

الحمد لله الذي
خلقنا من
الحمم



دانشگاه صنعتی شاهرود

دانشکده مهندسی کامپیوتر

رساله دکتری مهندسی هوش مصنوعی

افزایش وضوح تک تصویر به کمک روش خود یادگیرنده با در نظر گرفتن اطلاعات همسایگی

نگارنده: ملیحه حبیبی

استاد راهنما

دکتر علیرضا احمدی فرد

استاد مشاور

دکتر حمید حسن پور

فروردین ۹۸

شماره: ۶۱۶ رف.ک

تاریخ: ۹۸/۱/۲۶

ویرایش:

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره ۱۲: صورت جلسه نهایی دفاع از رساله دکتری (Ph.D)
(ویژه دانشجویان ورودی های ۹۴ و ما قبل)

بدینوسیله گواهی می شود خانم ملیحه حبیبی دانشجوی دکتری رشته هوش مصنوعی به شماره دانشجویی ۹۱۲۵۶۲۵ ورودی مهرماه سال ۱۳۹۱ در تاریخ ۱۳۹۸/۰۱/۲۴ از رساله نظری / عملی ☐ خود با عنوان: افزایش وضوح تک تصویر به کمک روش خودیادگیرنده و با در نظر گرفتن اطلاعات همسایگی دفاع و با اخذ نمره به درجه: بسیار خوب منتهی گردید.

☒ الف) درجه عالی: نمره ۱۹-۲۰	☒ ب) درجه بسیار خوب: نمره ۱۸/۹۹ - ۱۷
☐ ج) درجه خوب: نمره ۱۶/۹۹ - ۱۵	☐ د) غیر قابل قبول و نیاز به دفاع مجدد دارد
☐ ه) رساله نیاز به اصلاحات دارد	

ردیف	هیئت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱	دکتر علیرضا احمدی فرد	استاد راهنما	دانشیار	
۲	دکتر حمید حسن پور	مشاور	استاد	
۳	دکتر فرزین یغمایی	استاد مدعو خارجی	دانشیار	
۴	دکتر وحید ابوالقاسمی	استاد مدعو داخلی	استادیار	
۵	دکتر مرتضی زاهدی	استاد مدعو داخلی	استادیار	
۶	دکتر منصور فاتح	سرپرست (نماینده) تحصیلات تکمیلی دانشکده	استادیار	

مدیر محترم تحصیلات تکمیلی دانشگاه:

ضمن تأیید مراتب فوق مقرر فرمائید اقدامات لازم در خصوص انجام مراحل دانش آموزختگی خانم ملیحه حبیبی بعمل آید.

نام و نام خانوادگی رئیس دانشکده: علیرضا احمدی فرد
تاریخ و امضاء و مهر دانشکده: ۹۸/۱/۲۴

تعمدنامه

اینجانب ملیحه حبیبی دانشجوی دوره (دکتری) رشته مهندسی هوش مصنوعی دانشکده مهندسی کامپیوتر دانشگاه صنعتی شاهرود نویسنده پایان‌نامه افزایش وضوح تک‌تصویر به کمک روش خودیادگیرنده با در نظرگرفتن اطلاعات همسایگی تحت راهنمایی دکتر علیرضا احمدی فرد متعهد می‌شوم.

- تحقیقات در این پایان‌نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان‌نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان‌نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان‌نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری، ضوابط و اصول اخلاق انسانی رعایت شده است.

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود. استفاده از اطلاعات و نتایج موجود در پایان‌نامه بدون ذکر مرجع مجاز نمی‌باشد.

تقدیم به روح بلند پدر مهربانم:

که عالمانه به من آموخت تا چگونه در عرصه زندگی، ایستادگی را تجربه نمایم.

تقدیم به مادر صبور و فداکارم:

که آلفای زندگی را به من آموخت و زندگی‌ام را مدیون مهر و عطوفت او می‌دانم.

تقدیم به همسر مهربانم:

که آرامش روحی و آسایش فکری را برایم فراهم نمود تا با حمایت‌های همه جانبه‌اش در محیطی مطلوب بتوانم این مقطع تحصیلی را به اتمام رسانده و با صبرش در تمامی لحظات رفیق راهم بود.

تقدیم به گل نازم، بردیا:

که آسایش او آرامش من است.

از استاد گرانقدر و پرمایه‌ام جناب آقای دکتر علیرضا احمدی فرد بدلیل دلسوزی، تلاش و کوشش ایشان در انتقال معلومات و تجربیات ارزشمندشان بسیار سپاسگزارم چرا که بدون راهنمایی‌های ایشان، انجام این رساله بسیار مشکل بود.

اینجانب بر خود وظیفه می‌دانم که از زحمات و راهنمایی‌های استاد دانشمند، **جناب آقای دکتر حمید حسن‌پور** که مشاوره این رساله را بر عهده داشتند، تقدیر و تشکر نمایم.

از اساتید بزرگوار، **جناب آقای دکتر فرزین یغمایی**، **جناب آقای دکتر وحید ابوالقاسمی** و **جناب آقای دکتر مرتضی زاهدی** که عهده‌دار داوری این رساله بوده‌اند، صمیمانه تشکر می‌نمایم.

چکیده

افزایش تفکیک پذیری تصویر یک موضوع تحقیقاتی مهم در حوزه پردازش تصویر است. با توجه به محدودیت‌ها و هزینه‌های سیستم‌های تصویربرداری جهت ایجاد تصاویر با تفکیک پذیری بالا، در بسیاری از موارد یک سیستم تصویربرداری مقرون به صرفه مورد استفاده قرار گرفته و از تکنیک‌های پردازش سیگنال برای بهبود کیفیت تصویر اخذ شده استفاده می‌شود. این تکنیک‌ها، تحت عنوان افزایش تفکیک‌پذیری تصویر شناخته می‌شوند.

تمرکز این رساله بر افزایش تفکیک‌پذیری تک تصویر خودیادگیرنده است. لذا بر خلاف بسیاری از روش‌ها نیاز به پایگاه داده‌ای از تصاویر تفکیک‌پذیری بالا و پائین متناظر برای یادگیری نیست. بجای آن با کاهش مکرر نرخ نمونه‌ها هرم تصویر ورودی ساخته شده و با افزایش نرخ نمونه‌ها و درونیایی در هرم ورودی، هرم وضوح پایین تصویر ساخته می‌شود. تصاویر سطوح مختلف این هرم‌ها به عنوان مجموعه تصاویر آموزشی با تفکیک‌پذیری بالا و پایین شناخته می‌شوند. برای یادگیری رابطه تصاویر وضوح پایین و وضوح بالا از رگرسیون بردار پشتیبان استفاده نموده ایم. ویژگی‌های بکار رفته برای توصیف وصله‌های تصویر در این مدل سازی ضرایب بازنمایی تنک و گرادیان مرتبه اول و مرتبه دوم روشنایی می‌باشند.

در روش اول پیشنهادی در این رساله، برای افزایش تفکیک‌پذیری تصویر از اطلاعات همسایگی هر پیکسل که در مراحل قبل بازسازی شده است استفاده می‌شود. این روش برای تخمین روشنایی پیکسل‌ها در نواحی یکنواخت مناسب است. در نظر گرفتن اطلاعات همسایگی برای پیکسل‌های قرار گرفته در نواحی غیریکنواخت موجب از بین رفتن جزئیات تصویر بازسازی شده می‌گردد. برای رفع این مشکل، در روش دوم ارائه شده پیکسل‌های نواحی یکنواخت و غیریکنواخت تفکیک می‌گردند. از طرف دیگر، با عنایت به ماهیت متفاوت پیکسل‌های لبه و غیرلبه، برای تخمین روشنایی پیکسل‌ها در هر یک از این دو گروه الگوریتم‌های مجزایی ارائه می‌گردد. در روش سوم پیشنهادی استفاده از اطلاعات همسایگی به همراه خوشه‌بندی وصله‌ها قبل از شروع فاز آموزش مورد توجه قرار گرفته است. برای سازگاری بهتر روش با محتوای تصویر، در روش چهارم ابتدا تصویر ناحیه‌بندی شده و سپس به ازای هر ناحیه مدل جداگانه‌ای آموزش داده می‌شود. در یک راهکار دیگر برای ساماندهی وصله‌ها قبل از شروع فرایند آموزش استفاده از الگوریتم خوشه‌بندی زیر فضای تنک (روش پنجم) پیشنهاد می‌گردد.

در نهایت، روش‌های پیشنهادی این رساله با روش‌های موجود و مطرح در زمینه افزایش تفکیک‌پذیری تصویر مورد مقایسه قرار گرفت. براساس نتایج، در اغلب موارد، روش پیشنهادی براساس ناحیه‌بندی تصویر (روش چهارم)، بهترین عملکرد را در مقایسه با سایر روش‌ها در رابطه با ضریب افزایش ۲ و ۳، نویز گوسین و نویز نمک و فلفل داشته است. از لحاظ زمان اجرا، روش پیشنهادی مبتنی بر اطلاعات بازسازی شده قبلی

با تفکیک پیکسل‌ها در نواحی یکنواخت و غیریکنواخت (روش دوم) ، سریع‌ترین روش در بین روش‌های پیشنهادی است.

کلمات کلیدی: افزایش فراتفکیک‌پذیری تصویر، خودیادگیرنده، بازنمایی تنک، رگرسیون بردار پشتیبان، ناحیه‌بندی تصویر، خوشه‌بندی زیرفضای تنک.

پیش‌گفتار

پردازش تصویر، شاخه‌ای از علوم مهندسی است که در حوزه بهبود کیفیت تصاویر، استخراج ویژگی مناسب از تصاویر و بازنمایی تصاویر فعالیت می‌کند. امروزه، پردازش تصویر از تکنولوژی‌های در حال رشد در زمینه‌ی مهندسی و علوم کامپیوتر می‌باشد. یکی از مهم‌ترین زمینه‌های تحقیق در پردازش تصویر، بهبود کیفیت بصری تصویر است. از رویکردهای بهبود کیفیت تصویر می‌توان حذف نویز، حذف تاری، کالبراسیون و افزایش تفکیک پذیری را نام برد. در این رساله، از بین روش‌های بهبود کیفیت، افزایش تفکیک پذیری مورد مطالعه قرار می‌گیرد. از آنجائی که پیشنهاد اساسی رساله، در نظر گرفتن اطلاعات پیکسل‌های مجاور است، در روش‌های پیشنهادی سعی شده است تا به نحوی از اطلاعات همسایگی استفاده شود. از طرف دیگر، با در نظر گرفتن یک پیمایش رستری، از مقدار شدت روشنایی پیکسل‌های بازسازی شده در مراحل قبلی در تخمین مقادیر جدید پیکسل‌ها استفاده می‌شود. بکارگیری اطلاعات نواحی تصاویر و استفاده از خوشه‌بندی زیر فضای تنک از دیگر موارد قابل توجه در این رساله می‌باشد.

لیست مقالات مستخرج از پایان نامه

۱- حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۵) "افزایش وضوح تک تصویری با در نظر گرفتن بخش های مجاور بازسازی شده"، کنفرانس بین المللی مهندسی کامپیوتر و فناوری اطلاعات، تهران.

۲- حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با در نظر گرفتن سازگاری در همسایگی پیکسل ها و استفاده از روش خودیادگیرنده"، نشریه مهندسی برق و مهندسی کامپیوتر ایران، سال ۱۶، شماره ۲، ص ۱۵۷.

۳- حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۵) "افزایش تفکیک پذیری تک تصویری با استفاده از تقریب منیفلد و "k-means، پنجمین کنفرانس بین المللی مهندسی کامپیوتر، برق و الکترونیک، تهران.

۴- حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با یادگیری از نواحی استخراج شده تصویر ورودی"، مجله بینایی ماشین و پردازش تصویر، در حال انتشار.

5- Habibi, M., Ahmadyfard, A. and Hassanpour, H. "Content-based Image Super-Resolution via Sparse Subspace Clustering", (Preparing).

فهرست مطالب

فهرست جداول	س
فهرست اشکال	ع
فصل ۱ : مقدمه	۱
1-1 افزایش تفکیک پذیری تصویر	۲
۱-۲ روش‌های افزایش تفکیک پذیری تصویر	۳
۱-۳ کاربردهای افزایش تفکیک پذیری تصویر	۶
۱-۴ چالش‌های افزایش تفکیک پذیری تصویر	۸
۱-۵ هدف رساله	۱۰
۱-۶ دست‌آوردهای رساله	۱۱
۱-۷ ساختار رساله	۱۳
۱-۸ جمع‌بندی	۱۴
فصل ۲: مرور کارهای پیشین	۱۷
۲-۱ افزایش تفکیک پذیری تک تصویر	۱۸
۲-۲ الگوریتم‌های افزایش تفکیک پذیری تک تصویر	۱۹
۲-۲-۱ افزایش تفکیک پذیری تک تصویر مبتنی بر درون‌یابی	۱۹
۲-۲-۲ افزایش تفکیک پذیری تک تصویر مبتنی بر یادگیری	۲۰
۲-۲-۲-۱ افزایش تفکیک پذیری مبتنی بر نمونه	۲۲
۲-۲-۲-۲ افزایش تفکیک پذیری خودیادگیرنده (خودهمانندی)	۳۱
۲-۳ افزایش تفکیک پذیری مبتنی بر چند فریم	۳۵
۲-۴ جمع‌بندی	۴۰

فصل ۳: مفاهیم اولیه	۴۳
۱-۳ مقدمه	۴۴
۲-۳ ساخت هرم‌های با تفکیک پذیری بالا و تفکیک پذیری پایین	۴۵
۳-۳ استخراج ویژگی	۴۸
۱-۳-۳ بازنمایی تُنک	۴۸
۱-۱-۳-۳ استخراج ضرایب تنک در رساله	۵۴
۲-۳-۳ استخراج گرادینان مرتبه اول و دوم	۵۷
4-3 رگرسیون بردار پشتیبان (SVR)	۵۹
۵-۳ معیار ارزیابی	۶۷
۱-۵-۳ معیار PSNR	۶۸
۲-۵-۳ معیار SSIM	۶۸
۶-۳ پایگاه داده مورد استفاده	۶۹
۷-۳ جمع‌بندی	۷۱
فصل ۴: روشهای پیشنهادی فرا تفکیک‌پذیری تک تصویری با در نظر گرفتن اطلاعات همسایگی	۷۳
۱-۴ مقدمه	۷۴
۲-۴ روش اول: در نظر گرفتن مقادیر پیکسل‌های مجاور بازسازی شده	۷۴
۱-۲-۴ فاز آموزش	۷۵
۲-۲-۴ فاز آزمون	۷۷
۳-۲-۴ ارزیابی نتایج	۷۹
۳-۴ روش دوم: ارائه مدل جداگانه‌ای برای پیکسل‌های لبه و غیر لبه و نواحی هموار و غیر هموار	۸۱
۱-۳-۴ فاز آموزش	۸۲
۴-۳-۲ فاز آزمون	۸۸
۳-۳-۴ ارزیابی نتایج	۹۰

۴-۴	روش سوم: استفاده از K-MEANS و LLE.....	۹۳
۴-۴-۱	فاز آموزش.....	۹۳
۴-۴-۲	فاز آزمون.....	۹۴
۴-۴-۳	ارزیابی نتایج.....	۹۴
۴-۵	جمع بندی.....	۹۷
فصل ۵: روشهای پیشنهادی فراتفکیک پذیری تک تصویری مبتنی بر ناحیه بندی و خوشه بندی زیرفضای تنک.....		
۵-۱	مقدمه.....	۹۹
۵-۲	روش چهارم: افزایش تفکیک پذیری تک تصویری با تاکید بر یادگیری مجزا برای نواحی تصویر ورودی.....	۱۰۰
۵-۲-۱	فاز آموزش.....	۱۰۳
۵-۲-۱-۱	آموزش پیکسل های لبه.....	۱۰۳
۵-۲-۱-۲	آموزش پیکسل های غیر لبه.....	۱۰۶
۵-۲-۲	فاز آزمون.....	۱۰۷
۵-۲-۲-۱	تخمین روشنایی پیکسل های لبه.....	۱۰۸
۵-۲-۲-۲	تخمین پیکسل های غیر لبه.....	۱۰۹
۵-۲-۳	ارزیابی نتایج.....	۱۱۰
۵-۳	روش پنجم: افزایش فراتفکیک پذیری تک تصویری مبتنی بر محتوای تصویر ورودی با استفاده از خوشه بندی زیرفضای تنک.....	۱۱۶
۵-۳-۱	خوشه بندی زیرفضای تنک.....	۱۱۷
۵-۳-۲	استخراج ویژگی.....	۱۱۹
۵-۳-۳	فاز آموزش.....	۱۲۰
۵-۳-۴	فاز آزمون.....	۱۲۳
۵-۳-۵	ارزیابی نتایج.....	۱۲۵
۴-۵	جمع بندی.....	۱۲۸

فصل ۶ : مقایسه روشهای پیشنهادی رساله ۱۳۱

۱-۶ مقدمه ۱۳۲

۲-۶ افزایش تفکیکپذیری تصویر با ضریب افزایش ۲ ۱۳۳

۳-۶ افزایش تفکیکپذیری تصویر با ضریب افزایش ۳ ۱۳۷

۴-۶ زمان اجرای روشهای پیشنهادی رساله ۱۴۲

۵-۶ تاثیر نویز بر عملکرد روش های افزایش فراتفکیک پذیری تصویر ۱۴۳

۶-۶ جمع بندی ۱۴۷

فصل ۷: جمع بندی و کارهای آتی ۱۴۹

۱-۷ مقدمه ۱۵۰

۲-۷ جمع بندی پژوهش های انجام شده در رساله ۱۵۰

۱-۲-۷ افزایش وضوح تک تصویری با در نظر گرفتن مقادیر پیکسل های مجاور بازسازی شده . ۱۵۱

۲-۲-۷ افزایش تفکیک پذیری تک تصویری با ارائه مدل جداگانه ای برای پیکسل های لبه و غیر

لبه ۱۵۱

۳-۲-۷ افزایش تفکیک پذیری تک تصویری با استفاده از تقریب منیفلد و K-MEANS ۱۵۲

۴-۲-۷ افزایش تفکیک پذیری تک تصویری با تاکید بر یادگیری مجزا برای نواحی تصویر ورودی ۱۵۳

۵-۲-۷ افزایش فراتفکیک پذیری تک تصویری مبتنی بر محتوای تصویر ورودی با استفاده از

خوشه بندی زیرفضای تنک ۱۵۴

۳-۷ کارهای آتی ۱۵۴

فهرست جداول

- جدول (۱-۴) مقادیر PSNR(IN DB) برای روش های [۵۱]، [۳۶]، [۴۴] و روش پیشنهادی ۱..... ۸۱
- جدول (۲-۴) مقادیر PSNR(IN DB) و SSIM برای مقایسه ی روش پیشنهادی ۲ با روش های LSSR[44] و SLSR[51]، LLE[36]..... ۹۱
- جدول (۳-۴) مقایسه مقادیر PSNR(IN DB) و SSIM روش پیشنهادی ۳ با سایر روش های مطرح در SR..... ۹۴
- جدول (۱-۵) مقایسه ی روش پیشنهادی ۴ با روشهای مطرح افزایش تفکیک پذیری تصویر با استفاده از معیارهای PSNR (IN DB) و SSIM..... ۱۱۱
- جدول (۲-۵) مقادیر PSNR(IN DB) و SSIM برای روش پیشنهادی ۵ و چندین روش افزایش تفکیک پذیری تصویر..... ۱۲۶
- جدول (۱-۶) مقایسه روشهای پیشنهادی رساله با سایر روشهای مطرح در رساله (ضریب افزایش ۲)..... ۱۳۴
- جدول (۲-۶) میانگین مقادیر PSNR و SSIM برای هشت تصویر آزمون و به ازای روشهای مورد مقایسه (ضریب افزایش ۲)..... ۱۳۵
- جدول (۳-۶) مقادیر PSNR و SSIM روش های SR با ضریب افزایش ۳ (برای تصویر LENA)..... ۱۳۸
- جدول (۴-۶) مقادیر PSNR و SSIM روش های SR با ضریب افزایش ۳ (برای تصویر TREE)..... ۱۴۰
- جدول (۵-۶) زمان اجرای هر یک از روشهای پیشنهادی رساله (بر حسب ثانیه)..... ۱۴۲
- جدول (۶-۶) مقادیر PSNR و SSIM روش های SR پس از اعمال نویز (برای تصویر LENA)..... ۱۴۳
- جدول (۷-۶) مقادیر PSNR و SSIM روش های SR پس از اعمال نویز (برای تصویر TREE)..... ۱۴۵

فهرست اشکال

- شکل (۱-۱) افزایش تفکیکپذیری مبتنی بر تک تصویر-تصویر ورودی (سمت چپ)، تصویر خروجی (سمت راست) ۴
- شکل (۲-۱) نمایش شماتیک بازسازی یک تصویر وضوح بالا از چندین تصویر وضوح پایین [۱] ۴
- شکل (۳-۱) نتایج اعمال الگوریتم افزایش وضوح بر تصاویر پزشکی. چپ: ورودی، راست: خروجی الگوریتم ۶
- شکل (۴-۱) نتایج اعمال الگوریتم افزایش وضوح بر تصاویر ماهواره. چپ: ورودی، راست: خروجی الگوریتم ۷
- شکل (۵-۱) نتایج اعمال الگوریتم افزایش وضوح تصویر جهت تشخیص پلاک خودرو ۸
- شکل (۶-۱) نتایج اعمال الگوریتم افزایش وضوح تصویر جهت شناسایی چهره در تصویر ۸
- شکل (۱-۲) مدل شبکه مارکوف برای مساله افزایش تفکیکپذیری تصویر [۲۰] ۲۴
- شکل (۲-۲) بلوک دیاگرام الگوریتم تک گذر مرجع [۲۰] ۲۵
- شکل (۳-۲) بلوک دیاگرام الگوریتم مرجع [۴۴] ۲۷
- شکل (۴-۲) دیاگرام روش پیشنهادی مرجع [۴۷] ۲۹
- شکل (۵-۲) بلوک دیاگرام الگوریتم مرجع [۳۴] ۳۰
- شکل (۶-۲) بلوک دیاگرام الگوریتم مرجع [۴۴] ۳۳
- شکل (۷-۲) استخراج افزونگی وصله‌های موجود در اندازه‌های مختلف تصویر در یک هرم تصویر [۱۹] ۳۴
- شکل (۸-۲) یک مدل مشاهده از سیستم تصویربرداری واقعی با در نظر گرفتن حرکت بین صحنه و دوربین [۱] ۳۶
- شکل (۱-۳) دو هرم تصاویر با تفکیک پذیری بالا (سمت چپ) و با تفکیک پذیری پائین (سمت راست) بعنوان پایگاه داده‌ای از تصاویر آموزشی ۴۷
- شکل (۲-۳) دیکشنری فراکامل برای تصاویر house, tree و susan. سطر اول شامل ۱۰۰ اتم و سطر دوم شامل ۹۰۰ که اندازه هر اتم 5×5 ۵۵

شکل (۳-۳) دیکشنری فراکامل برای تصاویر lena, peppers و baboon به ترتیب شامل ۱۰۰ و ۹۰۰ اتم (از بالا به پایین) که اندازه هر اتم 5×5 ۵۶

شکل (۴-۳) محاسبه گردیدان مرتبه اول و دوم برای پیکسل شماره ۱۳ تصویر I ۵۸

شکل (۵-۳) جداسازی داده‌های آموزشی مشخص شده با دواير آبی و قرمز با خطوط جداساز (ابرفصفحه‌های) مختلف ۶۰

شکل (۶-۳) نمایش داده‌های آموزشی، پهنای حاشیه، خط جداساز و بردارهای پشتیبان برای دو کلاس مشخص شده با دواير آبی و قرمز ۶۱

شکل (۷-۳) نمایش داده‌های آموزشی جداپذیر غیرخطی برای دو کلاس مشخص شده با دواير آبی و قرمز ۶۶

شکل (۸-۳) استفاده از تابع کرنل برای نگاشت داده‌های آموزشی شکل (۷-۳) به فضای بالاتر (انتقال از فضای دو بُعدی به فضای سه بُعدی) ۶۶

شکل (۹-۳) مجموعه تصاویر برای آزمون (از چپ به راست و بالا به پایین): house, lena, tree, baboon و airplane, boat, peppers, susan ۷۱

شکل (۱-۴) الف- نمایش پیمایش تصویر از چپ به راست و از بالا به پایین. ب- تخمین پیکسل غیرلبه ی مرکزی وصله (پیکسل شماره ۵) با استفاده از پیکسل های مرکزی وصله های بالا و چپ (پیکسلهای ۱ تا ۴) ۷۶

شکل (۲-۴) دیاگرام فاز آموزش روش افزایش وضوح تک تصویری با در نظر گرفتن بخش‌های مجاور بازسازی شده ۷۸

شکل (۳-۴) دیاگرام فاز آزمون روش افزایش وضوح تک تصویری با در نظر گرفتن بخش‌های مجاور بازسازی شده ۷۸

شکل (۴-۴) مقایسه خروجی روش‌های افزایش وضوح تصویر برای تصویر airplane. به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی، خروجی روش‌های افزایش تفکیک پذیری مبتنی بر همسایگی تعیبه شده [۳۶]، افزایش تفکیک پذیری تک تصویر خودیادگیرنده [۵۱]، افزایش تفکیک پذیری مبتنی بر بازنمایی تَنک با استفاده از رگرسیون بردار پشتیبان [۴۴] و روش پیشنهادی ۱ ۸۰

شکل (۵-۴) بلوک دیاگرام فاز آموزش مدل‌های ارتباط بین اطلاعات تصاویر با تفکیک پذیری بالا و پایین و مدل‌های خطای تخمین به ازای پیکسل‌های لبه ۸۶

شکل (۴-۶) آموزش مدل‌های ارتباط بین اطلاعات تصاویر با تفکیک‌پذیری بالا و پایین و مدل‌های اختلاف به ازای پیکسل‌های غیرلبه ۸۷

شکل (۴-۷) بلوک دیاگرام فاز آزمون براساس روابط (۴-۹) تا (۴-۱۱) ۸۹

شکل (۴-۸) نتایج افزایش تفکیک‌پذیری برای تصویر lena. به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی، خروجی روش‌های درونیایی دومکعبی، مراجع [۵۱]، [۳۶]، [۴۴] و روش پیشنهادی ۲ ۹۲

شکل (۴-۹) نمودار مقادیر PSNR به ازای تعداد خوشه‌ها و تعداد همسایه‌های هر وصله در هر خوشه به ازای چندین تصویر از پایگاه تصاویر ۹۵

شکل (۴-۱۰) نتایج افزایش تفکیک‌پذیری برای تصویر airplane. به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی، خروجی روش‌های مراجع [۵۱]، [۳۶]، [۴۴] و روش پیشنهادی ۳ ۹۶

شکل (۵-۱) هرم تصویر با تفکیک‌پذیری پایین برای تصویر lena پس از ناحیه‌بندی تصاویر هرم (شروع ناحیه‌بندی از تصویر 1-2) ۱۰۲

شکل (۵-۲) نتایج SR برای تصویر house (کاهش اثرات تارشدگی و اثرات مصنوعی) ۱۱۲

(به ترتیب از چپ بر راست و بالا به پایین) ۱۱۲

شکل (۵-۳) نتایج SR برای تصویر susan (کاهش اثرات مصنوعی و غیرطبیعی) ۱۱۳

شکل (۵-۴) نتایج SR برای تصویر tree (کاهش اثرات تارشدگی و اثرات مصنوعی) ۱۱۴

شکل (۵-۵) اختلاف بین تصویر هدف و تصاویر خروجی (از بالا به پایین و چپ به راست) روش‌های bicubic، LLE[36]، SLSR[51]، SCSR[46]، LSSR[44]، روش پیشنهادی ۲ [۱۲۵] و روش پیشنهادی ۴ برای تصویر tree ۱۱۵

شکل (۵-۶) اختلاف بین پیکسل‌های تصویر هدف و تصاویر خروجی روش پیشنهادی برای تصاویر house و baboon، tree، susan، peppers (از چپ به راست) ۱۱۶

شکل (۵-۷) نتایج افزایش تفکیک‌پذیری برای تصویر tree. سطر بالا: تصویر هدف، ۱۲۷

(bicubic (PSNR: 28.3977, SSIM: 0.8730), LLE[36] (PSNR: 25.8251, SSIM: 0.8257), SCSR[46] (PSNR: 29.1265, SSIM: 0.8887), SCSR[46] (PSNR: 26.9405, SSIM: 0.8410), SLSR[51] (PSNR: 30.3624, SSIM: 0.9063) ۱۲۷

شکل (۵-۸) نتایج افزایش تفکیک پذیری تصویر susan. سطر بالا (از چپ به راست): تصویر هدف،
 (bicubic (PSNR: 35.4471 , SSIM: 0.9317)، LLE[36] (PSNR: 33.4981 , SSIM: 0.9056)،
 ۱۲۸.....

سطر پایین : (SCSR[46] (PSNR: 36.2441 , SSIM: 0.9380)، SSIM: 0.8986 , PSNR: 33.6579)
 (SLSR[51] و روش پیشنهادی ۵ (PSNR: 36.8518 , SSIM: 0.9434)، ۱۲۸.....

شکل (۶-۱) مقایسه خروجی روش های پیشنهادی ۱ تا ۴ برای تصویر lena..... ۱۳۶

شکل (۶-۲) مقایسه خروجی روش های پیشنهادی ۱ تا ۴ برای تصویر tree..... ۱۳۷

شکل (۶-۳) افزایش فراتفکیک پذیری تصویر با ضریب افزایش ۳ برای تصویر LENA - به ترتیب از
 چپ به راست و بالا به پایین: تصویر اصلی - درونیابی دومکعبی، LLE[36]، SLSR[51]، SCSR[46]
 و LSSR[44]..... ۱۳۹

شکل (۶-۴) نتایج روشهای پیشنهادی ۱ تا ۴ با ضریب افزایش ۳ برای تصویر LENA - به ترتیب از
 چپ به راست و بالا به پایین: تصویر اصلی - روشهای ۱ تا ۴..... ۱۳۹

شکل (۶-۵) افزایش فراتفکیک پذیری تصویر با ضریب افزایش ۳ برای تصویر tree - به ترتیب از چپ
 به راست و بالا به پایین: تصویر اصلی - درونیابی دومکعبی، LLE[36]، SLSR[51]، SCSR[46] و
 LSSR[44]..... ۱۴۱

شکل (۶-۶) نتایج روشهای پیشنهادی ۱ تا ۴ با ضریب افزایش ۳ برای تصویر tree - به ترتیب از چپ
 به راست و بالا به پایین: تصویر اصلی - روشهای ۱ تا ۴..... ۱۴۱

شکل (۶-۷) تاثیر نویز گوسین بر تصویر lena - به ترتیب از بالا به پایین و چپ به راست: تصویر اصلی -
 روش های درونیابی دومکعبی، LLE[36]، SLSR[51]، SCSR[46] و LSSR[44]..... ۱۴۴

شکل (۶-۸) تاثیر نویز گوسین بر تصویر lena - به ترتیب: تصویر اصلی و روش های ۱ تا ۴..... ۱۴۴

شکل (۶-۹) تاثیر نویز نمک و فلفل بر تصویر tree - به ترتیب از بالا به پایین و چپ به راست: تصویر
 اصلی - روش های درونیابی دومکعبی، LLE[36]، SLSR[51]، SCSR[46] و LSSR[44]..... ۱۴۶

فصل ۱: مقدمه

۱-۱ افزایش تفکیک پذیری تصویر^۱

تفکیک پذیری در پردازش تصویر به میزان اطلاعات قرار داده شده در تصویر اشاره دارد. تفکیک پذیری می‌تواند به روش‌های متعددی از قبیل تفکیک پذیری پیکسل، تفکیک پذیری طیفی، تفکیک پذیری فضایی، تفکیک پذیری زمانی و تفکیک پذیری نوری توصیف شود. در این رساله، تفکیک پذیری فضایی مورد بررسی قرار می‌گیرد. تفکیک پذیری فضایی به سطح جزئیات بصری قابل تشخیص در یک تصویر اشاره دارد. برای تصاویر دیجیتال، در جایی که پیکسل‌ها بعنوان واحد پایه استفاده می‌شوند، یک ارتباط بین تفکیک پذیری فضایی و مجموع پیکسل‌ها وجود دارد. در واقع، تفکیک پذیری فضایی را می‌توان بعنوان تعداد پیکسل‌های مستقل در واحد سطح در نظر گرفت. در اغلب موارد، تعداد پیکسل‌های عمودی و افقی تصویر، تفکیک پذیری پیکسل نامیده می‌شود که حد بالای تفکیک پذیری فضایی است. افزایش تعداد پیکسل‌ها در یک تصویر باعث افزایش تفکیک پذیری فضایی تصویر شده و جزئیات تصویر بهتر مشاهده می‌شود[۱].

افزایش تفکیک پذیری تصویر یک موضوع تحقیقاتی فعال در پردازش تصویر و بینایی ماشین است. اولین کار روی این موضوع در سال ۱۹۸۴ توسط Tsai و Huang، [۲]، منتشر شد و اصطلاح "سوپر رزولوشن" از سال ۱۹۹۰، [۳]، مورد استفاده قرار گرفت. هدف اصلی افزایش تفکیک پذیری تصویر، تخمین جزئیات تفکیک پذیری بالای از دست رفته در تصویر اصلی است که این امر به کمک یک یا تعداد بیش‌تر از تصاویر تفکیک پذیری پائین از یک صحنه انجام می‌شود. اهمیت الگوریتم‌های افزایش تفکیک پذیری تصویر، ایجاد اطلاعات بیشتر در یک تصویر تفکیک پذیری بالای خروجی در مقایسه با تصویر تفکیک پذیری پایین ورودی است که این موضوع یک نکته کلیدی در اغلب کاربردها است. بعنوان مثال، یکی از نیازهای حیاتی برای ایجاد تصاویر با تفکیک پذیری بالا در کاربردهای پزشکی است که دقت در تشخیص، به کیفیت تصویر وابسته است. اهمیت الگوریتم‌های افزایش تفکیک پذیری تصویر در این کاربرد از این واقعیت نشأت می‌گیرد که

¹ Image Super-Resolution (SR)

داشتن تفکیک پذیری بیشتر به معنی داشتن اطلاعات بیشتر است که منجر به دقت بیشتر از نقطه نظر پزشکی می‌شود [۴]. در این فصل، روش‌ها، کاربردها و چالش‌های افزایش تفکیک پذیری تصویر مورد بررسی قرار می‌گیرد. هدف رساله و دست‌آوردهای آن نیز جزء موارد مطرح شده‌ای است که در انتهای فصل به آن اشاره شده است.

۲-۱ روش‌های افزایش تفکیک پذیری تصویر


الگوریتم‌های افزایش تفکیک پذیری تصویر را می‌توان با توجه به تعداد تصاویر ورودی و تعداد تصاویر خروجی مورد استفاده در این الگوریتم‌ها به سه دسته تقسیم کرد [۵]. در صورتی که یک تصویر تفکیک پذیری بالا تنها از یک تصویر تفکیک پذیری پایین به دست آید، روش، "یک ورودی- یک خروجی" (SISO)^۱ است. از کاربردهای این گروه می‌توان به افزایش کارایی شناسایی شیء اشاره کرد. دسته‌ی دیگر، برای ایجاد یک تصویر تفکیک پذیری بالا، از چندین تصویر تفکیک پذیری پایین استفاده می‌کنند که روش "چند ورودی- یک خروجی" (MISO)^۲ گفته می‌شود. یک مثال کاربردی در این زمینه، شناسایی پلاک خودرو از یک دنباله ویدیویی برای افزایش نرخ بازشناسایی است. تمرکز دسته‌ی دیگر، مربوط به الگوریتم‌هایی است که هدف آنها بهبود مجموعه‌ای از فریم‌های تفکیک پذیری بالا از یک مجموعه مشابه از فریم‌های تفکیک پذیری پایین است که روش "چند ورودی- چند خروجی"^۳ (MIMO) نامیده می‌شود. یک کاربرد معمول از این الگوریتم‌ها می‌تواند بهبود کیفیت یک دنباله ویدیویی به دست آمده از دوربین‌های نظارتی باشد. الگوریتم‌های افزایش تفکیک پذیری تصویر چند ورودی-چندخروجی، یک کاربرد نوظهور در این حوزه‌ی روش‌های افزایش تفکیک پذیری تصویر است

^۱ Single-Input Single-Output (SISO)

^۲ Multiple-Input Single-Output (MISO)


^۳ Multiple-Input Multiple-Output (MIMO)

و از ترکیب الگوریتم‌های SISO و MISO به دست می‌آید. بنابراین، دو رویکرد اصلی برای افزایش تفکیک پذیری تصویر، SISO و MISO هستند که در سال‌های اخیر مورد مطالعه قرار گرفته‌اند که این روش‌ها به ترتیب در اشکال (۱-۱) و (۲-۱) نشان داده شده‌اند.



شکل (۱-۱) افزایش تفکیک‌پذیری مبتنی بر تک تصویر-تصویر ورودی (سمت چپ)، تصویر خروجی (سمت راست)

دو مکانیزم مختلف اکتساب تصویر وضوح پایین یعنی با یک یا چندین دوربین در شکل (۲-۱) آورده شده است [۱].



شکل (۲-۱) نمایش شماتیک بازسازی یک تصویر وضوح بالا از چندین تصویر وضوح پایین [۱]

در روش‌های مبتنی بر تک تصویر، اطلاعات فرکانس بالا تنها با استفاده از یک تصویر ورودی استخراج می‌شود. این الگوریتم‌ها می‌توانند به دو دسته‌ی اصلی الگوریتم‌های مبتنی بر یادگیری و مبتنی بر درون‌یابی طبقه‌بندی می‌شوند. روش‌های مبتنی بر یادگیری، از تکنیک‌های یادگیری ماشین استفاده می‌کنند و دیکشنری ایجاد شده بوسیله‌ی یک پایگاه داده از تصاویر را بکار می‌برند. فرض الگوریتم‌های درون‌یابی این است که تصویر تفکیک پذیری پایین بر اثر کاهش نرخ نمونه‌برداری تصویر تفکیک پذیری بالا ایجاد شده است. براساس این فرض، تلاش این الگوریتم‌ها بر به دست آوردن تصویر تفکیک پذیری بالا بوسیله‌ی افزایش نرخ نمونه‌برداری تصویر تفکیک پذیری پایین است. در درون‌یابی تک تصویر، پیکسل‌های جدید بوسیله‌ی درون‌یابی‌هایی از قبیل درون‌یابی دو خطی^۱ و درون‌یابی دومکعبی^۲ و با استفاده از پیکسل‌های همسایه، تخمین زده می‌شوند. روش‌های افزایش تفکیک پذیری مبتنی بر چند فریم، از چندین تصویر با تبدیلات هندسی متفاوت، از یک صحنه، استفاده می‌کنند که این تصاویر یا از طریق گرفتن چندین تصویر از یک صحنه و یا بکارگیری چندین دوربین در موقعیت‌های مختلف به دست می‌آیند. اگر تبدیلات هندسی شامل شیفت‌ها با واحدهای صحیح باشد، تمامی تصاویر تفکیک پذیری پایین دارای محتوای یکسان بوده و اطلاعات اضافی برای استخراج تصویر تفکیک پذیری بالا در این تصاویر وجود ندارد. بنابراین، بهترین حالت برای افزایش کارایی این روش‌ها، انتقال هر تصویر به اندازه‌ی کسری از پیکسل است که در اینصورت هر تصویر وضوح پایین شامل اطلاعات اضافی برای ایجاد تصویر تفکیک پذیری بالا است. تصاویر تفکیک پذیری پایین برای ایجاد یک تصویر تفکیک پذیری بالای خروجی، با یکدیگر ترکیب می‌شوند. در نتیجه، تصویر ایجاد شده دارای جزئیاتی است که در هیچ یک


^۱ bilinear terpolation

^۲ bicubic interpolation

از تصاویر ورودی به تنهایی وجود ندارد. به عبارت دیگر، با ترکیب این تصاویر، اطلاعات جدید ایجاد خواهد شد.


۳-۱ کاربردهای افزایش تفکیک پذیری تصویر

در اغلب کاربردهای تصویربرداری دیجیتالی، معمولاً تصاویر و یا ویدیوهایی با تفکیک پذیری بالا برای پردازش و تحلیل بیش‌تر مورد نیاز است. با توجه به محدودیت‌ها و هزینه‌های سیستم‌های تصویربرداری جهت ایجاد تصاویر تفکیک‌پذیری بالا، در بسیاری از موارد الزام به پذیرش تخریب‌های تصویر توسط سیستم تصویربرداری و اعمال روش‌های افزایش تفکیک‌پذیری تصویر بعنوان الگوریتم‌های پس پردازش برای بهبود کیفیت تصویر تخریب شده است. یکی از کاربردهای افزایش تفکیک‌پذیری تصویر، در حوزه‌ی پزشکی است. به دلیل محدودیت‌های موجود در دستگاه‌های تصویربرداری پزشکی که می‌تواند ناشی از فناوری و یا هزینه‌ی دستگاه‌ها باشد، تصاویر خروجی تفکیک‌پذیری کافی نداشته و این امر می‌تواند در قابلیت تشخیص و تصمیم‌گیری پزشک تاثیرگذار باشد. بنابراین، نیاز به بالا بردن تفکیک‌پذیری تصاویر پزشکی جهت تشخیص دقیق بیماری است [۶]، [۷] و [۸]. نمونه‌ای از افزایش وضوح تصویر پزشکی در شکل (۳-۱) نشان داده شده است.




شکل (۳-۱) نتایج اعمال الگوریتم افزایش وضوح بر تصاویر پزشکی. چپ: ورودی، راست: خروجی الگوریتم.

علاوه براین، در برخی موارد امکان مشاهده‌ی مستقیم و بدون واسطه‌ی برخی صحنه‌ها برای انسان وجود ندارد. برای این منظور، تصاویر توسط دستگاه‌های مختلف از قبیل ماهواره استخراج شده و برای پردازش و تحلیل بیش‌تر در اختیار انسان قرار داده می‌شوند. در صورت عدم تفکیک پذیری مناسب تصاویر گرفته شده، امکان تحلیل درست وجود ندارد. لذا، در سنجش از راه دور نیز نیاز به استفاده از الگوریتم‌های افزایش تفکیک پذیری تصویر جهت استنتاج دقیق‌تر [۲]، [۹]، [۱۰] و [۳] است. در شکل (۴-۱)، نمونه‌ای از تصویری ماهواره، قبل و بعد از اعمال الگوریتم افزایش وضوح تصویری نشان داده شده است.



شکل (۴-۱) نتایج اعمال الگوریتم افزایش وضوح بر تصاویر ماهواره. چپ: ورودی، راست: خروجی الگوریتم.

در برخی کاربردها نیاز به شناسایی دقیق اشیایی است که از دستگاه تصویربرداری فاصله دارند. از این قبیل کاربردها می‌توان به شناسایی چهره‌ی مجرمان در صحنه و تشخیص پلاک خودرو اشاره کرد [۱۱]، [۱۲]. در شکل (۵-۱) و (۶-۱)، خروجی الگوریتم افزایش وضوح تصویری برای تشخیص پلاک و شناسایی چهره‌ی شخص مدنظر که از دوربین فاصله دارد، نشان داده شده است.



شکل (۵-۱) نتایج اعمال الگوریتم افزایش وضوح تصویر جهت تشخیص پلاک خودرو



شکل (۶-۱) نتایج اعمال الگوریتم افزایش وضوح تصویر جهت شناسایی چهره در تصویر

بهبود تصاویر اثر انگشت [۱۳] و [۱۴]، بهبود تصاویر متن [۱۵] و [۱۶] و بهبود ویدیوها و تصاویر فشرده شده [۱۷] و [۱۸] از دیگر کاربردهای افزایش تفکیک پذیری تصویر است. در بخش بعدی، چالش‌های موجود در روش‌های افزایش تفکیک پذیری تصویر مورد بررسی قرار می‌گیرند.

۴-۱ چالش‌های افزایش تفکیک پذیری تصویر

روش‌های افزایش تفکیک پذیری تصویر در مواجهه با برخی شرایط با چالش‌هایی روبرو می‌شوند. در ادامه، چالش‌های موجود در روش‌های بخش ۱-۲ مورد بررسی قرار می‌گیرد.

همانطور که در بخش ۱-۲ ذکر شد، الگوریتم‌های پیشنهادی برای افزایش تفکیک پذیری تصویر در دهه‌های اخیر را می‌توان بر مبنای دو رویکرد اصلی افزایش تفکیک پذیری تک تصویر و افزایش تفکیک پذیری مبتنی بر چند فریم تقسیم کرد که الگوریتم‌های افزایش تک تصویر نیز به دو دسته‌ی اصلی روش‌های مبتنی بر درون‌یابی و روش‌های مبتنی بر یادگیری طبقه‌بندی می‌شوند. از آنجائی که افزایش تفکیک پذیری تصویر

براساس تک تصویر، نیاز به چندین تصویر بعنوان ورودی ندارد، توجه محققان و مهندسان را برای کاربردهای عملی در حوزه‌ی افزایش تفکیک پذیری تصویر بخود جلب کرده است. از راهکارهای افزایش تفکیک پذیری تک تصویر، می‌توان به روش‌های مبتنی بر درون‌یابی اشاره کرد. در این روش‌ها، مقادیر جدید پیکسل‌ها براساس مقادیر پیکسل‌های همسایه‌ی آن تخمین‌زده می‌شود. راهکارهای ساده‌ی درون‌یابی از قبیل درون‌یابی دوخطی و درون‌یابی دو مکعبی توانایی غلبه بر گسستگی‌های تصاویر بمانند لبه، را ندارند. این روش‌ها در کنار سادگی باعث ایجاد اختلالات در تصویر می‌شوند. مهم‌ترین این اختلالات، تارشدن تارشدن کل تصویر می‌باشد [۱۹].

در سال‌های اخیر به روش‌های افزایش تفکیک پذیری تصویر مبتنی بر یادگیری توجه بسیاری شده است. در این‌گونه روش‌ها، اطلاعات استخراج شده از داده‌های آموزشی برای افزایش تفکیک پذیری تصویر مورد استفاده قرار می‌گیرند. با این هدف که داده‌های آموزشی شامل جفت تصاویر تفکیک پذیری پائین و تفکیک پذیری بالای مرتبط با آن است، تمرکز روش‌های مبتنی بر یادگیری، بیش‌تر بر مدل‌سازی ارتباط بین تصاویر با تفکیک پذیری‌های مختلف می‌باشد. در این راهکار، برای بازسازی تصاویر با تفکیک پذیری بالا، فرض براین است که اطلاعات فرکانس‌های بالای تصاویر از بین رفته و با کمک مجموعه داده‌های آموزشی، می‌توان مقادیر این فرکانس‌ها را پیش‌بینی کرد. نحوه‌ی انتخاب داده‌های آموزشی و مدل‌های یادگیری می‌تواند از مشکلات موجود در این راهکار باشد بطوری‌که کارایی آن را تحت تاثیر قرار می‌دهد. بنابراین، برای دستیابی به نتایج بهتر، نیاز به دقت در انتخاب مجموعه داده‌های آموزشی است. در صورت اعمال نظارت در جمع‌آوری داده‌های آموزشی، پیچیدگی محاسباتی فاز آموزش و مشکلات در انتخاب داده‌های آموزشی به مساله‌ی افزایش تفکیک پذیری تصویر اضافه می‌شوند.

روش‌های مبتنی بر چند فریم، الگوریتم‌های مبتنی بر بازسازی^۱ هستند که از چندین تصویر تفکیک پذیری پایین برای یک ایجاد یک تصویر تفکیک پذیری بالا استفاده می‌کنند. این الگوریتم‌ها، در صورت کافی نبودن تعداد تصاویر تفکیک پذیری پائین، تعداد بی‌شماری تصویر تفکیک پذیری بالا را می‌توانند ایجاد کنند و این یکی از مشکلاتی است که از آن رنج می‌برند. از طرفی کارایی این روش‌ها به شدت تحت تاثیر تعداد تصاویر تفکیک پذیری پائین قرار می‌گیرد.

۵-۱ هدف رساله

براساس مطالب بخش ۱-۴، در رویکرد افزایش تفکیک پذیری مبتنی بر چندفریم نیاز به چندین تصویر متفاوت از یک صحنه است که در صورت ناکافی بودن تعداد تصاویر، این روش خروجی مناسبی را ایجاد نمی‌کند. این روش دارای محدودیت‌های زیادی می‌باشد از جمله اینکه برای برخی کاربردها امکان تهیه یک رشته ویوئویی با جابجایی کسری از پیکسل امکان پذیر نیست. از طرفی ضریب افزایش تفکیک پذیری در این روش‌ها بسیار محدود است. بدین خاطر در سال‌های اخیر تحقیق بر روی روش‌های مبتنی بر یک تصویر از صحنه مورد توجه بیشتری قرار گرفته است. در این میان تمرکز بیشتر تحقیقات اخیر بر روش‌های مبتنی بر یادگیری است.

فریم‌ن و همکارانش، [۲۰]، در تحقیقات خود نشان داده‌اند که بکارگیری تنها اطلاعات یک بخش از تصویر برای افزایش تفکیک پذیری تصویر مناسب نبوده و برای بهبود تفکیک پذیری تصویر باید از اطلاعات بخش‌های مجاور نیز استفاده کرد. شبکه مارکوف و الگوریتم تک‌گذر بیان شده توسط فریم‌ن و همکارانش برای این منظور ارائه شده است.

¹ Reconstruction-Based Super Resolution Algorithms

با توجه به مطالب ذکر شده، در این رساله افزایش تفکیک پذیری تک تصویر مبتنی بر یادگیری مورد بررسی بیشتر قرار می‌گیرد. از طرف دیگر، برای بهبود عملکرد الگوریتم‌های پیشنهادی این رساله، با تعریف ویژگی‌های مناسب به ازای هر وصله، سازگاری وصله‌های همسایه در انتخاب وصله‌ی بازسازی شده‌ی نهایی در نظر گرفته شده است.

۶-۱ دست‌آوردهای رساله

دست‌آوردهای این رساله را می‌توان بصورت زیر خلاصه کرد:

۱. علیرغم اینکه روش‌های مبتنی بر درون‌یابی بطور ناخواسته لبه‌های تصویر را مات می‌کنند، استفاده هوشمندانه از اطلاعات همسایگی می‌تواند در بهبود تخمین پیکسل‌های جدید موثر باشد. در نظر گرفتن اطلاعات همسایگی، یکی از پیشنهادات اصلی این رساله است. لذا، روش‌هایی برای افزایش وضوح تصویر با بکارگیری اطلاعات همسایگی از لحاظ مکانی پیشنهاد شده است. از دیگر موارد، تعریف یک پیمایش رستر است که براین اساس به ازای هر پیکسل، چهار پیکسل از هشت پیکسل همسایه آن از قبل مشخص و بازسازی شده است و می‌توان از اطلاعات بازسازی شده قبلی (بالا و سمت چپ) هر پیکسل برای بازسازی آن استفاده کرد که براساس این ایده، مقاله [۱۲۴] و تاحدی مقاله [۱۲۵] ارائه شده است.

[۱۲۴] حبیبی م، احمدی فرد ع، حسن پورح، (۱۳۹۵) "افزایش وضوح تک تصویری با در نظر گرفتن بخش‌های مجاور بازسازی شده"، کنفرانس بین المللی مهندسی کامپیوتر و فناوری اطلاعات، تهران.

[۱۲۵] حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با در نظر گرفتن سازگاری در همسایگی پیکسل‌ها و استفاده از روش خودیادگیرنده"، نشریه مهندسی برق و مهندسی کامپیوتر ایران، سال ۱۶، شماره ۲، ص ۱۵۷.

۲. نوآوری دیگر این رساله، تقسیم پیکسل‌های غیرلبه به دو مجموعه براساس قرار گرفتن در نواحی یکنواخت و غیریکنواخت است. چرا که در نظر گرفتن اطلاعات پیکسل‌های همسایه‌ی پیکسل‌های غیرلبه که در نواحی غیریکنواخت قرار گرفته‌اند، باعث تارشدن تصویر فراتفکیک شده می‌شود. از طرف دیگر، برای کاهش بیشتر اثر تاری در لبه‌های تصویر فراتفکیک شده، فرایند جداگانه‌ای برای یادگیری وصله‌های با مرکزیت پیکسل‌های لبه و غیر لبه ارائه شده است. چرا که این وصله‌ها ماهیت متفاوتی دارند که در مقاله [۱۲۵] پیاده‌سازی شده است و نتایج آن آورده شده است.

[۱۲۵] حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با در نظر گرفتن سازگاری در همسایگی پیکسل‌ها و استفاده از روش خودیادگیرنده"، نشریه مهندسی برق و مهندسی کامپیوتر ایران، سال ۱۶، شماره ۲، ص ۱۵۷.

۳. در این رساله، یک روش برای در نظر گرفتن همسایگی در فضای ویژگی‌ها پیشنهاد شده است. در این روش از الگوریتم k -means برای خوشه‌بندی وصله‌ها و سپس الگوریتم LLE برای انتخاب وصله‌های مشابه و ضرایب بازسازی آن‌ها در هر خوشه، استفاده شده است که در مقاله [۱۲۶] ارائه می‌گردد.

[۱۲۶] حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۵) "افزایش تفکیک پذیری تک تصویری با استفاده از تقریب منیفلد و k -means"، پنجمین کنفرانس بین المللی مهندسی کامپیوتر، برق و الکترونیک، تهران.

۴. یک ایده جهت ساماندهی وصله‌ها قبل از شروع فاز آموزش، انجام خوشه‌بندی به نحوی که تعداد خوشه‌ها، برخلاف روش ارائه شده در بالا، ثابت نباشد و براساس محتوای تصویر ورودی مشخص می‌شود. لذا، در ادامه دو روش برای افزایش تفکیک‌پذیری تصویر مبتنی بر ناحیه‌بندی تصویر و استفاده از الگوریتم خوشه‌بندی زیرفضای تنک آورده شده است.

الف - ایده‌ی دیگری که در این رساله برای دسته‌بندی وصله‌ها مورد بررسی قرار گرفته است، ناحیه‌بندی تصاویر آموزشی و ایجاد یک مدل آموزشی به ازای هر ناحیه است. موضوعی که در این روش بدان توجه شده است، شروع ناحیه‌بندی از تصویر قرار گرفته در پایین‌ترین سطح هرم و سپس

تعمیم نواحی به دست آمده به تصاویر سطوح بالاتر است. دلیل ارائه این ایده، داشتن تعداد نواحی یکسان در تمامی تصاویر دو هرم است. چرا که با شروع ناحیه‌بندی از تصویر قرار گرفته در بالاترین سطح هرم، برخی نواحی در تصاویر سطوح پایین‌تر از بین رفته و اطلاعاتی در رابطه با این نواحی در دسترس نیست.

[۱۲۷] حبیبی م، احمدی‌فرد ع، حسن‌پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با یادگیری از نواحی استخراج‌شده تصویر ورودی"، *مجله بینایی ماشین و پردازش تصویر*، در حال انتشار.

ب- روش دیگر ارائه شده در این رساله، از الگوریتم‌های kmeans، خوشه‌بندی زیرفضای تنک و گراف همسایگی استفاده می‌کند. ابتدا وصله‌های تصاویر با استفاده از الگوریتم kmeans بر اساس محتوای تصویر به تعدادی خوشه تقسیم می‌شود. این خوشه‌بندی تا زمانی که خوشه‌های ایجاد شده تعداد اندک وصله نداشته باشند، ادامه دارد. سپس، وصله‌های هر خوشه بعنوان یک دیکشنری فراکامل در نظر گرفته شده و ضرایب تنک به ازای هر وصله محاسبه و گراف همسایگی ایجاد می‌شود. درنهایت، گراف همسایگی با استفاده از الگوریتم خوشه‌بندی طیفی به تعدادی زیرفضا تقسیم می‌شود. نتایج این روش در [P1] آورده شده است.

[P1] Habibi, M., Ahmadyfard, A. and Hassanpour, H., "Content-based Image Super-Resolution via Sparse Subspace Clustering", (Preparing).

۷-۱ ساختار رساله

کارهای انجام شده در این رساله بدین صورت سازماندهی می‌شود. در فصل ۲ روش‌های موجود در افزایش تفکیک پذیری تصویر مورد بررسی قرار می‌گیرند. فصل ۳ به ارائه‌ی جزییات مباحث مورد استفاده در روش‌های پیشنهادی رساله از قبیل هرم تصاویر، بازنمایی تنک، گرادیان مرتبه اول و دوم، رگرسیون بردار پشتیبان، معیارهای ارزیابی PSNR و SSIM و پایگاه داده مورد استفاده برای فاز آزمون پرداخته است. با

عنایت به این مساله که اطلاعات پیکسل‌های همسایه از قبل مشخص نیست، در این رساله یک پیمایش بالا به پایین و چپ به راست تعیین گردید تا ارزش پیکسل‌های بالا و سمت چپ پیکسل مورد ارزیابی از در مراحل قبلی مشخص و بازسازی شده باشد. از دیگر موارد، تفکیک پیکسل‌های لبه و غیرلبه و پیکسل‌های نواحی یکنواخت و غیریکنواخت است که می‌تواند در جلوگیری از تارشدن تصویر موثر باشد. از آنجائی که یکی از پیشنهادات اساسی در رساله، در نظر گرفتن اطلاعات همسایگی است، می‌توان به جای همسایگی مکانی به همسایگی در ویژگی‌ها نیز توجه کرد. لذا، براساس مطالب ذکر شده، روش‌هایی پیشنهاد گردید که در فصل ۴ بدان پرداخته شده است. در اغلب موارد، استفاده از یک روش واحد برای افزایش تفکیک‌پذیری تصاویر با بافت‌های مختلف می‌تواند باعث از بین رفتن جزئیات و هموارشدن تصویر شود. برای این منظور در فصل ۵ روش‌هایی برای افزایش تفکیک‌پذیری تصویر پیشنهاد شده است که در آن روش‌ها، از ناحیه‌بندی تصویر ورودی و بکارگیری الگوریتم خوشه‌بندی زیرفضای تنک جهت افزایش تفکیک‌پذیری استفاده شده است. در نهایت، رساله با جمع‌بندی کارهای انجام شده و ارائه پیشنهاداتی در خصوص کارهای آتی در فصل ۶ به پایان می‌رسد.

۸-۱ جمع‌بندی

از آنجائی که ایجاد تصویر تفکیک‌پذیری بالا بدلیل محدودیت‌ها و هزینه‌های سخت‌افزاری با استفاده از سیستم‌های تصویربرداری مقرون به صرفه نیست، بنابراین، از روش‌های افزایش تفکیک‌پذیری تصویر بعنوان الگوریتم‌های پس‌پردازش استفاده می‌شود. با توجه به مطالب ذکر شده در این فصل، تصویر تفکیک‌پذیری بالای اولیه بر اثر تخریب‌های سیستم‌های تصویربرداری دچار اختلال شده و تصویر تفکیک‌پذیری پایین ایجاد می‌گردد. از آنجائی که هدف این روش‌ها، ایجاد تصویر تفکیک‌پذیری بالای اولیه از تصویر تخریب شده‌ی تفکیک‌پذیری پایین ثانویه است، بنابراین، این روش‌ها یک مساله معکوس هستند.

در ابتدای این فصل تعریف اولیه از افزایش تفکیک پذیری تصویر بیان گردید و دو رویکرد اصلی آن توضیح داده شد. در ادامه ی فصل، برخی کاربردهای آن از قبیل پزشکی، سنجش از راه دور و نظارت ویدئویی بیان شد. پیدا کردن روشی مناسب برای یک کاربرد، کار سختی است. برای این منظور باید ملاحظات در نظر گرفته شود. به عنوان مثال، اگر بیش از یک تصویر از صحنه وجود داشته باشد، می توان از روش مبتنی بر چند فریم استفاده کرد و اگر یک یا تعداد بیش تر تصاویر آموزشی از صحنه های مختلف تفکیک پذیری بالا در دسترس باشد، روش مبتنی بر تک تصویر پیشنهاد می شود.

در پایان این فصل، هدف از پژوهش های انجام شده، نوآوری ها و ساختار کلی رساله ارائه شده است. در فصل بعدی، کارهای مرتبط با این روش ها به تفکیک رویکردهای اصلی آن و با تمرکز بر رویکرد مبتنی بر تک تصویر آورده شده و سپس به بررسی ایده های موجود در پژوهش های مطرح در این حوزه پرداخته می شود و براین اساس موارد مهم و تاثیرگذار انتخاب می گردد.

فصل ۲: مرور کارهای پیشین

همانطور که در فصل اول بیان شد، روش‌های افزایش تفکیک پذیری تصویر براساس استفاده از یک یا چندین تصویر ورودی، به دو دسته‌ی اصلی افزایش تفکیک پذیری تک تصویر و افزایش تفکیک پذیری مبتنی بر چندفریم تقسیم می‌شوند. در ادامه، پژوهش‌های انجام شده در هر دسته با تمرکز بر افزایش تفکیک پذیری تک تصویر مبتنی بر یادگیری ارائه می‌شود.

۱-۲ افزایش تفکیک‌پذیری تک تصویر

افزایش تفکیک‌پذیری تک تصویر، مساله تخمین تصویر تفکیک‌پذیری بالا از تنها یک تصویر تفکیک‌پذیری پایین ورودی است. فرض این روش‌ها، عدم سترسی به مرحله‌ی تصویربرداری است، بطوری‌که نقطه‌ی شروع این الگوریتم‌ها، یک تصویر تفکیک‌پذیری پایین داده شده است که از فرایند تصویربرداری به دست آمده است. فرایند تولید تصویر تفکیک‌پذیری پایین از تصویر تفکیک‌پذیری بالایی اولیه، معمولاً بصورت رابطه‌ی (۱-۲) نوشته می‌شود.

$$I_L = (I_H * b) \downarrow_s \quad (1-2)$$

که در اینجا، I_L و I_H به ترتیب تصویر تفکیک‌پذیری پایین و تفکیک‌پذیری بالا، b یک هسته تارکننده‌ی تصویر اصلی که معمولاً بصورت تارکننده‌ی گوسین مدل می‌شود [۲۱]. $\downarrow_s$ یک عملگر کاهش نرخ نمونه‌برداری است که در آن s ، ضریب کاهش نرخ نمونه‌برداری است. بنابراین، تصویر تفکیک‌پذیری پایین بر اثر تار شدن و کاهش نرخ نمونه‌برداری از تصویر تفکیک‌پذیری بالا به دست می‌آید.

۲-۲ الگوریتم‌های افزایش تفکیک پذیری تک تصویر

الگوریتم‌های افزایش تفکیک پذیری تک تصویر می‌توانند به دو دسته‌ی افزایش تفکیک پذیری مبتنی بر درون‌یابی و مبتنی بر یادگیری تقسیم شوند که در ادامه به تفکیک با تمرکز بیشتر بر روش‌های مبتنی بر یادگیری، توضیح داده می‌شود.

۲-۲-۱ افزایش تفکیک پذیری تک تصویر مبتنی بر درون‌یابی

روش‌های ساده‌ی درون‌یابی از قبیل درون‌یابی نزدیک‌ترین همسایه، درون‌یابی دو خطی و درون‌یابی دومکعبی بدلیل سادگی محاسباتی در روش‌های افزایش تفکیک پذیری تصویر بسیار مورد استفاده قرار می‌گیرند. این روش‌ها از اطلاعات پیکسل‌های همسایه برای تخمین مقدار هر پیکسل استفاده می‌کنند. بنابراین، باعث تارشدن تصویر بخصوص در نواحی لبه می‌شوند. برای غلبه بر این مشکل، روش‌های درون‌یابی پیچیده‌تری پیشنهاد شده است. برای این منظور، hwang و همکارانش [۲۲]، دو روش درون‌یابی تطبیقی را بوسیله‌ی ترکیب گرادیان معکوس با درون‌یابی‌های دوخطی و دومکعبی، پیشنهاد کرده‌اند. Luong و همکارانش [۲۳]، یک روش درون‌یابی غیرمحلّی را ارائه کرده‌اند که مقدار یک پیکسل ناشناخته را براساس تمامی پیکسل‌های شناخته شده تخمین می‌زند. روش‌های ذکر شده در بالا، لبه‌ها را در طی مرحله‌ی درون‌یابی حفظ کرده و تصویر تفکیک پذیری بالای بازسازی شده را تیزتر می‌کند. در [۲۴]، Fei Zhou و همکارانش، از چندین سطح برای تخمین مقادیر پیکسل‌ها در تصویر تفکیک پذیری بالا استفاده کرده‌اند. این سطوح می‌توانند به طور موثر جزئیات تصویر مانند گرادیان، انحنا و یا حتی اطلاعات مرتبه بالاتر از تصویر را حفظ کنند. وزن هر سطح در تخمین ارزش پیکسل تصویر تفکیک پذیری بالا، متفاوت است. مقدار نهایی هر پیکسل در تصویر تفکیک پذیری بالا، از ترکیب مقادیر تخمین‌زده شده با در نظر گرفتن وزن‌ها به دست می‌آید. ادعا شده است که روش پیشنهادی [۲۴]، جزئیات تصویر را بطور موثر حفظ کرده است.

مفهوم دوگانگی هندسی، اولین بار توسط Xin Li و همکارش در [۲۵] مطرح شد. آن‌ها به دوگانگی هندسی موجود بین تصویر تفکیک پذیری بالا و تصویر تفکیک پذیری پایین متناظر با آن اشاره کرده‌اند. براساس اصل دوگانگی هندسی، کواریانس تصویر تفکیک پذیری بالا بوسیله‌ی محاسبه‌ی کواریانس تصویر تفکیک پذیری پایین تخمین زده می‌شود. سپس کواریانس محاسبه شده برای انجام درونیابی تطبیقی مورد استفاده قرار می‌گیرد. برای افزایش سرعت محاسباتی، این الگوریتم تنها برای نواحی لبه اجرا شده است و برای نواحی هموار درونیابی دومکعبی مورد استفاده قرار گرفته است. روش پیشنهادی [۲۵] باعث ایجاد لبه‌های تیز در تصویر تفکیک پذیری بالای خروجی می‌شوند ولی مقدار PSNR این تصاویر پایین است. در برخی موارد امکان پیدا کردن ساختار هندسی وصله‌ی تفکیک پذیری بالا در وصله‌ی تفکیک پذیری پایین متناظر وجود ندارد و این یکی از مشکلات این روش است.

برخی روش‌های درونیابی برای حفظ لبه‌های تصویر از معادلات دیفرانسیل جزئی^۱ استفاده می‌کنند [۲۶]، [۲۷]، [۲۸]، [۲۹] و [۳۰]. روش‌های مبتنی بر PDE، بر روی نواحی هموار از انتشار ایزوتروپیک و بر روی لبه‌ها از انتشار آنیزوتروپیک استفاده می‌کنند.

چانگ و همکارانش یک روش درونیابی براساس تجزیه و تحلیل موجک پیشنهاد کرده‌اند [۳۱]. در این الگوریتم، ابتدا لبه‌های تصویر با استفاده از نقاط دارای تغییرات شدید در دامنه‌ی موجک، کلاس‌بندی می‌شوند و سپس براساس نوع لبه، درونیابی انجام می‌گردد.

۲-۲-۲ افزایش تفکیک پذیری تک تصویر مبتنی بر یادگیری

همانطور که در بخش‌های قبلی بیان شد، روش‌های متعددی برای افزایش تفکیک پذیری تصویر وجود دارد ولی الگوریتم‌های افزایش تفکیک پذیری مبتنی بر یادگیری بطور کلی نتایج دقیق‌تری را در مقایسه با سایر

^۱ Partial Differential Equation (PDE)

روش‌ها ارائه می‌دهند. در روش‌های مبتنی بر یادگیری، نحوه انتخاب مجموعه داده‌های آموزشی، تاثیر به سزایی بر کیفیت تصویر خروجی دارد که این مساله یکی از چالش‌های موجود در این روش‌ها است. روش‌های افزایش تفکیک پذیری مبتنی بر یادگیری نیز می‌توانند براساس استفاده از دیکشنری خارجی و یا دیکشنری داخلی در دو دسته‌ی جداگانه قرار بگیرند که در ادامه نحوه‌ی ایجاد این دو دیکشنری توضیح داده می‌شود. به منظور ایجاد یک دیکشنری خارجی، چندین تصویر طبیعی تفکیک پذیری بالا بعنوان داده آموزشی در نظر گرفته می‌شوند. برای هر تصویر آموزشی، I_H ، تصویر متناظر تفکیک پذیری پایین آن، I_L ، با استفاده از رابطه ۱-۲ ایجاد می‌گردد. تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین متناظر به وصله‌های مساوی تقسیم می‌شوند. دو وصله که از یک تصاویر آموزشی (تصویر اصلی تفکیک پذیری بالا و تصویر تفکیک پذیری پایین متناظر با آن) در موقعیت یکسان استخراج شده‌اند، تشکیل یک زوج می‌دهند. دیکشنری خارجی، مجموعه‌ای از این زوج‌های به دست آمده است.

یک دیکشنری داخلی تنها با استفاده از تصویر ورودی تفکیک پذیری پایین، بدون نیاز به تصویر دیگری، ساخته می‌شود. این مورد اخیر از ویژگی خودهمانندی^۱ استفاده می‌کند. با توجه به اینکه ساختارهای یک تصویر تمایل به تکرار در همان تصویر و یا اندازه‌های مختلف از آن تصویر دارند، لذا، وصله‌های مشابه می‌توانند در همان تصویر ورودی و یا نسخه‌هایی با اندازه‌های مختلف آن پیدا شوند. در این حوزه می‌توان به الگوریتم‌های یک مرحله‌ای [۳۲] و [۳۳] و یا الگوریتم‌های مبتنی بر هرم که از اندازه‌های مختلف تصاویر با شروع از تصویر تفکیک پذیری پایین ورودی [۳۴]، [۱۹] و [۳۵] استفاده می‌کنند، اشاره کرد. هدف الگوریتم‌های یک مرحله‌ای کاهش تاحد امکان اندازه‌ی دیکشنری داخلی یعنی تعداد نمونه‌هایی که در بازسازی وصله مورد بررسی قرار می‌گیرند، است. لذا، زمان محاسباتی الگوریتم افزایش تفکیک پذیری نیز کاهش می‌یابد. در حقیقت، با استفاده از تصویر ورودی، تنها یک جفت از تصاویر آموزشی ایجاد می‌شود و

^۱ self-similarity

برای تولید دیکشنری مورد استفاده قرار می‌گیرد. در حالی که در روش‌های مبتنی بر هرم، برخلاف روش‌های یادگیری یک مرحله‌ای، چندین تصویر آموزشی با استفاده از اعمال روش‌های کاهش نرخ نمونه‌برداری بر تصویر ورودی تفکیک پذیری پایین، ساخته می‌شوند، به این ترتیب، یک هرم وارونه شکل می‌گیرد. برای یک وصله از تصویر ورودی، تمامی سطوح این هرم برای پیدا کردن مشابه‌ترین نمونه با انجام یک جستجوی نزدیکترین همسایه^۱، استفاده می‌شود.

واضح است که مزیت داشتن یک دیکشنری خارجی به جای یک دیکشنری داخلی در این است که دیکشنری خارجی از قبل ساخته می‌شود، در حالی که دیکشنری داخلی به ازای هر تصویر بطور جداگانه ایجاد شده و در هر اجرای الگوریتم، بروزرسانی می‌شود. با این حال، دیکشنری‌های خارجی یک عیب قابل توجه دارند و آن عدم تطبیق با تصویر ورودی است.

در برخی روش‌های افزایش تفکیک پذیری مبتنی بر یادگیری که روش‌های مبتنی بر نمونه، [۲۰] و [۳۶]، نامیده می‌شوند، از دیکشنری خارجی استفاده می‌شود. در حالی که در دسته‌ی دیگری از روش‌های مبتنی بر یادگیری که روش‌های خودیادگیرنده [۳۷] و [۳۲] شناخته می‌شوند، از افزونگی‌های موجود در سطوح مختلف هرم تصویر استفاده می‌شود که این امر چالش موجود در روش‌های مبتنی بر یادگیری را به حداقل می‌رساند. در ادامه کارهای انجام شده در این دو حوزه به تفکیک مورد بحث و بررسی قرار می‌گیرند.

۲-۲-۱-۲ افزایش تفکیک پذیری مبتنی بر نمونه

هدف روش‌های تک تصویر مبتنی بر نمونه، به دست آوردن مدل معکوس رابطه (۱-۲) بوسیله‌ی دیکشنری‌ای از وصله‌های تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین متناظر با آن است. همانطور که در بخش قبلی بیان شد، در این روش از دیکشنری خارجی استفاده شده است که برای ایجاد این دیکشنری،


^۱ Nearest Neighbor Search(NNS)

تعدادی تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین متناظر جمع‌آوری شده و سپس این تصاویر به وصله‌هایی با اندازه‌ی یکسان تقسیم می‌شوند. در این دیکشنری، ارتباط بین وصله‌های تفکیک پذیری بالا و تفکیک پذیری پایین متناظر آموزش داده می‌شود. پس از ایجاد و آموزش دیکشنری، به ازای هر وصله در تصویر تفکیک پذیری پایین ورودی، وصله‌ی تفکیک پذیری بالای متناظر آن، با جستجو کردن وصله‌ی تفکیک پذیری پایین در دیکشنری، مشخص می‌شود. بنابراین، الگوریتم‌های افزایش تفکیک پذیری مبتنی بر نمونه شامل دو مرحله می‌باشند. در مرحله‌ی آموزش، دیکشنری‌ای از وصله‌ها ایجاد می‌شود. در مرحله دوم که هدف آن افزایش تفکیک پذیری تصویر است، از دیکشنری تولید شده در مرحله‌ی قبل برای افزایش اندازه‌ی تصویر ورودی استفاده می‌شود. در ادامه، کارهای انجام شده در این زمینه ارائه می‌شود.

یکی از اولین مقاله‌ها در رابطه با افزایش تفکیک پذیری مبتنی بر نمونه که توسط فریمن و همکارانش [۲۰] منتشر شد، یک تحقیق گسترده در زمینه‌ی افزایش تک تصویر مبتنی بر یادگیری را آغاز کرده است. هرچند روش فریمن بوسیله‌ی برخی محدودیت‌ها از قبیل بیش برآزش^۱، وابستگی به داده‌های خارجی در برخی موارد و غیره، محدود می‌شود ولی می‌توان آن را به عنوان یک روش افزایش تفکیک پذیری تصویر قابل قبول در نظر گرفت. فریمن و همکارانش [۲۰]، از مدل مخفی مارکوف برای مدل‌سازی ارتباط بین نواحی مختلف تصویر استفاده کرده‌اند که این روش به تعداد داده‌های آموزشی زیادی نیاز داشته و قدرت تعمیم‌پذیری پائینی دارد. بیش‌ترین تاکید نویسندگان [۲۰] بر عدم کفایت تنها استفاده از اطلاعات محلی وصله‌های تصویر برای ایجاد تصویری با تفکیک پذیری بالا است. نویسندگان معتقدند که باید به اطلاعات وصله‌های مجاور برای تولید تصویر خروجی توجه شود. در [۲۰] دو روش متفاوت برای در نظر گرفتن ارتباط وصله‌های همسایه در الگوریتم‌های افزایش تفکیک پذیری تصویر بیان شده است. در روش اول از شبکه

¹ overfitting


مارکوف برای مدل کردن ارتباط بین وصله‌های تفکیک پذیری پائین و تفکیک پذیری بالا و همچنین بین همسایگان وصله‌های تفکیک پذیری بالا، استفاده شده است که در شکل (۲-۱) نشان داده شده است.



شکل (۲-۱) مدل شبکه مارکوف برای مساله افزایش تفکیک پذیری تصویر [۲۰]

روش دوم، یک الگوریتم تک مرحله‌ای است. در این روش، پس از انتخاب وصله‌ی تفکیک پذیری بالای متناظر با وصله‌ی تفکیک پذیری پایین ورودی، در هنگام جستجوی مجموعه‌ی آموزشی برای در نظر گرفتن بهترین وصله براساس وصله‌های همسایه، به میزان هم پوشانی وصله‌ی تفکیک پذیری بالا با وصله‌های تفکیک پذیری بالایی که قبلاً پیش‌بینی و مشخص شده‌اند نیز توجه می‌شود. وزنی در این روش وجود دارد که توسط کاربر قابل کنترل بوده و α نامیده می‌شود. این پارامتر میزان اهمیت مشابه بودن وصله‌ی تفکیک پذیری پائین با وصله‌ی تفکیک پذیری بالای انتخاب شده در مقابل میزان اهمیت سازگاری بین وصله‌ی تفکیک پذیری بالا جدید با وصله‌های تفکیک پذیری بالای مجاورش که قبلاً بازسازی شده‌اند، می‌باشد. وصله‌ی جدید در تصویر تفکیک پذیری بالا برای تولید تصویر نهایی قرار داده می‌شود. . بلوک دیاگرام [۲۰] در شکل (۲-۲) نشان داده شده است.

¹ One-Pass Algorithm



شکل (۲-۲) بلوک دیاگرام الگوریتم تک گذر مرجع [۲۰]

استفاده از تقریب منیفلد^۱ برای افزایش تفکیک پذیری تصویر در [۳۶]، [۳۸]، [۳۹]، [۴۰] و [۴۱] مطرح شده است. تمرکز روش های افزایش تفکیک پذیری تصویر مبتنی بر تقریب منیفلد بر یادگیری ویژگی های توابع نگاشت بین وصله های با تفکیک پذیری پایین و با تفکیک پذیری بالای متناظر است. در [۳۹]، [۴۰] و [۴۱] از تقریب منیفلد تنها برای وصله های تصاویر تفکیک پذیری بالا استفاده شده است. در این مقالات، ابتدا مجموعه وصله های تفکیک پذیری بالا به زیرفضاهایی تقسیم بندی شده و سپس فضای مماسی^۲ برای هر زیرفضا تخمین زده می شود. تفاوت این مقالات در روش تقسیم بندی مجموعه وصله های تفکیک پذیری بالا و روش انتخاب فضای مماس است. با توجه به دسته بندی الگوریتم های افزایش تفکیک پذیری تصویر در این رساله، [۳۹] و [۴۰]، بدلیل نیاز به پایگاه داده ای از تصاویر آموزشی، در گروه الگوریتم های افزایش تفکیک پذیری مبتنی بر نمونه و [۴۱] جزء الگوریتم های افزایش تفکیک پذیری خودیادگیرنده است که در بخش بعدی ارائه می شود. در [۳۹]، فضای منیفلد تفکیک پذیری بالا از طریق یک روش جدید تقریب خطی محلی

^۱Manifold Approximation

^۲Tangent Space

با استفاده از خوشه‌بندی زیرفضای تنکی^۱، [۴۲]، مورد تحلیل قرار می‌گیرد. مجموعه‌ی نهایی فضاهای مماسی تقریب‌زده شده برای تعیین یک وصله‌ی تفکیک پذیری بالا متناظر با یک وصله‌ی تفکیک پذیری پایین داده شده، استفاده می‌شود. درحالی‌که تمرکز [۴۰] بر نحوه‌ی تخمین منیفلد وصله‌های تفکیک پذیری بالا با انتخاب کوچکترین زیر مجموعه‌ی بهینه از فضاهای مماس و نحوه‌ی انتخاب نزدیکترین فضای مماس از مجموعه فضاهای مماس، برای هر وصله‌ی تصویر تفکیک پذیری پایین است.


در [۳۶] و [۳۸] از الگوریتم تعبیه شده خطی محلی^۲ برای وصله‌های تفکیک پذیری بالا و تفکیک پذیری پائین تصویر استفاده شده است. چانگ و همکارانش [۳۶] از تخمین میزان شباهت هندسه‌ی محلی بین منیفلدهای تفکیک پذیری بالا و تفکیک پذیری پایین برای افزایش تفکیک پذیری تصویر مبتنی بر نمونه، استفاده کرده‌اند.

در [۴۳]، یک مجموعه بزرگ از جفت تصاویر تفکیک پذیری بالا و تفکیک پذیری پائین، از تصاویر طبیعی جمع‌آوری شده و در دسته‌های مختلفی خوشه‌بندی می‌شوند. سپس، قوانین فازی برای هر یک از این خوشه‌ها تولید می‌شود.

در [۴۴]، وصله‌های تصاویر موجود در دیکشنری (تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین) استخراج می‌شود و سپس ضرایب تنکی به ازای هر وصله‌ی تفکیک پذیری پایین محاسبه می‌گردد. با استفاده از رگرسیون بردار پشتیبان ارتباط بین ضرایب تنکی وصله‌های تفکیک پذیری پایین و ارزش پیکسل‌ها در وصله‌ی تفکیک پذیری بالای متناظر، مدل می‌شود. از مدل تخمین‌زده شده برای تعیین مقادیر پیکسل‌ها در تصویر خروجی استفاده می‌شود. بلوک دیاگرام روش [۴۴]، در شکل (۳-۲) آورده شده است.

¹ Sparse Subspace Clustering (SSC)

² Locally Linear Embedding (LLE)



شکل (۳-۲) بلوک دیاگرام الگوریتم مرجع [۴۴]


روش‌های پیشنهادی مبتنی بر تئوری، می‌توانند با یک پایگاه داده کوچکتر به دلیل فضای خطی که از فرایند یادگیری دیکشنری ایجاد می‌شود، کار کنند. مولفین [۴۵] نیز از ضرایب تئوری بعنوان ویژگی هر وصله، استفاده کرده‌اند. ایده‌ی این مرجع، بکارگیری دو دیکشنری مجزا برای تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین است. درحالی که روش ارائه شده در [۴۵] تنها برای تصاویر عمومی پیشنهاد شده است، الگوریتم پیشنهادی مرجع علاوه بر افزایش تفکیک پذیری تصاویر عمومی، برای افزایش تفکیک پذیری تصاویر چهره نیز مورد استفاده قرار می‌گیرد. در [۴۵]، برای تصاویر عمومی کاملاً مشابه [۴۶] عمل کرده و برای تصاویر چهره رویکرد متفاوتی دارد. این مرجع مشابه [۴۵] از دو دیکشنری استفاده می‌کند. در [۴۶]، از دو روش برای ایجاد دیکشنری‌های مورد نیاز استفاده می‌شود. در روش اول، آموزش هریک از دیکشنری‌های تصاویر آموزشی تفکیک پذیری بالا و تصاویر آموزشی تفکیک پذیری پایین بطور جداگانه و در روش دوم، آموزش این دو دیکشنری همزمان انجام می‌شود. تا حد زیادی، کارایی این روش به تعداد عناصر دو دیکشنری وابسته است. اگر تعداد اتم‌های دیکشنری کاهش یابد، نتیجه‌ی الگوریتم بطور چشمگیری کاهش خواهد یافت. با این حال، یادگیری تعداد زیاد اتم در دیکشنری نیاز به زمان محاسباتی بسیار طولانی برای الگوریتم دارد. در مراجع [۴۶] و [۴۵]، با تغییر ضریب افزایش تصویر، نیاز به آموزش مجدد دیکشنری‌ها است.

استفاده از حداقل مربعات جزئی^۱ یکی دیگر از روش‌های ارائه شده در این دسته از الگوریتم‌های افزایش تفکیک پذیری تصویر است [۴۷]. در این مرجع، از دو مدل KPLS^۲ استفاده شده است. مدل اول براساس

^۱ Partial Least Squares

^۲ Kernel Partial Least Squares (KPLS)

تصاویر آموزشی تفکیک پذیری بالا و تفکیک پذیری پائین متناظر با آن ایجاد می‌شود که خروجی این مدل باعث ایجاد نسخه اولیه تصویر وضوح بالا می‌شود. در تصویر وضوح بالای ایجاد شده، برخی اطلاعات جزئی از دست رفته است. لذا، برای جبران این مساله، گام دوم شروع شده و از مدل دوم استفاده می‌شود. ابتدا، به ازای تمامی تصاویر مجموعه آموزشی، نسخه اولیه تصویر خروجی ایجاد می‌گردد. تفاضل این تصاویر و تصویر وضوح بالای اصلی در مجموعه‌ی آموزشی محاسبه می‌شود که تصاویر به دست آمده، تصاویر وضوح بالای باقی مانده نامیده می‌شوند. بطور مشابه، تصاویر وضوح پائین باقی مانده نیز از تفاضل نسخه‌ی کاهش نمونه یافته تصاویر وضوح بالای اولیه و تصاویر وضوح پائین اصلی مجموعه‌ی آموزشی به دست می‌آیند. ارتباط بین تصاویر وضوح بالای باقی مانده و وضوح پائین باقی مانده دوباره توسط *KLPS* مدل می‌شود. براساس مدل‌های ایجاد شده و تصویر ورودی وضوح پائین، تصویر وضوح بالای اولیه و وضوح بالای باقی مانده ایجاد و از ترکیب این دو تصویر، تصویر خروجی الگوریتم به دست می‌آید. مراحل بیان شده در بالا در شکل (۲-۴) نشان داده شده است.




شکل (۲-۴) دیاگرام روش پیشنهادی مرجع [۴۷]

مولفین [۴۸]، الگوریتم پیشنهادی [۴۶] را با ساده سازی فرآیند کلی از لحاظ پیچیدگی محاسباتی و معماری الگوریتم تغییر دادند. از مهم ترین تغییرات می توان به استفاده از الگوریتم کاهش ابعاد PCA برای کوچک کردن بردارهای ویژگی و وصله های تفکیک پذیری بالا و تفکیک پذیری پایین و سرعت بخشیدن به مرحله آموزش دیکشنری، بکارگیری الگوریتم های متفاوت برای آموزش دیکشنری و وصله های تفکیک پذیری پایین و تفکیک پذیری بالا، استفاده از الگوریتم سریع OMP بعنوان الگوریتم کدگذاری تنگی به جای روش های مبتنی بر بهینه سازی L_1 ، ساده سازی الگوریتم پیشنهادی با حذف مراحل تکراری روش [۴۶] و امکان استفاده از این الگوریتم بدون داشتن مجموعه ی آموزشی و تنها با استفاده از تصویر ورودی اشاره کرد. ژانگ و همکارانش، یک روش افزایش تفکیک پذیری تصویر مبتنی بر نمایش تنگی را پیشنهاد داده اند که برای

کاهش پیچیدگی محاسباتی از آموزش یک دیکشنری دوگانه و جایگزینی مرحله‌ی استخراج ضرایب تنکی با ضرب ساده ماتریسی استفاده کرده‌اند [۴۹].

مولفین مرجع [۳۴]، یک رویکرد ترکیبی پیشنهاد کرده‌اند که دو روش افزایش تفکیک پذیری تصویر کلاسیک و افزایش تصویر مبتنی بر نمونه را که در بالا توضیح داده شده است، بایکدیگر ترکیب می‌کند. ایده‌ی این کار این است که هر وصله در تصویر طبیعی تمایل به چندین بار تکرار در همان تصویر و یا مقیاس‌های مختلف آن تصویر دارد. در صورت تکرار وصله در تصویر ورودی از افزایش تفکیک پذیری کلاسیک و در صورت تکرار وصله در تصاویر تفکیک پذیری پائین ایجاد شده از تصویر ورودی، از روش افزایش مبتنی بر نمونه استفاده می‌شود. بلوک دیاگرام این روش در شکل (۵-۲) آورده شده است.



شکل (۵-۲) بلوک دیاگرام الگوریتم مرجع [۳۴]

در نهایت، عملکرد روش‌های افزایش تفکیک پذیری تصویر مبتنی بر نمونه به شدت به تصاویر تفکیک پذیری بالا در پایگاه داده وابسته می‌باشد. یک سوال اساسی این است که آیا یک دیکشنری سراسری وجود دارد که بتواند با دقت تمام وصله‌های تصویر را دربرداشته باشد. از آنجائی که یادگیری یک مجموعه‌ی آموزشی، امکان

بکارگیری نمونه‌های بیشتری از تصویر را می‌دهد، اما دقت اطلاعات به دست آمده از پایگاه داده برای تصویر تفکیک پذیری پایین داده شده تضمین نمی‌شود. تصویر تفکیک پذیری بالای خروجی ممکن است به نظر قابل قبول باشد، اما جزئیات به دست آمده از پایگاه داده ممکن است نامعتبر باشد زیرا در حال حاضر، یک دیکشنری سراسری که بتواند تمامی وصله‌های تصویر را در برداشته باشد، در دسترس نیست. اخیراً، تمرکز پژوهش‌های انجام شده بر افزایش تفکیک پذیری خودیادگیرنده است که می‌تواند بر محدودیت‌های افزایش تفکیک پذیری تصویر مبتنی بر نمونه غلبه کند. در بخش بعدی، افزایش تفکیک پذیری تصویر خودیادگیرنده مورد بحث و بررسی قرار می‌گیرد.

۲-۲-۲-۲ افزایش تفکیک پذیری خودیادگیرنده (خودهمانندی)

روش‌های افزایش تفکیک پذیری خودیادگیرنده بعنوان یک دسته از روش‌های مبتنی بر تک تصویر در نظر گرفته شده است. در این روش، تنها از تصویر تفکیک پذیری پایین ورودی استفاده می‌شود و هزینه‌ی محاسباتی و میزان حافظه‌ی مصرفی آن در مقایسه با روش افزایش تفکیک پذیری مبتنی بر نمونه، اندک است.


فرض اساسی روش افزایش تفکیک پذیری خودیادگیرنده این است که تعداد بسیاری از وصله‌های مشابه در تصویر تفکیک پذیری پایین و یا اندازه‌های متفاوت تصویر تفکیک پذیری پایین وجود دارد. بنابراین در این رویکرد از تشابه مابین وصله‌های مختلف تصویر ورودی و یا وصله‌های موجود در اندازه‌های مختلف آن، استفاده می‌شود.

روش‌های افزایش تفکیک پذیری خودیادگیرنده بعنوان یک روش افزایش تفکیک پذیری مناسب در نظر گرفته می‌شود. در این روش‌ها، علیرغم این واقعیت که پایگاه داده‌ای از تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین وجود ندارد، اجزای فرکانس بالای از دست رفته بطور رضایت‌بخشی بهبود می‌یابد. الگوریتم‌های

افزایش تفکیک پذیری خودیادگیرنده شامل دو مرحله‌ی اصلی می‌باشند. اولین مرحله، نحوه‌ی ایجاد مقیاس‌های مختلف تصویر ورودی رامشخص می‌کند. برای این منظور از الگوریتم‌های ساده‌ی درونیابی از قبیل درونیابی نزدیکترین همسایه، دو خطی و دومکعبی برای کاهش و افزایش نرخ نمونه‌برداری جهت ایجاد مقیاس‌های متفاوت تصویر ورودی، استفاده می‌شود. در اغلب مقالات درونیابی دومکعبی استفاده شده است. در مرحله‌ی دوم، نحوه‌ی افزایش تفکیک پذیری تصویر ارائه می‌شود. الگوریتم‌های خودیادگیرنده بدلیل جستجوی محلی وصله‌ها (به جای جستجوی سراسری) و عدم نیاز به استفاده از پایگاه داده‌ی خارجی می‌توانند به عنوان یک الگوریتم سریع طبقه‌بندی شوند. در ادامه، پژوهش‌های انجام شده در این زمینه مورد بررسی قرار می‌گیرد.

مقالات متعددی در زمینه توسعه روش‌های خودیادگیرنده وجود دارد. چی یوان یانگ و همکارانش، مشکل افزایش تفکیک پذیری تصویر را از دیدگاه مبتنی بر نمونه نشان داده‌اند [۵۰]. آن‌ها همچنین ادعا کرده‌اند که نیازی به استفاده از یک مجموعه تصویربرداری خارجی برای نگاشت بین زوج وصله‌های تفکیک پذیری بالا و تفکیک پذیری پایین وجود ندارد. در این قبیل روش‌ها، به جای استخراج وصله‌ها از پایگاه داده تصویر خارجی، تلاش بیشتری برای بررسی رابطه بین وصله‌ها در مقیاس‌های مختلف تصویر ورودی انجام می‌شود. در [۵۱] از الگوریتم درونیابی دومکعبی برای کاهش و افزایش نرخ نمونه‌برداری تصویر ورودی جهت ایجاد دو هرم تصویر تفکیک پذیری بالا و تفکیک پذیری پایین استفاده شده است. جفت تصاویر تفکیک پذیری بالا و تفکیک پذیری پایین در سطوح مشابه، به وصله‌هایی تقسیم شده و ضرایب T_n بکنون ویژگی هر وصله‌ی تفکیک پذیری بالا استخراج می‌شود. سپس، به ازای هر سطح مشابه دو هرم، یک مدل رگرسیونی شدت روشنایی با استفاده از ویژگی‌های وصله‌های وضوح پایین و ارزش پیکسل‌ها در وصله‌ی وضوح بالای متناظر و یک مدل براساس خطای تخمین مدل رگرسیونی شدت روشنایی، آموزش داده می‌شود. در نهایت،

برای ایجاد تصویر تفکیک پذیری بالای خروجی، از مدل‌های آموزش داده شده استفاده می‌شود. چارچوب روش [۵۱] در شکل (۶-۲) نشان داده شده است.




شکل (۶-۲) بلوک دیاگرام الگوریتم مرجع [۴۴]

در شکل (۶-۲)، I_0 ، تصویر ورودی وضوح پائین و I_{SR} تصویر خروجی با وضوح بالا است. تصاویر I_{-1} ، I_{-2} ، ... با کاهش نرخ نمونه‌برداری از تصویر ورودی ایجاد شده‌اند. تصاویر با وضوح پائین در سطح I ام هرم، S_i نامیده می‌شوند. مدل‌های I -SVR های رگرسیونی شدت روشنایی به ازای هر سطح هرم و E -SVR مدل‌های خطای تخمین مدل‌های I -SVR است.

در [۱۹]، ابتدا، جفت وصله‌های تفکیک پذیری پایین و تفکیک پذیری بالای متناظر از تصویر ورودی با استفاده از کاهش و افزایش نرخ نمونه‌برداری و پیدا کردن وصله‌های مشابه در مقیاس‌های مختلف تصویر ورودی، استخراج می‌شود. برای این منظور، به ازای هر وصله از تصویر ورودی، بدنبال تعدادی وصله‌ی مشابه در تصاویر سطوح پایین هرم هستیم. برای هر وصله مشابه به وصله تصویر، ناحیه‌ای متناسب با آن، در تصویر ورودی تعیین می‌گردد. سپس این ناحیه براساس سطحی که وصله مشابه در آن پیدا شده است، در تصویر سطح بالای تصویر ورودی که موافق با سطح وصله مشابه است و در مکان متناسب با وصله تصویر ورودی، کپی می‌شود (شکل (۷-۲)). سپس، با استفاده از محدودیت‌های تُنکی گروهی^۱ بین جفت وصله‌های مشابه،

¹ Group Sparsity Constraint

تصویر تفکیک پذیری بالای خروجی ایجاد می‌گردد. برای اعمال محدودیت‌های گروهی، از روش خوشه‌بندی k-means جفت وصله‌هایی که دارای بردارهای ویژگی مشابه هستند، استفاده می‌شود. زمانی که ضرائب تُنکی گروهی برای تک تک خوشه‌ها به دست آمد، نیاز به بروزرسانی دیکشنری برای بهینه‌سازی سراسری مساله است. بروزرسانی دیکشنری با استفاده الگوریتم K-SVD ارائه شده در [۵۲]، انجام می‌شود.



شکل (۷-۲) استخراج افزونگی وصله‌های موجود در اندازه‌های مختلف تصویر در یک هرم تصویر [۱۹]

همانطور که در بخش ۱-۲-۲-۱ بیان شد، روش [۴۱] جزء روش‌های خودیادگیرنده است. سه تفاوت عمده بین روش ارائه شده در [۳۹] و [۴۱] وجود دارد. اولین تفاوت این است که منیفلد وصله‌های تصویر تفکیک پذیری بالا در [۴۱] بطور بلادرنگ با استفاده از تک تصویر ورودی آموزش داده می‌شود و نیازی به آموزش برون خط و یا دیکشنری خارجی، برخلاف مواردی که در [۳۹] استفاده شده است، نیست. در [۴۱] از الگوریتم min-max ارائه شده در [۵۳] برای انتخاب تعداد محدود و مناسب از وصله‌ها برای فرایند خودیادگیرنده استفاده شده است که این دومین تفاوت [۳۹] و [۴۱] است. آخرین تفاوت، تعمیم رویکرد [۴۱] برای تقریب فضای مماسی خطی با استفاده از SVD است.

مولفین مرجع [۵۴]، یک کتاب کد^۱ برای نشان دادن رابطه‌ی بین مولفه‌های فرکانس پایین و فرکانس بالا با توجه به خودهمبستگی محلی طراحی کرده‌اند. تصویر تفکیک پذیری پایین برای ایجاد دو کتاب کد استفاده می‌شود که مربوط به مولفه‌های فرکانس پایین و فرکانس بالای وصله‌های تصویر است. پس از جستجو برای پیدا کردن وصله‌های مشابه در کتاب کد فرکانس پایین، وصله‌ی متناظر در کتاب کد فرکانس بالا را می‌توان برای بازسازی اطلاعات فرکانس بالای از دست رفته به وصله‌ی تصویر هدف اضافه کرد.

مولفین [۵۵] از خودهمبستگی‌های غیرمحلی برای تخمین مناسب ضرایب کدگذاری^۲ تنگی تصویر اصلی استفاده کرده‌اند. در [۵۶] یک معیار خودهمبستگی ساختاری^۲ معرفی شده است. این معیار در صورتی که تعداد وصله‌های مشابه بیش‌تری در یک تصویر سنجش از راه دور وجود داشته باشد، مقدار بیش‌تری دارد. بنابراین، نتایج بازسازی بهتری به دست می‌آید.

۳-۲ افزایش تفکیک پذیری مبتنی بر چند فریم


هدف روش‌های مبتنی بر چند فریم، استفاده از اطلاعات یک مجموعه از تصاویر تفکیک پذیری پایین بعنوان ورودی برای ایجاد یک تصویر تفکیک پذیری بالای خروجی است. ایده‌ی اصلی این روش‌ها، بازسازی اطلاعات فرکانس بالای از دست رفته با بکارگیری اطلاعات اضافی به دست آمده از حرکت بین پیکسلی در تصاویر تفکیک پذیری پایین ورودی است.

اولین مرحله در روش‌های مبتنی بر چند فریم، شکل دادن رابطه بین تصویر تفکیک پذیری بالا و تفکیک پذیری پایین به نام "مدل مشاهده" است. برای این منظور، چندین مدل مشاهده در [۱] پیشنهاد شده

^۱ codebook

^۲ the structural self-similarity (SSSIM) index

است که در شکل (۸-۲)، یک مدل مشاهده با اعمال حرکت بین دوربین و صحنه بر تصویر وضوح بالا نشان داده شده است.



شکل (۸-۲) یک مدل مشاهده از سیستم تصویربرداری واقعی با در نظر گرفتن حرکت بین صحنه و دوربین [۱]

دو پارامتر اصلی در روش‌های افزایش تفکیک پذیری مبتنی بر چندفریم، ضریب بزرگنمایی و تعداد تصاویر تفکیک پذیری پایین مشاهده شده است. کارایی این روش‌ها در صورت بزرگ بودن ضریب بزرگنمایی، کاهش می‌یابد [۳۴]. لذا، روش‌های مبتنی بر چندفریم برای هر ضریب افزایشی مناسب نیستند. در برخی موارد، تعداد تصویر تفکیک پذیری پایین برای به دست آوردن نتایج کارآمد در مساله افزایش تفکیک پذیری، کافی نیست. بنابراین، با توجه به کاربردهای مختلف، محدودیت‌هایی در این دسته از روش‌های افزایش تفکیک پذیری تصویر وجود دارد که می‌توان به موارد زیر اشاره کرد:

در روش‌های مبتنی بر چند فریم، اگر شیفت‌هایی مکانی با مقدار عددی غیر صحیح در تصاویر تفکیک پذیری پائین وجود نداشته باشد، افزایش تفکیک پذیری تصویر امکان‌پذیر نخواهد بود. به عبارت دیگر، باید بین تصاویر تفکیک پذیری پائین از یک صحنه، شیفت‌های غیر صحیح پیکسل‌ها وجود داشته باشد. در صورتی که اشیای موجود در تصاویر با سرعت بالایی حرکت نمایند، تصاویر گرفته شده تار می‌شود و برای الگوریتم

بازسازی مناسب نمی‌باشند. بنابراین نرخ نمونه‌برداری در هر زمان نمی‌تواند بسیار پایین باشد. اگر تصاویر اصلی دارای نویز بالایی باشند، امکان بازسازی تصاویر با تفکیک پذیری بالا در این روش‌ها وجود ندارد.

در فرایند بازسازی یک تصویر، برخی نویزهای طبیعی و اثرات مصنوعی به تصویر اعمال می‌شوند. اعوجاج نوری، تاری حرکت، نویز سنسور و غیره بعنوان عوامل تخریب تصویر شناخته می‌شوند. این نوع اختلالات باعث می‌شوند که تصویر تفکیک پذیری فضایی را از دست بدهد. لذا، روش‌های افزایش تفکیک پذیری تصویر، علاوه بر بازسازی یک تصویر تفکیک پذیری بالا از تصاویر تفکیک پذیری پایین باید همزمان تکنیک ترمیم را پوشش دهد. روش ترمیم تصویر به مقابله با اختلالات ذکر شده در بالا کمک می‌کند و همچنین باعث ایجاد یک تصویر با تفکیک پذیری بالا بدون نویز و یا اثرات تاری می‌شود. ترمیم تصویر، اندازه‌ی تصویر را تغییر نمی‌دهد [۱]. علاوه بر این، اطلاعات مربوط به سنسورها، تابع گسترش نقطه^۱، تنظیم تصاویر تفکیک پذیری پایین و غیره در روش‌های افزایش تفکیک پذیری چند فریم مورد نیاز است. بنابراین، این پارامترها باعث برخی محدودیت‌ها در برخی موارد می‌شوند. در ادامه، تحقیقات انجام شده در این حوزه ارائه می‌شود.

اولین کارها در زمینه‌ی افزایش تفکیک پذیری تصویر چندفریم، در حوزه‌ی فرکانس برای استخراج اطلاعات فرکانس بالای تصویر، در [۵۷] و بعد از آن در [۵۸] انجام شده است. مرجع [۵۷]، از تبدیل فوریه‌ی گسسته‌ی تصاویر بدون نویز تفکیک پذیری پایین برای ایجاد تصویر تفکیک پذیری بالا استفاده کرده است. در [۵۷] تصویر تفکیک پذیری پایین ورودی بدون نویز در نظر گرفته شده است، درحالی‌که در مرجع [۵۸]، این محدودیت بر تصویر ورودی تفکیک پذیری پایین اعمال نشده و نحوه‌ی غلبه بر نویز تصویر ورودی مورد توجه قرار گرفته است. مولفین مرجع [۵۹]، نویز و تاری تصویر ورودی را که در فرایند تصویربرداری به تصویر اعمال می‌شود را در روش پیشنهادی در نظر گرفته‌اند. در مرجع [۶۰]، ضرایب تبدیل کسینوسی گسسته (DCT)، به جای ضرایب تبدیل فوریه‌ی گسسته (DFT)، جهت کاهش حافظه‌ی موردنیاز و

¹ Point Spread Function (PSF)

هزینه‌های محاسباتی استفاده شده است. در [۶۱] و [۶۲]، یک رویکرد دو مرحله‌ای برای افزایش تفکیک پذیری تصویر ارائه شد که در مرحله‌ی اول این الگوریتم، حذف نویز و حذف تاری تصویر ورودی تفکیک پذیری پایین انجام می‌شود. مرحله‌ی دوم شامل درونیابی تصویر برای ایجاد تصویر تفکیک پذیری بالای خروجی است. برای اولین بار در [۶۳]، تصویر تفکیک پذیری بالا با استفاده از ضرایب موجک تصاویر تفکیک پذیری پایین و الگوریتم درونیابی به دست آمده است. مولفین [۶۴]، یک گام حذف نویز به چارچوب افزایش تفکیک پذیری تصویر با استفاده از موجک برای بسط همزمان افزایش تفکیک پذیری تصویر و حذف نویز، اضافه کرده‌اند.

تقریباً همزمان با اولین کارهای انجام شده در حوزه‌ی فرکانس، در عرصه‌ی بینایی کامپیوتر نیز افزایش تفکیک پذیری تصویر مورد پژوهش قرار گرفت [۳]، [۶۵]، [۱۰] و [۶۶]. این روش‌ها، بطور انحصاری در حوزه‌ی فضایی در نظر گرفته شده‌اند.

در [۶۷]، یک طرح فازی برای استخراج ارتباط بین پیکسل‌های تصویر هدف و تصاویر تفکیک پذیری پایین، توسعه داده شده است. در این مرجع به این مساله توجه شده است که روش‌های افزایش تفکیک پذیری چندفریم به‌شدت به تخمین دقیق حرکت وابسته هستند. بطوری‌که در صورت تخمین نادرست حرکت، اثرات مصنوعی در تصویر خروجی تفکیک پذیری بالا مشاهده می‌شود. بنابراین به تخمین حرکت در مرجع [۶۷] توجه شده است.

بطور گسترده‌ای از روش‌های رگولاسیون در مسائل افزایش تفکیک‌پذیری تصویر استفاده می‌شود که دلیل این امر ماهیت ill-posed بودن روش‌های افزایش تفکیک‌پذیری تصویر است. تحقیقات اخیر براساس چارچوب رگولاسیون در مسائل افزایش تفکیک‌پذیری تصویر، در [۶۸]، [۶۹]، [۷۰]، [۷۱]، [۷۲]، [۷۳]، [۷۴]، [۷۵]، [۷۶]، [۷۷]، [۷۸]، [۷۹]، [۸۰]، [۸۱]، [۸۲] و [۸۳] ارائه شده است. در این روش‌ها، تصویر تفکیک‌پذیری بالای خروجی با حداقل کردن یک تابع هدف که شامل دو پارامتر اصلی است، ایجاد می‌شود.

یکی از این دو پارامتر، میزان نزدیکی تصویر تخمین زده‌ی خروجی با تصاویر تفکیک پذیری پایین ورودی است. از پارامتر دوم که تنظیم کننده است برای ایجاد یک راه حل پایدار استفاده می شود. این بازسازی می تواند بعنوان یک رویکرد بیشینه گر احتمال پسین^۱ (MAP) شناخته شود. از آنجائی که نویز مشاهده شده در روش های افزایش تفکیک پذیری تصویر، معمولاً نویز گوسین است [۸۴]، تخمین حداکثر شباهت^۲ برای پارامتر اول تابع هدف، اغلب نتایج بهتری را به دست می آورد. در مراجع [۸۵]، [۸۶] و [۸۷] از تخمین حداکثر شباهت برای پارامتر اول تابع هدف در کنار تنظیم کننده رایج تیخونوف برای پارامتر دوم استفاده شده است. مولفین [۸۸]، یک الگوریتم جدید با استفاده از دانش پیشین پیشنهاد کرده اند. تنظیم کننده ی تغییرات کل^۳ در [۸۹] برای افزایش تفکیک پذیری دنباله های ویدئویی دیجیتال بکار گرفته شده است. مولفین [۸۹] نشان داده اند که این تنظیم کننده، نسبت سیگنال به نویز بسیار مناسب تری را روی تصویر تفکیک پذیری بالای بازسازی شده ایجاد می کند.

در کاربردهای عملی، پارامترهای مدل های تخمین زده شده معمولاً بطور دقیق محاسبه نمی شوند، بنابراین، مدل های ایجاد شده تقریبی از مدل های واقعی بوده و تصویر بازسازی شده دارای اثرات مصنوعی شدید است. از طرف دیگر، کیفیت تصویر تفکیک پذیری بالای خروجی در صورت استفاده از معیار **L2**، بعنوان پارامتر اول تابع هدف، به دقت مدل ریاضی ایجاد شده برای فرایند تصویربرداری وابسته است. برای این منظور، در مرجع [۹۰] از معیار خطای **L1** برای پارامتر اول تابع هدف استفاده شده است. در این مرجع نشان داده شده است که معیار **L1** پایداری بیشتری در برابر خطاهای بزرگ از قبیل خطای نقاط پرت و رجیستر کردن نادرست دارد. با این حال، معیار **L1** تخمین ها را با واریانس بالاتر از معیار **L2** تولید می کند [۹۱] و [۹۲]. اخیراً، برخی از M-تخمین زنده ها^۴ برای مساله ی افزایش تفکیک پذیری تصویر چند فریم

¹ Maximum A Posteriori (MAP)

² Maximum Likelihood (ML)

³ Total Variation (TV)

⁴ M-estimators

مورد بررسی قرار گرفته‌اند. در [۹۳]، [۹۴] و [۹۲] از M -تخمین‌زننده‌ها بدون تنظیم‌کننده استفاده کرده‌اند که در [۹۳] از نرم خطای گوسین و در [۹۴] و [۹۲] از نرم خطای $Lorentzian$ ^۱ استفاده شده است.

۴-۲ جمع‌بندی

در این فصل، کارهای پیشین در حوزه‌ی افزایش تفکیک پذیری تصویر مورد بحث و بررسی قرار گرفت. در ابتدای فصل، دسته‌بندی این رساله برای الگوریتم‌های افزایش تفکیک پذیری تصویر بیان شد و در ادامه، کارهای انجام شده در هر دسته با تمرکز بر الگوریتم‌های افزایش تفکیک پذیری تک تصویر مبتنی بر یادگیری ارائه گردید.

دو رویکرد اصلی افزایش تفکیک پذیری تصویر، الگوریتم‌های افزایش مبتنی بر چند فریم و الگوریتم‌های افزایش تک تصویر است که براساس تعداد تصاویر تفکیک پذیری پایین مورد نیاز این دسته‌بندی صورت پذیرفته است. از آنجائی که عملکرد روش‌های افزایش مبتنی بر چند فریم به تعداد تصاویر تفکیک پذیری پایین و نحوه‌ی استخراج آن‌ها بستگی دارد، روش‌های مبتنی بر تک تصویر مورد توجه بیشتر قرار گرفته‌اند. روش‌های مبتنی بر تک تصویر می‌توانند به دو دسته‌ی مبتنی بر درونیابی و مبتنی بر یادگیری تقسیم شوند. روش‌های مبتنی بر درونیابی باعث هموارشدن لبه‌ها می‌شوند. از آنجائی که الگوریتم‌های مبتنی بر یادگیری بطور کلی نتایج دقیق‌تری در مقایسه با سایر الگوریتم‌ها ایجاد می‌کنند، توجه محققین به این روش‌ها جلب شده است. این روش‌ها براساس استفاده یا عدم استفاده از مجموعه تصاویر آموزشی به دو دسته‌ی مبتنی بر نمونه و خودیادگیرنده تقسیم می‌شوند. کارایی الگوریتم‌های مبتنی بر نمونه به مجموعه تصاویر آموزشی وابسته است. از آنجائی که در این گونه روش‌ها تنها از یک دیکشنری برای انواع تصاویر ورودی

¹ the Lorentzian error norm

استفاده می‌شود و از طرف دیگر، یک دیکشنری جامع از تمامی وصله‌های موجود در انواع تصاویر ایجاد نشده است، بنابراین، امکان عدم تطابق وصله‌های دیکشنری با وصله‌های تصویر ورودی وجود دارد. در نتیجه، اطلاعات به دست آمده از دیکشنری ممکن است برای ایجاد یک تصویر تفکیک پذیری بالای با کیفیت، مناسب نباشد.

در حالی‌که، در روش‌های خودیادگیرنده از تک تصویر ورودی برای ایجاد دیکشنری از وصله‌ها استفاده می‌شود و این امر باعث افزایش تطابق وصله‌های دیکشنری با وصله‌های تصویر تفکیک پذیری پایین و در نتیجه بهبود کیفیت تصویر تفکیک پذیری بالای خروجی می‌شود. بنابراین، در این رساله، افزایش تفکیک پذیری خود یاد گیرنده برای ادامه‌ی کار و تمرکز بیشتر انتخاب شده است.

فصل ۳: مفاهیم اولیه


۳-۱ مقدمه

در این فصل، برخی مفاهیم و اصطلاحات را که در رساله مورد بطور مکرر مورد استفاده قرار می‌گیرد را بطور کامل مورد بررسی قرار می‌دهیم. از آنجائی که روش‌های ارائه شده در رساله برای افزایش تفکیک‌پذیری تصویر، روش‌های تک تصویر خودیادگیرنده هستند، نیاز به پایگاه‌داده‌ای از تصاویر با تفکیک‌پذیری بالا و تفکیک‌پذیری پائین متناوب وجود ندارد. لذا، برای آموزش اطلاعات موجود در تصاویر با تفکیک‌پذیری بالا و پایین از دو هرم تصویر استفاده می‌شود که این دو هرم تنها با استفاده از تصویر ورودی ساخته شده است که در بخش ۳-۲ نحوه‌ی ایجاد این دو هرم آورده شده است. برای استخراج ویژگی‌ها از وصله‌های تصاویر، روش‌های متعددی در مقالات افزایش تفکیک‌پذیری تصویر پیشنهاد شده است که بازنمایی تنک و گرادیان مرتبه اول و مرتبه دوم در این رساله مورد استفاده قرار گرفته است که در بخش ۳-۳ (به ترتیب در زیربخش‌های ۳-۳-۱ و ۳-۳-۲)، درخصوص این ویژگی‌ها توضیح داده شده است. برای بازسازی اطلاعات از دست رفته تصویر نیاز به مدل‌سازی ارتباط بین وصله‌های با تفکیک‌پذیری بالا و تفکیک‌پذیری پایین است که در رساله از رگرسیون بردار پشتیبان برای این منظور در فازهای آموزش و آزمون روش‌های پیشنهادی استفاده شده است که در بخش ۳-۴ به این مساله پرداخته شده است. از دو معیار PSNR و SSIM برای ارزیابی نتایج استفاده شده است که در بخش ۳-۵ بطور مختصر توضیح داده شده‌اند. پایگاه داده مورد استفاده نیز در بخش ۳-۶ آورده شده است. در نهایت این فصل با نتیجه‌گیری از مطالب ارائه شده به پایان می‌رسد.

۲-۳ ساخت هرم‌های با تفکیک پذیری بالا و تفکیک پذیری پایین

در سال‌های اخیر به روش‌های افزایش تفکیک پذیری تصویر توجه بسیاری شده است. در میان این روش‌ها، اخیراً تمرکز بر روش‌های مبتنی بر یادگیری می‌باشد. برخی از روش‌های مبتنی بر یادگیری به کمک پایگاه داده‌ای شامل تصاویر با تفکیک پذیری پایین و تفکیک پذیری بالا سعی در مدل‌سازی ارتباط بین اینگونه تصاویر دارند. در این رساله، مساله مورد بررسی افزایش تفکیک پذیری یک تصویر بدون استفاده از آموزش سیستم به کمک پایگاه داده می‌باشد. در این رویکرد، دو هرم وارونه بعنوان هرم با تفکیک پذیری پایین و تفکیک پذیری بالا با استفاده از تصویر ورودی به سیستم، ایجاد می‌شود. با عنایت به پژوهش‌های انجام شده در [۳۴]، وصله‌های یک تصویر در همان تصویر و یا تصاویر ایجاد شده از آن تصویر تکرار می‌شوند. در این تحقیق، به ازای هر تصویر پایگاه داده، I تصاویر سطوح پایین‌تر با کاهش نرخ نمونه‌برداری با ضریب 1.25^s به ازای $s=0, -1, \dots, -6$ ایجاد شده‌اند که تصویر ورودی $I_0 = I$ است. براساس یافته‌های مرجع [۳۴]، بطور متوسط، بیش از ۹۰ درصد وصله‌های هر تصویر، بیش از ۹ وصله مشابه در همان تصویر دارند. علاوه براین، بیش از ۸۰ درصد وصله‌های ورودی، بیش از ۹ وصله مشابه در سطح $s=-4$ و ۷۰ درصد وصله‌های ورودی در سطح $s=-6$ دارای بیش از ۹ وصله مشابه هستند. لذا، با توجه به وجود وصله‌های مشابه در یک تصویر و یا تصاویر ایجاد شده از آن، می‌توانیم رابطه بین وصله‌های وضوح بالا و وضوح پایین در سطوح مشابه دو هرم با وضوح بالا و پایین را یادگیری کنیم که این امر منجر به تخمین شدت روشنایی پیکسل‌ها در تصاویر وضوح بالا خواهد شد. روش‌های پیشنهادی این رساله دارای فاز آموزش و آزمون می‌باشند. ابتدا در فاز آموزش، با استفاده از وصله‌های متناظر دو هرم (شامل تصاویر با فراتفکیک‌پذیری بالا و فراتفکیک‌پذیری پائین) مدل‌هایی آموزش داده شده که در فاز آزمون از این مدل‌ها جهت تخمین مقادیر پیکسل‌ها در تصویر خروجی استفاده می‌شود. در ادامه، نحوه ساخت دو هرم با تفکیک پذیری بالا و تفکیک پذیری پایین توضیح داده می‌شود.

فرض کنید هدف ساختن یک تصویر با تفکیک پذیری بالا (تصویر خروجی) است که ابعاد این تصویر s برابر ابعاد تصویر ورودی است. در فاز آموزش، ابتدا هرم تصویر با تفکیک پذیری بالا با کاهش تدریجی ابعاد تصویر ورودی با نرخ s ساخته می‌شود. اگر تصویر ورودی را I_0 بنامیم، تصاویر هرم در سطوح پایین تر I_{-1} ، I_{-2} ، ...، I_{-n} نامیده می‌شوند. در سطح بالای این هرم (سطح بالای تصویر ورودی)، به دنبال ساختن تصویر خروجی I_{+1} هستیم که ابعاد آن s برابر ابعاد تصویر ورودی است. لذا، تعداد سطوح هرم با تفکیک پذیری بالا، $n+2$ می‌شود. برای مدل سازی رابطه بین تصاویر با تفکیک پذیری بالا و تفکیک پذیری پایین، هرم دیگری از تصاویر ساخته می‌شود که آنرا هرم با تفکیک پذیری پایین می‌نامیم. برای ساخت تصویر در بالاترین سطح این هرم (همسطح تصویر خروجی)، تصویر ورودی، I_0 را با استفاده از الگوریتم افزایش نرخ نمونه‌برداری و درونیابی دومکعبی به نسبت s افزایش ابعاد می‌دهیم و تصویر نتیجه را $\tilde{I}_{+1}$ می‌نامیم. این تصویر به لحاظ ابعاد هم سطح تصویری است که در فرایند فراتفکیک پذیری می‌خواهیم به دست آوریم ولی نتیجه الگوریتم درونیابی، جزییات و لبه‌های تصویر را مات می‌نماید. برای ساخت تصاویر سایر سطوح هرم با تفکیک پذیری پایین به همین ترتیب عمل می‌نماییم. بعنوان مثال، برای ساخت تصویر $\tilde{I}_{-1}$ ، تصویر I_{-2} از هرم با تفکیک پذیری بالا را به کمک الگوریتم درونیابی دومکعبی به نسبت s افزایش ابعاد می‌دهیم. هرم با تفکیک‌پذیری بالا و پایین به ترتیب در سمت چپ و راست شکل (۳-۱) نشان داده شده است.



شکل (۱-۳) دو هرم تصاویر با تفکیک پذیری بالا (سمت چپ) و با تفکیک پذیری پائین (سمت راست) بعنوان پایگاه داده‌ای از تصاویر آموزشی

دو تصویر هم‌اندازه I_{-1} و $\tilde{I}_{-1}$ که به ترتیب در سطح -1 هرم باتفکیک‌پذیری بالا و پایین قرار دارند را در نظر بگیرید. تصویر I_{-1} با استفاده از کاهش ابعاد تصویر ورودی، I_0 ایجاد شده است. لذا، تعدادی از پیکسل‌های تصویر I_0 دور ریخته شده و برای ایجاد تصویر I_{-1} نیازی به تخمین ارزش پیکسل‌ها نیست. درحالی‌که برای ایجاد تصویر $\tilde{I}_{-1}$ مطابق شکل (۱-۳)، ابتدا تعدادی از پیکسل‌های تصویر I_{-1} دور ریخته شده و تصویر I_{-2} ایجاد می‌شود. سپس، ابعاد این تصویر با استفاده از درون‌یابی دوماکعبی افزایش داده می‌شود تا تصویر $\tilde{I}_{-1}$ که هم‌اندازه تصویر I_{-1} است، به دست آید. بنابراین، در ایجاد تصویر $\tilde{I}_{-1}$ نیاز به تخمین ارزش پیکسل‌ها با استفاده از درون‌یابی دوماکعبی است. درحالی‌که برای ایجاد تصویر I_{-1} نیاز به تخمین ارزش پیکسل‌ها نیست. این موضوع دلیل نامگذاری این دو هرم به هرم تصاویر با تفکیک‌پذیری بالا و تفکیک‌پذیری پایین شده است.

۳-۳ استخراج ویژگی

از آنجائی که در این رساله، از ویژگی‌های وصله‌های تصویر برای آموزش و آزمون مدل‌های رگرسیونی استفاده شده است، لذا، هر وصله از تصویر باید با یک بردار ویژگی نشان داده شود که این بردار ویژگی می‌تواند شامل ارزش پیکسل‌های درون هر وصله بصورت خام و یا ویژگی‌های استخراج شده از شدت روشنایی پیکسل‌های درون هر وصله باشد. در این بخش، ویژگی‌های تعریف شده و مورد استفاده برای وصله‌های تصویر که در سرتاسر رساله مورد استفاده قرار گرفته‌اند، بیان می‌شود. لذا، بازنمایی تُنک و گرادیان مرتبه اول و مرتبه دوم در ادامه توضیح داده می‌شوند.

۳-۳-۱ بازنمایی تُنک^۱

برای استخراج ویژگی‌های هر وصله، روش‌های متعددی پیشنهاد شده است. در دهه اخیر، به بازنمایی تُنک توجه ویژه‌ای شده است. بازیابی تصویر، فراتفکیک‌پذیری تصویر، شناسایی چهره، طبقه‌بندی تصویر، تشخیص هویت، حذف نویز و فشرده‌سازی تنها نمونه‌هایی از کاربرد بازنمایی تُنک است. هدف در تخمین یک سیگنال گسسته با استفاده از بازنمایی تُنک، نمایش آن سیگنال با کمترین تعداد عناصر غیرصفر است. لذا، بدلیل صفر بودن اکثر عناصر موجود در بردار ویژگی مبتنی بر بازنمایی تُنک یک سیگنال، سرعت اجرا، افزایش و زمان و حجم حافظه‌ی مورد نیاز کاهش می‌یابد. دو مسأله مهم در بازنمایی تُنک وجود دارد. اولین مسأله، دیکشنری فراکامل^۲ شامل تعدادی عناصر پایه است که هر سیگنال را می‌تواند با بردار تُنکی از این عناصر، نمایش داد. این عناصر پایه در دیکشنری، اتم

^۱ Sparse Representation

^۲ Over-complete

نامیده می‌شوند. دومین مساله، نمایش تَنک هر سیگنال براساس اتم‌های دیکشنری است. در ادامه، نحوه استخراج بردار ویژگی تَنک به ازای هر وصله از تصویر آورده شده است.

فرض کنید $D \in \mathbb{R}^{n \times K}$ ، یک دیکشنری فرا کامل از K عنصر پایه (اتم) است که اندازه‌ی هر مولفه n می‌باشد و $y \in \mathbb{R}^n$ یک سیگنال ورودی است که این سیگنال را می‌توان بصورت یک ترکیب خطی از اتم‌های دیکشنری، مطابق رابطه (۱-۳)، نمایش داد.

$$y = Dx \quad (1-3)$$

در رابطه (۱-۳)، $x \in \mathbb{R}^K$ است. برای دستگاه معادلات خطی بالا (رابطه (۱-۳)) سه حالت می‌توان در نظر گرفت:

$n = k - 1$: در این حالت، بردار ضرایب x ، بصورت یکتا با استفاده از معکوس دیکشنری، D ، و با استفاده از رابطه (۲-۳) محاسبه می‌شود.

$$x = D^{-1}y \quad (2-3)$$

$n > k - 2$: این یک سیستم معادلات فرامعین^۱ است که با انتخاب یک ماتریس رتبه کامل برای دیکشنری، $D_r \in \mathbb{R}^{n \times n}$ ، مشابه حالت اول، محاسبه می‌شود که در رابطه (۳-۳) نشان داده شده است.

$$x = D_r^{-1}y \quad (3-3)$$

$n < k - 3$: این یک سیستم معادلات فرومعین^۲ است که در این دستگاه معادلات، تعداد مجهولات از معلومات بیشتر است که یا دستگاه اصلاً جواب ندارد و یا بی‌نهایت جواب دارد. در مسائل مختلف پرازش سیگنال، مخصوصاً مسائل معکوس، با اینگونه معادلات مواجه می‌شویم. بعنوان مثال، در زمینه فراتفکیک‌پذیری تصویر، تصویر اصلی x تحت نگاشت خطی D تغییر یافته و ما تنها به تصویر با تفکیک‌پذیری پایین و تخریب‌شده y دسترسی داریم و هدف بدست آوردن تصویر اصلی و با تفکیک‌پذیری بالای x است.

¹ Overdetermined

² Underdetermined

در این دستگاه معادلات، برای جلوگیری از بروز حالت عدم وجود جواب، فرض می‌شود که ماتریس D یک ماتریس رتبه کامل است.

تمرکز بازنمایی تُنک بر دستگاه معادلات فرومعیین است. همانطور که در بالا بیان شد، این معادلات بی‌نهایت جواب دارند که با رگولاریزه کردن دستگاه معادلات، می‌توان یک جواب با ویژگی خاص را انتخاب کرد. لذا، با قراردادن قیدی این جواب‌ها را محدود می‌کنیم که منجر به حل مساله نُرم می‌شود. اگر از نُرم صفر استفاده شود، هدف بدست آوردن ضرایب تُنک x برای سیگنال ورودی y با استفاده از دیکشنری D با قید نُرم صفر است که این قید تعداد مقادیر غیرصفر بردار ضرایب تُنک x را دربردارد که بصورت رابطه (۴-۳) نشان داده می‌شود.

$$f_0: \min_x \|x\|_0 \quad \text{subject to } y = Dx \quad (4-3)$$

در رابطه (۴-۳)، $\|x\|_0$ ، تعداد درایه‌های غیرصفر بردار ضرایب تُنک x است. از آنجائی که نُرم صفر محدب نیست، مساله بهینه‌سازی فوق، یک مساله NP-Hard تلقی می‌شود. یکی از جایگزین‌های نُرم صفر، نُرم یک است که هم محدب بوده و هم رابطه (۴-۳) را می‌توان با الگوریتم‌های مختلف و در زمان محدود حل کرد. لذا، با جایگزین کردن نُرم یک به جای نُرم صفر، رابطه (۴-۳)، به رابطه (۵-۳) تبدیل می‌شود.

$$f_1: \min_x \|x\|_1 \quad \text{subject to } y = Dx \quad (5-3)$$

از آنجائی که معمولاً تساوی $y = Dx$ به علت وجود نویز برقرار نیست، در بسیاری از کاربردها، مساله بالا، تبدیل به یک مساله پایدار نسبت به نویز می‌شود که در رابطه (۶-۳) آورده شده است.

$$f_1: \min_x \|x\|_1 \quad \text{subject to } \|y - Dx\|_2^2 \leq \varepsilon \quad (6-3)$$

برای حل نامعادله بالا با استفاده از ضرایب لاگرانژ و روش برنامه‌نویسی خطی، از رابطه (۷-۳) استفاده می‌شود.

$$f_1: \min \frac{1}{2} \|y - Dx\|_2^2 + \lambda \|x\|_1 \quad (7-3)$$

در رابطه (۷-۳)، D ، یک دیکشنری فراکامل، λ ، ضریب لاگرانژ برای ایجاد تعادل مابین میزان تُنک بودن (صفر بودن) ضرایب و مقدار خطای موجود در بازسازی سیگنال ورودی y است. x ، یک بردار با تعداد بسیار اندک ضریب غیر صفر است که بردار ضرایب تُنک خوانده می‌شود.

در حالت کلی، استخراج ضرایب تُنک در یک مجموعه فراکامل یک مسئله NP-Hard بوده و هیچ الگوریتمی توانایی نمایش دقیق یک سیگنال براساس ضرایب تُنک آن را ندارد. لذا، از روش‌های تخمینی استفاده می‌شود که همواره در این روش‌ها، نمایش تُنک یک سیگنال با خطا همراه است. الگوریتم‌های مختلفی برای این منظور ارائه شده است که می‌توان به روش‌های حریصانه اشاره کرد. در این روش‌ها، ابتدا تعدادی از عناصر دیکشنری (اتم‌ها) بطور تصادفی انتخاب می‌شود و سپس با انتخاب اتم‌های مناسب، خطای بازسازی را کاهش می‌دهند. این روش‌ها جزء سریع‌ترین الگوریتم‌های کدگذاری تُنک هستند. از دیگر روش‌های نمایش تُنک می‌توان به روش‌های مبتنی بر کمینه کردن تعداد عناصر غیرصفر بردار ضرایب و کمینه کردن یک تابع جریمه تُنک اشاره کرد. از معروف‌ترین الگوریتم‌های نمایش تُنک که از روش‌های حریصانه استفاده می‌کنند، می‌توان OMP^1 ، $ORMP^2$ و $WOMP^3$ را نام برد [۹۵] و [۹۶]. الگوریتم‌های LASSO و گرادیان نزولی نیز برای استخراج ضرایب تُنک مورد استفاده قرار می‌گیرند [۹۷].

همانطور که در بالا بیان شد، یکی از مسائل مهم در بازنمایی تُنک، ایجاد یک دیکشنری فراکامل است. اهمیت انتخاب یک دیکشنری فراکامل، اگر از نحوه استخراج ضرایب تُنک بیشتر نباشد، کمتر نیست. انتخاب یک دیکشنری مناسب می‌تواند باعث تُنک شدن هر چه بیشتر بردار ضرایب در نمایش تُنک شود و انتخاب یک دیکشنری نامناسب یک بردار غیرتُنک (انبوه) را نتیجه خواهد داد. معمولاً دیکشنری‌های مورد استفاده در بازنمایی تُنک در دو گروه، دیکشنری‌های از پیش تعیین شده و دیکشنری‌های بدون ساختار که به ازای

¹ Orthogonal Matching Pursuit (OMP)

² Order Recursive Matching Pursuit (ORMP)

³ Weak Orthogonal Matching Pursuit (WOMP)

هر مساله بطور جداگانه طراحی می‌شوند، قرار می‌گیرند. دیکشنری فراکامل گابور، دیکشنری فراکامل DCT و دیکشنری فراکامل موجک‌ها، نمونه‌ای از دیکشنری‌های از پیش تعیین شده هستند. پیچیدگی اجرایی یک مساله با دیکشنری از پیش تعیین شده کمتر از پیچیدگی اجرای بازنمایی تُنک با استفاده از دیکشنری بدون ساختار است. بعنوان مثال، پیچیدگی اجرای بازنمایی تُنک یک سیگنال بطول n بر پایه یک دیکشنری از قبل طراحی شده، $O(n)$ و براساس یک دیکشنری بدون ساختار $O(n^2)$ است. با این وجود، دلیل رغبت بیشتر به سمت دیکشنری بدون ساختار، قابلیت تطابق این نوع دیکشنری با هر مساله جدید است. به عبارت دیگر، هر یک از دیکشنری‌های از پیش تعیین شده در یک کاربرد خاص از عملکرد خوبی برخوردار هستند و استفاده از آن‌ها در کاربردهای دیگر، عملکردشان را به شدت پائین می‌آورد. بعنوان مثال، دیکشنری فراکامل DCT برای خانواده تصاویر طبیعی و دیکشنری فراکامل گابور برای سیگنال‌های صحبت مناسب هستند. برای ایجاد دیکشنری بدون ساختار، براساس مساله مورد نظر، داده‌های آموزشی استخراج و دیکشنری با استفاده از داده‌های آموزشی، استخراج می‌شود. لذا، در مورد دیکشنری‌های بدون ساختار، مساله آموزشی و یادگیری دیکشنری مطرح می‌شود.

از الگوریتم‌های مورد استفاده برای آموزش دیکشنری می‌توان به MOD و K-SVD اشاره کرد. در حالی که کارایی الگوریتم‌های K-SVD و MOD مشابه هستند، روش‌های K-SVD نسبت به الگوریتم‌های MOD، پیچیدگی کمتری دارند. هدف از یادگیری دیکشنری، ایجاد دیکشنری مناسبی است که بوسیله آن بتوان داده‌های آموزشی را با خطای کمتر و با تُنک‌ترین بردار، تخمین زد. در اکثر روش‌های یادگیری دیکشنری برای بازنمایی تُنک، یک فرایند بازگشتی دومرحله‌ای مورد استفاده قرار می‌گیرد. در مرحله اول، با استفاده از یک دیکشنری ثابت اولیه، ضرایب تُنک استخراج می‌شود که به عنوان مرحله "کدگذاری تُنک"^۱ شناخته

¹ Sparse Coding

می‌شود. در مرحله دوم با فرض ثابت بودن ضرایب تُنک بدست آمده از مرحله اول، دیکشنری بروزرسانی می‌شود که به این مرحله "بروزرسانی دیکشنری" گفته می‌شود.

در این رساله جهت استخراج ضرایب تُنک و آموزش دیکشنری فراکامل از جعبه ابزار SPAMS (SPArse Modeling Software)^۱ استفاده شده است [۹۸] و [۹۹]. در این نرم‌افزار، داده‌های آموزشی بصورت متغیرهای تصادفی، مستقل و با توزیع یکسان^۲ در نظر گرفته شده است. در ادامه نحوه آموزش و بروزرسانی دیکشنری فراکامل و استخراج ضرایب تنک براساس جعبه ابزار مورد استفاده در مقاله آورده شده است. فرض کنید m داده آموزشی با توزیع p داریم $X \in \mathbb{R}^m \sim p(X)$. اگر $D_0 \in \mathbb{R}^{m \times k}$ ، دیکشنری اولیه، T تعداد تکرار الگوریتم، λ ، پارامتر رگولاریزه کردن و $A_0 \in \mathbb{R}^{k \times k}$ و $B_0 \in \mathbb{R}^{m \times k}$ متغیرهایی با مقادیر اولیه صفر برای نگهداشتن اطلاعات قبلی باشند، ضرایب تُنک در تکرار t ام، با استفاده از LARS^۳ از رابطه (۳-۸) بدست می‌آید [۹۸] و [۹۹].

$$\alpha_t \triangleq \arg \min_{\alpha \in \mathbb{R}^k} \frac{1}{2} \|X_t - D_{t-1} \alpha\|_2^2 + \lambda \|\alpha\|_1. \quad (۸-۳)$$

سپس، متغیرهای A و B در تکرار t ام، با استفاده از رابطه (۳-۹)، مقدار جدید می‌گیرند.

$$\begin{aligned} A_t &\leftarrow A_{t-1} + \alpha_t \alpha_t^T, \\ B_t &\leftarrow B_{t-1} + X_t \alpha_t^T. \end{aligned} \quad (۹-۳)$$

با بکارگیری مقادیر متغیرهای A_t و B_t ، دیکشنری فراکامل D_t در تکرار t ام از رابطه (۳-۱۰) بدست می‌آید.

$$\begin{aligned} D_t &\triangleq \arg \min_{D \in C} \frac{1}{t} \sum_{i=1}^t \left(\frac{1}{2} \|X_i - D_{i-1} \alpha\|_2^2 + \lambda \|\alpha\|_1 \right), \\ &= \arg \min_{D \in C} \frac{1}{t} \left(\frac{1}{2} \text{Tr}(D^T D A_t) - \text{Tr}(D^T B_t) \right). \end{aligned} \quad (۱۰-۳)$$

^۱ <http://spams-devel.gforge.inria.fr/>

^۲ independent and identically distributed (i.i.d.)

^۳ Least-Angle Regression (LARS)

در نهایت، هر یک از ستون‌های دیکشنری طبق رابطه (۱۱-۳)، بروزرسانی می‌شوند و این مرحله تا زمان رسیدن به همگرایی ادامه دارد.






$$\begin{aligned} u_j &\leftarrow \frac{1}{A[j,j]}(b_j - Da_j) + d_j, \\ d_j &\leftarrow \frac{1}{\max(\|u_j\|_2, 1)} u_j. \end{aligned} \quad (11-3)$$

رابطه (۱۱-۳)، نحوه بروزرسانی ستون j ام دیکشنری فراکامل D را نشان می‌دهد که در این رابطه، $D = [d_1, \dots, d_k] \in \mathbb{R}^{m \times k}$ و $A = [a_1, \dots, a_k] \in \mathbb{R}^{k \times k}$ و $B = [b_1, \dots, b_k] \in \mathbb{R}^{m \times k}$ است.








۳-۱-۱-۳ استخراج ضرایب تنک در رساله

در این رساله، وصله‌های هم‌پوشان از تصاویر موجود در پایگاه تصاویر استخراج می‌شوند. معمولاً این وصله‌ها به اندازه‌ی 5×5 با یک پیکسل هم‌پوشانی هستند. با استفاده از این وصله‌ها و بکارگیری جعبه ابزار ارائه شده در [۹۸] و [۹۹]، دیکشنری فراکامل با تعداد از پیش تعیین شده اتم ایجاد و سپس ضرایب تنک به ازای هر وصله از تصویر استخراج می‌شوند.

در اشکال (۲-۳) و (۳-۳) دیکشنری فراکامل برای تعدادی از تصاویر موجود در پایگاه تصاویر نشان داده شده است. دیکشنری‌های ایجاد شده شامل ۱۰۰ (سطر اول) و ۹۰۰ (سطر دوم) اتم می‌باشند. از آنجائی که تصاویر به وصله‌های 5×5 تقسیم شده‌اند، هر اتم دیکشنری‌ها نیز یک ماتریس 5×5 می‌باشند.



شکل (۲-۳) دیکشنری فراکامل برای تصاویر tree، house و susan. سطر اول شامل ۱۰۰ اتم و سطر دوم شامل ۹۰۰ که اندازه هر اتم 5×5



شکل (۳-۳) دیکشنری فراکامل برای تصاویر peppers و baboon به ترتیب شامل ۱۰۰ و ۹۰۰ اتم
(از بالا به پایین) که اندازه هر اتم 5×5

برای استخراج ضرایب هر وصله، میزان مشارکت هر اتم دیکشنری در بازسازی وصله مدنظر بررسی و سپس برداری بعنوان ویژگی آن وصله ایجاد می‌شود که تعداد عناصر این بردار با تعداد اتم‌های دیکشنری برابر بوده و مقدار هر عنصر نیز میزان مشارکت هر اتم در بازسازی وصله را نشان می‌دهد. همانطور که در بالا بیان شد، بیشتر عناصر این بردار صفر بوده و تنها عناصر غیرصفر در نظر گرفته می‌شود.

در این رساله، بدلیل عملکرد متفاوت نسبت به پیکسل‌های لبه و غیرلبه، مراحل ایجاد دیکشنری و استخراج ضرایب بطور جداگانه به ازای مجموعه پیکسل‌های لبه و غیرلبه انجام می‌شود.

۳-۲-۳ استخراج گرادیان مرتبه اول و دوم

برای تعریف یک بردار ویژگی به ازای هر وصله تصویر، راه‌های متعددی وجود دارد. از آنجائی که چشم انسان به مولفه‌های فرکانس بالای تصویر حساس هستند، استفاده از یک فیلتر بالاگذر می‌تواند کارآمد باشد. فریمن و همکارانش [۲۰]، از یک فیلتر بالا گذر برای استخراج اطلاعات لبه‌ها بعنوان ویژگی برای وصله‌های تصویر با تفکیک‌پذیری پائین استفاده کرده‌اند. سان و همکارانش [۱۰۰]، از فیلترهای مشتق گوسین برای استخراج مرزها در وصله‌های تصویر با تفکیک‌پذیری پائین بهره جسته‌اند. چانگ و همکارانش [۳۶]، از گرادیان مرتبه اول و دوم بعنوان ویژگی هر وصله استفاده کرده‌اند. گرادیان تصویر، یک تغییر جهت دار در شدت روشنایی هر وصله از تصویر را نشان می‌دهد. برای استخراج گرادیان، چهار فیلتر بالا گذر، بصورت رابطه (۳-۱۲)، مورد استفاده قرار می‌گیرد.

$$\begin{aligned} g_1 &= [-1, 0, 1] & g_2 &= g_1^T \\ g_3 &= [1, 0, -2, 0, 1] & g_4 &= g_3^T \end{aligned} \quad (۳-۱۲)$$

در رابطه (۳-۱۲)، بردارهای g_2 و g_4 به ترتیب ترانهاده بردارهای g_1 و g_3 هستند. با اعمال هر یک از فیلترهای بالاگذر g_1, g_2, g_3 و g_4 بر شدت روشنایی هر پیکسل از وصله، یک بردار ویژگی بدست می‌آید. لذا، به ازای هر پیکسل، چهار بردار ویژگی داریم. با قرار دادن این چهار بردار در یک بردار، به ازای هر پیکسل از وصله، یک بردار ویژگی ایجاد می‌شود.

برای محاسبه‌ی بردار ویژگی گرادیان مرتبه اول و دوم یک پیکسل، از یک پنجره با همسایگی $n \times n$ حول پیکسل استفاده می‌شود [۳۶]. اگر $F(i,j)$ بردار ویژگی گرادیان‌های مرتبه اول و دوم در پیکسل (i,j) از تصویر I باشد، بردار گرادیان در این پیکسل مطابق رابطه (۳-۱۳) محاسبه می‌شود [۳۶].

$$F(i,j) = \begin{bmatrix} (I(i+1,j) - I(i-1,j)) \\ (I(i,j+1) - I(i,j-1)) \\ I(i+2,j) - 2 \times I(i,j) + I(i-2,j) \\ I(i,j+2) - 2 \times I(i,j) + I(i,j-2) \end{bmatrix} \quad (۳-۱۳)$$

بردار گرادیان تعریف شده در رابطه (۳-۱۳)، شامل چهار مولفه است که به ازای هر پیکسل موجود در وصله محاسبه می‌شود. بنابراین، اگر اندازه هر وصله را $M = m \times m$ در نظر بگیریم، اندازه‌ی بردار ویژگی گرادیان مرتبه اول و دوم هر وصله، $4 \times M$ است. در شکل (۳-۴)، نحوه محاسبه گرادیان مرتبه اول و مرتبه دوم برای پیکسل شماره ۱۳ با شدت روشنایی I_{13} جهت محاسبه گرادیان مرتبه اول، $\nabla_{I_{13}}$ و گرادیان مرتبه دوم $\nabla^2_{I_{13}}$ در این پیکسل نشان داده شده است.

I_1	I_2	I_3	I_4	I_5
I_6	I_7	I_8	I_9	I_{10}
I_{11}	I_{12}	I_{13}	I_{14}	I_{15}
I_{16}	I_{17}	I_{18}	I_{19}	I_{20}
I_{21}	I_{22}	I_{23}	I_{24}	I_{25}

$$\nabla_{I_{13}} = \begin{bmatrix} (I_{14} - I_{13}) + (I_{13} - I_{12}) \\ (I_{18} - I_{13}) + (I_{13} - I_8) \end{bmatrix} = \begin{bmatrix} I_{14} - I_{12} \\ I_{18} - I_8 \end{bmatrix}$$

$$\nabla^2_{I_{13}} \begin{bmatrix} (I_{15} - I_{13}) + (I_{13} - I_{11}) \\ (I_{23} - I_{13}) + (I_{13} - I_3) \end{bmatrix} = \begin{bmatrix} I_{15} - 2I_{13} + I_{11} \\ I_{23} - 2I_{13} + I_3 \end{bmatrix}$$

شکل (۳-۴) محاسبه گرادیان مرتبه اول $\nabla_{I_{13}}$ و دوم $\nabla^2_{I_{13}}$ برای پیکسل شماره ۱۳ تصویر I

۳-۴ رگرسیون بردار پشتیبان (SVR)^۱

الگوریتم بردار پشتیبان یک تعمیم غیرخطی از الگوریتم ارائه شده در [۱۰۱] و [۱۰۲] است. این الگوریتم در چارچوب تئوری یادگیری آماری و یا تئوری VC گروه‌بندی می‌شود که در طول سه دهه اخیر توسط [۱۰۳]، توسعه داده شده است. این الگوریتم قابلیت تعمیم خوبی برای داده‌های ناشناخته دارد. شکل کنونی ماشین بردار پشتیبان، بطور گسترده‌ای در آزمایشگاه‌های AT & T Bell توسط Vapnik و همکارانش توسعه داده شده است.

اولین کاربرد ماشین پشتیبان در شناسایی کاراکتر نوری (OCR)^۲ بوده است. در یک مدت زمان کوتاه، کلاس‌بندی کننده‌ی بردار پشتیبان، بعنوان رقیب بهترین سیستم‌های موجود در زمینه شناسایی شیء و OCR شناخته شد [۱۰۴]. یک آموزش جامع در رابطه با کلاس‌بندی کننده‌ی SV در [۱۰۵] ارائه شده است. در [۱۰۶]، [۱۰۷]، [۱۰۸] و [۱۰۹] عملکرد عالی از کاربرد کلاس‌بندی کننده‌ی SV در پیش‌بینی سری‌های زمانی و رگرسیون، نشان داده شده است.

Smola و Scholkopf، بررسی جامعی در رابطه با رگرسیون ماشین بردار پشتیبان انجام داده‌اند. بعلاوه، در [۱۱۰] و [۱۱۱] جزئیات بیشتری درخصوص هسته‌ها در زمینه کلاس‌بندی آورده شده است.


رگرسیون بردار پشتیبان یک روش برگرفته از الگوریتم ماشین بردار پشتیبان است. فرض کنید داده‌های آموزش $\{(x_1, y_1), \dots, (x_l, y_l)\} \subset \mathcal{X} \times \mathbb{R}$ داده شده است که در آن $\mathcal{X}$ مشخص کننده‌ی فضای داده‌های ورودی است بطوری که $\mathcal{X} = \mathbb{R}^d$.

اگر داده‌های آموزشی بصورت خطی جداپذیر باشند، همانطور که در شکل (۳-۵) دیده می‌شود، بی‌نیازیت خط (ابرفاصله) برای جداسازی این داده‌ها وجود دارد و در الگوریتم بردار پشتیبان باید خط جداسازی

^۱ Support Vector Regression (SVR)


^۲ Optical character recognition (OCR)

انتخاب شود که خطای تعمیم را به حداقل می‌رساند. براساس قضیه‌ای در تئوری یادگیری، از بین جداسازهای خطی، آن جداسازی که حاشیه داده‌های آموزشی را حداکثر می‌کند، می‌تواند بعنوان بهترین جداساز در نظر گرفته شود زیرا باعث حداقل کردن خطای تعمیم می‌شود.



شکل (۳-۵) جداسازی داده‌های آموزشی مشخص شده با دواير آبی و قرمز با خطوط جداساز (ابرفصله‌های مختلف)

در مواردی که داده‌های آموزشی بصورت خطی جداپذیر نیستند، ابتدا داده‌ها به فضایی با ابعاد بیشتر نگاشت داده می‌شوند تا در آن فضا بتوانند بصورت خطی جداسازی شوند. در شکل (۳-۶)، خط پررنگ، بهترین خط جداساز، ρ ، پهنای حاشیه و داده‌های آموزشی که روی خطوط کمرنگ قرار گرفته‌اند و با دایره‌های بزرگتر متمایز شده‌اند، بعنوان بردارهای پشتیبان در نظر گرفته می‌شوند. به عبارت دیگر، نزدیکترین داده‌های آموزشی به خط جداساز، "بردارهای پشتیبان" نامیده می‌شوند.



شکل (۶-۳) نمایش داده‌های آموزشی، پهنای حاشیه، خط جداساز و بردارهای پشتیبان برای دو کلاس مشخص شده با دوائر آبی و قرمز

در رگرسیون $\varepsilon - SV$ [۱۱۲]، هدف پیدا کردن یک تابع $f(x)$ است که به ازای تمامی داده‌های آموزشی، حداکثر انحراف از داده‌های هدف، y_1 مقدار ε باشد. به عبارت دیگر، در رگرسیون $\varepsilon - SV$ ، به خطاهای کمتر از ε توجه نمی‌شود و در ضمن، اجازه‌ی داشتن خطاهای بیشتر از ε نیز داده نمی‌شود. برای این منظور، توابع خطی f بصورت رابطه (۱۴-۳) در نظر گرفته می‌شوند:

$$f(x) = \langle w, x \rangle + b \quad w \in \chi, b \in \mathbb{R} \quad (۱۴-۳)$$

در رابطه (۱۴-۳)، $\langle \dots \rangle$ ضرب نقطه‌ای در χ است. در این معادله، w و b ناشناخته است. لذا، هدف، تخمین این مقادیر براساس داده‌های آموزشی مجموعه χ است.

برای سادگی، به ازای تمامی داده‌های آموزشی χ ، فقط دو کلاس در نظر می‌گیریم که با $y_i \in \{+1, -1\}$ نشان داده می‌شود. لذا، با توجه به رابطه (۱۴-۳) و پهنای حاشیه ρ ، رابطه (۱۵-۳) بدست می‌آید.

$$\begin{aligned} W^T x_i + b &\leq -\frac{\rho}{2} & \text{if } y_i = -1 \\ W^T x_i + b &\geq +\frac{\rho}{2} & \text{if } y_i = +1 \end{aligned} \quad (۱۵-۳)$$

به ازای بردارهای پشتیبان هر کلاس، نامساوی‌های رابطه (۳-۱۵) به مساوی تبدیل می‌شوند. فاصله بین هر بردار پشتیبان و خط جداساز از رابطه (۳-۱۶) محاسبه می‌شود.

$$r = \frac{y_s(W^T x_s + b)}{\|W\|} = \frac{1}{\|W\|} \quad (۳-۱۶)$$

x_s و y_s بعنوان داده‌های آموزشی $\mathcal{X}$ مربوط به بردارهای پشتیبان در نظر گرفته شده‌اند. با استفاده از رابطه (۳-۱۶)، پهنای حاشیه ρ ، از رابطه (۳-۱۷) بدست می‌آید.

$$\rho = 2r = \frac{2}{\|W\|} \quad (۳-۱۷)$$

همانطور که در بالا بیان شد، هدف، ماکزیمم کردن پهنای حاشیه، ρ ، است. لذا باید $\frac{2}{\|W\|}$ ماکزیمم و یا به عبارت دیگر، $\frac{1}{2}\|w\|^2$ می‌نیمم شود. بنابراین، در فاز یادگیری الگوریتم بردار پشتیبان، بدنبال بردار w که نرم تابع نگاشت مدل و b افست مدل، هستیم. برای رسیدن به این پارامترها، رابطه (۳-۱۸) با قید (۳-۱۹) می‌بایست کمینه شود.

$$\text{minimize} \quad \frac{1}{2}\|w\|^2 \quad (۳-۱۸)$$

$$\text{subject to} \quad \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon \end{cases} \quad (۳-۱۹)$$

تا این مرحله، فرض بر این است که تابع f به ازای تمامی داده‌های آموزشی، با دقت ε وجود دارد. برخی مواقع، ممکن است این فرضیه صدق نکرده و یا بخواهیم مقداری خطا در تخمین را بپذیریم. اگر داده‌های آموزشی دارای نویز بوده و یا نقاط پرت داشته باشند، از تابع جریمه برای این موضوع استفاده می‌شود. بر

این اساس، "حاشیه نرم" در ماشین‌های SV توسط [۱۱۳] مطرح شد. لذا، روابط (۳-۱۸) و (۳-۱۹) بصورت رابطه (۳-۲۰)، بازنویسی می‌شود.

$$\begin{aligned} \text{minimize} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{subject to} \quad & \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned} \quad (3-20)$$

در رابطه (۳-۱۹)، خطای آموزشی صفر است ولی در رابطه (۳-۲۰)، خطای آموزشی ξ و ξ^* است. پارامتر C ، میزان جریمه در ازای قرار گرفتن در ناحیه پرت را دربردارد. براساس مطالب بالا، تابع لاگرانژ بصورت رابطه (۳-۲۱) نوشته می‌شود.

$$\begin{aligned} L := & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \\ & - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) \\ & - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x_i \rangle - b) \end{aligned} \quad (3-21)$$

در رابطه (۳-۲۱)، α_i ، η_i ، α_i^* و η_i^* ضرایب لاگرانژ هستند و بزرگتر از صفر می‌باشند که در رابطه (۳-۲۲) نشان داده شده است.

$$\alpha_i, \eta_i, \alpha_i^*, \eta_i^* \geq 0 \quad (3-22)$$

مطابق رابطه‌های (۲۳-۳) تا (۲۶-۳)، برای مینیم کردن تابع L ، از این تابع نسبت به w, b, ξ, ξ^* مشتق گرفته و برابر صفر قرار داده می‌شود.

$$\partial_b L = \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \quad (23-3)$$

$$\partial_w L = w - \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i = 0 \quad (24-3)$$

$$\partial_\xi L = C - \alpha_i - \eta_i = 0 \quad (25-3)$$

$$\partial_{\xi^*} L = C - \alpha_i^* - \eta_i^* = 0 \quad (26-3)$$


با جایگزینی رابطه‌های (۲۳-۳) تا (۲۶-۳)، در رابطه (۲۱-۳)، تابع هدف برای رگرسیون خطی بردار پشتیبان بصورت رابطه (۲۷-۳) تعریف می‌شود.

$$\begin{aligned} & \underset{\alpha_i, \alpha_i^*}{\text{minimize}} \quad \begin{cases} -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \\ -\varepsilon \sum_{i=1}^l (\alpha_i - \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{cases} \quad (27-3) \\ & \text{subject to} \quad \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \quad \text{and} \quad \alpha_i, \alpha_i^* \in [0, C] \end{aligned}$$


پس از محاسبه ضرایب α_i و α_i^* ، ضرایب η_i و η_i^* با جایگزینی مقادیر α_i و α_i^* در رابطه‌های (۲۵-۳) و (۲۳-۳) بدست می‌آیند. لذا، رابطه (۱۴-۳) بصورت رابطه (۲۸-۳) بازنویسی می‌شود.

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (28-3)$$

در صورت غیرخطی بودن داده‌های آموزشی و عدم امکان جداسازی آن‌ها بصورت خطی، از یک تابع نگاشت استفاده می‌شود که داده‌های آموزشی را به فضای جدیدی نگاشت می‌دهد تا در این فضا، داده‌ها بتوانند بصورت خطی جداسازی شوند. در شکل (۳-۷)، داده‌های آموزشی بصورت خطی جداپذیر نیستند. لذا، باید با استفاده از تابع کرنل به فضای با ابعاد بالاتر، مشابه شکل (۳-۸) نگاشت داده شوند در این فضا بتوانند بصورت خطی جداسازی شوند. بنابراین، برای رگرسیون غیرخطی، نیاز به اضافه کردن تابع کرنل به تابع هدف است.



شکل (۷-۳) نمایش داده‌های آموزشی جداپذیر غیرخطی برای دو کلاس مشخص شده با دوایر آبی و قرمز



شکل (۸-۳) استفاده از تابع کرنل برای نگاشت داده‌های آموزشی شکل (۷-۳) به فضای بالاتر (انتقال از فضای دو بُعدی به فضای سه بُعدی)

رابطه (۲۹-۳)، رگرسیون غیرخطی بردار پشتیبان براساس تابع کرنل k را نشان می‌دهد.

$$\underset{\alpha^*, \alpha}{\text{maximize}} \quad \begin{cases} -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(x_i, x_j) \\ -\varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{cases} \quad (29-3)$$

$$\text{subject to} \quad \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \quad \alpha_i, \alpha_i^* \in [0, C]$$

پس از محاسبه ضرایب لاگرانژ و سپس w ، رابطه (۳-۱۴) بصورت رابطه (۳-۳۰) بازنویسی می شود.

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b \quad (30-3)$$

۳-۵ معیار ارزیابی

ارزیابی کیفیت تصویر، یکی از زمینه های چالش برانگیز در سیستم پردازش تصاویر دیجیتالی است. ارزیابی کیفیت تصویر، به معنای تخمین کیفیت یک تصویر بوده که استفاده از آن برای بسیاری از کاربردهای پردازش تصویر ضروری می باشد. این ارزیابی می تواند توسط انسان یا بدون دخالت انسان انجام پذیرد. در اغلب تحقیقات افزایش وضوح تصویر از معیار^۱ PSNR برای مقایسه ی میزان خطای تصاویر بازسازی شده استفاده شده است. لذا، جهت مقایسه ی روش پیشنهادی با سایر راهکارها، از این معیار استفاده می شود. هرچند استفاده از معیارهای ساختاری از قبیل SSIM^۲ که به سیستم بینایی انسان نزدیک تر می باشند،

^۱ Peak Signal to Noise Ratio (PSNR)

^۲ Structural SIMilarity (SSIM)

می‌تواند کارآمدتر بوده و بعنوان یک معیار مناسب برای مقایسه‌ی کارایی راهکارهای افزایش وضوح تصویر مورد استفاده قرار گیرد. در ادامه توضیح مختصری از دو معیار PSNR و SSIM آورده شده است.

۳-۵-۱ معیار PSNR

یکی از معیارهای ارزیابی کیفیت تصویر براساس میزان قدرت سیگنال به نویز است که برحسب دسی‌بل (dB) بیان می‌شود و طبق رابطه‌ی زیر تعریف می‌گردد:

$$PSNR(A, B) = 10 \log_{10} \left(\frac{MAX^2}{MSE(A, B)} \right) = 20 \log_{10} \left(\frac{MAX}{\sqrt{MSE(A, B)}} \right) \quad (3-31)$$

که در رابطه‌ی بالا MAX بیشترین مقدار ممکن روشنایی یک پیکسل از تصویر است. مثلاً برای تصاویر b بیتی، مقدار MAX برابر با $2^b - 1$ است.

۳-۵-۲ معیار SSIM

یکی از معیارهایی اندازه‌گیری کیفیت تصویر که شباهت ساختاری را لحاظ می‌نماید SSIM است. ایده اصلی معیار شباهت ساختاری، براین اساس استوار است که سیستم بینایی انسان برای استخراج اطلاعات ساختاری صحنه قابلیت بالایی دارد. بنابراین، در اندازه‌گیری کیفیت تصویر، حفظ ساختار آن باید یکی از موارد مهم باشد.

برای محاسبه‌ی SSIM دو تصویر، فرض کنید x و y دو بخش از تصویر باشند که از محلی یکسان از دو تصویر مورد مقایسه گرفته شده‌اند. شاخص SSIM، شباهت سه عامل از بخش تصویر x و y را اندازه‌گیری می‌کند که روشنایی دو بخش $l(x, y)$ ، تباین دو بخش $c(x, y)$ ، و ساختار دو بخش $s(x, y)$ هستند. این

شباهت‌های محلی با استفاده از روابط آماری ساده که به آسانی قابل مقایسه‌اند بیان شده‌اند و به صورت زیر با هم ترکیب شده تا SSIM را ایجاد کنند.

$$SSIM(x, y) = l(x, y) \cdot c(x, y) \cdot s(x, y) = \left(\frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \right) \left(\frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \right) \left(\frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \right) \quad (3-32)$$

که در آن μ_x و μ_y به ترتیب میانگین مقادیر روشنایی در پنجره‌های x و y و σ_x و σ_y به ترتیب انحراف معیار روشنایی در پنجره‌های x و y است و σ_{xy} همبستگی متقابل بین پنجره‌های x و y می‌باشد. اعداد c_1 ، c_2 و c_3 ثابت‌هایی کوچک و مثبت هستند که برای جلوگیری از ناپایداری محاسباتی زمانی که میانگین، واریانس یا همبستگی پیکسل‌ها نزدیک صفر است استفاده می‌شوند.

۳-۶ پایگاه داده مورد استفاده

یکی از پایگاه‌های داده‌ای که در مقالات اخیر در زمینه‌ی افزایش وضوح تک تصویر مورد استفاده قرار گرفته شده است، پایگاه داده‌ی USC-SIPI^۱ می‌باشد. این پایگاه داده شامل چهار گروه متفاوت از تصاویر است. هر یک از این گروه‌ها دربرگیرنده‌ی تصاویری با اندازه‌های مختلف ۲۵۶×۲۵۶، ۵۱۲×۵۱۲ و ۱۰۲۴×۱۰۲۴ پیکسل می‌باشند. تصاویر سیاه و سفید، ۸ بیتی و تصاویر رنگی ۲۴ بیتی هستند. این گروه‌ها عبارتند از:

مجموعه تصاویر متفرقه^۲

این گروه شامل ۴۴ تصویر است که ۱۶ تصویر آن رنگی و ۲۸ تصویر آن تک رنگ می‌باشند. ۴ تصویر آن به اندازه‌ی ۲۵۶×۲۵۶، ۲۶ تصویر ۵۱۲×۵۱۲ و ۴ تصویر ۱۰۲۴×۱۰۲۴ هستند.

^۱ <http://sipi.usc.edu/database>

^۲ Miscellaneous volume

مجموعه تصاویر بافت^۱

این گروه شامل ۱۵۵ تصویر است که تمام تصاویر سطح خاکستری بوده و اندازه‌ی ۱۳۰ تصویر آن ۵۱۲×۵۱۲ و ۲۵ تصویر ۱۰۲۴×۱۰۲۴ هستند.

مجموعه تصاویر هوایی^۲

این مجموعه تصاویر شامل ۳۸ تصویر بوده که از این تصاویر، ۳۷ تصویر رنگی و ۱ تصویر سطح خاکستری می‌باشد. اندازه‌ی ۱۲ تصویر ۵۱۲×۵۱۲، ۲۵ تصویر ۱۰۲۴×۱۰۲۴ و تنها ۱ تصویر ۲۲۵۰×۲۲۵۰ است.

مجموعه تصاویر دنباله‌ای^۳

این مجموعه شامل ۶۹ تصویر در ۴ دنباله می‌باشد. ۳ دنباله‌ی آن شامل ۱۶، ۳۲ و ۱۱ تصویر ۲۵۶×۲۵۶ و ۱ دنباله شامل ۱۰ تصویر ۵۱۲×۵۱۲ است.

روش‌های پیشنهادی این رساله، بدلیل وقت‌گیر بودن اجرای برنامه، برای هشت تصویر که غالباً در مقالات افزایش تفکیک‌پذیری مورد مقایسه استفاده شده‌اند، اجرا شده است و سپس نتایج برای این تصاویر مورد بررسی و مقایسه قرار گرفته است. در شکل (۳-۹)، هشت تصویر برای آزمون نشان داده شده است.

¹ Texture volume

² Aerials volume

³ Sequences volume



شکل (۳-۹) مجموعه تصاویر برای آزمون (از چپ به راست و بالا به پایین): tree, dena, house, susan, peppers, baboon و airplane, boat

۳-۷ جمع‌بندی

در روش‌های ارائه شده در این رساله، به جای استفاده از پایگاه‌داده‌ای از تصاویر با تفکیک‌پذیری بالا و پایین، از دو هرم تصویر استفاده شده است. این دو هرم با اعمال مکرر الگوریتم‌های کاهش و افزایش نرخ نمونه‌برداری بر تصویر ورودی ایجاد می‌شوند. این دو هرم شامل تصاویر با تفکیک‌پذیری بالا و پایین متناظر هستند که از اطلاعات این تصاویر می‌توان برای تخمین ارزش پیکسل‌ها در تصویر خروجی استفاده کرد. برای این منظور باید ارتباط بین ویژگی‌های تصاویر با تفکیک‌پذیری بالا و پایین به نحوی مدل‌سازی شود. در این رساله، از مدل‌های رگرسیونی برای یادگیری این ارتباط استفاده شده است. بازنمایی تنک و گرادیان مرتبه اول و دوم، بعنوان ویژگی هر وصله از تصویر در آموزش و آزمون این مدل‌ها مورد استفاده قرار گرفته است. در نهایت، برای مقایسه نتایج، از دو معیار PSNR و SSIM استفاده شده است.

فصل ۴: روش های پیشنهادی فرا تعلیم پذیری تک تصویری باد نظر گرفتن اطلاعات همسایگی

۴-۱ مقدمه

همانطور که اشاره شد الگوریتم پیشنهادی برای افزایش تفکیک پذیری تصویر در این رساله مبتنی بر اطلاعات تصویر ورودی است. از طرفی برای یادگیری رابطه وصله های وضوح بالا و نسخه وضوح پایین آن از بازنمایی تصویر ورودی در هرم های وضوح بالا و پایین استفاده می نماییم. در این رساله برای افزایش وضوح تصویر ورودی از پیکسل های همسایه بازسازی شده هر پیکسل استفاده می نماییم. همانگونه که نتایج تجربی نشان می دهد این روش موجب بهبود کیفیت در تصویر فرا تفکیک شده خواهد شد.

۴-۲ روش اول: در نظر گرفتن مقادیر پیکسل های مجاور بازسازی


شده

یکی از چالش های راهکار مبتنی بر یادگیری، وابستگی کارایی این راهکار به مجموعه داده های آموزشی است. با استفاده از تک تصویر وضوح پائین ورودی و ایجاد هرم تصویر، می توان بدون نیاز به پایگاه داده ای از تصاویر، به جفت وصله های متناظر با تفکیک پذیری پایین و بالا دست یافت. در برخی تحقیقات انجام شده، استفاده از وصله های مجاور هر وصله از تصویر برای بازسازی نسخه تفکیک پذیری بالای آن وصله مهم گزارش شده است [۲۰] و [۳۶]. از طرف دیگر، برای بهبود در تخمین مقادیر جدید پیکسل ها براساس پیکسل های همسایه، می توان از مقادیر پیکسل های بازسازی شده قبلی و مجاور استفاده نمود. لذا با تکیه بر ایده ی [۲۰] و [۳۶] و استفاده از اطلاعات همسایه های مجاور هر پیکسل که در مراحل قبل بازسازی شده است این روش پیشنهادی را ارائه می کنیم.

از آنجائی که تصویر خروجی جهت تعیین ارزش پیکسل‌ها، سطر به سطر از چپ به راست و از بالا به پایین پیمایش می‌شود. لذا، مقادیر پیکسل مرکزی وصله‌های بالا و چپ هر وصله از تصویر از قبل تخمین زده شده است. از طرف دیگر، با عنایت به اندازه‌ی هر وصله از تصویر، در اغلب موارد، تغییرات در ارزش پیکسل‌ها در وصله‌های مجاور در یک تصویر ناچیز است. لذا، در روش پیشنهادی از بین مقادیر کاندیدا برای هر پیکسل، مقداری که دارای کمترین اختلاف با مقادیر پیکسل‌ها در وصله‌های مجاور است، انتخاب می‌گردد. در ادامه مراحل اجرای این روش که از فاز آموزش و آزمون تشکیل می‌شود توضیح داده شده است.

۴-۲-۱ فاز آموزش

در فاز آموزش، برای ایجاد وصله‌های وضوح بالا و پائین متناظر، به جای استفاده از پایگاه داده‌ای از سایر تصاویر، از دو هرم ساخته شده از تصویر ورودی استفاده می‌شود. همانطور که در فصل سوم توضیح داده شد، هرم با تفکیک‌پذیری بالا با استفاده از کاهش نرخ نمونه‌برداری تصویر ورودی تا ۳ سطح و هرم با تفکیک‌پذیری پایین با استفاده از درونیابی دومکعبی تصاویر در سطوح مختلف هرم تفکیک‌پذیری بالا ایجاد می‌گردند. ارتباط بین هر پیکسل از هرم اول و وصله متناظر آن در سطح مشابه هرم دوم، با استفاده از رگرسیون بردار پشتیبان مطابق توضیحات داده شده در فصل سوم مدل رگرسیونی شدت روشنایی آموزش داده می‌شود. لذا، به ازای هر پیکسل، به تعداد سطوح هرم، مقادیر کاندیدا برای تخمین ارزش پیکسل وجود دارد. برای انتخاب مقدار بهینه برای هر پیکسل، از مدل اختلاف استفاده شده است که این مدل، میزان اختلاف مابین پیکسل مرکزی وصله مدنظر با پیکسل‌های مرکزی وصله‌های بالا و چپ که قبلاً در فرایند بازسازی مقدار گرفته‌اند، را نشان می‌دهد (شکل ۴-۱). به این نکته توجه شود که وصله‌های تصویر از گوشه‌ی بالا سمت چپ تا گوشه‌ی پایین سمت راست در هر سطر از چپ به راست جاروب می‌شود.



الف ب

شکل (۱-۴) الف- نمایش پیمایش تصویر از چپ به راست و از بالا به پایین. ب- تخمین پیکسل غیرلبه‌ی مرکزی وصله (پیکسل شماره ۵) با استفاده از پیکسل‌های مرکزی وصله‌های بالا و چپ (پیکسل‌های ۱ تا ۴).

با فرض در نظر گرفتن $p1, p2, p3, p4$ بعنوان مراکز وصله‌های همجوار پیکسل p که در ردیف بالاتر و یا سمت چپ پیکسل p قراردارند، خطای پیکسل p و پیکسل‌های همجوار، $diff$ ، بصورت رابطه (۱-۴) محاسبه می‌شود:

$$diff = \sqrt{\sum_{i=1}^4 (p - p_i)^2} \quad (1-4)$$

در روش پیشنهادی هم برای مدل سازی رابطه وصله‌های وضوح پایین با ارزش پیکسل مرکزی در مرکز وصله وضوح بالا و همچنین خطای تخمین در ارزش پیکسل‌ها از مدل رگرسیون بردار پشتیبان استفاده می‌گردد. در این روش توصیف هر وصله از تصویر به کمک بردار ویژگی مناسب بجای استفاده‌ی مستقیم از ارزش پیکسل‌ها، کارایی مساله را افزایش می‌دهد. بدین منظور، برای توصیف هر وصله از تصویر، از نمایش تنک استفاده شده است.

بنابراین در فاز آموزش، به ازای هر سطح هرم، دو مدل رگرسیونی آموزش داده می‌شود. از آنجائی که در روش پیشنهادی ۳ سطح برای هرم تفکیک پذیری بالا و پایین در نظر گرفته شده است، شش مدل آموزش

داده می شود که ۳ مدل، ارتباط بین ویژگی (ضرایب تنک) هر وصله در تصویر تفکیک پذیری پایین و ارزش پیکسل مرکزی در وصله متناظر از تصویر تفکیک پذیری بالا را یاد می گیرند. ۳ مدل دیگر براساس مدل اختلاف ارائه شده در رابطه (۴-۱) ایجاد می شوند. در این ۳ مدل، ارتباط بین بردار ویژگی هر وصله در تصویر تفکیک پذیری پایین و میزان اختلاف ارزش پیکسل مرکزی آن با پیکسل های مرکزی وصله های همجوار متناظر در تصویر تفکیک پذیری بالا آموزش داده می شود.

۴-۲-۲ فاز آزمون

در فاز آزمون، ابتدا، اندازه ی تصویر ورودی با استفاده از الگوریتم درویابی دومکعبی، افزایش یافته تا نسخه ی وضوح پایین هم بُعد با تصویر فرا تفکیک شده ($\tilde{I}_{+1}$) در شکل (۳-۱) ایجاد گردد. هدف تخمین ارزش پیکسل های نسخه ی فرا تفکیک شده از روی نسخه کم وضوح و اطلاعات سطوح مختلف هرم های تصویر می باشد. تصویر $\tilde{I}_{+1}$ به وصله های هم پوشان تقسیم می شود. بردار ویژگی هر وصله به مدل های اختلاف روشنایی هر یک از سه سطح داده می شود. هر یک از سطوح هرم که دارای کمترین مقدار خطای تخمین باشد برای تخمین روشنایی مرکز وصله مورد بررسی انتخاب می گردد. در نهایت، بردار ویژگی وصله مورد بررسی به مدل تخمین رگرسیونی تخمین روشنایی سطح انتخاب شده داده شده و ارزش نهایی پیکسل مرکزی وصله تعیین می گردد. این عمل به ازای هر وصله از تصویر $\tilde{I}_{+1}$ تکرار می شود. در اشکال (۴-۲) و (۴-۳)، دیاگرام روش پیشنهادی برای فاز آموزش و آزمون آورده شده است.



```

graph TD
    A[تصویر درون یابی شده  
+۱] --> B[استخراج ویژگی  
(ضرایب تنک)]
    B --> C[مدل های ارتباط]
    B --> D[مدل های اختلاف]
    C --> E[تخمین مقادیر جدید  
(با استفاده از مدل های ارتباط)]
    D --> F[تخمین میزان خطا  
با استفاده از مدل های اختلاف]
    E --> G[انتخاب بهترین مقدار براساس میزان خطا]
    F --> G
    G --> H[تصویر خروجی  
H]

```

 $\vee \wedge$

۴-۲-۳ ارزیابی نتایج

روش پیشنهادی بر هشت تصویر پایگاه داده‌ی USC-SIPI اعمال شده است. از آنجائی که سیستم بینایی انسان به کانال روشنایی بیشتر از سایر کانال‌های رنگ حساس است، تصاویر رنگی مورد استفاده به مدل رنگ YCbCr تبدیل شده و الگوریتم پیشنهادی تنها بروی کانال روشنایی (Y) اعمال می‌شود. در تصویر خروجی، سایر مؤلفه‌های رنگ با استفاده از درونیابی دومکعبی مقدار گرفته‌اند. برای ایجاد دو هرم شکل (۳-۱)، از الگوریتم درونیابی دومکعبی برای کاهش و افزایش نرخ نمونه‌برداری استفاده شده است. برای آموزش و آزمون مدل‌ها، جعبه ابزار مرجع [114] بکار گرفته شده است.



شکل (۴-۴) مقایسه خروجی روش‌های افزایش وضوح تصویر برای تصویر airplane. به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی، خروجی روش‌های افزایش تفکیک پذیری مبتنی بر همسایگی تعبیه شده [۳۶]، افزایش تفکیک پذیری تک تصویر خودیادگیرنده [۵۱]، افزایش تفکیک پذیری مبتنی بر بازنمایی تنگ با استفاده از رگرسیون بردار پشتیبان [۴۴] و روش پیشنهادی ۱.

در جدول (۴-۱)، از معیار PSNR جهت مقایسه‌ی نتایج استفاده شده است.

جدول (۴-۱) مقادیر PSNR(in dB) برای روش های [۵۱]، [۳۶]، [۴۴] و روش پیشنهادی ۱

تصویر	tree	lena	house	susan	peppers	Boat	airplane	baboon	میانگین
SISR [۵۱]	۲۶,۹۴۰۵	۳۳,۶۵۷۹	۳۰,۹۲۱۵	۳۳,۷۵۶۰	۳۱,۷۱۷۸	۲۹,۷۹۱۹	۳۱,۱۵۵۶	۲۳,۳۸۴۳	۳۰,۱۶۵۷
LLE [۳۶]	۲۵,۸۲۵۱	۳۳,۴۹۸۱	۲۹,۴۹۹۵	۳۱,۸۴۰۴	۳۰,۶۴۲۷	۲۴,۲۷۹۴	۲۹,۶۸۷۵	۲۲,۹۴۸۷	۲۸,۵۲۷۷
LsSR [۴۴]	۲۷,۳۹۶۲	۳۳,۸۸۲۹	۳۱,۰۲۷۰	۳۲,۱۰۶۶	۳۱,۳۹۵۹	۳۰,۲۷۲۸	۳۱,۶۶۰۵	۲۳,۶۵۲۴	۳۰,۱۷۴۳
ProposedMethod1	27.2932	34.0052	31.8025	32.6234	33.3997	30.2921	31.3635	23.8913	30.6589

از آنجائی که در اغلب موارد، تغییرات در ارزش پیکسل ها در وصله های مجاور تصاویر ناچیز است، لحاظ کردن اطلاعات همسایگی برای تخمین مقدار جدید ارزش پیکسل می تواند باعث ایجاد سازگاری بین روشنایی پیکسل های همجوار گردد. همانطور که در جدول (۴-۱) نشان داده شده است، روش پیشنهادی در اغلب موارد، دارای مقادیر PSNR بالاتری نسبت روش های [۵۱]، [۳۶] و [۴۴] است که این موضوع نشان از تاثیر اطلاعات همسایگی وصله های تصویر در افزایش وضوح آن دارد.

۴-۳ روش دوم: ارائه مدل جداگانه ای برای پیکسل های لبه و غیر لبه

و نواحی هموار و غیر هموار

در روش ارائه شده در بخش قبل، از مدل کردن اختلاف روشنایی پیکسل های مرکزی در وصله های همجوار برای انتخاب سطح هرم مناسب برای تخمین مقدار پیکسل مرکزی در وصله وضوح بالا استفاده شده است.

از آنجائی که مدل اختلاف روشنایی پیکسل های همجوار برای لبه ها و پیکسل های غیر لبه متفاوت است در نظر گرفتن یک مدل برای اختلاف روشنایی باعث هموار شدن روشنایی در پیکسل های لبه می شود، برای رفع این مشکل پیشنهاد می گردد از مدل های جداگانه ای برای اختلاف روشنایی در لبه ها و غیر لبه ها استفاده شود. لذا، برای بهبود نتایج و کاهش اثرات تارشدگی و اثرات غیرطبیعی بر پیکسل های لبه، الگوریتم لبه یابی بر تصاویر سطوح مختلف دو هرم (تفکیک پذیری بالا و تفکیک پذیری پائین) اعمال می شود. در روش های پیشنهادی این رساله، الگوریتم های لبه یابی متفاوتی با روش آزمون و خطا مورد بررسی قرار گرفت و در نهایت الگوریتم لبه یابی سو بل با حد آستانه 0.03 انتخاب گردید. پس از تفکیک پیکسل های لبه و غیر لبه رویکرد متفاوتی برای تخمین روشنایی این پیکسل ها در تصویر فراتفکیک شده پیشنهاد می گردد. در ادامه، فاز آموزش و آزمون روش پیشنهادی آورده شده است.

۴-۳-۱ فاز آموزش

وصله های اطراف پیکسل های لبه ی تصاویر هرم تفکیک پذیری پائین استخراج شده و ضرائب تُنک هر وصله بعنوان بردار ویژگی آن وصله محاسبه می شود (رابطه (۳-۷)). متناظر با هر وصله وضوح پایین در هر یک از سطوح هرم یک وصله وضوح بالا در سطح متناظر از هرم تفکیک پذیری بالا وجود دارد. رابطه روشنایی مرکز وصله های وضوح بالا و ویژگی های تُنک وصله های متناظر وضوح پایین در یک مدل رگرسیونی بصورت رابطه (۴-۲)، یادگیری می شود:

$$M_E = SVR(\alpha_E, L_E) \quad (2-4)$$

در رابطه (۴-۲)، α_E بردار ضرائب تُنک وصله های شامل پیکسل لبه در تصاویر هرم تفکیک پذیری پائین، L_E شدت روشنایی پیکسل های لبه در تصاویر هرم با تفکیک پذیری بالا، SVR ، رگرسیون بردار پشتیبان برای یادگیری ارتباط بین ویژگی های وصله های تصاویر باتفکیک پذیری پائین و تفکیک پذیری بالا M_E ،

مدل ایجاد شده براساس پیکسل‌های لبه است. به ازای تمامی سطوح هرم، تنها یک مدل برای پیکسل‌های لبه آموزش داده می‌شود.

حتی برای پیکسل‌ها غیر لبه که در نواحی با بافت غیر هموار قرار دارند اعمال سازگاری بین روشنایی همسایه‌ها باعث تارشدن و از دست رفتن جزئیات می‌شود. لذا، از دیگر موارد مدنظر جهت کاهش اثرات تارشدگی تصویر، تفکیک پیکسل‌های غیرلبه در نواحی یکنواخت از نواحی غیریکنواخت است. برای تخمین روشنایی پیکسل‌ها در این دو گروه نیز استراتژی‌های مختلفی بکار گرفته می‌شود.

برای تفکیک پیکسل‌های مناطق یکنواخت از پیکسل‌های مناطق غیر یکنواخت از الگوریتم لبه یابی با حد آستانه پایین استفاده می‌نماییم. پس از تفکیک پیکسل‌ها با استفاده از الگوریتم لبه‌یابی مذکور، پیکسل‌های غیرلبه‌ای که چهار پیکسل همسایه بازسازی شده‌ی قبلی آن‌ها (پیکسل‌های ۱ تا ۴ در شکل (۴-۱ب))، نیز پیکسل غیرلبه هستند، بعنوان پیکسل‌های نواحی یکنواخت و مابقی پیکسل‌ها بعنوان پیکسل‌های نواحی غیریکنواخت شناخته می‌شوند.

با توجه اینکه در تخمین روشنایی پیکسل‌های تصویر فراتفکیک شده پیمایش سطرها چپ به راست و بالا به پایین است، ارزش پیکسل‌های همجوار بالا و سمت چپ هر پیکسل در مراحل قبلی الگوریتم مشخص شده است که از آن‌ها می‌توان برای تخمین مقدار جدید پیکسل استفاده کرد. به ازای هر پیکسل غیر لبه، وصله‌ای با مرکزیت آن پیکسل در نظر گرفته می‌شود اگر تمامی پیکسل‌های بالا و سمت چپ پیکسل مرکزی نیز غیر لبه باشند، پیکسل مرکز وصله در مجموعه هموار U_{NE} قرار می‌گیرد در غیر اینصورت این پیکسل در مجموعه غیر هموار P_{NE} قرار می‌گیرد. برای یادگیری رابطه بین پیکسل‌های همجوار در این دو دسته واژه نامه‌های جداگانه‌ای تهیه می‌گردد. برای آموزش مدل براساس پیکسل‌های مجموعه‌ی P_{NE} در تصویر با تفکیک پذیری پائین، ابتدا وصله‌های اطراف هر پیکسل را استخراج کرده و براساس وصله‌ها بدست آمده، واژه نامه D_{1NE} ایجاد می‌شود. سپس، با استفاده از واژه نامه D_{1NE} و رابطه (۳-۷)، ضرایب تُنک،

α_{1NE} ، بعنوان بردار ویژگی هر وصله محاسبه می‌شود. درنهایت، مشابه رابطه (۳-۴)، با استفاده از رگرسیون بردار پشتیبان، ضرایب تنگ و ارزش پیکسل مرکزی وصله‌ها متناظر در تصویر با تفکیک پذیری بالا، به کمک رابطه (۳-۴) مدل می‌شود.

$$M_{1NE} = SVR(\alpha_{1NE}, L_{NE}) \quad (3-4)$$

در رابطه (۳-۴)، M_{1NE} ، مدل ایجاد شده براساس پیکسل‌های غیرلبه مجموعه‌ی P_{NE} ، SVR اشاره به مدل رگرسیون بردار پشتیبان و α_{1NE} ضرایب تنگ وصله‌ها در اطراف پیکسل‌های غیرلبه در مجموعه‌ی P_{NE} و L_{NE} ارزش پیکسل‌های غیر لبه مجموعه‌ی P_{NE} در تصویر با تفکیک پذیری بالا است. مدل تعریف شده در رابطه (۳-۴)، به ازای هر سطح هرم، ایجاد می‌شود. برای انتخاب سطح مناسب هرم برای تخمین روشنایی یک پیکسل خطای تخمین روشنایی در هر سطح هرم نیز به کمک یک مدل رگرسیونی آموزش داده می‌شود. رابطه (۴-۴)، مدل رگرسیونی بکار گرفته شده برای تخمین خطا را نشان می‌دهد:

$$\begin{aligned} Pr_{NE} &= M_{1NE}(\alpha_{1NE}) \\ ER_{1NE} &= SVR(d(Pr_{NE}, L_{NE}), \alpha_{1NE}) \end{aligned} \quad (4-4)$$

در رابطه (۴-۴)، ER_{1NE} ، مدل خطای تخمین، $d(.)$ ، میزان اختلاف بین مقدار واقعی هر پیکسل در تصویر وضوح بالا، L_{NE} ، و مقدار تخمین زده شده توسط مدل M_{1NE} ، یعنی Pr است. مشابه مدل خطای تخمین ER_{1NE} ، برای پیکسل‌های لبه نیز آموزش داده می‌شود که در رابطه (۵-۴) نشان داده شده است.

$$\begin{aligned} Pr_E &= M_E(\alpha_E) \\ ER_{1E} &= SVR(d(Pr_E, L_E), \alpha_E) \end{aligned} \quad (5-4)$$

پارامترهای رابطه (۵-۴) مشابه رابطه (۴-۴) ولی به ازای پیکسل‌های لبه است.

برای مدل سازی ویژگی های پیکسل غیر لبه در نواحی هموار که در مجموعه U_{NE} لیست شده است، وصله های اطراف هر پیکسل در تصاویر هرم تفکیک پذیری پائین و متناظر آن در هرم تفکیک پذیری بالا استخراج

می‌شود و مشابه رابطه (۳-۴)، براساس این پیکسل‌ها نیز مدلی مبتنی بر رگرسیون ماشین بردار پشتیبان مطابق با رابطه (۶-۴)، آموزش داده می‌شود.

$$M_{2NE} = SVR(\alpha_{2NE}, L_{NE}) \quad (۶-۴)$$

پارامترهای این رابطه، مشابه رابطه (۳-۴) و برای پیکسل غیر لبه‌ی مجموعه U_{NE} ، تعریف می‌شوند. در روش پیشنهادی، برای انتخاب مقدار نهایی پیکسل‌های مجموعه U_{NE} ، از پیکسل‌های تخمین زده شده‌ی قبلی استفاده می‌شود که در بالا و سمت چپ هر یک از این پیکسل‌ها، قرار دارند. از آنجائی که تمامی این پیکسل‌ها غیرلبه هستند و الگوریتم لبه‌یابی با حد آستانه‌ی پائین مورد استفاده قرار گرفته است، اختلاف شدت روشنایی این پیکسل‌ها اندک است و از این موضوع در تخمین مقادیر پیکسل‌های غیرلبه‌ی مجموعه U_{NE} استفاده شده است.

به ازای هر وصله در هرم وضوح بالا که در نواحی هموار قرار گرفته است، فاصله‌ی اقلیدسی بین پیکسل مرکزی و پیکسل‌های مجاور محاسبه می‌شود که در رابطه (۷-۴) نشان داده شده است.

$$diff_Ne_j = \sqrt{\sum_{i=1}^4 (p_j - N_i)^2} \quad (۷-۴)$$


در رابطه (۷-۴)، $diff_Ne_j$ ، اختلاف مربوط به وصله‌ی زام تصویر در هرم وضوح بالا، p_j ، پیکسل مرکزی این وصله و N_i ، پیکسل i ام از چهار پیکسل بالا و سمت چپ در وصله‌ی زام است.

پس از تعیین بردار ویژگی‌های وصله‌های متناظر در دو هرم وضوح بالا و وضح پایین در نواحی هموار، مطابق رابطه‌ی (۸-۴)، مدل اختلاف ER_{2NE} برای پیکسل‌های غیرلبه‌ی مجموعه U_{NE} آموزش داده می‌شود.

$$ER_{2NE} = SVR(diff_Ne, \alpha_{2NE}) \quad (۸-۴)$$





در رابطه (۸-۴)، ER_{2NE} ، مدل اختلاف ایجاد شده برای مجموعه پیکسل‌های غیرلبه‌ی U_{NE} و SVR اشاره به مدل رگرسیون بردار پشتیبان برای یادگیری دارد. $diff_Ne$ ، فاصله‌ی اقلیدسی بین پیکسل مرکزی و پیکسل‌های بالا و سمت چپ وصله‌های وضوح بالا در مجموعه U_{NE} و α_{2NE} ، ضرایب تنگ وصله‌های وضوح

پایین مجموعه‌ی $U_{\mathcal{E}}$ است. بلوک دیاگرام فاز آموزش روش پیشنهادی برای آموزش مدل‌های تعریف شده به ازای پیکسل‌های لبه (روابط (۴-۲) و (۵-۴)) در شکل (۵-۴) نشان داده شده است.



شکل (۵-۴) بلوک دیاگرام فاز آموزش مدل‌های ارتباط بین اطلاعات تصاویر با تفکیک‌پذیری بالا و پایین و مدل‌های خطای تخمین به ازای پیکسل‌های لبه

در شکل (۶-۴)، نحوه‌ی آموزش مدل تعریف شده به ازای پیکسل‌های غیرلبه آورده شده است.



شکل (۴-۶) آموزش مدل‌های ارتباط بین اطلاعات تصاویر با تفکیک‌پذیری بالا و پایین و مدل‌های اختلاف به ازای پیکسل‌های غیر لبه

۴-۳-۲ فاز آزمون

بالاترین سطح هرم وضوح پایین $\tilde{I}_{+1}$ و تصویر خروجی، I_{+1} ، ابعاد یکسانی دارند. ابتدا، تصویر $\tilde{I}_{+1}$ به پیکسل‌های لبه و غیرلبه تقسیم می‌شود. سپس، از مدل رابطه (۴-۱) برای تخمین شدت روشنایی پیکسل‌های لبه استفاده می‌شود که در رابطه (۴-۹) نشان داده شده است.

$$\begin{aligned} H_E &= M_E(\alpha_E) \\ dif_{1E} &= ER_{1NE}(\alpha_{NE}) \end{aligned} \quad (۴-۹)$$

در رابطه (۴-۹)، مقدار تخمین زده شده برای پیکسل لبه، H_E ، با استفاده از مدل M_E و براساس ویژگی تُنک، α_E ، و dif_{1E} ، خطای تخمین این مدل است. از آنجائی که برای پیکسل‌های غیرلبه مجموعه P_{NE} ، به ازای هر سطح هرم، یک مدل با استفاده از رابطه (۴-۳) آموزش داده می‌شود، لذا، برای این پیکسل‌ها، به تعداد سطوح هرم، مقادیر کاندیدا وجود دارد که برای انتخاب مقدار نهایی، از مدل خطای تخمین (رابطه (۴-۴)) استفاده می‌شود. بنابراین، مقدار پیشنهادی مدلی با کمترین خطای تخمین، انتخاب می‌شود. در رابطه (۴-۱۰)، نحوه‌ی استفاده از مدل‌های روابط (۴-۳) و (۴-۴) به ازای یک سطح هرم آورده شده است.


$$\begin{aligned} H_{NE} &= M_{1NE}(\alpha_{NE}) \\ dif_{1NE} &= ER_{1NE}(\alpha_{NE}) \end{aligned} \quad (۴-۱۰)$$

در این رابطه، H_{NE} ، مقدار تخمین زده شده توسط مدل M_{1NE} و dif_{1NE} ، خطای تخمین این مدل است. نحوه تخمین مقادیر پیکسل‌های غیرلبه‌ی مجموعه هموار U_{NE} مشابه تخمین پیکسل‌های غیرلبه‌ی مجموعه P_{NE} و با استفاده از مدل رابطه (۴-۵) است. لذا، مقادیر پیشنهادی به ازای هر پیکسل غیرلبه‌ی مجموعه U_{NE} به تعداد سطوح هرم است. برای انتخاب بهترین مقدار، از مدل اختلاف (رابطه (۴-۸)) استفاده می‌شود و مقداری که کمترین اختلاف را با پیکسل‌های غیرلبه‌ی همسایه داشته باشد، در نظر گرفته می‌شود که در رابطه (۴-۱۱) مشخص شده است.

$$H_{NE} = M_{2NE}(\alpha_{NE})$$

$$ER_{2NE} = ER_{2NE}(\alpha_{NE}) \quad (۱۱-۴)$$

در رابطه (۱۱-۴)، H_{NE} ، مقدار تخمین زده شده برای پیکسل‌های غیرلبه‌ی مجموعه U_{NE} توسط مدل M_{2NE} و ER_{2NE} ، میزان اختلاف مقدار پیشنهادی با مقادیر غیرلبه‌ی بازسازی شده‌ی قبلی (بالا و سمت چپ) است. در شکل (۷-۴)، بلوک دیاگرام فاز آزمون روش پیشنهادی آورده شده است.



شکل (۷-۴) بلوک دیاگرام فاز آزمون براساس روابط (۹-۴) تا (۱۱-۴)

در شکل (۷-۴)، Pr ها مقادیر تخمین زده شده برای هر پیکسل براساس مدل‌های آموزشی و ER ها، خطای تخمین این مدل‌ها است.

۳-۳-۴ ارزیابی نتایج

در این روش، اندازه‌ی وصله‌ها برای تصاویر با تفکیک پذیری پائین و تفکیک پذیری بالا، 3×3 است. جدول (۲-۴) مقادیر PSNR و SSIM را برای روش‌های افزایش تفکیک پذیری مبتنی بر همسایگی تعیبیه شده [۳۶]، افزایش تفکیک پذیری تک تصویر خودیادگیرنده [۵۱]، افزایش تفکیک پذیری مبتنی بر بازنمایی تُنک با استفاده از رگرسیون بردار پشتیبان [۴۴] و روش پیشنهادی با ضریب افزایش تفکیک پذیری ۲ دربردارد. در این رساله، برای محاسبه‌ی معیارهای PSNR و SSIM، از توابع Matlab R2016a استفاده شده است. به ازای هر روش، سطر سفید مقادیر PSNR و سطر تیره، مقادیر SSIM هستند.


جدول (۲-۴) مقادیر PSNR(in dB) و SSIM برای مقایسه‌ی روش پیشنهادی ۲ با روش‌های [36] LLE.

LsSR[44] و SlSR[51]

روش تصویر	LLE [۳۶]	SlSR [۵۱]	LsSR [۴۴]	ProposedMethod2
Tree	۲۵,۸۲۵۱	۲۶,۹۴۰۵	۲۷,۳۹۶۲	۲۸,۵۰۸۹
	۰,۸۴۱۰	۰,۸۴۱۰	۰,۸۱۲۲	۰,۸۷۷۹
Lena	۳۳,۴۹۸۱	۳۳,۶۵۷۹	۳۳,۸۸۲۹	۳۵,۷۳۸۷
	۰,۹۰۵۶	۰,۸۹۸۶	۰,۹۰۶۲	۰,۹۳۴۶
House	۲۹,۴۹۹۵	۳۰,۹۲۱۵	۳۱,۰۲۷۰	۳۳,۱۳۸۲
	۰,۸۶۴۶	۰,۸۶۹۳	۰,۸۸۴۱	۰,۹۰۸۸
Susan	۳۱,۸۴۰۴	۳۳,۷۵۶۰	۳۲,۱۰۶۶	۳۵,۷۳۴۲
	۰,۹۲۳۹	۰,۹۲۹۰	۰,۹۳۹۱	۰,۹۵۱۰
Peppers	۳۰,۶۴۲۷	۳۱,۷۱۷۸	۳۱,۳۹۵۹	۳۳,۸۲۳۲
	۰,۸۶۶۹	۰,۸۶۶۰	۰,۷۹۲۴	۰,۹۱۹۵
Airplane	۲۹,۶۸۷۵	۳۱,۱۵۵۶	۳۱,۶۶۰۵	۳۳,۰۵۹۵
	۰,۹۱۲۲	۰,۹۲۱۱	۰,۹۲۴۲	۰,۹۴۷۲
Baboon	۲۹,۶۸۷۵	۲۳/۳۸۴۳	۲۳,۶۵۲۴	۲۵,۲۹۹۶
	۰,۹۱۲۲	۰/۶۸۵۴	۰,۶۶۶۳	۰,۷۵۵۵
میانگین	۲۹/۱۳۴۶	۳۰/۲۱۹۱	۳۰/۱۶۰۲۱	۳۲,۱۸۶۰
	۰/۸۵۳۰	۰/۸۵۸۶	۰/۸۴۶۳۵	۰,۸۹۹۲

همانطور که در جدول (۴-۲) مشاهده می‌شود، روش پیشنهادی به ازای تمامی تصاویر، بهبود قابل توجهی در هر دو معیار PSNR و SSIM نسبت به روش‌های مورد مقایسه داشته است. بیشترین اختلاف روش پیشنهادی با سایر روش‌های مطرح شده براساس معیار PSNR مربوط به Susan با ۳,۸۹۳۸ و معیار SSIM با ۰,۱۱۵۷ به تصویر baboon اختصاص دارد. میانگین اختلاف بین معیار PSNR و SSIM روش پیشنهادی با روش‌های مطرح شده به ترتیب ۲,۶۲۵۷ و ۰,۰۴۵۸ است.

در شکل (۴-۹)، تصویر هدف و تصاویر خروجی روش‌های درون‌یابی دومکعبی، افزایش تفکیک پذیری مبتنی بر همسایگی تعبیه شده [۳۶]، افزایش تفکیک پذیری تک تصویر خودیادگیرنده [۵۱] و روش پیشنهادی برای تصاویر lena نشان داده شده است. بخشی از تصویر که با مربع قرمز مشخص شده است، با جزئیات بیشتر در گوشه‌ی پایین-سمت راست هر تصویر نشان داده می‌شود.



شکل (۴-۸) نتایج افزایش تفکیک‌پذیری برای تصویر lena. به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی، خروجی روش‌های درون‌یابی دومکعبی، مراجع [۵۱]، [۳۶]، [۴۴] و روش پیشنهادی ۲.

همانطور که مشاهده می‌شود، روش پیشنهادی بدلیل اعمال الگوریتم‌های متفاوت به پیکسل‌های تصویر براساس پیکسل‌های همسایه‌ی آن‌ها، باعث کاهش اثر تارشدگی در لبه‌های تصویر نسبت به سایر روش‌ها شده است.

۴-۴ روش سوم: استفاده از k-means و LLE

هدف روش پیشنهادی، تخمین ارزش نهایی پیکسل مرکزی هر وصله با در نظر گرفتن ارزش پیکسل‌های وصله‌های مجاور آن است. تفاوت این روش با دو روش پیشنهادی قبلی در این است که در این روش، همسایگی در فضای ویژگی‌ها به جای همسایگی مکانی در نظر گرفته می‌شود.

۴-۴-۱ فاز آموزش


در فاز آموزش، ابتدا، براساس تصویر با تفکیک پذیری پائین ورودی، دو هرم تصویر با استفاده از الگوریتم درون‌یابی دومکعبی و کاهش نرخ نمونه‌برداری، ایجاد می‌شود. در فاز آموزش، تصاویر دو هرم به وصله‌های یکسان و هم‌پوشان تقسیم می‌شوند. مشتق مرتبه اول و مرتبه دوم، بعنوان ویژگی پیکسل‌های وصله‌های با تفکیک پذیری پائین در نظر گرفته شده است. ویژگی‌های استخراج شده از وصله‌های با تفکیک پذیری پائین، خوشه‌بندی می‌شوند. در این روش، از الگوریتم خوشه‌بندی k-means استفاده شده است. لذا، در این مرحله، وصله‌های تصاویر با تفکیک‌پذیری پائین براساس ویژگی‌های مشخص شده به تعدادی خوشه از پیش تعیین شده تقسیم می‌شوند.

۴-۴-۲ فاز آزمون

در فاز آزمون، به ازای هر وصله از "نسخه میانی تصویر خروجی"، خوشه آن وصله مشخص می‌گردد. با عنایت به اندازه‌ی هر وصله از تصویر، در اغلب موارد، تغییرات در ارزش پیکسل‌ها در وصله‌های مجاور تصاویر ناچیز است. لذا، می‌توان یک منیفلد با هندسه محلی مشابه را ایجاد کرد. لذا، برای این منظور از الگوریتم تعبیه خطی محلی استفاده شده است. دلیل استفاده از الگوریتم تعبیه خطی محلی، حفظ اطلاعات وصله‌های مجاور است. لذا، در خوشه برنده بدنبال k تا از نزدیک‌ترین وصله به وصله‌ی مدنظر می‌گردیم. ضرائب بازسازی وصله‌ی مدنظر براساس k وصله‌ی برنده، استخراج می‌شوند. وصله‌های با تفکیک پذیری بالای متناظر با k وصله‌ی برنده را در نظر گرفته و با اعمال ضرایب بازسازی بر این وصله‌ها، وصله‌ی با تفکیک پذیری بالا ایجاد می‌شود.


۴-۴-۳ ارزیابی نتایج

در شکل (۴-۱۱)، مقدار PSNR برای تصاویر مختلف و به ازای تعداد خوشه‌های مختلف و تعداد متفاوت همسایه‌های هر وصله نشان داده شده است. همانطور که در شکل (۴-۱۱) دیده می‌شود، بیشترین مقدار PSNR مربوط به تعداد ۵ خوشه و ۵ همسایه مجاور می‌باشد، لذا، در این روش، تعداد خوشه و تعداد نزدیک‌ترین همسایه‌های هر وصله، ۵ در نظر گرفته می‌شود.



شکل (۴-۹) نمودار مقادیر PSNR به ازای تعداد خوشه‌ها و تعداد همسایه‌های هر وصله در هر خوشه به ازای چندین تصویر از پایگاه تصاویر

با بررسی‌های بعمل آمده، اندازه‌ی وصله‌ها برای تصاویر پایگاه‌داده، 5×5 و میزان هم‌پوشانی وصله‌های مجاور، یک پیکسل در نظر گرفته شده است. روش پیشنهادی بر تصاویر پایگاه‌داده مذکور و با در نظر گرفتن مقادیر پارامترهای بالا، اعمال شده است. در شکل (۴-۱۲)، خروجی روش پیشنهادی، روش‌های [۳۶]، [۵۱] و [۴۴] نشان داده شده است.



شکل (۴-۱۰) نتایج افزایش تفکیک پذیری برای تصویر airplane. به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی، خروجی روش های مراجع [۵۱]، [۳۶]، [۴۴] و روش پیشنهادی ۳.

خروجی روش پیشنهادی این مقاله با روش های مراجع [۵۱]، [۳۶]، [۴۴] براساس معیار PSNR مقایسه شده است. نتایج این مقایسه در جدول (۴-۳) آورده شده است. به ازای هر روش، سطر سفید مقادیر PSNR و سطر تیره، مقادیر SSIM هستند.

جدول (۳-۴) مقایسه مقادیر PSNR(in dB) و SSIM روش پیشنهادی ۳ با سایر روش های مطرح در SR

baboon	airplane	Boat	Peppers	susan	house	lena	Tree	تصویر
								روش SR
۲۳,۳۸۴۳	۳۱,۱۵۵۶	۲۹,۷۹۱۹	۳۱,۷۱۷۸	۳۳,۷۵۶۰	۳۰,۹۲۱۵	۳۳,۶۵۷۹	۲۶,۹۴۰۵	SISR [51]
۰,۶۸۵۴	۰,۹۲۱۱	۰,۸۳۳۴	۰,۸۶۶۰	۰,۹۲۹۰	۰,۸۶۹۳	۰,۸۹۸۶	۰,۸۴۱۰	
۲۲,۹۴۸۷	۲۹,۶۸۷۵	۲۴,۲۷۹۴	۳۰,۶۴۲۷	۳۱,۸۴۰۴	۲۹,۴۹۹۵	۳۳,۴۹۸۱	۲۵,۸۲۵۱	LLE [36]
۰,۶۶۳۰	۰,۹۱۲۲	۰,۶۲۱۴	۰,۸۶۶۹	۰,۹۲۳۹	۰,۸۶۴۶	۰,۹۰۵۶	۰,۸۲۵۷	
۲۳,۶۵۲۴	۳۱,۶۶۰۵	۳۰,۲۷۲۸	۳۱,۳۹۵۹	۳۲,۱۰۶۶	۳۱,۰۲۷۰	۳۳,۸۸۲۹	۲۷,۳۹۶۲	LsSR [44]
۰,۶۶۶۳	۰,۹۲۴۲	۰,۸۴۶۱	۰,۷۹۲۴	۰,۹۳۹۱	۰,۸۸۴۱	۰,۹۰۶۲	۰,۸۱۲۲	
23.9209	33.1026	30.4685	33.1194	32.9309	30.7718	34.5019	27.9875	ProposedMethod3
0.7286	0.9484	0.8768	0.9042	0.9368	0.8767	0.9352	0.8860	

۴-۵ جمع بندی

در این فصل دو روش افزایش تفکیک پذیری خودیادگیرنده ارائه شد که هدف این روش ها در نظر گرفتن اطلاعات همسایگی و بکارگیری اطلاعات بازسازی شده ی قبلی است. از آنجائی که هر دو روش خودیادگیرنده هستند، نیازی به پایگاه تصاویر غیر از تصویر ورودی نیست. برای آموزش و آزمون مدل ها از رگرسیون بردار پشتیبان و از ضرایب تنک بعنوان ویژگی هر وصله استفاده می شود. از آنجائی که تصویر از چپ به راست و بالا به پایین جهت بازسازی پیمایش می شود، ارزش پیکسل های بالا و سمت چپ هر پیکسل از قبل تخمین زده شده است. با عنایت به اندازه ی هر وصله از تصویر، در اغلب موارد، تغییرات در ارزش پیکسل ها در وصله های مجاور تصاویر ناچیز است. لذا، از این مساله می توان در انتخاب مقادیر جدید هر پیکسل استفاده کرد و از بین مقادیر کاندیدا به ازای هر پیکسل، مقداری که دارای کمترین اختلاف با پیکسل های بازسازی

شده همسایه است، انتخاب نمود. در این روش با وجود اینکه از اطلاعات همسایگی بازسازی شده برای تخمین ارزش پیکسل‌ها استفاده می‌شود ولی باعث تارشدگی در لبه‌ها و در نتیجه هموارشدن تصویر می‌گردد. برای بهبود این روش و کاهش اثرات هموارسازی تصویر، ابتدا با الگوریتم لبه‌یابی پیکسل‌های به و غیرلبه در دو مجموعه قرار داده شدند و سپس برای پیکسل‌های غیرلبه نیز براساس قرارگرفتن در نواحی یکنواخت و یا غیریکنواخت دو الگوریتم متفاوت ارائه شد. لذا، جهت کاهش اثرات تارشدگی لبه‌های تصویر خروجی، برای پیکسل‌های لبه و یا پیکسل‌های غیرلبه‌ای که در همسایگی آن‌ها پیکسل‌های لبه قرار دارند، از اطلاعات پیکسل‌های همسایه استفاده نشده است. در این روش، از فاصله‌ی اقلیدسی بعنوان معیار سازگاری وصله‌های مجاور استفاده شده است که برای کار آتی می‌توان معیار مناسب دیگری استفاده کرد.

در روش دوم، وصله‌های تصاویر با تفکیک‌پذیری پایین با استفاده از الگوریتم k-means به تعدادی از پیش تعیین‌شده خوشه تقسیم شده و سپس در فرایند بازسازی مورد استفاده قرار می‌گیرند. در فاز آموزش، به ازای هر خوشه یک مدل ایجاد می‌شود. در فاز آزمون، به ازای هر وصله، پس از انتخاب نزدیک‌ترین خوشه به آن، با استفاده از الگوریتم LLE، تعدادی از وصله‌های مشابه و ضرایب بازسازی آن‌ها تعیین شده و در تخمین نهایی مورد استفاده قرار می‌گیرد. انتخاب تعداد ثابت خوشه به ازای هر تصویر بدون توجه به محتوی تصویر، باعث تارشدن لبه‌ها می‌شود. در این روش تعداد خوشه‌ها و تعداد همسایگی‌ها به ازای تمامی تصاویر ۵ در نظر گرفته شده است که برای کارهای آتی باید این انتخاب بصورت خودکار و براساس محتوای تصویر ورودی انجام شود.

فصل ۵: روش‌های پیشنهادی فرا تعلیم پذیری تک تصویری مبتنی بر ناحیه بندی و خوشه بندی زیر فضای تک

۵-۱ مقدمه

تمرکز این فصل بر افزایش تفکیک پذیری تصویر مبتنی بر محتوای تصویر ورودی است. در مبحث ارائه شده در فصل چهارم، از اطلاعات وصله‌های مجاور برای تخمین ارزش پیکسل‌ها استفاده شده است. ابتدا به ازای تمامی پیکسل‌های تصویر خروجی، اطلاعات همسایگی در نظر گرفته شد که این امر باعث تاری تصویر با تفکیک پذیری بالا بخصوص در پیکسل‌های لبه شد. سپس، با تفکیک پیکسل‌های لبه و غیرلبه و قراردادن پیکسل‌های غیرلبه در دو مجموعه جداگانه (براساس نواحی یکنواخت و غیریکنواخت) و اعمال اطلاعات همسایگی تنها برای پیکسل‌های غیرلبه قرار گرفته در نواحی یکنواخت، میزان تاری بطور قابل توجهی کاهش یافت. در این فصل، علاوه به در نظر گرفتن اطلاعات همسایگی به محتوای تصویر ورودی توجه ویژه‌ای شده است.

اغلب روش‌های مطرح در زمینه‌ی افزایش تفکیک پذیری تک تصویری، از هرم تصویر ورودی برای تخمین تصویر با تفکیک پذیری بالا استفاده می‌کنند. در برخی مقالات، صرفاً اطلاعات وصله‌های هر سطح هرم (نه تشابه وصله‌ها)، بطور جداگانه مورد استفاده قرار گرفته است. در دیگر روش‌ها، از تشابه مابین وصله‌ها در تصویر ورودی و یا در تصاویر سطوح مختلف هرم برای ایجاد تصویر با تفکیک پذیری بالای خروجی استفاده شده است. نکته ای که در کارهای گذشته به آن پرداخته نشده است موضوع گروه بندی وصله های تصاویر در سطوح مختلف هرم تصویر ورودی در فرایند یادگیری اطلاعات با تفکیک پذیری بالا می‌باشد که در روش پیشنهادی بدان پرداخته شده است. علاوه بر این، فرایند جداگانه ای برای یادگیری وصله های با مرکزیت پیکسل های لبه و غیر لبه (مشابه روش ارائه شده در فصل گذشته) ارائه می‌شود، چرا که این وصله ها ماهیت متفاوتی دارند.

نکته ای که در کارهای گذشته به آن پرداخته نشده است موضوع گروه بندی وصله های تصاویر در سطوح مختلف هرم تصویر ورودی در فرایند یادگیری اطلاعات با تفکیک پذیری بالا می‌باشد. با دسته بندی وصله ها

و قرار دادن وصله‌های مشابه در یک دسته و سپس استفاده از آن‌ها، می‌توان به تخمین دقیق‌تری برای پیکسل‌ها رسید که در ادامه این فصل مورد بررسی قرار می‌گیرد.


۵-۲ روش چهارم: افزایش تفکیک پذیری تک تصویری با تاکید بر

یادگیری مجزا برای نواحی تصویر ورودی

در روش ارائه شده در بخش ۴-۴، براساس تعدادی از تصاویر پایگاه داده، تعداد خوشه و تعداد همسایگی مدنظر در هر خوشه، مشخص شده است. درحالی‌که در صورت استفاده از تعداد بیشتر از تصاویر، تعداد خوشه و همسایگی براساس محتوای هر تصویر متغیر خواهد بود که بهتر است این موضوع به نحوی در روش پیشنهادی لحاظ شود. از طرف دیگر، به جای درنظر گرفتن تمامی وصله‌های تصاویر هرم و سپس خوشه بندی آنها، بهتر است پس از ایجاد هرم تصویر با تفکیک پذیری پایین، تصویر در پایین ترین سطح هرم ناحیه بندی شود و این نواحی به تصاویر در سطوح بالاتر تعمیم داده شود. لذا، برخلاف اغلب روش‌های افزایش تفکیک‌پذیری تصویر بجای ساختن یک دیکشنری برای تمام وصله های تصویر ورودی، که بسیاری از این وصله ها نامتشابه هستند، به ازای هر ناحیه، دیکشنری جداگانه ای ساخته شود و از هر دیکشنری برای مدل سازی وصله های همان ناحیه استفاده شود. همانطوریکه نتایج نشان می‌دهد این ایده خطای مدل سازی را کاهش داده و تخمین تصویر با تفکیک‌پذیری بالا را بهبود می‌بخشد.

این روش پیشنهادی نیز دارای فاز آموزش و فاز آزمون می‌باشد. در فاز آموزش، ابتدا هرم تصویر ورودی با کاهش تدریجی ابعاد تصویر ورودی با نرخ s در دو مرحله ساخته می‌شود. اگر تصویر ورودی را I_0 بنامیم، تصاویر هرم در سطوح پایین تر I_{-1} و I_{-2} نامیده می‌شوند. هرم تصویر به دست آمده را هرم با تفکیک‌پذیری بالا می‌نامیم. در سطح بالای این هرم، به دنبال ساختن تصویر I_{+1} هستیم که ابعاد آن s برابر ابعاد تصویر

ورودی است (شکل ۳-۱ سمت چپ). برای مدل سازی رابطه بین تصاویر با تفکیک پذیری بالا و پایین، هرم دیگری از تصاویر ساخته می شود که آنرا هرم با تفکیک پذیری پایین می نامیم (شکل ۳-۱ سمت راست). برای ساماندهی وصله ها در تصاویر هرم با تفکیک پذیری پایین، تصویر پایین ترین سطح هرم، I_{-2} را با در نظر گرفتن اطلاعات رنگ و روشنایی به کمک روش مرجع [۱۱۵] ناحیه بندی می کنیم و تصویر نتیجه را $\tilde{I}_{s-2}$ می نامیم. در نظر بگیرید که این تصویر شامل n ناحیه همگن باشد. ناحیه بندی را بطور متناظر در سطوح بالاتر هرم با تفکیک پذیری پایین اعمال می کنیم. در این صورت تعداد نواحی در تمام سطوح یکسان و این نواحی در تمام سطوح هرم متناظر می باشند. در شکل (۵-۱)، هرم تصویر lena پس از ناحیه بندی نشان داده شده است.



شکل (۵-۱) هرم تصویر با تفکیک پذیری پایین برای تصویر lena پس از ناحیه بندی تصاویر هرم (شروع ناحیه بندی از تصویر I_{-2})

چنانچه ناحیه بندی بر روی تصویر بالاترین سطح هرم انجام می شد با تعمیم آن به سطوح پایین تر، برخی نواحی در پایین ترین سطح هرم از بین می رفتند بنابراین تعداد نواحی در سطوح مختلف هرم ثابت نمی ماند.

در حالی که با شروع ناحیه‌بندی از پایین‌ترین سطح هرم، تعداد نواحی در تصاویر موجود در تمامی سطوح یکسان بوده و تنها تعداد پیکسل‌های هر ناحیه با حرکت به سمت بالاترین سطح، افزایش می‌یابد. در ادامه فاز آموزش و آزمون این روش آورده شده است.

۵-۲-۱ فاز آموزش

هدف این فاز، آموزش مدلی برای یادگیری رابطه بین ارزش پیکسل‌های تصاویر هرم‌های با تفکیک پذیری بالا و پایین است. در این فاز، برای کاهش اثر تاری، پیکسل‌ها در تصاویر سطوح مختلف هرم با تفکیک پذیری پایین به لبه و غیرلبه تقسیم می‌شوند. هرم تصویر با تفکیک پذیری پایین ناحیه‌بندی شده و پیکسل‌های غیرلبه‌ی هر ناحیه در یک مجموعه قرار گرفته و سپس مدل‌های مختلف براساس هر ناحیه آموزش داده می‌شود.

۵-۲-۱-۱ آموزش پیکسل‌های لبه

ابتدا، پیکسل‌های لبه در تمامی سطوح هرم با تفکیک پذیری پایین استخراج می‌شوند. سپس، مجموعه‌ای از وصله‌ها به ابعاد $Q = q \times q$ با مرکزیت این پیکسل‌ها به دست می‌آید که روشنایی پیکسل‌های هر وصله بصورت یک بردار ستونی p_{e_i} نمایش داده شده و مجموعه حاصل بصورت $P_E = \{p_{e_1}, p_{e_2}, \dots, p_{e_N}\} \in \mathbb{R}^{Q \times N}$ تعریف می‌گردد. N ، تعداد وصله‌ها و Q ، تعداد پیکسل‌های هر وصله در نظر گرفته شده است. برای مدل سازی رابطه بین وصله‌ها از بازنمایی تنک استفاده می‌نماییم. ویژگی‌های تنک به دست آمده برای بازنمایی هر وصله بعنوان ویژگی وصله در فرایند یادگیری استفاده خواهد شد. برای بازنمایی تنک وصله‌ها یک دیکشنری فراکامل از روی وصله‌های مجموعه‌ی P_E می‌بایست ساخته شود.

دیکشنری فراکامل شامل تعداد قابل توجهی وصله بعنوان وصله‌های پایه است که هر وصله دیگر را می‌توان از ترکیب خطی وصله‌های پایه موجود در دیکشنری بازسازی کرد (مطابق بخش ۳-۲-۱).

در روش پیشنهادی علاوه بر ویژگی تنک، بردار حاصل از گرادیان‌های مرتبه اول و مرتبه دوم پیکسل‌های هر وصله در مجموعه‌ی P_E نیز بعنوان ویژگی آن وصله در نظر گرفته شده است. برای محاسبه‌ی بردار ویژگی گرادیان مرتبه اول و دوم یک پیکسل، از یک پنجره با همسایگی 5×5 حول پیکسل استفاده می‌شود [36] که در بخش (۳-۲-۲) بطور کامل توضیح داده شده است.

همانگونه که اشاره شد، هر پیکسل لبه در سطوح مختلف هرم با تفکیک پذیری پایین متناظر با یک وصله $q \times q$ متناظر است که دو دسته ویژگی از آن استخراج می‌شود: ضرایب تُنک در بازنمایی وصله به کمک دیکشنری آموزش دیده و بردار گرادیان مرتبه اول و دوم. در فرایند یادگیری بدنبال آن هستیم تا رابطه‌ای بین ویژگی‌های استخراج شده از هر لبه (ضرایب تُنک و گرادیان) در هر سطح هرم با تفکیک پذیری پایین و روشنایی پیکسل متناظر در تصویر هم سطح آن در هرم با تفکیک پذیری بالا برقرار کنیم. که برای این منظور مطابق روشهای پیشنهادی قبلی از رگرسیون بردار پشتیبان استفاده می‌کنیم.

بنابراین، پس از استخراج ضرایب تُنک و بردار گرادیان مرتبه اول و دوم، با استفاده از الگوریتم SVR دو مدل آموزش ساخته می‌شود. یک مدل براساس ضرایب تُنک وصله‌های مرتبط با پیکسل‌های لبه، $M_{E\alpha}$ ، و مدلی دیگر براساس گرادیان مرتبه اول و دوم، M_{EG} این وصله‌ها آموزش داده می‌شود. مطابق رابطه (۵-۱) در این مدل سازی از تمام پیکسل‌های لبه در سطوح مختلف هرم تصویر با تفکیک پذیری پایین، استفاده می‌شود تا ارتباط بین ارزش پیکسل تصویر با تفکیک پذیری بالا و ویژگی‌های وصله مرتبط با تفکیک پذیری پایین برقرار گردد.

$$M_{E\alpha} = \text{SVR}(\alpha_E, L_E) \quad (۵-۱)$$

$$M_{EG} = \text{SVR}(G_E, L_E)$$

در رابطه (۱-۵)، α_E و G_E ، به ترتیب بردار ضرائب تنک و گرادیان مرتبه اول و دوم وصله ها با مرکزیت پیکسل‌های لبه در تصاویر هرم تفکیک پذیری پائین، L_E ، شدت روشنایی پیکسل مرکزی وصله در تصاویر هرم با تفکیک پذیری بالا، SVR، رگرسیون بردار پشتیبان برای یادگیری ارتباط بین ویژگی‌های وصله های تصاویر باتفکیک پذیری پائین و تفکیک پذیری بالا و $M_{E\alpha}$ و M_{EG} به ترتیب مدل‌های ایجاد شده براساس ویژگی های تنک و گرادیان مرتبه اول و دوم وصله‌ها با مرکزیت پیکسل‌های لبه است.

پس از یادگیری، تخمین ارزش پیکسل با تفکیک پذیری بالا به کمک این دو مدل، مقادیر $Pr_{E\alpha}$ و Pr_{EG} می باشند که در رابطه (۲-۵) آورده شده است.

$$\begin{aligned} Pr_{E\alpha} &= M_{E\alpha}(\alpha_E) \\ Pr_{EG} &= M_{EG}(G_E) \end{aligned} \quad (2-5)$$

برای ارزیابی خطای تخمین در دو مدل SVR بدست آمده، رابطه اختلاف مقدار ارزش پیکسل با تفکیک پذیری بالای واقعی در هرم با تفکیک پذیری بالا، L_E ، و مقادیر تخمین زده شده از دو مدل $M_{E\alpha}$ و M_{EG} ، به ترتیب $Pr_{E\alpha}$ و Pr_{EG} را با بردارهای ویژگی استفاده شده در این مدل ها، یاد گیری می کنیم. این یادگیری بصورت رابطه (۳-۵) فرموله می شوند.

$$\begin{aligned} ER_{E\alpha} &= SVR(d(Pr_{E\alpha}, L_E), \alpha_E) \\ ER_{EG} &= SVR(d(Pr_{EG}, L_E), G_E) \end{aligned} \quad (3-5)$$

این ایده از مرجع [۵۱] اقتباس شده است. در رابطه (۳-۵)، $ER_{E\alpha}$ و ER_{EG} به ترتیب مدل خطای تخمین به ازای ویژگی های تنک و گرادیان مرتبه اول و دوم، $d(.)$ ، میزان اختلاف بین مقدار واقعی هر پیکسل در تصویر وضوح بالا، L_E ، ارزش پیکسل در هرم با تفکیک پذیری بالا است.

این مدل‌ها به همراه ویژگی‌های تعریف شده، برای پیکسل‌های غیرلبه نیز تعمیم داده می‌شوند که در بخش ۲-۱-۳-۵ بطور کامل توضیح داده شده است.

۵-۲-۱ آموزش پیکسل‌های غیرلبه

همانطور که در بالا بیان شد، تصاویر سطوح مختلف هرم با تفکیک پذیری پایین به تعداد یکسانی از نواحی، ناحیه بندی می شوند. پیکسل های هر ناحیه رنگ و روشنایی مشابهی دارند. این ناحیه بندی هم در فاز آموزش و هم در فاز آزمون پیکسل‌های غیرلبه مورد استفاده قرار می گیرد.

در فاز آموزش، پیکسل‌های غیرلبه در هر ناحیه از سطوح مختلف هرم تصویر در نظر گرفته می شود. سپس، وصله‌هایی به ابعاد $Q = q \times q$ با مرکزیت هر یک از پیکسل‌های غیرلبه از هر ناحیه گردآوری شده که آنرا مجموعه‌ی $P_{NE-r} = \{p_{n_1}, p_{n_2}, \dots, p_{n_{M_r}}\} \in \mathbb{R}^{Q \times S_r}$ می نامیم. S_r ، مجموع وصله‌های ناحیه‌ی r ام در تمامی سطوح هرم می باشد. مطابق آنچه برای پیکسل های لبه در بخش‌های قبلی گفته شد، از هر وصله ضرایب تُنک و بردار گرادیان مربوط به وصله با مرکزیت پیکسل غیر لبه استخراج می گردد. از روی ضرایب تُنک وصله ها و به کمک مدل رگرسیون بردار پشتیبان، رابطه بین وصله های با تفکیک پذیری پایین هر ناحیه و روشنایی پیکسل های متناظر در هرم با تفکیک پذیری بالا یادگیری می شود. بطور مشابه از روی بردار گرادیان وصله ها و به کمک مدل رگرسیون بردار پشتیبان، رابطه بین وصله های با تفکیک پذیری پایین هر ناحیه و روشنایی پیکسل های متناظر در هرم با تفکیک پذیری بالا یادگیری می شود. لذا برای هر ناحیه در هرم با تفکیک پذیری پایین دو مدل رگرسیونی یادگیری می شود. برای تخمین هر یک از مدل های یادگیری شده برای هر ناحیه، خطا در تخمین روشنایی به کمک رگرسیون بردار پشتیبان مدل سازی می شود. لذا برای هر ناحیه در هرم یک مدل مبتنی بر ضرایب تُنک و یک مدل مبتنی بر گرادیان یادگیری شده و برای هر یک از این مدل ها، خطای تخمین نیز مدل سازی می گردد [۵۱]. لذا برای ناحیه r مدل های تخمین روشنایی و خطای تخمین روشنایی به ازای بردارهای ضرایب تُنک و گرادیان مطابق رابطه (۵-۴)، آموزش داده می شود:

$$M_{NE\alpha} = SVR(\alpha_{NE}, L_{NE}) \quad (4-5)$$

$$M_{NEG} = SVR(G_{NE}, L_{NE})$$

به کمک مدل های فوق برای هر ناحیه، تخمین روشنایی پیکسل های داخل ناحیه مطابق رابطه (5-5) صورت می گیرد.

$$Pr_{NE\alpha} = M_{NE\alpha}(\alpha_{NE}) \quad (5-5)$$

$$Pr_{NEG} = M_{EG}(G_{NE})$$

برای یادگیری دو مدل خطای تخمین مدل های $M_{NE\alpha}$ و M_{NEG} ، از اختلاف ارزش پیکسل با تفکیک پذیری بالای واقعی در هرم تفکیک پذیری بالا، L_{NE} ، و مقادیر تخمین زده شده $Pr_{NE\alpha}$ و Pr_{NEG} توسط دو مدل $M_{NE\alpha}$ و M_{NEG} ، مطابق رابطه (6-5)، استفاده می شود.

$$ER_{NE\alpha} = SVR(d(Pr_{NE\alpha}, L_{NE}), \alpha_{NE}) \quad (6-5)$$

$$ER_{NEG} = SVR(d(Pr_{NEG}, L_{NE}), G_{NE})$$

مدل های آموزش داده شده توسط روابط (4-5) و (6-5) باید به ازای تک تک نواحی تصویر یادگیری شوند. لذا، با فرض n ناحیه متناظر در هرم با تفکیک پذیری پایین، $n \times 4$ مدل رگرسیون بردار پشتیبان آموزش داده می شود.

5-2-2 فاز آزمون

برای تخمین روشنایی پیکسل ها در تصویر بالاترین سطح هرم تفکیک پذیری بالا، I_{+1} ، از مدل های آموزش داده شده و تصویر بالاترین سطح هرم با تفکیک پذیری پایین، $\tilde{I}_{+1}$ ، استفاده می کنیم. ابتدا الگوریتم لبه یابی را بر روی تصویر با تفکیک پذیری پایین $\tilde{I}_{+1}$ اعمال نموده تا پیکسل های لبه مشخص شوند. سپس، با استفاده از مدل های آموزش داده شده در بخش 5-2-1، ارزش هر پیکسل در تصویر با تفکیک پذیری بالای خروجی I_{+1} تخمین زده می شود.

۵-۲-۱ تخمین روشنایی پیکسل‌های لبه

مدل‌های تعریف شده در روابط (۵-۱) و (۵-۳) برای تعیین روشنایی پیکسل‌های لبه در تصویر با تفکیک پذیری بالا، I_{+1} ، مورد استفاده قرار می‌گیرند. وصله ای به ابعاد $q \times q$ در اطراف هر پیکسل از تصویر $\tilde{I}_{+1}$ استخراج می‌شود. بردار ضرایب تُنک وصله به کمک دیکشنری یادگیری شده از وصله‌های اطراف پیکسل‌های لبه استخراج شده و سپس بردار گرادیان وصله نیز محاسبه گردیده و به کمک مدل‌های SVR آموزش دیده شده و در نهایت دو تخمین برای روشنایی پیکسل مطابق رابطه (۵-۷) بدست می‌آید:

$$\begin{aligned} H_E &= M_{E\alpha}(\alpha_E) \\ H_E &= M_{EG}(G_E) \end{aligned} \quad (۵-۷)$$

بردارهای ضرایب تُنک و گرادیان بدست آمده به مدل‌های خطای یادگیری شده (رابطه (۵-۳)) نیز داده می‌شود تا خطای دو تخمین مطابق رابطه (۵-۸)، بدست آید. هر یک از مدل‌ها که خطای کمتری ایجاد نمود، تعیین کننده روشنایی پیکسل مدنظر است.

$$\begin{aligned} dif_{E\alpha} &= ER_{E\alpha}(\alpha_E) \\ dif_{EG} &= ER_{EG}(G_E) \end{aligned} \quad (۵-۸)$$

در رابطه (۵-۸)، $ER_{E\alpha}$ و ER_{EG} ، به ترتیب مدل‌های خطای تخمین آموزش داده شده براساس ویژگی‌های تُنک و گرادیان مرتبه اول و دوم (تعریف شده در رابطه (۵-۳)) و $dif_{E\alpha}$ و dif_{EG} ، خطای تخمین مدل‌ها برای دو ویژگی مطرح شده است. از آنجائی که به ازای هر سطح هرم، یک مدل آموزش داده می‌شود، لذا، برای هر پیکسل، به تعداد سطوح هرم، مقادیر کاندیدا وجود دارد که برای انتخاب مقدار نهایی، از مدل‌های خطای تخمین استفاده می‌شود. بنابراین، مقدار پیشنهادی مدلی با کمترین خطای تخمین، انتخاب می‌گردد.

۵-۲-۲ تخمین پیکسل‌های غیرلِبه

در مرحله آزمون پیکسل‌های غیرلِبه، تصویر با تفکیک پذیری پایین $\tilde{I}_{+1}$ به n ناحیه تقسیم می‌شود. سپس، مراحل زیر برای تخمین روشنایی پیکسل‌های غیر لبه اجرا می‌شود.

ابتدا ناحیه ای که پیکسل در آن قرار گرفته، r ، مشخص می‌شود. برای این ناحیه، دو مدل برای تخمین روشنایی و دو مدل برای خطای تخمین در فاز آموزش یادگیری شده است. وصله اطراف پیکسل، استخراج و بردارهای تَنک به کمک دیکشنری ناحیه محاسبه و بردار گرادیان وصله نیز بعنوان ویژگی بعدی استخراج می‌گردد. به کمک بردارهای بدست آمده و مدل های SVR آموزش داده شده در رابطه (۴-۵)، دو مقدار روشنایی برای پیکسل غیر لبه تخمین زده می‌شود که در رابطه (۹-۵) مشخص شده است.

$$\begin{aligned} H_{NE} &= M_{NE\alpha}(\alpha_{NE}) \\ H_{NE} &= M_{NEG}(G_{NE}) \end{aligned} \quad (9-5)$$

برای تخمین مقدار نهایی پیکسل غیرلِبه، از بین دو مقدار کاندیدا، مقداری با کمترین خطای تخمین انتخاب می‌شود که در رابطه (۱۰-۵) آورده شده است.

$$\begin{aligned} dif_{NE\alpha} &= ER_{NE\alpha}(\alpha_{NE}) \\ dif_{NEG} &= ER_{NEG}(G_{NE}) \end{aligned} \quad (10-5)$$

در رابطه (۱۰-۵)، $dif_{NE\alpha}$ و dif_{NEG} ، به ترتیب خطای تخمین مدل‌های $M_{NE\alpha}$ و M_{NEG} برای دو ویژگی تَنک و گرادیان مرتبه اول و دوم است. بدین ترتیب روشنایی تک تک پیکسل‌های تصویر فراتفکیک شده (لبخ و غیرلِبه)، تخمین زده می‌شود.

۵-۲-۳ ارزیابی نتایج

در این بخش، خروجی روش پیشنهادی برای چندین تصویر رنگی و سطح خاکستری نشان داده شده است. برای تصاویر رنگی، ابتدا تصاویر به مدل رنگ YCbCr تبدیل شده و الگوریتم پیشنهادی تنها بر مؤلفه‌ی روشنایی، Y، اعمال می‌شود و سایر مؤلفه‌ها با استفاده از الگوریتم درونیابی دومکعبی مقدار می‌گیرند. هرم ایجاد شده شامل چهار سطح است. سطح ورودی، یک سطح بالای سطح ورودی و دو سطح در پایین سطح ورودی است. برای ایجاد تعداد نواحی یکسان در تمامی سطوح مختلف هرم، تصویر پایین‌ترین سطح هرم را ناحیه بندی می‌کنیم و این ناحیه بندی رابه سطوح بالاتر تعمیم می‌دهیم. در پیاده‌سازی روش پیشنهادی، برای آموزش و آزمون مدل‌ها از libsvm-3.21^1 و برای ناحیه‌بندی تصاویر از $\text{SRM}[115]$ استفاده شده است. برای ویژگی تُنک، اندازه‌ی وصله‌ها 3×3 و میزان هم‌پوشانی دو پیکسل و اندازه‌ی وصله‌ها برای ویژگی گرادیان، 5×5 و میزان هم‌پوشانی، چهار پیکسل در نظر گرفته شده است. برای مقایسه‌ی کمی و کیفی نتایج این مقاله با نتایج سایر روش‌های مطرح در زمینه‌ی افزایش تفکیک پذیری تصویر، از معیارهای PSNR و SSIM استفاده شده است.

در جدول (۵-۱)، روش پیشنهادی باروش‌های درونیابی دومکعبی، افزایش تفکیک پذیری تک تصویر خودیاگیرنده [۵۱]، افزایش تفکیک پذیری مبتنی بر تقریب منیفلد (الگوریتم تعبیه‌شده خطی محلی) [۳۶]، افزایش تفکیک پذیری از طریق بازنمایی تُنک [۴۶] و افزایش تفکیک پذیری مبتنی بر بازنمایی تُنک با استفاده از رگرسیون بردار پشتیبان [۴۴] با استفاده از معیارهای PSNR و SSIM مقایسه شده است. در این روش، برای اجرای روش‌های مراجع [۵۱]، [۳۶]، [۴۶] و [۴۴] از کد به‌مراه پایگاه تصاویر قرار داده شده در صفحات شخصی و یا آزمایشگاه نویسندگان با انجام تنظیمات در matlab R2016a استفاده شده است.


¹<https://www.csie.ntu.edu.tw/~cjlin/libsvm/>

جدول (۵-۱) مقایسه‌ی روش پیشنهادی ۴ با روش‌های مطرح افزایش تفکیک پذیری تصویر

با استفاده از معیارهای PSNR (in dB) و SSIM


تصویر	tree	Lena	house	susan	Peppers	boat	airplane	baboon	میانگین
روش SR	۲۸,۳۹۷۷	۳۵,۴۴۷۱	۳۲,۲۱۲۱	۳۴,۷۱۱۴	۳۳,۱۷۴۱	۲۹,۹۴۷۲	۳۲,۶۸۴۴	۲۴,۹۶۱۵	۳۱,۴۴۱۹
Bicubic	۰,۸۷۳۰	۰,۹۳۱۷	۰,۹۰۳۴	۰,۹۴۶۶	۰,۹۰۲۴	۰,۸۵۴۱	۰,۹۴۵۰	۰,۷۲۵۵	۰,۸۸۵۲
SISR [51]	۲۶,۹۴۰۵	۳۳,۶۵۷۹	۳۰,۹۲۱۵	۳۳,۷۵۶۰	۳۱,۷۱۷۸	۲۹,۷۹۱۹	۳۱,۱۵۵۶	۲۳,۳۸۴۳	۳۰,۱۶۵۷
LLE [36]	۲۵,۸۲۵۱	۳۳,۴۹۸۱	۲۹,۴۹۹۵	۳۱,۸۴۰۴	۳۰,۶۴۲۷	۲۴,۲۷۹۴	۲۹,۶۸۷۵	۲۲,۹۴۸۷	۲۸,۵۲۷۷
ScSR [46]	۲۹,۱۲۶۵	۳۶,۲۴۴۱	۳۲,۷۲۶۶	۳۵,۳۷۸۶	۳۳,۵۹۵۳	۳۰,۶۴۴۸	۳۳,۳۵۳۱	۲۵,۴۹۴۷	۳۲,۰۷۰۴
LsSR [44]	۲۷,۳۹۶۲	۳۳,۸۸۲۹	۳۱,۰۲۷۰	۳۲,۱۰۶۶	۳۱,۳۹۵۹	۳۰,۲۷۲۸	۳۱,۶۶۰۵	۲۳,۶۵۲۴	۳۰,۱۷۴۳
SINE [۱۲۵]	۲۸,۵۰۸۹	۳۵,۷۳۸۷	۳۳,۱۳۸۲	۳۵,۷۳۴۲	۳۳,۸۲۳۲	۲۸,۵۶۴۰	۳۳,۰۵۹۵	۲۵,۲۹۹۶	۳۱,۷۳۲۸
ProposedMethod4	۲۹,۶۴۰۳	۳۶,۶۳۸۵	۳۳,۴۶۹۴	۳۵,۵۷۲۱	۳۴,۶۵۴۲	۳۲,۱۸۳۳	۳۴,۲۰۴۱	۲۵,۷۰۱۴	۳۲,۷۵۷۹

همانطور که در جدول (۵-۱) مشاهده می‌شود، روش پیشنهادی این مقاله بهترین عملکرد را براساس معیارهای PSNR و SSIM نسبت به سایر روش‌ها داشته است. در اشکال (۵-۲) تا (۵-۴)، تصویر هدف و تصاویر خروجی روش‌های Bicubic, SISR [51], LLE [36], ScSR [46], LsSR [44], SINE [125] و روش پیشنهادی به ترتیب برای تصاویر ورودی house, susan و tree نشان داده شده است. برای مقایسه‌ی بهتر، بخشی از تصویر با مربع قرمز مشخص شده است. بخش منتخب با جزئیات بیشتر در پایین-سمت راست تصویر نشان داده می‌شود.




شکل (۵-۲) نتایج SR برای تصویر house (کاهش اثرات تارشدگی و اثرات مصنوعی)
(به ترتیب از چپ برآست و بالا به پائین)

الف: تصویر هدف	ب: bicubic (PSNR=۳۲,۲۱۲ و SSIM=۰,۹۰۳۴)
ج: SISR[51] (PSNR=۳۰,۹۲۱۵ و SSIM=۰,۸۶۹۳)	د: LLE[۳۶] (PSNR=۲۹,۴۹۹۵ و SSIM=۰,۸۶۴۶)
ه: ScSR [۴۶] (PSNR=۳۲,۷۲۶۶ و SSIM=۰,۹۰۷۹)	و: LsSR[44] (PSNR=۳۱,۰۲۷۰ و SSIM=۰,۸۸۴۱)
ز: روش پیشنهادی ۲ [۱۲۵] و SSIM=۰,۹۰۸۸ (PSNR=۳,۱۳۸۲)	ح: روش پیشنهادی ۴ [۱۲۷] و SSIM=۰,۹۱۵۹ (PSNR=۳۳,۴۶۹۴)



شکل (۳-۵) نتایج SR برای تصویر susan (کاهش اثرات مصنوعی و غیرطبیعی)
(به ترتیب از چپ بر راست و بالا به پایین)

الف: تصویر هدف	ب: bicubic (PSNR=۳۴,۷۱۱۴ و SSIM=۰,۹۴۶۶)
ج: SISR[51] (PSNR=۳۳,۷۵۶۰ و SSIM=۰,۹۲۹۰)	د: LLE[36] (PSNR=۳۱,۸۴۰۴ و SSIM=۰,۹۲۳۹)
ه: ScSR[46] (PSNR=۳۵,۳۷۸۶ و SSIM=۰,۹۴۸۰)	و: LsSR[44] (PSNR=۳۲,۱۰۶۶ و SSIM=۰,۹۳۹۱)
ز: روش پیشنهادی [۱۲۵] (SSIM=۰,۹۵۱۰ و PSNR=۳۵,۷۳۴۲)	ح: روش پیشنهادی [۱۲۷] (SSIM=۰,۹۵۳۸ و PSNR=۳۵,۵۷۲۱)




شکل (۴-۵) نتایج SR برای تصویر tree (کاهش اثرات تارشدگی و اثرات مصنوعی)
(به ترتیب از چپ بر راست و بالا به پایین)

الف: تصویر هدف	ب: bicubic (PSNR=۲۸,۳۹۷۷ و SSIM=۰,۸۷۳۰)
ج: SISR[51] (PSNR=۲۶,۹۴۰۵ و SSIM=۰,۸۴۱۰)	د: LLE[36] (PSNR=۲۵,۸۲۵۱ و SSIM=۰,۸۲۵۷)
ه: ScSR[46] (PSNR=۲۹,۱۲۶۵ و SSIM=۰,۸۸۸۷)	و: LsSR[44] (PSNR=۲۷,۳۹۶۲ و SSIM=۰,۸۱۲۲)
ز: روش پیشنهادی [۱۲۵] (PSNR=۲۵,۵۰۸۹ و SSIM=۰,۸۷۷۹)	ح: روش پیشنهادی [۱۲۷] (PSNR=۲۹,۶۴۰۳ و SSIM=۰,۸۹۸۸)

با ملاحظه این اشکال می‌توان پی برد، بدلیل عملکرد متفاوت روش پیشنهادی در رابطه با پیکسل‌های لبه و غیرلبه، میزان تارشدگی لبه‌های تصویر نسبت به روش‌های دیگر بسیار ناچیز و اثرات مصنوعی و غیرطبیعی بر این پیکسل‌ها کمتر از سایر روش‌ها است. در حالی که در سایر روش‌ها (به‌خصوص روش [ScSR[46] اثرات مصنوعی بر لبه‌های تصویر مشهود است.

برای مقایسه‌ی بهتر، در شکل (۵-۵)، اختلاف بین پیکسل‌های تصویر هدف و تصاویر خروجی روش‌های Bicubic، LLE[36]، SISR[51]، ScSR[46]، LsSR[44]، SINE[۱۲۵] و روش پیشنهادی برای تصویر tree نشان داده شده است.



شکل (۵-۵) اختلاف بین تصویر هدف و تصاویر خروجی (از بالا به پایین و چپ به راست) روش‌های Bicubic، LLE[36]، SISR[51]، ScSR[46]، LsSR[44]، SINE[۱۲۵] و روش پیشنهادی برای تصویر tree

کاهش اختلاف بین تصویر خروجی و تصویر هدف، به معنی کاهش خطای تخمین روشنایی پیکسل ها است. همانطوریکه از شکل (۵-۵) ملاحظه می گردد خطای تخمین روش پیشنهادی کمتر از سایر روش ها است. با ملاحظه این نتایج می توان دید که روش پیشنهادی توانسته است بهبود قابل ملاحظه ای در نواحی هموار نسبت به لبه های تصویر داشته باشد که در شکل (۵-۶) نشان داده شده است.



شکل (۵-۶) اختلاف بین پیکسل های تصویر هدف و تصاویر خروجی روش پیشنهادی برای تصاویر peppers, house و baboon, tree, susan (از چپ به راست)

همانطور که در شکل (۵-۶) نشان داده شده است، روش پیشنهادی برای نواحی هموار بخوبی عمل کرده و بیشترین اختلاف مربوط به نواحی غیریکنواخت و پیکسل های لبه است.

۵-۳ روش پنجم: افزایش فراتفکیک پذیری تک تصویری مبتنی بر

محتوای تصویر ورودی با استفاده از خوشه بندی زیرفضای تنک

در این روش، از گراف همسایگی برای در نظر گرفتن اطلاعات وصله های مجاور برای بازسازی تصویر استفاده شده است. برای این منظور، الگوریتم خوشه بندی زیرفضای تنک برای ایجاد گراف همسایگی و سپس خوشه بندی آن مورد استفاده قرار می گیرد. برای کاهش پیچیدگی محاسباتی و افزایش سرعت ایجاد گراف همسایگی، از کاهش افزونگی داده ها با حذف داده های تکراری استفاده شده است. در برخی مقالات، تعداد

ثابت و محدودی داده در هر خوشه در نظر گرفته شده و مابقی داده‌ها حذف می‌گردند. در روش پیشنهادی این مقاله، برخلاف سایر روش‌ها، تعداد عناصر هر خوشه متفاوت و براساس محتوای تصویر ورودی است. برای این منظور از الگوریتم خوشه‌بندی k-means برای خوشه‌بندی داده‌ها قبل از ایجاد گراف همسایگی و کاهش افزونگی داده‌ها استفاده شده است. براساس نتایج آزمایشات، این روش پیشنهادی بهبود قابل ملاحظه‌ای را در ایجاد تصویر با تفکیک‌پذیری بالای خروجی در مقایسه با سایر روش‌ها داشته است. در ادامه، بدلیل استفاده از خوشه‌بندی زیرفضای تنک، توضیح مختصری در این باره داده می‌شود و سپس ویژگی‌های مورد استفاده، فاز آموزش، فاز آزمون و نتایج آزمایشات این روش آورده شده است.

۵-۳-۱ خوشه‌بندی زیرفضای تنک

امروزه با حجم بالایی از داده‌ها که باید مورد پردازش قرار گیرند، مواجه هستیم. در سال‌های اخیر، ایده‌ی اصلی الگوریتم‌های پیشنهادی برای پردازش اینگونه داده‌ها این است که داده‌ها با ابعاد بالا می‌توانند بصورت داده‌هایی با ابعاد بسیار پایین بدون از دست دادن اطلاعات ضروری، در نظر گرفته شوند. این امر منجر به توسعه‌ی روش‌هایی برای کاهش ابعاد داده‌ها شده است. فرض روش‌های متداول کاهش ابعاد داده‌ها از قبیل PCA این است که داده‌ها با ابعاد بالا تنها در یک فضا با ابعاد پایین قرار گرفته‌اند. درحالی‌که در حقیقت، براساس نحوه‌ی توزیع داده‌ها، می‌توان یک یا چندین زیرفضا برای داده‌ها با ابعاد پایین در نظر گرفت.

الگوریتم خوشه‌بندی زیرفضای تنک (SSC)^۱، اولین بار در مرجع [۴۲] برای خوشه‌بندی داده‌ها به چندین زیرفضا با استفاده از بازنمایی تنک داده‌ها، ارائه شد. ایده‌ی اصلی SSC از خصوصیت خودبیانگر^۲ داده‌ها نشأت گرفته است که براساس این ویژگی، تمامی داده‌ها با ابعاد بالا را می‌توان بعنوان یک دیکشنری از داده‌ها در

^۱ Spare Subspace Clustering (SSC)

^۲self-expressive

نظر گرفت بطوری که هر داده در این دیکشنری را می توان از ترکیب خطی عناصر دیگر دیکشنری بدست آورد. برای این منظور، فرض کنید $N \gg D$ ، $x_i \in \mathbb{R}^D$ ، $X = \{x_1, x_2, \dots, x_N\} \in \mathbb{R}^{D \times N}$ یک مجموعه شامل N داده با ابعاد D است که تعداد داده ها (N) از ابعاد هر یک از داده ها (D) بسیار بیشتر است. به ازای هر داده، ستون مربوط به آن داده در مجموعه داده ها، X ، مطابق رابطه (۱۱-۵) حذف می شود تا بتوان این داده را از ترکیب خطی سایر داده های مجموعه بدست آورد.

$$X_{\bar{i}} = \{x_1, x_2, \dots, x_{i-1}, x_{i+1}, \dots, x_N\} = X / \{x_i\} \quad (11-5)$$

برای استخراج ضرایب بهینه ی تَنکِ داده ی $\bar{i}$ ام از رابطه (۱۲-۵) استفاده می شود.

$$\alpha_i = \arg \min_{\alpha} \frac{1}{2} \|X_{\bar{i}} \alpha_i - x_i\|_2^2 + \lambda \|\alpha_i\|_1 \quad (12-5)$$

در رابطه (۱۲-۵)، α_i بردار ضرایب تَنکِ داده ی $\bar{i}$ ام و λ ضریب لاگرانژ برای ایجاد تعادل بین میزان تَنک بودن ضرایب و مقدار خطای تخمین داده ی $\bar{i}$ ام براساس سایر داده ها است. عناصر بردار α_i میزان مشارکت هر یک از داده های مجموعه $X_{\bar{i}}$ را در بازسازی داده $\bar{i}$ ام تعیین می کند. با اضافه کردن صفر در سطر $\bar{i}$ ام بردار α_i بدست آمده از رابطه (۱۲-۵)، بردار ضرایب تَنک $\hat{\alpha}_i \in \mathbb{R}^{N \times 1}$ برای داده ی $\bar{i}$ ام بدست می آید. با حل مساله بهینه سازی رابطه ی (۱۲-۵)، به ازای تمامی داده های مجموعه ی X ، ماتریس $W = [\hat{\alpha}_1, \hat{\alpha}_2, \dots, \hat{\alpha}_N] \in \mathbb{R}^{N \times N}$ که یک ماتریس مجاورت است، ایجاد می شود. تعداد سطرها و ستون های این ماتریس، مساوی تعداد داده های مجموعه ی X است. هر ستون ماتریس W ، میزان ارتباط بین یک داده با داده های دیگر مجموعه ی X را بصورت یک بردار تَنک، نشان می دهد. بنابراین، ستون $\bar{i}$ ام این ماتریس، نمایش تَنکِ داده ی $\bar{i}$ ام است. این ماتریس مطابق رابطه زیر به یک متقارن، $\tilde{W}$ ، با استفاده از رابطه (۱۳-۵)، تبدیل می شود.

$$\tilde{W} = [\tilde{W}_{ij}]_{N \times N} \quad (13-5)$$

$$\tilde{W}_{ij} = |W_{ij}| + |W_{ji}|$$

ماتریس $\tilde{W}$ مشابه ماتریس W ، میزان شباهت داده‌ها را نشان می‌دهد، زیرا در حالت کلی، داده‌ی i ام می‌تواند بعنوان ترکیب خطی برخی نقاط از قبیل داده‌ی j ام در نظر گرفته شود. درحالی‌که، ممکن است نیاز به انتخاب داده‌ی i ام در نمایش $\tilde{W}$ داده‌ی j ام نباشد. با استفاده از رابطه (۵-۱۳) برای ایجاد ماتریس متقارن مجاورت، این اطمینان وجود دارد که داده‌های i ام و j ام در صورتی که حداقل یکی از این داده‌ها در نمایش $\tilde{W}$ دیگری وجود داشته باشند، به یکدیگر متصل هستند.

یک گراف با استفاده از داده‌ها و ماتریس مجاورت ایجاد می‌شود که اعضای مجموعه‌ی X ، گره‌های گراف و ماتریس مجاورت، مقادیر یال‌های گراف هستند. در نهایت، داده‌ها با استفاده از خوشه‌بندی طیفی، به زیرفضاها تقسیم می‌شوند. در حالت ایده‌آل، تعداد مولفه‌های مستقل در گراف ایجاد شده برابر با تعداد زیرفضاهای داده‌ها است.

۵-۳-۲ استخراج ویژگی

برای استخراج ویژگی، تصاویر با تفکیک پذیری پایین به وصله‌هایی به اندازه‌ی یکسان $q \times q$ تقسیم شده و در مجموعه‌ی $Q = q \times q$ قرار می‌گیرند که N تعداد وصله‌های تصویر و Q ، تعداد پیکسل‌های هر وصله است. در روش پیشنهادی، ویژگی‌های استخراج شده از وصله‌های اطراف پیکسل‌های لبه و پیکسل‌های غیرلبه در تصاویر با تفکیک پذیری پایین متفاوت است که در ادامه به تفکیک توضیح داده می‌شود.

برای وصله‌های اطراف پیکسل‌های غیرلبه، ابتدا، وصله‌های استخراج شده با استفاده از خوشه‌بندی k -means، به تعداد از پیش تعیین شده خوشه تقسیم می‌شوند. براساس تعداد وصله‌های قرارگرفته در هر خوشه، این خوشه‌بندی می‌تواند ادامه داشته باشد. هدف این تقسیم‌بندی، انتخاب مرتبط‌ترین وصله‌ها بعنوان یک خوشه، کاهش زمان و غلبه بر انجام محاسبات پیچیده در زمان ایجاد گراف شباهت از وصله‌ها است. برای

این منظور، از خوشه‌بندی سلسله‌مراتبی استفاده شده است. تعداد نهایی خوشه‌ها براساس تعداد وصله‌ی قرار گرفته در هر خوشه متفاوت بوده و بصورت تطبیقی با هر محتوی تصویر، تعیین می‌شود.

وصله‌های هر خوشه، بعنوان دیکشنری آن خوشه در نظر گرفته شده و ضرایب تُنک هر وصله براساس سایر وصله‌های آن خوشه بدست می‌آید. بعنوان مثال، ارزش پیکسل‌های وصله‌ی l_i ام، با x_i ، دیکشنری مورد استفاده برای استخراج ضرایب تُنک وصله‌ی l_i ام، X_i و ضریب تُنک وصله‌ی i ام با $\hat{\alpha}_i$ نشان داده می‌شود. با در نظر گرفتن ضرایب تُنک تمامی وصله‌های هر خوشه و با استفاده از معادله‌ی (۳)، ماتریس مجاورت متقارن، $\tilde{W}$ ، ایجاد شده و سپس گراف شباهت ساخته می‌شود که گره‌های این گراف، ویژگی‌های هر وصله و یال‌های آن مقادیر ماتریس مجاورت متقارن هر وصله است. در نهایت، از گراف شباهت ایجاد شده و الگوریتم خوشه‌بندی طیفی، برای تقسیم مجدد وصله‌های هر خوشه به چندین زیرفضا استفاده می‌شود.

به ازای هر وصله‌ی اطراف پیکسل‌های لبه، ضرایب تُنک استخراج می‌شود. در روش پیشنهادی، علاوه بر ضرایب تُنک، بردار حاصل از مشتق‌های مرتبه اول و مرتبه دوم روشنایی پیکسل‌های هر وصله نیز بعنوان ویژگی آن وصله در نظر گرفته شده است. برای محاسبه‌ی بردار ویژگی مشتق‌های مرتبه اول و دوم، از یک پنجره‌حول هر پیکسل استفاده می‌شود [۳۶]. نحوه‌ی استخراج مشتق‌های مرتبه اول و دوم در یک پنجره همسایگی 5×5 ، در بخش ۳-۲-۲ نشان داده شده است.

۵-۳-۳ فاز آموزش

دو هرم با تفکیک‌پذیری بالا و پایین از تصویر ورودی مطابق شکل (۳-۱) ساخته می‌شود که تصاویر این دو هرم بعنوان پایگاه داده‌ای از تصاویر با تفکیک‌پذیری بالا و پایین در نظر گرفته می‌شوند.

ابتدا الگوریتم لبه‌یابی بر تصاویر تمامی سطوح هرم با تفکیک‌پذیری پایین اعمال و سپس این تصاویر به وصله‌هایی به اندازه‌ی یکسان $Q = q \times q$ $Q \in \mathbb{R}^{Q \times N}$ $L_p = \{l_1, l_2, \dots, l_N\}$ تقسیم می‌شوند. براساس

پژوهش انجام شده در مرجع [۱۱۶] و [۵]، وصله‌های تصویر اولین سطح هرم با تفکیک‌پذیری پایین که همسطح تصویر ورودی است، تقریباً ۶۵ درصد از وصله‌های مشابه به وصله‌های "نسخه‌ی میانی تصویر خروجی" را دربردارد. با این حال، تقریباً ۳۵ درصد از وصله‌های مشابه در سطوح دیگر هرم یافت می‌شوند. بنابراین، برای بازسازی تصویر، سطح اول بیشترین استفاده را دارد ولی سطوح پایین‌تر نیز درصد قابل توجهی از وصله‌های مشابه را شامل می‌شود که قابل چشم‌پوشی نمی‌باشند. با توجه به این تحقیق، در روش پیشنهادی ما، مجموعه تصاویر آموزشی سطوح مختلف هرم تصاویر با تفکیک‌پذیری پایین توسط دو مدل جداگانه، مورد استفاده قرار می‌گیرند. ویژگی‌های وصله‌های تصویر سطح اول هرم با تفکیک‌پذیری پایین، برای آموزش یک مدل استفاده می‌شود. مدل آموزشی دیگر براساس ویژگی‌های وصله‌های تمامی تصاویر در سطوح دیگر هرم با تفکیک‌پذیری پایین، ایجاد می‌گردد.

برای وصله‌های اطراف پیکسل‌های لبه در تصاویر با تفکیک‌پذیری پایین، با استفاده از روش یادگیری رگرسیون بردار پشتیبان، دو مدل به تفکیک ویژگی‌های استخراج شده، آموزش داده می‌شود که آموزش این مدل‌ها در رابطه (۱۴-۵) نشان داده شده است.

$$\begin{aligned} M_{E\alpha} &= \text{SVR}(\alpha_E, L_E) \\ M_{EG} &= \text{SVR}(G_E, L_E) \end{aligned} \quad (14-5)$$

α_E و G_E ، به ترتیب ضرایب تَنک و گرادیان مرتبه اول و دوم وصله‌ی اطراف پیکسل لبه، L_E ارزش پیکسل لبه در وصله‌ی متناظر در هرم با تفکیک‌پذیری بالا، SVR ، رگرسیون بردار پشتیبان برای یادگیری ارتباط بین ویژگی‌های وصله‌ی با تفکیک‌پذیری پایین و ارزش پیکسل در هرم با تفکیک‌پذیری بالا، $M_{E\alpha}$ ، مدل مبتنی بر ویژگی تَنکی و M_{EG} ، مدل مبتنی بر بردار گرادیان مرتبه اول و دوم است.

علاوه بر مدل‌های ایجاد شده در رابطه (۱۴-۵) دو مدل دیگر نیز براساس خطای تخمین مدل‌های $M_{E\alpha}$ و M_{EG} ، آموزش داده می‌شوند که این دو مدل مطابق با رابطه (۱۵-۵) تعریف می‌شوند.

$$ER_{E\alpha} = \text{SVR}(d(\text{Pr}_{E\alpha}, L_E), \alpha_E)$$

$$ER_{EG} = SVR(d(\Pr_{EG}, L_E), G_E) \quad (۱۵-۵)$$

در رابطه (۱۵-۵)، تابع d ، اختلاف بین مقدار تخمین زده شده توسط مدل های رابطه (۱۴-۵)، $\Pr_{EG}$ و $\Pr_{E\alpha}$ و مقدار واقعی پیکسل در تصویر با تفکیک پذیری بالا، L_E را در بردارد. سایر متغیرها مشابه رابطه (۱۴-۵) تعریف می شوند.

برای ایجاد مدل های آموزشی به ازای پیکسل های غیرلبه، ابتدا، براساس پژوهش انجام شده در مرجع [۱۱۶] و [۵]، دو مجموعه براساس ویژگی های وصله های تصویر سطح اول هرم با تفکیک پذیری پایین و ویژگی های وصله های تمامی تصاویر در سطوح دیگر هرم با تفکیک پذیری پایین، ایجاد می گردد. سپس، این دو مجموعه با استفاده از خوشه بندی k -means به تعدادی از پیش تعیین شده خوشه تقسیم می شوند، بطوری که تعداد خوشه های هر مجموعه C_1 و C_2 متفاوت است. خوشه بندی این دو مجموعه، C_1 و C_2 ، بصورت رابطه (۵-۱۶) و (۱۷-۵) تعریف می شود.

$$C_1 = \{c1_i\}_{i=1}^{M_1} \quad (۱۶-۵)$$

$$c1_i = \{l_t\}_{t=1}^{c1n_i}$$

$$c1n_i < M_1$$

$$C_2 = \{c2_i\}_{i=1}^{M_2} \quad (۱۷-۵)$$

$$c2_i = \{l_t\}_{t=1}^{c2n_i}$$

$$c2n_i < M_2$$

M_1 و M_2 ، به ترتیب تعداد خوشه های مجموعه ی اول و دوم (C_1 و C_2)، $c1_i$ و $c2_i$ ، خوشه ی i ام هر یک از این دو مجموعه، $c1n_i$ و $c2n_i$ ، تعداد وصله های خوشه ی i ام در C_1 و C_2 و l_t ، ارزش پیکسل های وصله ی وضو t ام است. سپس، هر خوشه، با استفاده از خوشه بندی زیرفضای تنگ به تعدادی زیرفضا تقسیم می شوند. $S_i = \{v_j\}_{j=1}^{sn_i}$ ، زیرفضای i ام از بین زیرفضاهای ایجاد شده، v_j ، وصله ی i ام زیرفضای i ام و sn_i ، تعداد وصله ها در این زیرفضا است. $T_i \in \mathbb{R}^{D \times K}$ ، یک دیکشنری فراکامل از وصله های زیرفضای S_i است، بطوری که تعداد عناصر دیکشنری K و اندازه ی هر عنصر دیکشنری، $D = q \times q$ ، برابر با اندازه ی وصله های زیرفضا می باشد. بنابراین،

وصله‌ی زام زیرفضای S_i را می‌توان بوسیله یک ترکیب خطی تَنگ از عناصر دیکشنری بصورت رابطه (۵-۱۸) نمایش داد.

$$v_j = T_i \alpha_j \quad (۵-۱۸)$$

α_j ، ضریب تَنگ وصله‌ی v_j در زیرفضای S_i است که با استفاده از رابطه (۵-۱۲) بدست می‌آید. T_i دیکشنری فراکامل زیرفضای S_i است که براساس وصله‌های زیرفضای S_i آموزش داده می‌شود. ضرایب تَنگ به ازای تمامی وصله‌های زیرفضای S_i استخراج می‌شود. این ضرایب بعنوان ویژگی وصله‌های با تفکیک پذیری پایین و ارزش پیکسل مرکزی وصله‌های با تفکیک پذیری بالای متناظر بعنوان ویژگی وصله‌های با تفکیک پذیری بالا برای ایجاد مدل زیرفضا استفاده می‌شوند. استخراج ویژگی‌های وصله‌های با تفکیک پذیری پایین و با تفکیک پذیری بالای متناظر جهت آموزش به ازای تمامی زیرفضاها، تکرار می‌شود. در نهایت، ارتباط بین این ویژگی‌ها بوسیله‌ی روش یادگیری رگرسیون بردار پشتیبان بصورت رابطه (۵-۱۹)، مدل می‌شود.

$$M_{NE} = SVR(\alpha_{NE}, L_{NE}) \quad (۵-۱۹)$$

در رابطه (۵-۱۹)، SVR ، رگرسیون بردار پشتیبان برای یادگیری ارتباط بین ویژگی‌های وصله‌های با تفکیک پذیری پایین و با تفکیک پذیری بالا، α_{NE} ، ضرایب تَنگ تمامی وصله‌های با تفکیک پذیری پایین زیرفضای I ام، L_{NE} ، ارزش پیکسل مرکزی تمامی وصله‌ی با تفکیک پذیری بالا در این زیرفضا، و M_{NE} ، مدل زیرفضای I ام است. مدل رابطه (۵-۱۹) به ازای تک تک نواحی تصویر ورودی، آموزش داده می‌شود.

۵-۳-۴ فاز آزمون

با اعمال الگوریتم افزایش نرخ نمونه‌برداری بر تصویر ورودی، نسخه‌ی میانی تصویر خروجی، $\tilde{A}_{+1}$ ، بدست می‌آید.

هدف این فاز، افزایش تفکیک پذیری پیکسل‌های این تصویر با استفاده از مدل‌های آموزش داده شده در فاز آموزش است.

ابتدا، به ازای هر پیکسل تصویر $\tilde{I}_{+1}$ ، لبه و غیرلبه بودن آن مشخص شده و وصله‌ی اطراف آن استخراج می‌شود. سپس، ویژگی‌های هر وصله براساس مطالب بخش (۳-۱)، محاسبه می‌شود. برای وصله‌های اطراف پیکسل‌های غیرلبه، از آنجائی‌که خوشه‌های ایجاد شده در فاز آموزش، هریک دارای یک نماینده هستند، ارزش پیکسل‌های این وصله‌ها با ارزش پیکسل‌های نماینده‌ی هر خوشه مقایسه می‌شود و بدین ترتیب، نزدیک‌ترین خوشه انتخاب می‌گردد. که در رابطه (۵-۲۰) آورده شده است.

$$I = \arg \min_{1 \leq j \leq sn} d(ph, cent_j) \quad (۵-۲۰)$$

$d(ph, cent_j)$ ، اختلاف بین وصله‌ی ph تصویر $\tilde{I}_{+1}$ و نماینده‌ی خوشه‌ی j ام و sn ، تعداد خوشه‌های ایجاد شده در فاز آموزش است. سپس، براساس دیکشنری خوشه‌ی برنده، ضرایب α_{ph} و وصله‌ی آزمون بعنوان ویژگی آن وصله، براساس رابطه (۵-۲۱)، استخراج می‌شود.

$$\alpha_{ph} = spr(ph, T_I) \quad (۵-۲۱)$$

تابع spr ، ضرایب α_{ph} و وصله‌ی ph را با استفاده از دیکشنری خوشه‌ی برنده، T_I ، محاسبه می‌کند. α_{ph} ، ضرایب α_{ph} و وصله‌ی ph تصویر $\tilde{I}_{+1}$ است. بردار ویژگی وصله به مدل خوشه‌ی برنده داده می‌شود تا ارزش نهایی پیکسل‌های غیرلبه تصویر $\tilde{I}_{+1}$ ، با استفاده از رابطه (۵-۲۲) تخمین زده شود.

$$H_{NE} = M_{NE\alpha}(\alpha_{NE}) \quad (۵-۲۲)$$

mdl_I ، مدل خوشه‌ی I ام، α_{ph} ، ضرایب α_{ph} و وصله‌ی ph تصویر $\tilde{I}_{+1}$ و مقدار جدید پیکسل I ام تصویر $\tilde{I}_{+1}$ است. این مراحل به ازای تمامی پیکسل‌های غیرلبه‌ی تصویر $\tilde{I}_{+1}$ تکرار می‌شود.

از وصله‌های اطراف پیکسل‌های لبه در تصویر $\tilde{I}_{+1}$ ، ویژگی α_{ph} و گرادیان مرتبه اول و دوم استخراج می‌شود. از مدل‌های آموزش داده شده‌ی پیکسل‌های لبه برای تخمین مقدار جدید پیکسل و میزان خطای تخمین

هر مدل در پیش‌بینی مقدار این پیکسل، استفاده می‌شود. مقدار تخمین زده شده توسط مدلی که کمترین میزان خطای تخمین را دارد، بعنوان مقدار جدید پیکسل انتخاب می‌شود که در رابطه (۵-۲۳) نشان داده شده است. این مراحل به ازای هر پیکسل لبه در تصویر $\tilde{I}_{+1}$ ، تکرار می‌شود.

$$H_E = M_{E\alpha}(\alpha_E)$$

$$H_E = M_{EG}(G_E)$$

(۵-۲۳)

$$\text{dif}_{E\alpha} = ER_{E\alpha}(\alpha_E)$$

$$\text{dif}_{EG} = ER_{EG}(G_E)$$

$\text{dif}_{E\alpha}$ و dif_{EG} ، میزان خطای تخمین مدل‌های $M_{E\alpha}$ و M_{EG} هستند.

در نهایت، مقادیر جدید تخمین زده شده برای پیکسل‌های لبه و غیرلبه در تصویر $\tilde{I}_{+1}$ قرار داده می‌شود تا تصویر نهایی با تفکیک پذیری بالای I_{+1} بدست آید.

۵-۳-۵ ارزیابی نتایج

در این روش، مشابه روش‌های قبلی، از تصاویر پایگاه داده USC-SIPI استفاده شده است. تصاویر سطح خاکستری و تصاویر رنگی با اندازه‌های مختلف در این پایگاه داده قرار دارند. برای تصاویر رنگی، روش پیشنهادی تنها بر مولفه‌ی روشنایی تصویر اعمال شده است. بنابراین، تصاویر رنگی پایگاه داده، به دستگاه رنگ YCbCr تبدیل شده و تنها مؤلفه‌ی روشنایی، Y ، در پردازش‌های بعدی مورد استفاده قرار گرفته است. مولفه‌های Cb و Cr دستگاه رنگ، با استفاده از درون‌یابی دوماکعبی برای تصویر خروجی تخمین زده شده‌اند. اندازه‌ی وصله‌های تصویر برای پیکسل‌های لبه و غیرلبه، 3×3 و میزان هم‌پوشانی وصله‌ها، دو پیکسل در نظر گرفته شده است.

روش پیشنهادی با روش‌های روش‌های Bicubic, SISR [۵۱], LLE [۳۶], ScSR [۴۶], LsSR [۴۴].
 SINE [۱۲۵] مقایسه شده است. نتایج این مقایسه براساس معیارهای PSNR و SSIM، در جدول (۲-۵) نشان داده شده است.


جدول (۲-۵) مقادیر PSNR(in dB) و SSIM برای روش پیشنهادی ۵ و چندین روش افزایش تفکیک پذیری

تصویر

تصویر	tree	lena	house	susan	Peppers	میانگین
روش SR						
Bicubic	۲۸,۳۹۷۷	۳۵,۴۴۷۱	۳۲,۲۱۲۱	۳۴,۷۱۱۴	۳۳,۱۷۴۱	32.78848
	۰,۸۷۳۰	۰,۹۳۱۷	۰,۹۰۳۴	۰,۹۴۶۶	۰,۹۰۲۴	0.91142
SISR [۵۱]	۲۶,۹۴۰۵	۳۳,۶۵۷۹	۳۰,۹۲۱۵	۳۳,۷۵۶۰	۳۱,۷۱۷۸	31.39874
	۰,۸۴۱۰	۰,۸۹۸۶	۰,۸۶۹۳	۰,۹۲۹۰	۰,۸۶۶۰	0.88078
LLE [۳۶]	۲۵,۸۲۵۱	۳۳,۴۹۸۱	۲۹,۴۹۹۵	۳۱,۸۴۰۴	۳۰,۶۴۲۷	30.26116
	۰,۸۲۵۷	۰,۹۰۵۶	۰,۸۶۴۶	۰,۹۲۳۹	۰,۸۶۶۹	0.87734
ScSR [۴۶]	۲۹,۱۲۶۵	۳۶,۲۴۴۱	۳۲,۷۲۶۶	۳۵,۳۷۸۶	۳۳,۵۹۵۳	33.41422
	۰,۸۸۸۷	۰,۹۳۸۰	۰,۹۰۷۹	۰,۹۴۸۰	۰,۹۰۴۶	0.91744
LsSR [۴۴]	۲۷,۳۹۶۲	۳۳,۸۸۲۹	۳۱,۰۲۷۰	۳۲,۱۰۶۶	۳۱,۳۹۵۹	31.16172
	۰,۸۱۲۲	۰,۹۰۶۲	۰,۸۸۴۱	۰,۹۳۹۱	۰,۷۹۲۴	0.8668
SINE [۱۲۵]	۲۸,۵۰۸۹	۳۵,۷۳۸۷	۳۳,۱۳۸۲	۳۵,۷۳۴۲	۳۳,۸۲۳۲	33.38864
	۰,۸۷۷۹	۰,۹۳۴۶	۰,۹۰۸۸	۰,۹۵۱۰	۰,۹۱۹۵	0.91836
ProposedMethod5	۳۰,۳۶۲۴	۳۶,۵۸۱۸	۳۴,۹۹۹۴	۳۵,۳۹۹۵	۳۴,۷۰۱۲	34.40886
	۰,۹۰۶۳	۰,۹۴۳۴	۰,۹۲۱۱	۰,۹۵۲۵	۰,۹۱۹۳	0.92852

برای اغلب تصاویر جدول (۲-۵)، روش پیشنهادی ما نتایج بهتری براساس دو معیار PSNR و SSIM نسبت به سایر روش‌ها داشته است. برای مشاهده نتایج بصری، یک ناحیه در تصویر خروجی مشخص شده است

که برای بهتر دیده شده در گوشه‌ای از تصویر با جزئیات بیشتر نشان داده شده است. اشکال (۷-۵) و (۵-۵-۸) خروجی بصری روش‌های مورد مقایسه به ترتیب برای تصاویر tree و susan است.




شکل (۷-۵) نتایج افزایش تفکیک‌پذیری برای تصویر tree. سطر بالا: تصویر هدف،

(bicubic (PSNR: 28.3977, SSIM: 0.8730), LLE[36] (PSNR: 25.8251, SSIM: 0.8257)

سطر پایین: ScSR[46] (PSNR: 29.1265, SSIM: 0.8887), SISR[51] (PSNR: 26.9405, SSIM: 0.8410) و

روش پیشنهادی ۵ (PSNR: 30.3624, SSIM: 0.9063)



شکل (۵-۸) نتایج افزایش تفکیک پذیری تصویر susan. سطر بالا (از چپ به راست): تصویر هدف،

.LLE[36] (PSNR: 33.4981 , SSIM: 0.9056) ,bicubic (PSNR: 35.4471 , SSIM: 0.9317)

سطر پایین : (ScSR[46] (PSNR: 36.2441 , SSIM: 0.9380) , SISR[51] (PSNR: 33.6579 , SSIM: 0.8986) و

روش پیشنهادی ۵ (PSNR: 36.8518 , SSIM: 0.9434).

۴-۵ جمع بندی

در این فصل دو روش برای افزایش تفکیک پذیری تصویر مبتنی بر محتوی تصویر ورودی ارائه شده است. در برخی مراجع، صرفاً اطلاعات وصله های هر سطح هرم (نه تشابه وصله ها)، بطور جداگانه مورد استفاده قرار گرفته است. در دیگر روش ها، از تشابه مابین وصله ها در تصویر ورودی و یا در تصاویر سطوح مختلف هرم برای ایجاد تصویر وضوح بالای خروجی استفاده شده است. نکته ای که در کارهای گذشته به آن پرداخته نشده است، موضوع گروه بندی وصله های تصاویر در سطوح مختلف هرم تصویر ورودی و سپس بکارگیری آن ها در فرایند یادگیری اطلاعات از تصاویر با تفکیک پذیری بالا می باشد که در این فصل بدان

پرداخته شده است. یک راهکار برای دسته‌بندی وصله‌ها قبل از فرایند بازسازی، شروع ناحیه‌بندی تصویر از پایین‌ترین سطح هرم و تعمیم آن به سطوح بالاتر است. در این روش به ازای هر ناحیه یک مدل آموزش داده شده و در فاز آزمون مورد استفاده قرار می‌گیرد. براساس نتایج به دست آمده، این ایده خطای مدل‌سازی را کاهش داده و تخمین تصویر وضوح بالا را بهبود می‌بخشد. استفاده از گراف همسایگی برای درنظر گرفتن اطلاعات همسایگی به همراه الگوریتم خوشه‌بندی زیرفضای تنک برای دسته‌بندی وصله‌ها قبل از بازسازی در روش دیگری مورد توجه قرار گرفت. با خوشه‌بندی تصویر ورودی با استفاده از الگوریتم خوشه‌بندی k-means و سپس اعمال الگوریتم خوشه‌بندی زیرفضای تنک، در ایجاد گراف همسایگی، پیچیدگی محاسباتی کاهش و سرعت اجرای الگوریتم افزایش یافته است. در این روش پیشنهادی، برخلاف سایر روش‌هایی که از خوشه‌بندی زیرفضای تنک استفاده نموده‌اند نیاز به درنظر گرفتن تعدادی محدودی وصله‌های تصویر و حذف مابقی آنان نمی‌باشد زیرا با خوشه‌بندی اولیه براساس خوشه‌بندی k-means می‌توان داده‌های مشابه را در یک خوشه قرار داد و با حذف تعدادی از وصله‌های قرار گرفته در هر خوشه، افزونگی داده‌ها را کاهش داد. در نهایت، گراف همسایگی با تعداد کمتر و مرتبط‌تر داده رسم می‌شود.

فصل ۶: مقایسه روش‌های پیشنهادی رساله

۶-۱ مقدمه

یکی از پیشنهادات اساسی این رساله، در نظر گرفتن اطلاعات همسایگی برای افزایش تفکیک‌پذیری تصویر است. در ابتدا، برای لحاظ کردن موضوع همسایگی، روش پیشنهادی ۱ و ۲ ارائه شد که در این دو روش، از اطلاعات بازسازی شده قبلی برای تخمین مقادیر جدید پیکسل‌ها استفاده شد. رفتار الگوریتم پیشنهادی ۱، به ازای تمامی پیکسل‌های تصویر، کاملاً مشابه بود که این امر باعث تاری تصویر به خصوص در لبه‌ها گردید. در روش پیشنهادی ۲، ابتدا، پیکسل‌های لبه و غیرلبه جداسازی شد و سپس، پیکسل‌های غیرلبه براساس قرارگرفتن در نواحی یکنواخت و غیریکنواخت نیز در دو گروه متفاوت قرار داده شدند. لذا، در این روش، ۳ استراتژی متفاوت ارائه گردید که تارشدگی تصویر نسبت به روش ۱ کاهش یافت. در روش پیشنهادی ۳، به جای در نظر گرفتن همسایگی مکانی، از همسایگی در فضای ویژگی‌ها استفاده شد. در این روش، از K -means برای خوشه‌بندی ویژگی وصله‌ها و از LLE برای پیدا کردن نزدیکترین همسایه‌ها در خوشه برنده استفاده شد. در روش پیشنهادی ۳، تعداد خوشه‌ها و تعداد همسایگی به ازای تمامی تصاویر ثابت در نظر گرفته شد که این امر باعث تارشدن برخی تصاویر آزمون گردید. لذا، جهت در نظر گرفتن محتوای تصویر ورودی، در روش پیشنهادی ۴، از ناحیه‌بندی هر تصویر و آموزش مدل‌های رگرسیونی براساس هر ناحیه استفاده شد. بنابراین، تعداد مدل‌های آموزشی براساس محتوای تصویر ورودی متغیر بود. از دیگر مواردی که در آن، گروه‌بندی داده‌ها براساس تعداد از پیش تعیین شده خوشه نبوده و به بافت تصویر توجه شده است، استفاده از گراف همسایگی و خوشه‌بندی زیرفضای تنک می‌باشد که در روش ۵ مورد استفاده قرار گرفته است. در این فصل به مقایسه خروجی روش‌های پیشنهادی رساله از لحاظ کمی و کیفی با استفاده از معیارهای PSNR و SSIM پرداخته شده است. برای این منظور، ابتدا ضریب افزایش را ۲ در نظر گرفته و خروجی روش‌ها براساس دو معیار PSNR و SSIM بصورت جدولی و سپس بصورت بصری نشان داده شده است. جداول و اشکالی نیز برای افزایش تفکیک‌پذیری با ضریب ۳ در این فصل آورده شده است. در

نهایت، نحوه عملکرد روش‌های پیشنهادی رساله و روش‌های مورد مقایسه در خصوص نویز (گوسین و نمک و فلغل) مورد بررسی قرار گرفته است.

۶-۲ افزایش تفکیک‌پذیری تصویر با ضریب افزایش ۲

نتایج روش‌های پیشنهادی رساله و روش‌های مورد مقایسه در سرتاسر رساله، برای ضریب افزایش ۲ و به ازای هشت تصویر مورد بررسی در جدول (۶-۱) آورده شده است. همانطور که در جدول (۶-۱) مشاهده می‌شود، روش پیشنهادی ۴ در اغلب موارد بهترین عملکرد و روش LLE[36] ضعیف‌ترین نتایج را نسبت به سایر روش‌ها براساس دو معیار PSNR و SSIM داشته‌اند. در روش پیشنهادی ۴ از ناحیه‌بندی تصویر قبل از شروع فاز آموزش استفاده نموده ایم که این امر باعث آموزش مدل‌هایی مرتبط‌تر با بافت تصویر می‌شود. در روش LLE[36]، از الگوریتم تعبیه شده خطی محلی برای افزایش تفکیک‌پذیری تصویر استفاده شده است. روش ۱، در بین روش‌های پیشنهادی رساله، دارای ضعیف‌ترین عملکرد است زیرا در این روش به ازای تمامی پیکسل‌های تصویر، همسایگی در نظر گرفته شده است. در جدول (۶-۱)، بالاترین مقادیر PSNR و SSIM با حالت توپر و خط زیر (bold and underline)، کمترین مقادیر با حالت خط زیر (underline) نشان داده شده است. کمترین مقادیر در بین روش‌های پیشنهادی رساله با حالت توپر و کج (bold and italic) مشخص شده است.

جدول (۱-۶) مقایسه روش‌های پیشنهادی رساله با سایر روش‌های مطرح در رساله (ضریب افزایش ۲)

تصویر روش	tree	lena	house	susan	peppers	airplane	baboon	boat
bicubic	۲۸,۳۹۷۷	۳۵,۴۴۷۱	۳۲,۲۱۲۱	۳۴,۷۱۱۴	۳۳,۱۷۴۱	۳۲,۶۸۴۴	۲۴,۹۶۱۵	۲۹,۹۴۷۲
	۰,۸۷۳۰	۰,۹۳۱۷	۰,۹۰۳۴	۰,۹۴۶۶	۰,۹۰۲۴	۰,۹۴۵۰	۰,۷۲۵۵	۰,۸۵۴۱
SISR[51]	۲۶,۹۴۰۵	۳۳,۶۵۷۹	۳۰,۹۲۱۵	۳۳,۷۵۶۰	۳۱,۷۱۷۸	۳۱,۱۵۵۶	۲۳,۳۸۴۳	۲۹,۷۹۱۹
	۰,۸۴۱۰	۰,۸۹۸۶	۰,۸۶۹۳	۰,۹۲۹۰	۰,۸۶۶۰	۰,۹۲۱۱	۰,۶۸۵۴	۰,۸۳۳۴
LLE[36]	۲۵,۸۲۵۱	۳۳,۴۹۸۱	۲۹,۴۹۹۵	۳۱,۸۴۰۴	۳۰,۶۴۲۷	۲۹,۶۸۷۵	۲۲,۹۴۸۷	۲۴,۲۷۹۴
	۰,۸۲۵۷	۰,۹۰۵۶	۰,۸۶۴۶	۰,۹۲۳۹	۰,۸۶۶۹	۰,۹۱۲۲	۰,۶۶۳۰	۰,۶۲۱۴
ScSR[46]	۲۹,۱۲۶۵	۳۶,۲۴۴۱	۳۲,۷۲۶۶	۳۵,۳۷۸۶	۳۳,۵۹۵۳	۳۳,۳۵۳۱	۲۵,۴۹۴۷	۳۰,۶۴۴۸
	۰,۸۸۸۷	۰,۹۳۸۰	۰,۹۰۷۹	۰,۹۴۸۰	۰,۹۰۴۶	۰,۹۴۸۴	۰,۷۸۰۹	۰,۸۷۱۴
LsSR[44]	۲۷,۳۹۶۲	۳۳,۸۸۲۹	۳۱,۰۲۷۰	۳۲,۱۰۶۶	۳۱,۳۹۵۹	۳۱,۶۶۰۵	۲۳,۶۵۲۴	۳۰,۱۷۳۷
	۰,۸۱۲۲	۰,۹۰۶۲	۰,۸۸۴۱	۰,۹۳۹۱	۰,۷۹۲۴	۰,۹۲۴۲	۰,۶۶۶۳	۰,۸۴۶۳
ProposedMethod1 [124]	۲۷,۲۹۳۲	۳۴,۰۰۵۲	۳۱,۸۰۲۵	۳۲,۶۲۳۴	۳۳,۳۹۹۷	۳۱,۳۶۳۵	۲۳,۸۹۱۳	۳۱,۲۳۷۵
	۰,۸۵۹۴	۰,۹۳۰۰	۰,۸۵۹۱	۰,۹۳۶۶	۰,۹۰۰۴	۰,۹۱۷۹	۰,۶۵۹۴	۰,۹۱۰۹
ProposedMethod2 [125]	۲۸,۵۰۸۹	۳۵,۷۳۸۷	۳۳,۱۳۸۲	۳۵,۷۳۴۲	۳۳,۸۲۳۲	۳۳,۰۵۹۵	۲۵,۲۹۹۶	۲۸,۵۳۶۰
	۰,۸۷۷۹	۰,۹۳۴۶	۰,۹۰۸۸	۰,۹۵۱۰	۰,۹۱۹۵	۰,۹۴۷۲	۰,۷۵۵۵	۰,۸۸۲۷
ProposedMethod3 [126]	۲۷,۹۸۷۵	۳۴,۵۰۱۹	۳۰,۷۷۱۸	۳۲,۹۳۰۹	۳۳,۱۱۹۴	۳۳,۱۰۲۶	۲۳,۹۲۰۹	۳۰,۴۶۸۵
	۰,۸۸۶۰	۰,۹۳۵۲	۰,۸۷۶۷	۰,۹۳۶۸	۰,۹۰۴۲	۰,۹۴۸۴	۰,۷۲۸۶	۰,۸۷۶۸
ProposedMethod4 [127]	۲۹,۶۴۰۳	۳۶,۶۳۸۵	۳۳,۴۶۹۴	۳۵,۵۷۲۱	۳۴,۶۵۴۲	۳۴,۲۰۴۱	۲۵,۷۰۱۴	۳۲,۰۱۸۵
	۰,۸۹۸۸	۰,۹۴۲۵	۰,۹۱۵۹	۰,۹۵۳۸	۰,۹۱۳۱	۰,۹۵۶۱	۰,۷۸۸۶	۰,۸۸۷۴

همانطور که در جدول (۱-۶) مشاهده می‌شود، کمترین مقادیر معیار (PSNR, SSIM) تمامی روش‌های مورد بررسی، به ازای تصویر baboon است که این امر می‌تواند از بافت این تصویر نسبت به سایر تصاویر باشد.

جدول (۲-۶) میانگین مقادیر PSNR و SSIM برای هشت تصویر آزمون و به ازای روش‌های مورد مقایسه

(ضریب افزایش ۲)

میانگین	روش
۳۱,۴۴۱۹۴	Bicubic
۰,۸۸۵۲۱۳	
۳۰,۱۶۵۶۹	SISR[51]
۰,۸۵۵۴۷۵	
۲۸,۵۲۷۶۸	LLE[36]
۰,۸۲۲۹۱۳	
۳۲,۰۷۰۴۶	ScSR[46]
۰,۸۹۸۴۸۸	
۳۰,۱۶۱۹	LsSR[44]
۰,۸۴۶۳۵	
۳۰,۷۰۲۰۴	ProposedMethod1[124]
۰,۸۷۱۷۱۳	
۳۱,۷۲۹۷۹	ProposedMethod2[125]
۰,۸۹۷۱۵	
۳۰,۸۵۰۴۴	ProposedMethod3[126]
۰,۸۸۶۵۸۸	
۳۲,۷۳۷۳۱	ProposedMethod4[127]
۰,۹۰۷۰۲۵	

در جدول (۲-۶)، روش ۴، بامیانگین ۳۲,۷۳۷۳۱ برای PSNR و ۰,۹۰۷۰۲۵ برای معیار SSIM بهترین و روش LLE[36] با میانگین ۲۸,۵۲۷۶۸ PSNR = و میانگین ۰,۸۲۲۹۱۳ SSIM بدترین عملکرد را داشته‌اند.

در اشکال (۱-۶) و (۲-۶)، خروجی روش‌های پیشنهادی رساله (روش‌های ۱ تا ۴)، به ترتیب برای تصاویر lena و tree با ضریب افزایش ۲ نشان داده شده است. از آنجائی که در فصل‌های ۴ و ۵، هر یک از روش‌های

پیشنهادی رساله با روش‌های درونیابی دومکعبی، [51]SISR، [36]LLE، [46]ScSR و [44]LsSR برای ضریب افزایش ۲ مقایسه شده‌اند، در این اشکال، خروجی این روش‌ها نشان داده نشده است.



شکل (۱-۶) مقایسه خروجی روش‌های پیشنهادی ۱ تا ۴ برای تصویر lena



شکل (۲-۶) مقایسه خروجی روش های پیشنهادی ۱ تا ۴ برای تصویر tree

همانطور که در جدول (۱-۶) مشخص شده است، روش ۴، دارای بالاترین و روش ۱ دارای کمترین مقادیر PSNR و SSIM به ازای اکثر تصاویر آزمون است که این نتیجه در اشکال (۱-۶) و (۲-۶) قابل مشاهده می باشد.

۳-۶ افزایش تفکیک پذیری تصویر با ضریب افزایش ۳

جداول (۳-۶) و (۴-۶)، مقادیر PSNR و SSIM را به ترتیب برای دو تصویر lena و tree به ازای ضریب افزایش ۳، نشان می دهند.

جدول (۶-۳) مقادیر PSNR و SSIM روش های SR با ضریب افزایش ۳

(برای تصویر lena)


SSIM	PSNR	معیار روش
0.8826	۳۲,۱۲۹۰	Bicubic
<u>۰,۸۴۴۶</u>	<u>۲۹,۹۳۲۹</u>	LLE[36]
۰,۸۵۱۵	۳۰,۲۸۹۷	SlSR[51]
۰,۸۹۲۶	۳۲,۸۲۷۲	ScSR[46]
۰,۸۷۷۹	۳۲,۳۵۶۴	LsSR[44]
۰,۹۰۸۶	۳۲,۲۰۲۷	Proposed Method1 [124]
۰,۹۲۸۰	۳۵,۰۰۳۰	Proposed Method2 [125]
۰,۸۵۸۴	۳۰,۵۰۶۸	Proposed Method3 [126]
۰,۹۴۳۷	۳۶,۷۷۴۵	Proposed Method4 [127]

شکل (۶-۳)، خروجی روش های درونیابی دوماکعبی، [LLE[36], SlSR[51], ScSR[46] و LsSR[44] با ضریب افزایش ۳ را نشان می دهد. در این شکل، بخشی از تصویر lena که با مربع کوچک (قرمز رنگ) مشخص شده است، با جزئیات بیشتر در گوشه پایین-سمت راست با مربع بزرگتر (آبی رنگ)، نشان داده شده است.



شکل (۳-۶) افزایش فراتفکیک پذیری تصویر با ضریب افزایش ۳ برای تصویر lena - به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی - درونیابی دومکعبی، [36] LLE، [51] SISR، [46] ScSR و [44] LsSR

در شکل (۴-۶)، خروجی روش‌های پیشنهادی رساله برای تصویر lena با ضریب افزایش ۳ آورده شده است. بخش منتخب اشکال (۳-۶) و (۴-۶)، یکسان است.




شکل (۴-۶) نتایج روش‌های پیشنهادی ۱ تا ۴ با ضریب افزایش ۳ برای تصویر lena - به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی - روش‌های ۱ تا ۴

جدول (۶-۴) مقادیر PSNR و SSIM روش های SR با ضریب افزایش ۳

(برای تصویر tree)

SSIM	PSNR	معیار روش
۰,۷۷۷۲	۲۶,۱۵۳۲	Bicubic
۰,۸۵۱۱	۲۶,۵۳۷۱	LLE[36]
۰,۷۴۲۶	۲۴,۴۶۹۰	SISR[51]
۰,۸۸۸۷	۲۶,۸۱۸۵	ScSR[46]
۰,۷۰۹۴	۲۴,۷۶۴۲	LsSR[44]
۰,۸۲۶۷	۲۶,۵۰۹۸	Proposed Method1[124]
۰,۸۶۹۷	۲۷,۹۰۸۷	Proposed Method2[125]
۰,۷۷۶۸	۲۴,۷۶۹۵	Proposed Method3[126]
۰,۹۰۰۳	۳۰,۱۰۰۲	Proposed Method4[127]

همانطور که در جداول (۶-۳) و (۶-۴) مشاهده می‌شود، روش ۴، بالاترین مقادیر PSNR و SSIM را به ازای ضریب افزایش ۳ برای تصاویر lena و tree دارد. کمترین مقادیر PSNR و SSIM برای تصویر lena مربوط به روش LLE[36] است. برای تصویر tree کمترین مقادیر PSNR و SSIM به ترتیب برای روش‌های SISR[51] و LsSR[44] است. در بین روش‌های ۱ تا ۴، ضعیف‌ترین عملکرد براساس این دو معیار به ازای هر دو تصویر برای روش ۳ است.



شکل (۵-۶) افزایش فراتفکیک پذیری تصویر با ضریب افزایش ۳ برای تصویر tree- به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی - درون یابی دومکعبی، [36]LLE، [51]SISR، [46]ScSR و [44]LsSR



شکل (۶-۶) نتایج روش های پیشنهادی ۱ تا ۴ با ضریب افزایش ۳ برای تصویر tree- به ترتیب از چپ به راست و بالا به پایین: تصویر اصلی - روش های ۱ تا ۴

۴-۶ زمان اجرای روش‌های پیشنهادی رساله

در این بخش، زمان اجرای هر یک از روش‌های پیشنهادی رساله به تفکیک هشت تصویر آزمون آورده شده است. این روش‌ها در نرم‌افزار Matlab R2016a نوشته شده و بر روی سیستم با پردازشگر Intel® Core™ i7 4700HQ و حافظه 8G اجرا شده‌اند.

جدول (۵-۶) زمان اجرای هر یک از روش‌های پیشنهادی رساله (بر حسب ثانیه)

Proposed Method4		Proposed Method3	Proposed Method2		Proposed Method1		روش
Test	Train	Test	Test	Train	Test	Train	تصویر
۲۵,۲۶۰۲	۱۰۶,۹۱۴۸	۱۲۷۶,۴۱۳	۲۴,۰۰۰۱	۵۲,۷۷۳۴	۲,۷۸۹۱	۱۲۵,۵۶۶۰	tree
۲۷۸,۲۰۲۱	۱۷۰۴,۳	۳۰۸۹,۳۰۱	۲۹۱,۲۴۱۵	۴۷۳,۱۸۴۳	۱۵,۷۸۴۹	۱۴۱,۸۶۱۵	lena
۳۸,۴۴۵۹	۱۷۵,۳۳۷۳	۷۵,۲۵۴	۱۵,۸۴۵۸	۳۷,۴۹۸۸	۱,۷۹۶۹	۱۳۷,۷۰۱۱	house
۲۰,۲۲۴۳	۸۹,۷۷۱۰	۱۰۰,۷۷۵	۱۸,۹۶۹۵	۴۶,۰۳۱۳	۱,۹۲۸۰	۱۳۹,۵۳۵۳	susan
۲۲۸,۱۰۰۶	۹۶۵,۷۶	۲۱۰۵,۹۳۸	۲۹۳,۸۷۴۳	۵۰۱,۰۴۱۷	۱۶,۳۲۱۶	۱۴۲,۸۹۰۹	pappers
۵۱۸,۳۲۲۸	۲۵۴۹,۶	۳۰۰۹۲,۰۴۰	۲۸۸,۸۱۷۷	۴۶۱,۲۹۹۸	۱۶,۶۹۹۶	۱۴۲,۹۹۶۶	airplane
۵۷۴,۲۰۹۸	۲۴۳۳,۴	۱۰۱۴۸,۶۳۱	۳۴۰,۴۰۶۴	۳۹۹,۷۷۰۴	۱۷,۹۲۴۸	۱۴۸,۸۸۹۰	baboon
۶۳۰,۸۸۱۴	۷۰۶۷,۴	۹۰۷۸,۳۹۱	۳۳۴,۲۴۴۳	۵۰۰,۳۵۲۶	۱۶,۳۴۹۹	۱۴۵,۱۴۳۴	boat

در جدول (۵-۶)، بیشترین زمان اجرای هر روش بصورت تیره‌تر و کمترین زمان اجرا بصورت خط زیر نشان داده شده است. قابل پیش‌بینی است که روش‌های پیشنهادی برای تصاویر با ابعاد کوچک‌تر، زمان اجرای کمتری دارند (تصاویر tree, house, susan) و بیشترین زمان اجرا مربوط به تصاویر با ابعاد بزرگ‌تر و مخصوصاً برای تصاویر با بافت‌های متفاوت است.

۵-۶ تاثیر نویز بر عملکرد روش های افزایش فراتفکیک پذیری


تصویر

در این بخش از رساله، عملکرد روش های پیشنهادی ۱ تا ۴ و روش های درون یابی دومکعبی، [36]LLE، [51]SISR، [46]ScSR و [44]LsSR در مواجهه با یک تصویر نویزی مورد بررسی قرار می گیرد. برای این منظور، به تصاویر ورودی، نویز گوسین با میانگین صفر و واریانس ۰,۰۱ اضافه شد. برای بررسی بیشتر، تصاویر ورودی تحت تاثیر نویز نمک و فلفل با چگالی ۰,۰۵ نیز قرار گرفتند. در جدول (۶-۶)، مقادیر معیار برای نویز گوسین و نمک و فلفل به ازای تصویر lena نشان داده شده است.


جدول (۶-۶) مقادیر PSNR و SSIM روش های SR پس از اعمال نویز (برای تصویر lena)

Salt & pepper Noise		Gaussian Noise		نویز
SSIM	PSNR	SSIM	PSNR	روش
۰,۳۹۲۲	۲۲,۸۶۴۷	۰,۴۰۹۲	۲۴,۶۷۷۰	Bicubic
۰,۴۵۲۵	۲۲,۱۱۱۶	۰,۴۶۰۹	۲۳,۹۹۴۱	LLE[36]
۰,۴۳۴۹	۲۲,۰۶۶۱	۰,۴۴۳۵	۲۳,۹۸۲۶	SISR[51]
۰,۵۶۶۲	۲۳,۹۱۳۵	۰,۵۷۹۸	۲۵,۸۷۲۰	ScSR[46]
۰,۳۲۲۴	۱۸,۰۵۱۶	۰,۲۶۵۷	۲۰,۴۸۶۲	LsSR[44]
۰,۵۶۹۰	۲۳,۹۳۰۵	۰,۵۸۳۵	۲۵,۹۷۱۰	Proposed Method1[124]
۰,۵۸۹۵	۲۶,۲۳۷۴	۰,۵۸۳۱	۲۶,۲۱۵۸	Proposed Method2[125]
۰,۶۲۷۹	۲۳,۶۶۰۵	۰,۶۴۱۰	۲۵,۶۷۲۹	Proposed Method3[126]
۰,۸۱۱۰	۲۷,۱۹۰۲	۰,۸۱۴۶	۲۸,۷۴۳۹	Proposed Method4[127]

همانطور که در جدول (۶-۶) مشاهده می شود، روش ۴ بهترین عملکرد و روش [44]LsSR، ضعیف ترین عملکرد را در بین روش های مورد مقایسه داشته اند.



شکل (۶-۷) تاثیر نویز گوسین بر تصویر lena - به ترتیب از بالا به پایین و چپ به راست: تصویر اصلی - روش های درونیابی دو مکهبی، [36]LLE، [51]SISR، [46]ScSR و [44]LsSR




شکل (۶-۸) تاثیر نویز گوسین بر تصویر lena - به ترتیب: تصویر اصلی و روش های ۱ تا ۴


در اشکال (۷-۶) و (۸-۶) نیز برتری روش ۴ نسبت به سایر روش‌ها مشهود است. از آنجائی که نویز یک نوع تخریب تصویر محسوب می‌شود، هر روشی که خروجی آن کمتر تحت تاثیر تخریب انجام شده قرار بگیرد، می‌تواند عملکرد بهتری از خود نشان دهد. همانطور که در اشکال (۷-۶) و (۸-۶) دیده می‌شود، نویز موجود در تصویر ورودی در بسیاری از روش‌ها باعث تار شدن تصویر خروجی شده است. درحالی‌که در روش ۴ تارشدگی نسبت به سایر روش‌ها اندک است. همین مطالب در رابطه با اشکال (۹-۶) و (۱۰-۶) نیز صادق است. در جدول (۵-۶)، مقادیر PSNR و SSIM در ازای اعمال نویز نمک و فلفل و برای تصویر tree آورده شده است. مشابه جدول (۴-۶)، روش ۴ در این مورد نیز بهترین عملکرد و روش LsSR[44] بدترین عملکرد را داشته است. در جداول (۴-۶) و (۵-۶)، روش ۳ در بین روش‌های پیشنهادی رساله، عملکرد ضعیفی در برابر نویز از خود نشان داده است.

جدول (۷-۶) مقادیر PSNR و SSIM روش‌های SR پس از اعمال نویز (برای تصویر tree)

Salt & pepper Noise		Gaussian Noise		نویز
SSIM	PSNR	SSIM	PSNR	روش
۰,۴۵۳۱	۲۱,۵۱۷۸	۰,۴۷۸۴	۲۲,۸۶۴۹	Bicubic
۰,۵۲۶۵	۲۰,۶۶۲۸	۰,۵۳۹۰	۲۲,۲۳۶۹	LLE[36]
۰,۵۲۳۲	۲۰,۸۴۱۱	۰,۶۵۴۳	۲۴,۶۹۵۷	SISR[51]
۰,۶۳۷۳	۲۲,۸۹۶۰	۰,۶۵۷۸	۲۴,۵۳۴۴	ScSR[46]
۰,۳۳۴۳	۱۷,۵۴۱۳	۰,۳۲۳۷	۱۹,۱۱۰۳	LsSR[44]
۰,۶۴۱۹	۲۳,۰۳۹۱	۰,۶۶۰۸	۲۴,۷۷۶۶	Proposed Method1[124]
۰,۶۹۷۵	۲۳,۱۰۶۹	۰,۶۹۱۳	۲۳,۶۷۵۵	Proposed Method2[125]
۰,۶۴۳۱	۲۲,۳۵۷۲	۰,۶۴۹۱	۲۴,۵۹۱۴	Proposed Method3[126]
۰,۸۱۵۷	۲۵,۱۴۱۷	۰,۸۲۳۴	۲۶,۱۶۶۹	Proposed Method4[127]



شکل (۶-۹) تاثیر نویز نمک و فلفل بر تصویر tree - به ترتیب از بالا به پایین و چپ به راست: تصویر اصلی - روش های درون یابی دو مکعبی، [36] LLE، [51] SISR، [46] ScSR و [44] LsSR



شکل (۶-۱۰) تاثیر نویز نمک و فلفل بر تصویر tree - به ترتیب از بالا به پایین و چپ به راست: تصویر اصلی و روش های ۱ تا ۴

۶-۶ جمع بندی

در این فصل به مقایسه روش های پیشنهادی رساله پرداخته شده است. ابتدا این مقایسه براساس ضریب افزایش ۲ انجام شده است. در بین روش های پیشنهادی و روش های درونیابی دومکعبی، LLE[36]، SISR[51]، ScSR[46] و LsSR[44]، روش پیشنهادی ۴، بامیانگین ۳۲,۷۳۷۳۱ برای PSNR و میانگین ۰,۹۰۷۰۲۵ برای معیار SSIM بهترین و روش LLE[36] با میانگین $PSNR = ۲۸,۵۲۷۶۸$ و میانگین $SSIM = ۰,۸۲۲۹۱۳$ بدترین عملکرد را به ازای تصاویر آزمون داشته اند. در بین روش های رساله نیز روش پیشنهادی ۱، کمترین مقدار PSNR و SSIM را برای اغلب تصاویر آزمون در برداشته است.

برای ضریب افزایش ۳، در بین روش های پیشنهادی ۱ تا ۴ نیز، روش ۴، بهترین و روش ۳، بدترین عملکرد را براساس مقادیر معیار برای دو تصویر lena و tree از خود نشان داده اند.

روش های پیشنهادی رساله، در نرم افزار Matlab R2016a نوشته شده و بر روی سیستم با پردازشگر Intel® Core™ i7 4700HQ و حافظه 8G اجرا شده اند. بررسی زمان اجرای روش های پیشنهادی نشان داده است که زمان اجرای این روش ها با افزایش ابعاد و پیچیدگی تصویر، افزایش می یابد.

برای بررسی تاثیر نویز بر خروجی الگوریتم های مورد مقایسه، نویز گوسین و نمک و فلفل بر تصویر ورودی اعمال شده و نتایج حاکی از مقاومت روش پیشنهادی ۴ رساله در برابر نویز نسبت به سایر روش ها است. برخی از الگوریتم های مورد بررسی، تحت تاثیر نویز قرار گرفته و تارشدگی در تصویر خروجی مشهود است. لذا، در بررسی انجام شده، روش پیشنهادی ۴ توانسته است در تمامی زمینه ها براساس معیارهای PSNR و SSIM بهتر از سایر روش ها عمل کند.

فصل ۷: جمع‌بندی و کارهای آتی

۷-۱ مقدمه

در این فصل به جمع‌بندی روش‌های پیشنهادی و ایده‌های مطرح شده در رساله پرداخته می‌شود و سپس پیشنهاداتی جهت ادامه کار و انجام پژوهش‌هایی در آینده داده می‌شود.

۷-۲ جمع‌بندی پژوهش‌های انجام شده در رساله

در این رساله، افزایش تفکیک‌پذیری تک تصویر خودیادگیرنده مورد بررسی قرار گرفت. در روش‌های پیشنهادی، به جای استفاده از پایگاه‌داده‌ای از تصاویر با تفکیک‌پذیری بالا و تفکیک‌پذیری پایین متناظر، از دو هرم ایجاد شده از تنها تصویر ورودی استفاده شده است. این دو هرم، با اعمال متناوب (به تعداد سطوح هرم) الگوریتم‌های کاهش (هرم با تفکیک‌پذیری بالا) و افزایش (هرم با تفکیک‌پذیری پایین) نرخ نمونه‌برداری از تصویر ورودی ایجاد شده‌اند. بازنمایی تنک یکی از ویژگی‌های مورد استفاده برای هر وصله از تصویر بود. در سال‌های اخیر به این ویژگی توجه بسیاری شده است. بدلیل صفر بودن اکثر ضرایب در این ویژگی، سرعت اجرا افزایش و حافظه و زمان مصرفی کاهش می‌یابد. از دیگر ویژگی مورد استفاده در این رساله می‌توان به گرادیان مرتبه اول و دوم اشاره کرد. در این ویژگی اختلاف بین پیکسل‌های قرار گرفته در یک وصله در نظر گرفته می‌شود. در فاز آموزش، براساس ویژگی‌های استخراج شده از وصله‌های تصاویر با تفکیک‌پذیری پایین و ارزش پیکسل مرکزی وصله متناظر در تصاویر با تفکیک‌پذیری بالا توسط رگرسیون بردار پشتیبان مدل‌سازی می‌شود که در فاز آزمون برای تخمین ارزش پیکسل‌ها از این مدل‌ها استفاده می‌شود. در ادامه، روش‌های مطرح شده در رساله به اختصار توضیح داده می‌شود.

۷-۲-۱ افزایش وضوح تک تصویری با در نظر گرفتن مقادیر پیکسل های

مجاور بازسازی شده

براساس موضوع رساله، بیشتر تمرکز ما بر در نظر گرفتن اطلاعات همسایگی بود. در ابتدا تمرکز بیشتر بر پیکسل های بازسازی شده قبلی و مجاور پیکسل ها بود. با توجه به نحوه پیمایش تصویر جهت بازسازی (از چپ به راست و بالا به پایین)، از اختلاف پیکسل مد نظر (در حال بازسازی) با پیکسل های بالا و سمت چپ آن (بازسازی شده) در مدل سازی استفاده شد که این مساله باعث تارشدن لبه های تصویر گردید. با عنایت به اندازه ی هر وصله از تصویر، در اغلب موارد، تغییرات در ارزش پیکسل ها در وصله های مجاور تصاویر ناچیز است. لذا، از این مساله می توان در انتخاب مقادیر جدید هر پیکسل استفاده کرد و از بین مقادیر کاندیدا به ازای هر پیکسل، مقداری که دارای کمترین اختلاف با پیکسل های بازسازی شده همسایه است، انتخاب نمود. در این روش با وجود اینکه از اطلاعات همسایگی بازسازی شده برای تخمین ارزش پیکسل ها استفاده می شود ولی باعث تارشدگی در لبه ها و در نتیجه هموارشدن تصویر می گردد.

۷-۲-۲ افزایش تفکیک پذیری تک تصویری با ارائه مدل جداگانه ای برای

پیکسل های لبه و غیر لبه

برای بهبود روش قبلی، بدلیل ماهیت متفاوت پیکسل های لبه و غیرلبه، ابتدا پیکسل های لبه و غیرلبه از هم جدا شدند و دو الگوریتم متفاوت به ازای آن ها تعریف شد. از طرف دیگر، عملکرد روش پیشنهادی برای پیکسل های غیرلبه نیز براساس قرار گرفتن در نواحی یکنواخت و غیریکنواخت متفاوت بود. در این روش، تنها برای پیکسل های غیرلبه که در نواحی یکنواخت قرار گرفته اند، به اطلاعات پیکسل های مجاور توجه

شده است. برای پیکسل‌های لبه و پیکسل‌های غیرلبه که در نواحی غیریکنواخت قرار دارند، اطلاعات همسایگی مورد استفاده قرار نگرفت.

۷-۲-۳ افزایش تفکیک پذیری تک تصویری با استفاده از تقریب منیفلد و k-means

برخی از پژوهش‌های انجام شده در زمینه افزایش تفکیک‌پذیری تنها از ویژگی‌های وصله‌ها در هر سطح هرم برای یادگیری مدل‌های آموزشی استفاده می‌کنند. در اغلب تحقیقات نیز از تشابه وصله‌ها در تصویر ورودی و یا تصاویر ایجاد شده از تصویر ورودی در سطوح مختلف هرم استفاده می‌شود. در هیچ یک از این مقالات از سازماندهی وصله‌های تصاویر هرم قبل از شروع فرایند یادگیری مدل‌ها استفاده نشده است. در این رساله به این موضوع پرداخته شده است. لذا، روش‌های متفاوتی برای ساماندهی وصله‌ها پیش از آموزش مدل‌های رگرسیونی ارائه شده است. در این روش‌ها نیز الگوریتم‌های متفاوتی برای وصله‌های با مرکزیت پیکسل‌های لبه و غیرلبه اجرا گردید. در یکی از روش‌های پیشنهادی رساله، وصله‌های تصویر با استفاده از الگوریتم kmeans به تعدادی از پیش تعیین شده خوشه تقسیم می‌شوند. سپس، به ازای هر خوشه یک مدل آموزش داده می‌شود. در فاز آزمون، به ازای هر وصله و ویژگی‌های مستخرج از آن، خوشه برنده انتخاب می‌شود. اطلاعات بازسازی شده براساس وصله‌های خوشه برنده و ضرایب بازسازی الگوریتم LLE به دست می‌آید.

برای انتخاب تعداد خوشه‌ها در الگوریتم kmeans و تعداد همسایگی در LLE از میانگین PSNR چندین تصویر استفاده شده است. میانگین PSNR برای این تصاویر به ازای تعداد خوشه و تعداد همسایگی ۵ بیشترین بوده است. لذا تعداد خوشه و خوشه به ازای ۵ در نظر گرفته شده است. با این وجود، نیاز به یک

روش سیستماتیک برای انتخاب خودکار و بهینه تعداد خوشه‌ها به ازای هر بافت تصویر است که در خروجی روش بسیار تاثیرگذار می‌باشد.

۷-۲-۴ افزایش تفکیک پذیری تک تصویری با تاکید بر یادگیری مجزا برای نواحی تصویر ورودی

در روش بخش ۷-۲-۳، براساس تعدادی از تصاویر پایگاه داده، تعداد خوشه و تعداد همسایگی مدنظر در هر خوشه، مشخص شد. درحالی‌که در صورت استفاده از تعداد بیشتر از تصاویر، تعداد خوشه و همسایگی براساس محتوای هر تصویر متغیر خواهد بود که بهتر است این موضوع به نحوی در روش پیشنهادی لحاظ شود. لذا، از دیگر ایده‌های ارائه شده در این رساله، افزایش تفکیک‌پذیری تصویر مبتنی بر محتوای تصویر ورودی است. یک راهکار برای این مساله، ناحیه‌بندی تصاویر هرم است. به عبارت دیگر، به جای در نظر گرفتن تمامی وصله‌های تصاویر هرم و سپس خوشه بندی آنها، بهتر است از ناحیه‌بندی تصاویر در هر سطح هرم استفاده شود. لذا، برخلاف اغلب روش‌های افزایش تفکیک‌پذیری تصویر بجای ساختن یک دیکشنری برای تمام وصله‌های تصویر ورودی، که بسیاری از این وصله‌ها نامتشابه هستند، به ازای هر ناحیه، دیکشنری جداگانه‌ای ساخته شد و از هر دیکشنری برای مدل سازی وصله‌های همان ناحیه استفاده شود. سپس، در فاز آموزش، به ازای هر ناحیه، یک مدل رگرسیونی یادگیری شد که در فاز آزمون نیز پس از ناحیه‌بندی تصویر میانی تصویر خروجی، به ازای ناحیه هر پیکسل، مدل آموزشی آن ناحیه مورد استفاده قرار گرفت. از طرف دیگر، برای داشتن تعداد یکسان نواحی به ازای تمامی تصاویر هرم، ناحیه‌بندی از تصویر پایین‌ترین سطح هرم شروع و به سطوح بالاتر تعمیم داده شد. براساس نتایج به دست آمده این ایده خطای مدل سازی را کاهش داده و تخمین تصویر با تفکیک‌پذیری بالا را بهبود می‌بخشد.

۷-۲-۵ افزایش فراتفکیک پذیری تک تصویری مبتنی بر محتوای تصویر ورودی با استفاده از خوشه بندی زیرفضای تنک

یک راهکار دیگر برای سازماندهی وصله ها قبل از شروع فرایند یادگیری، استفاده از بازنمایی تنک، گراف همسایگی و الگوریتم های خوشه بندی برای سازماندهی وصله ها است. برخلاف روش پیشنهادی بخش ۶-۲-۳، در این روش تعداد خوشه های هر تصویر براساس محتوای تصویر انتخاب می شود. برای این منظور، الگوریتم kmeans تا زمانی ادامه پیدا می کند که در یکی خوشه های جدید ایجاد شده تعداد اندکی داده موجود باشد که در این حالت دیگر خوشه بندی انجام نمی شود. در هر خوشه، الگوریتم خوشه بندی زیرفضای تنک اعمال شده و سپس گراف همسایگی به ازای هر خوشه ایجاد شده، ساخته می شود.

۷-۳ کارهای آتی

در روش هایی که اختلاف پیکسل های همسایه برای بازسازی تصویر مورد استفاده قرار گرفته است، از فاصله ی اقلیدسی بعنوان معیار سازگاری وصله های مجاور استفاده شده است که برای کار آتی پیشنهاد می گردد معیارهای فاصله دیگر نیز مورد بررسی قرار گیرد.

از آنجائی که تصاویر بافت متفاوتی دارند، لذا در نظر گرفتن تعداد از پیش تعیین شده خوشه می تواند خروجی نامطلوبی را ایجاد کند. برای این منظور، نیاز به یک روش سیستماتیک برای انتخاب خودکار و بهینه تعداد خوشه ها به ازای هر محتوای تصویر است که در خروجی روش بسیار تاثیرگذار می باشد.

در تحقیقات معدودی در زمینه افزایش تفکیک پذیری تصویر، از روش های یادگیری عمیق استفاده شده است [۱۱۷]، [۱۱۸]، [۱۱۹] و [۱۲۰]. بکارگیری یادگیری عمیق می تواند باعث افزایش کیفیت و سرعت

در روش‌های افزایش تفکیک‌پذیری شود که برای ادامه کار، استفاده از یادگیری عمیق برای آموزش مدل‌ها می‌تواند دقت تخمین را بالا ببرد.

در مراجع [۱۱۷] تا [۱۲۰]، برای نگاشت بین تصاویر با تفکیک‌پذیری بالا و تفکیک‌پذیری پایین متناظر از یک شبکه عصبی کانولوشن عمیق (DCNN)^۱ استفاده شده است. در روش‌های افزایش تفکیک‌پذیری نیاز به نگاشت بین تصاویر با تفکیک‌پذیری بالا و پایین است که شبکه‌های عصبی کانولوشن بعنوان نگاشت در نظر گرفته می‌شود که ورودی به این شبکه‌ها، تصویر با تفکیک‌پذیری پایین و خروجی آن تصویر با تفکیک‌پذیری بالا است.

^۱ Deep Convolutional Neural Network (DCNN)

- [1] Huang, T. and J. Yang, Image super-resolution: Historical overview and future challenges, in Super-resolution imaging. ٢٠١٠, CRC Press. p. ٥٢-١٩
- [٢] Tsai, R., Multiframe image restoration and registration. Advance Computer Visual and Image Processing, :١. ١٩٨٤p. ٣٣٩-٣١٧
- [3] Irani, M. and S. Peleg. Super resolution from image sequences. in Pattern Recognition, ١٩٩٠. Proceedings., ١٠th International Conference on. ١٩٩٠. IEEE.
- [4] Park, S.C., M.K. Park, and M.G.J.I.s.p.m. Kang, Super-resolution image reconstruction: a technical overview. ٢٠٠٣. ٢٠(٣): p. ٣٦-٢١
- [5] Bevilacqua, M., Algorithms for super-resolution of images and videos based on learning methods. ٢٠١٤, Rennes .١
- [6] Schatzberg, A. and A.J.J.I.P. Devaney, Super-resolution in diffraction tomography. ١٩٩٢. ٨(١): p. ١٤٩
- [7] Sauer, K.D., S. Borman, and C.A. Bouman. Parallel computation of sequential pixel updates in statistical tomographic reconstruction. in Image Processing, ١٩٩٥. Proceedings., International Conference on. ١٩٩٥. IEEE.
- [8] Rajan, D. and S. Chaudhuri. Generation of super-resolution images from blurred observations using Markov random fields. in Acoustics, Speech, and Signal Processing, ٢٠٠١. Proceedings.(ICASSP'٠١). ٢٠٠١IEEE International Conference on. ٢٠٠١. IEEE.
- [9] Peleg, S., D. Keren, and L.J.P.r.l. Schweitzer, Improving image resolution using subpixel motion. ١٩٨٧. ٥(٣): p. ٢٢٦-٢٢٣
- [10] Keren, D., S. Peleg, and R. Brada. Image sequence enhancement using sub-pixel displacements. in Computer Vision and Pattern Recognition, ١٩٨٨. Proceedings CVPR'٨٨., Computer Society Conference on. ١٩٨٨. IEEE.
- [11] Tipping, M.E. and C.M. Bishop. Bayesian image super-resolution. in Advances in neural information processing systems. .٢٠٠٣
- [12] Miravet, C. and F.B. Rodríguez, A hybrid MLP-PNN architecture for fast image superresolution, in Artificial Neural Networks and Neural Information Processing—ICANN/ICONIP ٢٠٠٣. ٢٠٠٣, Springer. p. ٤٢٤-٤١٧
- [13] Lian, H. Variational local structure estimation for image super-resolution. in Image Processing, ٢٠٠٦IEEE International Conference on. ٢٠٠٦. IEEE.
- [14] Reibman, A.R., R.M. Bell, and S. Gray. Quality assessment for super-resolution image enhancement. in Image Processing, ٢٠٠٦IEEE International Conference on. ٢٠٠٦. IEEE.
- [15] Capel, D. and A. Zisserman. Super-resolution enhancement of text image sequences. in Pattern Recognition, ٢٠٠٠. Proceedings. ١٥th International Conference on. ٢٠٠٠. IEEE.
- [16] Chiang, M.-C., T.E.J.I. Boulton, and V. Computing, Efficient super-resolution via image warping. ٢٠٠٠. ١٨(١٠): p. ٧٧١-٧٦١
- [17] Gilboa, G., N. Sochen, and Y.Y. Zeevi, Forward-and-backward diffusion processes for adaptive image enhancement and denoising. IEEE transactions on image processing, ٢٠٠٢. ١١(٧): p. ٧٠٣-٦٨٩

- [18] Gunturk, B., Y. Altunbasak, and R.J.I.S.P.L. Mersereau, Multiframe resolution-enhancement methods for compressed video. 2002. 9(6): p. 1144-1150.
- [19] Yang, C.-Y., J.-B. Huang, and M.-H. Yang. Exploiting self-similarities for single frame super-resolution. in Asian conference on computer vision. 2010. Springer.
- [20] Freeman, W.T., et al., Example-based super-resolution. 2002. 22(2): p. 160-167.
- [21] Baker, S., T.J.I.T.o.P.A. Kanade, and M. Intelligence, Limits on super-resolution and how to break them. 2002. 24(9): p. 11183-11167.
- [22] Hwang, J.W. and H.S.J.I.S.P.L. Lee, Adaptive image interpolation based on local gradient features. 2004. 11(3): p. 366-369.
- [23] Luong, H.Q., A. Ledda, and W. Philips. Non-local image interpolation. in Image Processing, 2006 IEEE International Conference on. 2006. IEEE.
- [24] Zhou, F., W. Yang, and Q.J.I.T.o.I.P. Liao, Interpolation-based image super-resolution using multisurface fitting. 2012. 21(7): p. 3318-3312.
- [25] Li, X. and M.T. Orchard, New edge-directed interpolation. IEEE transactions on image processing, 2003. 12(10): p. 1527-1531.
- [26] Cha, Y. and S. Kim, Edge-forming methods for color image zooming. IEEE Transactions on Image Processing, 2006. 15(8): p. 2323-2310.
- [27] Cha, Y. and S. Kim. PDE-based interpolation methods for image super resolution. in Future Generation Communication and Networking (FGCN 2007). 2007. IEEE.
- [28] Kim, H., Y. Cha, and S. Kim, Curvature interpolation method for image zooming. IEEE transactions on image processing, 2011. 20(7): p. 1903-1910.
- [29] Malgouyres, F. and F. Guichard, Edge direction preserving image zooming: a mathematical and numerical analysis. SIAM Journal on Numerical Analysis, 2001. 39(1): p. 37-1.
- [30] Belahmidi, A. and F. Guichard. A partial differential equation approach to image zoom. in Image Processing, 2004. ICIP'04. 2004 International Conference on. 2004. IEEE.
- [31] Chang, S.G., Z. Cvetkovic, and M. Vetterli, Locally adaptive wavelet-based image interpolation. IEEE Transactions on Image Processing, 2006. 15(6): p. 1480-1491.
- [32] Freedman, G. and R. Fattal, Image and video upscaling from local self-examples. ACM Transactions on Graphics (TOG), 2011. 30(2): p. 12.
- [33] Yang, J., Z. Lin, and S. Cohen. Fast image super-resolution based on in-place example regression. in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2012.
- [34] Glasner, D., S. Bagon, and M. Irani. Super-resolution from a single image. in Computer Vision, 2009 IEEE 12th International Conference on. 2009. IEEE.
- [35] Yang, M.-C., et al. Learning context-aware sparse representation for single image super-resolution. in Image Processing (ICIP), 18 2011th IEEE International Conference on. 2011. IEEE.
- [36] Chang, H., D.-Y. Yeung, and Y. Xiong. Super-resolution through neighbor embedding. in Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on. 2004. IEEE.
- [37] Suetake, N., M. Sakano, and E.J.O.r. Uchino, Image super-resolution based on local self-similarity. 2008. 15(1): p. 30-26.

- [38] Gong, M., et al., Single color image super-resolution through neighbor embedding. ٢٠١١. ٧(١): p. ٥٦-٤٩
- [39] Dang, C.T., et al. Single image super resolution via manifold linear approximation using sparse subspace clustering. in Global Conference on Signal and Information Processing (GlobalSIP), ٢٠١٢IEEE. ٢٠١٢ IEEE.
- [40] Dang, C., M. Aghagolzadeh, and H.J.I.S.P.L. Radha, Image super-resolution via local self-learning manifold approximation. ٢٠١٤. ٢١(١٠): p. ١٢٤٩-١٢٤٥
- [41] Dang, C. and H. Radha. Fast image super-resolution via selective manifold learning of high-resolution patches. in Image Processing (ICIP), ٢٠١٥IEEE International Conference on. ٢٠١٥. IEEE.
- [42] Elhamifar, E. and R. Vidal. Sparse subspace clustering. in Computer Vision and Pattern Recognition, ٢٠٠٩. CVPR ٢٠٠٩. IEEE Conference on. ٢٠٠٩. IEEE.
- [43] Purkait, P. and B. Chanda. Fuzzy-rule based approach for single frame super resolution. in Fuzzy Systems (FUZZ), ٢٠١٢IEEE International Conference on. ٢٠١٢. IEEE.
- [44] Yang, M.-C., C.-T. Chu, and Y.-C.F. Wang. Learning sparse image representation with support vector regression for single-image super-resolution. in Image Processing (ICIP), ١٧ ٢٠١٠th IEEE International Conference on. ٢٠١٠. IEEE.
- [45] Jianchao, Y., et al. Image super-resolution as sparse representation of raw image patches. in Proc. IEEE Conf. on Computer Vision and Pattern Recognition. ٢٠٠٨
- [46] Yang, J., et al., Image super-resolution via sparse representation. ٢٠١٠. ١٩(١١): p. ٢٨٧٣-٢٨٦١
- [47] Wu, W., et al., Learning-based super resolution using kernel partial least squares. ٢٠١١. : (٦) ٢٩p. ٤٠٦-٣٩٤
- [48] Zeyde, R., M. Elad, and M. Protter. On single image scale-up using sparse-representations. in International conference on curves and surfaces. ٢٠١٠. Springer.
- [49] Zhang, H., Y. Zhang, and T.S. Huang. Efficient sparse representation based image super resolution via dual dictionary learning. in Multimedia and Expo (ICME), ٢٠١١ IEEE International Conference on. ٢٠١١. IEEE.
- [50] Tang, Y., et al. Single-image super-resolution based on semi-supervised learning. in Pattern Recognition (ACPR) ٢٠١١, First Asian Conference on. ٢٠١١. IEEE.
- [51] Yang, M.-C. and Y.-C.F.J.I.T.o.m. Wang, A self-learning approach to single image super-resolution. ٢٠١٣. ١٥(٣): p. ٥٠٨-٤٩٨
- [52] Aharon, M., M. Elad, and A.J.I.T.o.s.p. Bruckstein, K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation. ٢٠٠٦. ٥٤(١١): p. ٤٣١١
- [53] Dang, C.T. and H. Radha, Heterogeneity image patch index and its application to consumer video summarization. IEEE Transactions on Image Processing, ٢٠١٤. ٢٣(٦): p. ٢٧١٨-٢٧٠٤
- [54] Suetake, N., M. Sakano, and E. Uchino, Image super-resolution based on local self-similarity. Optical review, ٢٠٠٨. ١٥(١): p. ٣٠-٢٦
- [55] Dong, W., et al., Nonlocally centralized sparse representation for image restoration. IEEE Transactions on Image Processing, ٢٠١٣. ٢٢(٤): p. ١٦٣٠-١٦٢٠
- [56] Pan, Z., et al., Super-resolution based on compressive sensing and structural self-similarity for remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, ٢٠١٣. ٥١(٩): p. ٤٨٧٦-٤٨٦٤

- [57] Tsai, R.Y. and T.S.J.C.S.L.R.n.U.-E.-, Huang, R-⁹², Uniqueness and estimation of three-dimensional motion parameters of rigid objects with curved surfaces. .⁹⁸
- [58] Kim, S., et al., Recursive reconstruction of high resolution image from noisy undersampled multiframe. ⁹⁹. 38(7): p. .1027-1033
- [59] Tekalp, A.M., M.K. Ozkan, and M.I. Sezan. High-resolution image reconstruction from lower-resolution image sequences and space-varying image restoration. in Acoustics, Speech, and Signal Processing, ⁹⁹. ICASSP-⁹⁹., ⁹⁹IEEE International Conference on. ⁹⁹. IEEE.
- [60] Rhee, S. and M.G. Kang. DCT-based regularized algorithm for high-resolution image reconstruction. in Image Processing, ⁹⁹. ICIP ⁹⁹. Proceedings. ⁹⁹International Conference on. ⁹⁹. IEEE.
- [61] Tom, B.C. and A.K. Katsaggelos. Reconstruction of a high-resolution image by simultaneous registration, restoration, and interpolation of low-resolution images. in icip. ⁹⁹. IEEE.
- [62] Tom, B.C., A.K. Katsaggelos, and N.P. Galatsanos. Reconstruction of a high resolution image from registration and restoration of low resolution images. in Image Processing, ⁹⁹. Proceedings. ICIP-⁹⁹., IEEE International Conference. ⁹⁹. IEEE.
- [63] Cheeseman, P., et al., Super-resolved surface reconstruction from multiple images, in Maximum Entropy and Bayesian Methods. ⁹⁹, Springer. p. .308-313
- [64] Chung, J., E. Haber, and J.J.I.P. Nagy, Numerical methods for coupled super-resolution. ⁰⁰. 22(2): p. .1271
- [65] Irani, M. and S. Peleg, Improving resolution by image registration. CVGIP: Graphical models and image processing, ⁹⁹. 53(3): p. .239-251
- [66] Peleg, S., D. Keren, and L. Schweitzer, Improving image resolution using subpixel motion. Pattern recognition letters, ⁹⁹. 5(3): p. .226-223
- [67] Protter, M., et al .,Generalizing the nonlocal-means to super-resolution reconstruction. ⁰⁰. 18(1): p. .51-37
- [68] Lee, E.S. and M.G.J.I.T.o.I.P. Kang, Regularized adaptive high-resolution image reconstruction considering inaccurate subpixel registration. ⁰⁰. 12(7): p. .837-846
- [69] He, H. and L.P.J.I.T.o.I.P. Kondi, An image super-resolution algorithm for different error levels per frame. ⁰⁰. 10(3): p. .602-592
- [70] Park, M.K., M.-G. Kang, and A.K.J.O.E. Katsaggelos, Regularized high-resolution image reconstruction considering inaccurate motion information. ⁰⁰. 26(11): p. .117004
- [71] Shankar, P.M. and M.A.J.J.A. Neifeld, Sparsity constrained regularization for multiframe image restoration. ⁰⁰. 20(5): p. .1214-1199
- [72] Ng, M.K., et al., A total variation regularization based super-resolution reconstruction algorithm for digital video. ⁰⁰. 2007(1): p. .074580
- [73] Farsiu, S., et al., Fast and robust multiframe super resolution. ⁰⁰. 13(10): p. -1327 .1344
- [74] Patanavijit, V. and S. Jitapunkul. A robust iterative multiframe super-resolution reconstruction using a Huber Bayesian approach with Huber-Tikhonov regularization. in Intelligent Signal Processing and Communications, ⁰⁰. ISPACS'06. International Symposium on. ⁰⁰. IEEE.

- [75] Zibetti, M.V.W., J.J.I.T.o.C. Mayer, and S.f.V. Technology, A robust and computationally efficient simultaneous super-resolution scheme for image sequences. ٢٠٠٧. ١٧(١٠): p. .١٣٠٠-١٣٨٨
- [76] Chantas, G.K., N.P. Galatsanos, and N.A.J.I.T.o.I.P. Woods, Super-resolution based on fast registration and maximum a posteriori reconstruction. ٢٠٠٧. ١٦(٧): p. -١٨٢١ .١٨٣٠
- [77] Patanavijit, V. and S.J.E.J.o.A.i.S.P. Jitapunkul, A Lorentzian stochastic estimation for a robust iterative multiframe super-resolution reconstruction with Lorentzian-Tikhonov regularization. ٢٠٠٧. ٢٠٠٧(٢): p. .٢١-٢١
- [87] Pickup, L.C., S.J. Roberts, and A. Zisserman. Optimizing and Learning for Super-resolution. in BMVC. ٢٠٠٦. Citeseer.
- [79] Li, Y.-R., et al., Multiframe super-resolution reconstruction using sparse directional regularization. ٢٠١٠. ٢٠(٧): p. .٩٥٦-٩٤٥
- [80] Zhang, X. and E.Y. Lam, Superresolution reconstruction using nonlinear gradient-based regularization. Multidimensional Systems and Signal Processing, ٢٠٠٩. ٢٠(٤): p. .٣٨٤-٣٧٥
- [81] Zhang, L., et al., A super-resolution reconstruction algorithm for surveillance images. Signal Processing, ٢٠١٠. ٩٠(٣): p. .٨٥٩-٨٤٨
- [82] Li, X., et al., A multi-frame image super-resolution method. Signal Processing, ٢٠١٠. ٩٠(٢): p. .٤١٤-٤٠٥
- [83] Omer, O.A. and T. Tanaka, Region-based weighted-norm with adaptive regularization for resolution enhancement. Digital Signal Processing, ٢٠١١. ٢١(٤): p. .٥١٦-٥٠٨
- [84] Park, S.C., M.K. Park, and M.G. Kang, Super-resolution image reconstruction: a technical overview. IEEE signal processing magazine, :(٣)٢٠.٢٠٠٣p. .٣٦-٢١
- [85] Lee, E.S. and M.G. Kang, Regularized adaptive high-resolution image reconstruction considering inaccurate subpixel registration. IEEE Transactions on Image Processing, ٢٠٠٣. ١٢(٧): p. .٨٣٧-٨٢٦
- [86] He, H. and L.P. Kondi, An image super-resolution algorithm for different error levels per frame. IEEE Transactions on Image Processing, ٢٠٠٦. ١٥(٣): p. .٦٠٣-٥٩٢
- [87] Park, M.K., M.-G. Kang, and A.K. Katsaggelos, Regularized high-resolution image reconstruction considering inaccurate motion information. Optical Engineering, ٢٠٠٧. ٤٦(١١): p. .١١٧٠٠٤
- [88] Shankar, P.M. and M.A. Neifeld, Sparsity constrained regularization for multiframe image restoration. JOSA A, ٢٠٠٨. ٢٥(٥): p. .١٢١٤-١١٩٩
- [89] Ng, M.K., et al., A total variation regularization based super-resolution reconstruction algorithm for digital video. EURASIP Journal on Advances in Signal Processing, ٢٠٠٧. ٢٠٠٧(١): p. .٠٧٤٥٨٥
- [90] Farsiu, S., et al., Fast and robust multiframe super resolution. IEEE transactions on image processing, :(١٠)١٣.٢٠٠٤p. .١٣٤٤-١٣٢٧
- [91] Patanavijit, V. and S. Jitapunkul, A Lorentzian stochastic estimation for a robust iterative multiframe super-resolution reconstruction with Lorentzian-Tikhonov regularization. EURASIP Journal on Advances in Signal Processing, ٢٠٠٧. ٢٠٠٧(٢): p. .٢١-٢١

- [92] El-Yamany, N.A. and P.E. Papamichalis. An adaptive M-estimation framework for robust image super resolution without regularization. in Visual Communications and Image Processing 2008. 2008. International Society for Optics and Photonics.
- [93] Pham, T.Q., L. v Vliet, and K. Schutte. Robust super-resolution by minimizing a gaussian-weighted l_1 error norm. in Journal of Physics: Conference Series. 2008. IOP Publishing.
- [94] El-Yamany, N. and P. Papamichalis, Robust color image superresolution: An adaptive M-estimation framework. EURASIP Journal on Image and Video Processing, 2008. 2008(1): p. 173204
- [95] Gharavi-Alkhansari, M. and T.S. Huang. A fast orthogonal matching pursuit algorithm. in Acoustics, Speech and Signal Processing, 1998. Proceedings of the 1998 IEEE International Conference on. 1998. IEEE.
- [96] Liu, E. and V.N. Temlyakov, The orthogonal super greedy algorithm and applications in compressed sensing. IEEE Transactions on Information Theory, 2012. 58(4): p. 2040.
- [97] Zhang, Z., et al., A survey of sparse representation: algorithms and applications. IEEE access, 2015. 3: p. 530-540.
- [98] Mairal, J., et al. Online dictionary learning for sparse coding. in Proceedings of the 26th annual international conference on machine learning. 2009. ACM.
- [99] Mairal, J., et al., Online learning for matrix factorization and sparse coding. Journal of Machine Learning Research, 2010. 11(Jan): p. 60-100
- [100] Sun, J., et al. Image hallucination with primal sketch priors. in Computer Vision and Pattern Recognition, 2009. Proceedings. 2009 IEEE Computer Society Conference on. 2009. IEEE.
- [101] Vapnik, V., Pattern recognition using generalized portrait method. Automation and remote control, 1963. 24: p. 180-184
- [102] Vapnik, V., A note one class of perceptrons. Automation and remote control, 1964
- [103] Vapnik, V.N. and A.J. Chervonenkis, Theory of pattern recognition. 1974
- [104] Smola, A.J. and B. Schölkopf, A tutorial on support vector regression. Statistics and computing, 2004. 14(3): p. 199-211
- [105] Burges, C.J., A tutorial on support vector machines for pattern recognition. Data mining and knowledge discovery, 1998. 2(2): p. 115-121
- [106] Müller, K.-R., et al. Predicting time series with support vector machines. in International Conference on Artificial Neural Networks. 1999. Springer.
- [107] Stitson, M., et al., Support vector regression with ANOVA decomposition kernels. Advances in kernel methods—Support vector learning, 1999: p. 292-280
- [108] Drucker, H., et al. Support vector regression machines. in Advances in neural information processing systems. 1999
- [109] Mattera, D. and S. Haykin. Support vector machines for dynamic reconstruction of a chaotic system. in Advances in kernel methods. 1999. MIT Press.
- [110] Cristianini, N. and J. Shawe-Taylor, An introduction to support vector machines and other kernel-based learning methods. 2000: Cambridge university press.
- [111] Herbrich, R., Learning kernel classifiers: theory and algorithms. 2001: Mit Press.
- [112] Vapnik, V., The nature of statistical learning theory. 2013: Springer science & business media.

- [113] Cortes, C. and V. Vapnik, Support-vector networks. Machine learning, ۱۹۹۵. ۲۰(۳): p. ۲۹۷-۲۷۳
- [114] Chang, C.-C. and C.-J. Lin, LIBSVM: a library for support vector machines. ACM transactions on intelligent systems and technology (TIST), ۲۰۱۱. ۲(۳): p. ۲۷
- [115] Nock, R. and F. Nielsen, Statistical region merging. IEEE Transactions on pattern analysis and machine intelligence, ۲۰۰۴. ۲۶(۱۱): p. ۱۴۵۸-۱۴۵۲
- [116] Bevilacqua, M., et al., Single-image super-resolution via linear mapping of interpolated self-examples. IEEE Transactions on image processing, ۲۰۱۴. ۲۳(۱۲): p. ۵۳۴۷-۵۳۳۴
- [117] Dong, C., et al., Image super-resolution using deep convolutional networks. IEEE transactions on pattern analysis and machine intelligence, ۲۰۱۶. ۳۸(۲): p. ۳۰۷-۲۹۵
- [118] Kim, J., J. Kwon Lee, and K. Mu Lee. Deeply-recursive convolutional network for image super-resolution. in Proceedings of the IEEE conference on computer vision and pattern recognition. ۲۰۱۶
- [119] Dong, C., et al. Learning a deep convolutional network for image super-resolution. in European conference on computer vision. ۲۰۱۴. Springer.
- [120] Wang, Z., et al. Deeply improved sparse coding for image super-resolution. in ICCV.

[۱۲۱] صادقی، م، (۱۳۹۱)، پایان‌نامه ارشد: "نمایش تنک و کاربرد آن در نویززدایی تصاویر"، دانشکده مهندسی برق، دانشگاه صنعتی شریف.

[۱۲۲] رشید ع، شریفی ح، (۱۳۹۲)، پایان‌نامه ارشد: "نمایش تنک و کاربرد آن در نویز زدایی سیگنال رفتار"، دانشکده مهندسی برق، دانشگاه شهید بهشتی.

[۱۲۳] طاهری ا.م، مهدوی‌نسب ه، (۱۳۹۶)، "ارائه یک روش جدید فشرده‌سازی تصاویر چهره با استفاده از نمایش تنک سیگنال و الگوریتم یادگیری دیکشنری"، **مجله مهندسی مخابرات**، سال هفتم، شماره ۲۴، ص ۳۴-۴۸.

[۱۲۴] حبیبی م، احمدی‌فرد ع، حسن‌پورح، (۱۳۹۵) "افزایش وضوح تک تصویری با در نظر گرفتن بخش های مجاور بازسازی شده"، کنفرانس بین المللی مهندسی کامپیوتر و فناوری اطلاعات، تهران.

[۱۲۵] حبیبی م، احمدی‌فرد ع، حسن‌پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با در نظر گرفتن سازگاری در همسایگی پیکسل ها و استفاده از روش خودیادگیرنده"، **نشریه مهندسی برق و**

مهندسی کامپیوتر ایران، سال ۱۶، شماره ۲، ص ۱۵۷.

[۱۲۶] حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۵) "افزایش تفکیک پذیری تک تصویری با استفاده از تقریب منیفلد و "k-means، پنجمین کنفرانس بین المللی مهندسی کامپیوتر، برق و الکترونیک، بهار ۱۳۹۵، تهران.

[۱۲۷] حبیبی م، احمدی فرد ع، حسن پور ح، (۱۳۹۷) "افزایش تفکیک پذیری تک تصویری با یادگیری از نواحی استخراج شده تصویر ورودی"، مجله بینایی ماشین و پردازش تصویر، در حال انتشار.

Abstract

Super Resolution (SR) has been an active research topic in image processing. Due to the limitations and cost of high quality imaging systems, in many situations an affordable imaging system is used, instead using signal processing techniques the quality of captured image is improved. These techniques are specifically referred as Super-Resolution (SR) reconstruction.

In this dissertation, we focus on self-learning approach for super resolution. Self-learning super-resolution methods utilize only input image for constructing a collection of training low and high-resolution image data. The goal of these methods is to estimate missing high-resolution details using information obtained from relationship between low and high-resolution pyramids that are constructed by input image. The images in the high-resolution pyramid are constructed using two steps down-sampling of the input image. The image at each level of the high-resolution pyramid is then up-sampled to construct the image at upper level in the low resolution pyramid. The relationship between low and corresponding high-resolution patches is modeled using support vector regression (SVR). Sparse representation and first-second order gradients are used as feature of each patches. We use sparse representation and first-order and second order gradients as feature of image patches.

Using preserving adjacent information, and information of previous reconstruction are more attention in this dissertation. By considering adjacent pixels in non- smooth regions, the details of the image are removed. So, this method is useful for smooth regions in each images. To solve this problem, we introduce two methods based on smooth and non-smooth regions. Two algorithms are presented based on edge and non-edge pixels, separately. Applying one SR method on different texture images will result blurring and smoothing image. For this purpose, in this dissertation, content-based image super resolution is introduced. Unlike existing methods, the images in the low-resolution pyramid are segmented and then used for the process of super-resolution. Another way to content-based SR is to use sparse representation, neighborhood graph and clustering algorithms. For this purpose, k-means is used to cluster the data points before creating the similarity graph and data duplicate removal. Finally, the proposed methods in this dissertation are compared with several SR approaches, qualitatively and quantitatively.

Keywords: image super-resolution, self-learning, sparse representation, support vector machine (SVR), image segmentation, sparse space clustering (SSC).



Shahrood University of
Technology

Faculty of Computer Engineering

Ph.D. Thesis in Artificial Intelligence Engineering

Single Image Super Resolution using self learning considering consistency in a local neighborhood

By: Maliheh Habibi

Supervisor:
Dr. Alireza Ahmadyfard

Advisor:
Dr. Hamid Hassanpour

April 2019