{i=1}^N R_i^T R_i \right)^{-1} \sum_{i=1}^N (R_i^T x_i) \quad (17)$$

دو زیر مساله تخمین α_{Gi} و تخمین x_i جداگانه و به شکل تکراری تا برآورده شدن معیار توقف ادامه می‌یابند. برای اطمینان از اینکه تصویر HR بازیابی شده، \hat{x} ، با تصویر LR ورودی در مدل تخریب معادله (1) صدق می‌کند، از روش بازیابی کلی استفاده می‌کنیم:

$$x = \arg \min_x \|y - DHx\|_2^2 + \quad (18)$$

$\mu_1 \|(I - W)x\|_2^2 + \mu_2 \|x - \hat{x}\|_2^2$ عبارت دوم، پیش فرض شباهت غیرمحلّی است که W در آن ماتریس وزن شباهت غیر محلّی برای \hat{x} است:

$$W(i, j) = \begin{cases} w_{ij} & j \in \Omega(x_i) \\ 0 & \text{otherwise} \end{cases} \quad (19)$$

مساله بهینه سازی (۱۸) با الگوریتم گرادیان نزولی حل می‌شود:

که γ اندازه‌ی گام حرکت است. خلاصه‌ی روش SISR پیشنهادی با استفاده از A_GSDS در جدول (۱) نشان داده شده است. در اولین تکرار، تخمین اولیه تصویر با استفاده از درونیایی دومکعبی به دست می‌آید. به ازای هر بلوک از تصویر تخمین زده شده، بلوک‌های مشابه آن با روش NLM تشکیل یک گروه با بردار وزن شباهت غیرمحملی را می‌دهند. نمایش تنک هر گروه با استفاده از واژه‌نامه‌ی متناسب آن که از بین واژه‌نامه‌های آموزش یافته انتخاب شده است، انجام می‌گیرد. با توجه به رابطه‌ی (۹)، بلوک‌های مشابه هم در یک گروه از اتم‌های یکسانی از واژه‌نامه برای کد شدن استفاده می‌کنند. هر بلوک از تصویر، با استفاده از قید شباهت غیرمحملی و اولین بلوک بازسازی شده به- وسیله‌ی نمایش تنک، تخمین زده می‌شود. این روند تا برآورده شدن شرط توقف، تکرار می‌شود. در نهایت با اعمال بازیابی کلی روی تصویر بازیابی شده‌ی \hat{x} ، تصویر نهایی به دست می‌آید.

۴- نتایج آزمایش‌ها

در این قسمت روش ارائه شده را با روش دومکعبی و برخی از مهم-ترین الگوریتم‌های موجود در SISR اعم از [10] SCSR، ASDS [11]، [16] A+، [17] LANR و [18] SRCNN مقایسه می‌کنیم. روش پیشنهادی با به کارگیری خوشه‌بندی‌های K-means و K-medoids، در فاز آموزش واژه‌نامه، به ترتیب با A_GSDS_men_1 و A_GSDS_med_2 نشان داده شده است. در این آزمایش‌ها تصویرهای LR از به کارگیری کرنل گوسی به اندازه 7×7 و انحراف معیار 1.6 روی تصویرهای آزمایشی HR (که در شکل (۱) نشان داده شده‌اند) و سپس زیر-نمونه‌برداری شده آنها با مقیاس 3 به دست می-آیند. در تمام آزمایش‌ها اندازه بلوک 7×7 HR با 4 پیکسل همپوشانی است. اندازه گروه‌ها و اندازه پنجره جستجو، به ترتیب 12 و 20×20 است.

پارامترهای به کاررفته عبارتند از:

$$\mu_2 = 0.2, \mu_1 = 0.1, \lambda_2 = 3, \sigma = 7, \tau = 0.1, \gamma = 5$$


برای سنجش پایداری روش پیشنهادی نسبت به داده‌های آموزشی به-کاررفته، از دو مجموعه داده‌های آموزشی به کاررفته در [۱۱]، شکل (۲)، استفاده شده است. نتایج حاصل از داده‌های آموزشی اول و دوم با پسوند ۱ و ۲ در انتهای روش پیشنهادی نشان داده شده است. از آنجایی که سیستم بینایی انسان به تغییرات روشنایی حساس‌تر است، الگوریتم‌های SISR فقط به مولفه‌های روشنایی اعمال شده و برای مولفه‌های رنگی از روش‌های درونیایی استفاده می‌شود. برای ارزیابی

عملکرد روش پیشنهادی، از معیارهای تشابه ساختاری (SSIM) و

$$x^{m+1} = x^m + \gamma((DH)^T (y - DHx^m) - \mu_1(I - W)^T (I - W) + \mu_2(\hat{x} - x^m)) \quad (20)$$

نسبت بیشینه سیگنال به نویز (PSNR) بین محتوای روشنایی تصویرهای آزمایشی و تصویرهای بازیابی شده استفاده می‌شود. مقایسه بصری الگوریتم پیشنهادی و بقیه روش‌ها در شکل‌های ۳ و ۴ برای تصویرهای *leaves* و *flower* نشان داده شده‌اند. لبه‌های تیزتر و ساختارهای مطلوب، عملکرد بالای روش پیشنهادی را تصدیق می-کنند که ناشی از به کارگیری مطلوب ترکیب تنکی محلی و خود-شباهتی غیرمحملی در مدل پیشنهادی است. نتایج PSNR و SSIM حاصل از الگوریتم‌های مختلف بر روی تصویرهای آزمایشی در جدول ۲، برتری روش پیشنهادی را نسبت به سایر روش‌ها نشان می‌دهد. همانگونه که دیده می‌شود نتایج حاصل از A_GSDS_med_1 و A_GSDS_med_2 بسیار نزدیک به هم هستند که مقاوم بودن روش پیشنهادی نسبت به داده‌های آموزشی به کاررفته را نشان می‌دهد. همانگونه که انتظار می‌رفت به دلیل منطبق بودن معیار تشکیل گروه و خوشه بندی K-medoids، نتایج حاصل از اعمال خوشه بندی K-medoids نسبت به نتایج حاصل از اعمال خوشه بندی K-means (A_GSDS_men_1) بهینه است. برای نمونه در روش پیشنهادی A_GSDS_med_2، مقادیر میانگین PSNR/SSIM به ترتیب نسبت به روش‌های دومکعبی، SCSR، A+، LANR، SRCNN، ASDS و A_GSDS_men_1 به میزان $4.73/0.1546$ ، $0.73/0.199$ ، $0.75/0.202$ ، $1.06/0.261$ ، $1.63/0.408$ و $0.24/0.052$ بهبود یافته است.

در جدول (۳)، زمان لازم برای آموزش دیکشنری‌ها، میانگین زمان لازم برای اجرای روش‌های مختلف و میانگین مقادیر PSNR/SSIM به-دست آمده از اجرای روش‌های مختلف بر روی تصویرهای آزمایشی نشان داده شده است. تخمین α_G در روش پیشنهادی، دارای پیچیدگی $O(PT_D(\beta \times c + T_G))$ است که P تعداد بلوک‌های تصویر، T_D میانگین زمانی برای یافتن واژه‌نامه‌ی مناسب هر گروه، $(\beta \times c)$ اندازه‌ی هر گروه و T_G میانگین زمانی برای تشکیل هر گروه است. در حالی که اگر می‌خواستیم بردار نمایش تنک برای یک بلوک را به-دست آوریم پیچیدگی $O(PT_D(\beta))$ می‌شد. از آنجایی که x_i در روش پیشنهادی از فرمول بسته به دست می‌آید از نظر محاسباتی مناسب بوده و نیازمند زمانی در حدود ۲ ثانیه است و تخمین زمان



شکل (۱): تصویرهای آزمایشی

جدول (۱): الگوریتم فراتفکیک پذیری تصویر با استفاده از A-GSDS

Input : LR input image, learned sub dictionaries $\{\phi_{gk}\}_{k=1}^K$, clustering centers, $\lambda_2 = 3, \delta = 7, \tau = 0.1, \mu_1 = 0.1, \mu_2 = 0.2, \gamma = 5$ and $\max Iter$

Output: HR image x

Initialization:
Set: $t = 0$
 $x^{(0)}$ as initial estimation of HR target image by bicubic interpolation

repeat
 $x^{(t+1)} = x^{(t)}$

1) **Update** α_{Gi}

for Each patch x_i
construct groups x_{gi}
obtain the nonlocal weight w_i ,
select the subdictionary ϕ_{gi} by computing Eq.(10)

for
 $x^{(t+\frac{1}{2})} = x^{(t)} + \sigma(DH)^T (y - DHx^{(t)})$

end for
 $\alpha_{Gi}^{(t+\frac{1}{2})} = \Phi_{gi}^T R_{Gi} x^{(t+\frac{1}{2})}, \alpha_{Gi,j}^{(t+1)} = \text{soft}(\alpha_{Gi,j}^{(t+\frac{1}{2})}, \tau)$

end for

2) **Reconstruction** x :

Update x_i :

$$x_i = [(\lambda_2 + 1)I]^{-1} \cdot [w_i (x_{Gi})^T + \lambda_2 (\phi_{Gi} \alpha_{Gi})^T]$$

Reconstruct $x : x = (\sum_{i=1}^N R_i^T R_i)^{-1} \sum_{i=1}^N (R_i^T x_i)$

$t = t + 1$

until $t > \max Iter$,
Global reconstruction by Eq. (18)

صرف شده برای محاسبه‌ی گرادیان نزولی، در بازیابی کلی برای هر تکرار در حدود ۰.۳ ثانیه است. همانگونه که از جدول (۳) دیده می‌شود A+, LANR, SRCNN و SCSR به ترتیب روشهای سریع برای بازسازی تصویر هستند. اکثر این روش‌ها با وجود زمان لازم کم برای بازسازی، به نتایج مناسبی نمی‌رسند. روش پیشنهادی ما به ازای اندک زمان بازیابی بیشتر، به بهترین نتیجه در بین روش‌های مهم در مساله SISR می‌رسد. برای آموزش واژه‌نامه‌ها در روش‌های SCSR, A+, LANR و SRCNN از ۹۱ تصویر آموزشی و در روش پیشنهادی و روش ASDS از ۵ تصویر آموزشی استفاده شده است. از آنجاییکه آموزش واژه‌نامه‌ها در روش پیشنهادی به جای در نظر گرفتن بلوک‌ها به‌طور مستقل، برای گروه‌هایی از بلوک‌های مشابه انجام گرفته است، زمان لازم برای این آموزش نسبت به روش ASDS بیشتر است. نتایج حاصل، کارا بودن روش پیشنهادی در آموزش واژه‌نامه‌ها را نشان می‌دهند.

۵- نتیجه‌گیری

در این مقاله یک روش فراتفکیک پذیری به‌وسیله معرفی A-GSDS به عنوان تنظیم‌کننده پیشنهاد شده است. در A-GSDS گروه‌هایی از بلوک‌های مشابه به شکل بردارهایی، به عنوان واحد پایه نمایش تنک، در نظر گرفته می‌شوند که به شکل موثری تنکی محلی و خود شباهتی غیرمحلی را در یک روش واحد مدل می‌کنند. برای کدکردن هر یک از گروه‌ها، واژه‌نامه‌ی آموزش یافته به شکل وفقی انتخاب می‌شود. این واژه‌نامه‌ها برای گروه‌های آموزشی موجود در دسته‌هایی که از خوشه بندی K-medoids به‌دست آمده‌اند، با استفاده از تبدیل PCA آموزش داده می‌شوند. برای بهبود بیشتر روش پیشنهادی از الگوریتم‌های NLM و بازیابی کلی استفاده می‌شود. نتایج آزمایش‌ها نشان از برتری روش پیشنهادی با معیارهای PSNR و SSIM نسبت به برخی از روش‌های مهم را دارد.



شکل (۲): مجموعه داده های آموزشی شماره ۱ و ۲ برای فاز آموزش واژه نامه ها [11].


جدول (۲): مقادیر PSNR/SSIM حاصل از الگوریتم های مختلف برای مساله SISR

تصویرها	دومکعبی	ScSR	SCRNN	A+	ASDS
Bike	20.80/0.5759	23.34/0.7400	24.21/0.7735	24.18/0.6714	24.31/0.7913
Butterfly	20.78/0.7175	25.14/0.8541	26.51/0.8661	26.44/0.8989	27.09/0.8975
Comic	20.87/0.5573	23.53/0.7371	24.30/0.7686	24.02/0.7652	24.60/0.7869
Flower	24.83/0.6753	27.85/0.7998	29.00/0.8414	28.51/0.8261	29.18/0.8466
Foreman	26.48/0.8491	30.34/0.9149	29.86/0.9293	28.48/0.9327	31.71/0.9330
Girl	29.95/0.7334	32.84/0.7990	33.31/0.8195	33.23/0.8180	33.46/0.8201
Hat	27.20/0.7778	29.86/0.8449	30.51/0.8518	30.77/0.8668	30.97/0.8650
Leaves	19.83/0.6411	24.40/0.8482	26.06/0.8756	25.32/0.8898	26.93/0.9096
Parrots	25.58/0.8261	28.14/0.8620	29.92/0.9027	29.65/0.8842	30.04/0.9099
Parthenon	24.12/0.6205	26.27/0.7248	26.57/0.7278	26.52/0.7297	26.89/0.7367
Plants	27.83/0.7875	31.55/0.8902	33.30/0.9051	32.63/0.9012	33.42/0.9074
Raccoon	26.38/0.6280	28.51/0.7275	29.08/0.7541	28.91/0.7482	29.23/0.7655
Average	24.55/0.6991	27.65/0.8129	28.55/0.8338	28.22/0.8276	29.04/0.8485
تصویرها	LANR	A_GSDS_men_1	A_GSDS_med_1	A_GSDS_med_2	
Bike	24.27/0.6890	24.51/0.7958	24.72/0.7988	24.74/0.7991	
Butterfly	26.80/0.8994	27.50/0.9052	27.61/0.9077	27.64/0.9082	
Comic	24.09/0.7632	24.60/0.7875	24.64/0.7895	24.64/0.7896	
Flower	28.56/0.8417	29.33/0.8519	29.44/0.8541	29.48/0.8549	
Foreman	29.43/0.9365	31.86/0.9341	31.95/0.9350	31.95/0.9351	
Girl	33.58/0.8207	33.51/0.8224	33.57/0.8233	33.56/0.8233	
Hat	30.81/0.8661	31.14/0.8675	31.27/0.8713	31.28/0.8713	
Leaves	26.52/0.8923	27.00/0.9101	27.19/0.9144	27.22/0.9153	
Parrots	30.12/0.9116	30.48/0.9157	30.54/0.9163	30.55/0.9166	
Parthenon	26.55/0.7306	27.03/0.7421	27.07/0.7440	27.08/0.7442	
Plants	32.60/0.9002	33.85/0.9101	33.95/0.9174	33.95/0.9176	
Raccoon	29.02/0.7512	29.25/0.7680	29.30/0.7701	29.31/0.7701	
Average	28.53/0.8335	29.17/0.8508	29.27/0.8534	29.28/0.8537	

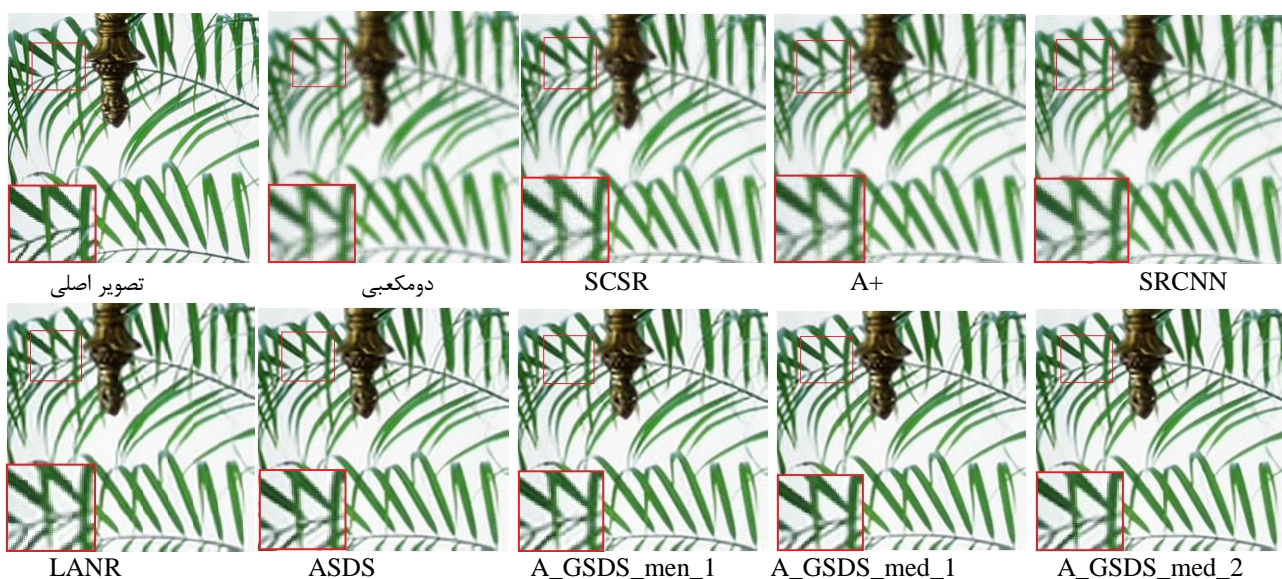
جدول (۳): زمان لازم برای آموزش دیکشنری‌ها، میانگین زمان لازم برای اجرای روش‌های مختلف و میانگین PSNR/SSIM حاصل از اجرای روش‌های مختلف

روش‌ها	دومکعبی	SCSR	SRCNN	A+
Dict. Training time	-	Hours	Days	1304.05s
SR. reconstruction time	20s	42s	14s	10s
PSNR/SSIM	24.55/0.6991	27.65/0.8129	28.55/0.8338	28.22/0.8276

روش‌ها	LANR	ASDS	A-GSDS
Dict. Training time	3854s	361.43s	2281s
SR. reconstruction time	12s	176s	220s
PSNR/SSIM	28.53/0.8335	29.04/0.8485	29.28/0.8537



شکل (۴): فراتفکیک پذیری تصویر *flower* با روش‌های مختلف



شکل (۳): فراتفکیک پذیری تصویر *leaves* با روش‌های مختلف

- [18] C. Dong, C. Loy, K. He, K. and X. Tang, "Learning a deep convolutional network for image super-resolution," IEEE Trans. Pattern Anal. Mach. Intell., vol. 38, no. 2, pp. 295-307, Feb. 2016.
- [19] J. Kim, J. Kwon Lee and K. Mu Lee, "Accurate image super resolution using very deep convolutional networks. In CVPR 2016.
- [20] A. Soltani -Farani, H. Rabiee, "When Pixels Team up: Spatially Weighted Sparse Coding for Hyperspectral Image Classification," IEEE Geosci. Remote Sens. Lett., vol. 12, no. 1, Jan. 2015.
- [21] J. Zhang, D. Zhao, and W. Gao, "Group-Based Sparse Representation for Image Restoration," IEEE Trans. Image Process., vol. 23, no. 8, pp. 3336-3351, Aug. 2014.
- [22] N. Eslahi, A. Aghagolzadeh, and S. M. H. Andargoli, "Image/video compressive sensing recovery using joint adaptive sparsity measure," Elsevier. Neurocomputing, vol. 200, pp. 88-109, 2016.
- [23] Z. Zhang, Y. Xu, J. Yang, X. Li, and D. Zhang, "A Survey of sparse Representation: Algorithms and Applications," IEEE. open Access, vol. 3, pp. 490-530, Apr. 2015.
- [24] I. Tošić and P. Frossard, "Dictionary Learning," IEEE Signal Process Mag., vol. 28, no. 2, pp. 27-38, Mar. 2011.
- [25] Ch. Bishop, "Pattern Recognition and Machine Learning," springer, USA, 2006.
- [26] I. Daubechies, M. Defriese, and C. DeMol, "An iterative thresholding algorithm for linear inverse problems with a sparsity constraint," Commun. Pure Appl. Math., vol. 57, pp. 1413-1457, 2004.
- [27] E. Mikaeli, A. Aghagolzadeh, and M. Azghani, "Single Image Super Resolution Via Adaptive Group-Based Sparse Domain Selection," 26th Iranian Conf. on Electrical Engineering (ICEE), Mashhad, IRAN, 2018.
- [1] پویا پارسا و رضا صفابخش، "روش جدید تقطیع تصویر بر مبنای خوشه بندی فازی مبتنی بر تکامل تفاضلی چندهدفه،" مجله مهندسی برق و الکترونیک ایران، جلد ۱۳، شماره ۲، ۱۳۹۵.
- [۲] رحیم کامران، حسین نظام آبادی پور و سعید سریزدی، "ترمیم تصاویر رنگی با نواحی مخدوش بزرگ بر اساس تجزیه تصویر به مولفه های بافت و ساختار،" مجله مهندسی برق و الکترونیک ایران، جلد ۸، شماره ۲، ۱۳۹۰.
- [۳] صادق کلانتری، محمدجواد عبداللهی فرد و صادق احمدی، "افزایش تفکیک پذیری تصویر با استفاده از مدل تحلیلی لبه،" مجله مهندسی برق و الکترونیک ایران، جلد ۱۵، شماره ۲، ۱۳۹۷.
- [4] S. C. Park, M. K. Park, and M. G. Kang, "Super-resolution image reconstruction: A technical overview," IEEE Signal Process. Mag., vol. 20, no. 3, pp. 21-36, May 2003.
- [5] L. Yue, H. Shen, J. Li, Q. Yuan, H. Zhang, L. Zhang, "Image super-resolution: The techniques, applications, and future," Elsevier. Signal Processing, vol. 128, pp. 389-408, 2016.
- [6] A. Marquina and S. J. Osher, "Image super-resolution by TV regularization and bregman iteration," J. Sci. Comput., vol. 37, no. 3, pp. 367-382, Dec. 2008.
- [7] M. Protter, M. Elad, H. Takeda, and P. Milanfar, "Generalizing the nonlocal-means to super-resolution reconstruction," IEEE Trans. Image Process., vol. 18, no. 1, pp. 36-51, Jan. 2009.
- [8] A. Buades, B. Coll and J. M. Morel, "A non-local algorithm for image denoising," in Proc. Int. Conf. CVPR, pp. 60-65, Jun. 2005.
- [9] J. Yang, J. Wright, T. Huang, and Y. Ma, "Image super-resolution as sparse representation of raw image patches," in IEEE Conf. Comput. Vis. Pattern Recog, pp. 1-8, 2008.
- [10] J. Yang, J. Wright, T. Huang, and Y. Ma, "Image super-resolution via sparse representation," IEEE Trans. Image Process., vol. 19, no. 11, pp. 2861-2873, Nov. 2010.
- [11] W. Dong, L. Zhang, G. Shi, and X. Wu, "Image deblurring and superresolution by adaptive sparse domain selection and adaptive regularization," IEEE Trans. Image Process., vol. 20, no. 7, pp. 1838-1857, Jul. 2011.
- [12] W. Dong, L. Zhang, G. Shi, and X. Li, "Nonlocally centralized sparse representation for image restoration," IEEE Trans. Image Process., vol. 22, no. 4, pp. 1620-1630, Apr. 2013.
- [13] T. Peleg and M. Elad, "A statistical prediction model based on sparse representations for single image super-resolution," IEEE Trans. Image Process., vol. 23, no. 6, pp. 2569-2582, Jun. 2014.
- [14] H. Chang, D.-Y. Yeung, and Y. Xiong, "Super-resolution through neighbor embedding," CVPR, pp. 275-282, 2004.
- [15] R. Timofte, V. De Smet, and L. Van Gool, "Anchored neighborhood regression for fast example-based super resolution," in Proc. IEEE Int. Conf. Comput. Vis., pp. 1920-1927, Dec. 2013.
- [16] R. Timofte, V. De Smet, and L. Van Gool, "A+: Adjusted anchored neighborhood regression for fast super-resolution," in Proc. Asian Conf. Comput. Vis., pp. 111-126, Nov. 2014.
- [17] J. Jiang, X. Ma, C. Chen, T. Lu, Z. Wang and J. Ma, "Single image super-resolution via locally regularized anchored neighborhood regression and nonlocal means," IEEE Trans. Multimedia., vol. 19, no. 1, pp. 15-26, Jan. 2017.

¹ Single Image Super Resolution

² High Resolution

³ Low Resolution

⁴ Maximum Aposterior

⁵ Total Variation

⁶ Nonlocal Means

⁷ Dictionary Learning

⁸ Neighbor Embedding

⁹ Sparse Coding Super Resolution

¹⁰ Adaptive Sparse Domain Selection

¹¹ Principle Component Analysis

¹² Nonlocal Centralizes Sparse Representation

¹³ Anchored Neighbor Regression

¹⁴ Offline

¹⁵ Locally Anchored Neighbor Regression

¹⁶ Super Resolution via Convolutional

¹⁷ Adaptive Group-based Sparse Domain Selection

¹⁸ Iterative Algorithm

¹⁹ Iterative Shrinkage Algorithm