

افزایش تفکیک پذیری تک تصویری با یادگیری از نواحی قطعه‌بندی شده

تصویر ورودی

ملیحه حبیبی^۱، علیرضا احمدی فرد^۲ و حمید حسن پور^۳

چکیده

در این مقاله، یک روش جدید خودیادگیرنده برای افزایش تفکیک پذیری تک تصویر ارائه شده است. در این روش، از تصویر ورودی، دو هرم وضوح پایین و وضوح بالا ساخته می‌شود. رابطه بین وصله‌های هرم وضوح پایین و روشنایی متناظر وصله‌ها در تصویر هم سطح از هرم وضوح بالا توسط رگرسیون بردار پشتیبان یادگیری می‌شود. برای ایجاد تخمین بهتری از روشنایی وضوح بالا، تصاویر دو هرم را براساس رنگ ناحیه بندی می‌کنیم و مدل‌های رگرسیونی را برای هر ناحیه بطور مجزا آموزش می‌دهیم. از طرفی برای کاهش اثر تاری در لبه‌های تصویر فراتفکیک شده، مدل‌های جداگانه‌ای برای یادگیری روشنایی لبه‌ها ارائه شده است. ویژگی‌های بکار رفته در یادگیری رگرسیون بردار پشتیبان، ضرایب تُنک وصله‌ها در بازنمایی تُنک و گرادیان وصله‌ها می‌باشد. برای هر یک از ویژگی‌های اشاره شده مدل‌های رگرسیون مجزایی آموزش داده می‌شود و خطای این مدل‌ها نیز به کمک رگرسیون بردار پشتیبان مدل می‌گردد. در هنگام بازسازی تصویر فراتفکیک شده، هر وصله‌ی تصویر در بالاترین سطح هرم وضوح پایین به مدل‌های رگرسیونی داده شده و مدلی که کمترین خطا را در تخمین مقدار روشنایی ایجاد کند مشخص می‌گردد. روشنایی مرکز هر وصله را مدل برنده شده تعیین می‌کند. نتایج آزمایشات نشان می‌دهد که روش پیشنهادی نسبت به سایر روش‌ها با توجه به معیار PSNR و SSIM تخمین بهتری از تصویر فراتفکیک شده ایجاد می‌کند. مشاهده بصری نتایج نیز این ادعا را تایید می‌نماید.

کلیدواژه‌ها

فراتفکیک‌پذیری تک تصویر، ناحیه‌بندی تصویر، بازنمایی تُنک، رگرسیون بردار پشتیبان

تحقیق در پردازش تصویر، بهبود کیفیت بصری تصویر است. از رویکردهای بهبود کیفیت تصویر می‌توان حذف نویز تصویر، حذف تاری از تصویر، کالیبراسیون تصویر و افزایش تفکیک پذیری تصویر^۱ (SR) را نام برد. در این مقاله، افزایش تفکیک پذیری تصویر مورد مطالعه قرار گرفته است. هدف اصلی افزایش تفکیک پذیری تصویر، تخمین جزییات وضوح بالای از دست رفته در فرایند تصویر برداری است که این امر به کمک یک یا چند فریم تصویر وضوح پایین از صحنه انجام می‌شود.

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

۱ مقدمه

امروزه، پردازش تصویر از تکنولوژی‌های درحال رشد در زمینه‌ی مهندسی و علوم کامپیوتر می‌باشد. یکی از مهم‌ترین زمینه‌های این مقاله در شهریورماه سال ۹۷ دریافت، در دی‌ماه بازنگری و در بهمن‌ماه همان سال پذیرفته شد.

^۱ دانشجوی دکتری مهندسی کامپیوتر گرایش هوش مصنوعی دانشگاه صنعتی شاهرود

رایانامه: habibi.malihe@gmail.com

^۲ دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود

رایانامه: alireza.ahmadyard@gmail.com

^۳ دانشکده مهندسی برق، دانشگاه صنعتی شاهرود

رایانامه: ahmadyard@shahroodut.ac.ir

www.SID.ir

نویسنده مسئول: ملیحه حبیبی

¹ Super Resolution(SR)

Archive of SID

وضوح پایین وجود ندارد، اجزای فرکانس بالای اژدست رفته در تصویر ورودی بطور رضایت بخشی بهبود می‌یابد. در [۴] به جای جستجو برای پیدا کردن وصله‌های مشابه، مدل‌سازی ارتباط بین وصله‌های وضوح پایین و وضوح بالای متناظر در هر سطح هرم با استفاده از رگرسیون بردار پشتیبان^۴ مدل‌سازی می‌شود. تفاوت مرجع [۵] با [۴] در این است که در [۵] پایگاه‌داده‌ای از تصاویر وضوح بالا و پائین مرتبط برای آموزش مورد استفاده قرار می‌گیرد در حالی که در [۴] تنها از تصویر ورودی استفاده شده است.

در تحقیقات معدودی نیز در زمینه افزایش تفکیک پذیری تصویر، از روش‌های یادگیری عمیق^۵ استفاده شده است [۶] تا [۹]. در مراجع [۶] تا [۹]، برای نگاشت بین تصاویر وضوح بالا و وضوح پایین متناظر از یک شبکه عصبی کانولوشن عمیق^۶ استفاده شده است. در مقالات متعددی در رابطه با افزایش تفکیک پذیری تک تصویر، از تشابه موجود مابین وصله‌های تصویر در تصویر ورودی وضوح پایین و یا در تصاویر ایجاد شده از تصویر ورودی استفاده شده است [۳] و [۱۰]. بکارگیری تنها تشابه مابین وصله‌ها در اندازه‌های مختلف تصویر ورودی و سپس اعمال محدودیت‌های ساختاری گروهی بر وصله‌های مشابه در مرجع [۳] مطرح شده است. در [۱۰]، از هر دو نوع تشابه مابین وصله‌ها (تشابه در تصویر ورودی و یا تشابه در اندازه‌های مختلف تصویر ورودی) استفاده شده است. در صورت وجود تشابه در تصویر ورودی از افزایش تفکیک پذیری کلاسیک و در صورت وجود تشابه در تصاویر ایجاد شده از تصویر ورودی، روش افزایش تفکیک پذیری مبتنی بر نمونه بکار گرفته می‌شود.

یکی از موفق‌ترین روش‌های مبتنی بر یادگیری، رویکرد مبتنی بر بازنمایی^۷ تنگ^۷ است [۱۱]. در برخی مقالات ضرایب تنگ هر وصله بعنوان بردار ویژگی آن وصله در نظر گرفته می‌شود [۴]، [۱۲] و [۱۳]. در [۱۲] و [۱۳]، دو دیکشنری خارجی مجزا برای تصاویر وضوح بالا و وضوح پایین استفاده می‌شود. در این مراجع، با تغییر ضریب افزایش تفکیک پذیری تصویر، نیاز به آموزش مجدد دیکشنری‌ها است. در [۳]، ضرایب تنگ به عنوان ویژگی هر وصله‌ی وضوح پایین تعریف می‌شود. ژانگ و همکارانش، یک روش افزایش تفکیک پذیری تصویر مبتنی بر نمایش تنگ^۷ را پیشنهاد داده‌اند که برای کاهش پیچیدگی محاسباتی از آموزش یک دیکشنری دوگانه و جایگزینی مرحله‌ی استخراج ضرایب تنگ^۷ با ضرب ساده ماتریس استفاده کرده‌اند [۱۴].

بیش‌ترین تاکید نویسندگان مرجع [۱۵] بر عدم کفایت تنها استفاده از اطلاعات وصله‌های تصویر برای ایجاد تصویری با وضوح بالا است. آن‌ها معتقدند که باید به اطلاعات وصله‌های

تقسیم می‌شوند. افزایش تفکیک پذیری تک تصویر، مساله تخمین تصویر وضوح بالا از تنها یک تصویر وضوح پایین ورودی است. در این فرایند رابطه تصویر وضوح پایین ورودی و تصویر وضوح بالای نتیجه، بصورت رابطه ۱ مدل می‌شود [۱]:

$$L = (H * b) \downarrow_s \quad (1)$$

در رابطه ۱، L و H به ترتیب تصویر وضوح پایین و وضوح بالا و b هسته تارکننده‌ای است که فرایند تصویر برداری را مدل می‌کند. هسته تارکننده معمولاً بصورت تابع گوسی مدل می‌شود [۲] و \downarrow_s یک عملگر کاهش نرخ نمونه‌برداری با ضریب کاهش s است. بنابراین، با توجه به رابطه ۱، تصویر وضوح پایین بر اثر تار شدن و کاهش نرخ نمونه‌برداری از تصویر وضوح بالا بدست می‌آید.

الگوریتم‌های افزایش تفکیک پذیری تک تصویر می‌توانند به دو دسته‌ی افزایش تفکیک پذیری مبتنی بر درون‌یابی و مبتنی بر یادگیری تقسیم شوند. روش‌های درون‌یابی مانند درون‌یاب نزدیک‌ترین همسایه، درون‌یاب دو خطی و درون‌یاب دو مکعبی 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 تار شدن تصویر بخصوص در لبه‌ها و جزئیات تصویر می‌شوند.

در سال‌های اخیر به روش‌های افزایش تفکیک پذیری تصویر مبتنی بر یادگیری توجه بسیاری شده است. در این گونه 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 وضوح پایین و وضوح بالای مرتبط با آن است، تمرکز روش‌های مبتنی بر یادگیری بیش‌تر بر مدل‌سازی ارتباط بین تصاویر با وضوح‌های مختلف می‌باشد. در این راهکار، برای بازسازی تصاویر با وضوح بالا، فرض بر این است که اطلاعات فرکانس‌های بالای تصاویر از بین رفته و با کمک مجموعه داده‌های آموزشی، می‌توان مقادیر بخشی از این اطلاعات را پیش‌بینی کرد. روش‌های افزایش تفکیک پذیری مبتنی بر یادگیری نیز می‌توانند براساس اینکه از پایگاه تصاویر خارجی استفاده می‌کنند و یا فقط از اطلاعات خود تصویر ورودی استفاده می‌نمایند، در دو دسته‌ی روش‌های مبتنی بر مثالها و روش‌های خودیادگیرنده^۲ قرار گیرند.

فرض اساسی روش‌های افزایش تفکیک پذیری خودیادگیرنده این است که تعداد بسیاری از وصله‌های^۳ مشابه در تصویر وضوح پایین و با اندازه‌های متفاوت ایجاد شده از تصویر وضوح پایین وجود دارد. بنابراین در این رویکرد، از تشابه مابین وصله‌های مختلف تصویر ورودی و یا وصله‌های موجود در اندازه‌های مختلف آن با ایجاد یک هرم، استفاده می‌شود [۳]. در این روش‌ها، علیرغم این واقعیت که پایگاه‌داده‌ای از تصاویر وضوح بالا و

⁴ Support Vector Regression (SVR)

⁵ Deep Learning

⁶ Deep Convolutional Neural Network (DCNN)

⁷ Sparse Representation

² Self-Learning

³ Patches

وضوح پایین و وضوح بالا، استخراج ویژگی، فاز آموزش و فاز آزمون به تفکیک وصله های با مرکزیت لبه و غیر لبه آورده شده است. نتایج پیاده سازی روش پیشنهادی و مقایسه آن با سایر روش های مطرح در زمینه ی افزایش تفکیک پذیری تصویر، با استفاده از دو معیار PSNR و SSIM، در بخش ۵ نشان داده می شود. در نهایت، مقاله در بخش ۶ به نتیجه گیری می انجامد.

۲ ساخت هرم های وضوح بالا و وضوح پایین و ناحیه بندی تصاویر هرم وضوح پایین

روش پیشنهادی دارای فاز آموزش و فاز آزمون می باشد. در فاز آموزش، ابتدا هرم تصویر ورودی با کاهش تدریجی ابعاد تصویر ورودی با نرخ s در دو مرحله ساخته می شود. اگر تصویر ورودی را I_0 بنامیم، تصاویر هرم در سطوح پایین تر I_{-1} و I_{-2} نامیده می شوند. هرم تصویر بدست آمده را هرم وضوح بالا می نامیم. در سطح بالای این هرم، به دنبال ساختن تصویر I_{+1} هستیم که ابعاد آن برابر ابعاد تصویر ورودی است.

برای مدل سازی رابطه بین تصاویر وضوح بالا و وضوح پایین، هرم دیگری از تصاویر ساخته می شود که آنرا هرم وضوح پایین می نامیم. برای ساخت تصویر در بالاترین سطح این هرم، تصویر ورودی، I_0 ، را با استفاده از الگوریتم درونیابی دوکعبی به نسبت s افزایش ابعاد می دهیم و تصویر نتیجه را I_{+1} می نامیم. این تصویر به لحاظ ابعاد هم سطح تصویری است که در فرایند فراتفکیک پذیری می خواهیم بدست آوریم ولی همانطوریکه ذکر شد نتیجه الگوریتم درونیابی، جزییات و لبه های تصویر را مات می نماید. برای ساخت تصاویر سایر سطوح هرم وضوح پایین به همین ترتیب عمل می نماییم. بعنوان مثال، برای ساخت تصویر I_{-1} ، تصویر I_{-2} از هرم وضوح بالا را به کمک الگوریتم درونیابی دوکعبی به نسبت s افزایش ابعاد می دهیم.

برای ساماندهی وصله ها در تصاویر هرم وضوح پایین، تصویر پایین ترین سطح هرم، I_{-2} ، را با در نظر گرفتن اطلاعات رنگ و روشنایی به کمک روش مرجع [۲۰] ناحیه بندی می کنیم و تصویر نتیجه را 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 وضوح 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 ۱، هرم تصویر Lena پس از ناحیه بندی نشان داده شده است.

مجاور برای تولید تصویر خروجی توجه شود. در [۱۶ و ۱۷] از تقریب منیفلد^۸ برای مدل سازی ارتباط بین وصله های مجاور در فضای وضوح بالا و وضوح پایین استفاده شده است. در [۱۶]، الگوریتم تعبیه شده خطی محلی^۹ برای این منظور مورد استفاده قرار گرفته است.

در [۱۸] و [۱۹] از یک روش خودیادگیرنده برای افزایش فراتفکیک پذیری تصویر با در نظر گرفتن اطلاعات همسایگی پیکسل ها، استفاده شده است. در این مراجع، به این مساله که برای بازسازی پیکسل ها، تصویر از چپ به راست و از بالا به پایین پیمایش می شود و لذا مقادیر پیکسل های بالا و سمت چپ هر پیکسل از قبل تخمین زده شده است، توجه می شود. تفاوت این دو مرجع در نحوه استفاده از مقادیر پیکسل های بازسازی شده ی قبلی است. در [۱۸]، به ازای تمامی پیکسل های غیر لبه، اختلاف بین هر پیکسل و پیکسل های مرکزی وصله های بالا و سمت چپ آن، مدل می شود. پیکسل های غیر لبه بر اساس قرار گرفتن در نواحی یکنواخت و غیر یکنواخت به دو گروه تقسیم شده و سپس در [۱۹] برای نواحی یکنواخت از مقادیر پیکسل های بازسازی شده ی قبلی استفاده می کند.

در این مقاله یک روش خود یادگیرنده برای افزایش تفکیک پذیری تصویر ورودی پیشنهاد می گردد. اغلب روش های مطرح در زمینه ی افزایش تفکیک پذیری تک تصویری، از هرم تصویر ورودی برای تخمین تصویر وضوح بالا استفاده می کنند. در برخی مقالات، صرفاً اطلاعات وصله های هر سطح هرم (نه تشابه وصله ها)، بطور جداگانه مورد استفاده قرار گرفته است [۴]. 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 [۱۲] و [۱۳].

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 وضوح بالا می باشد. ایده ی اصلی این مقاله، این است که بجای ساختن یک دیکشنری برای تمام وصله های تصویر ورودی، که بسیاری از این وصله ها نامتشابه هستند، پس از ناحیه بندی تصویر در پایین ترین سطح هرم، به ازای هر ناحیه، دیکشنری جداگانه ای بسازیم و از هر دیکشنری برای مدل سازی وصله های همان ناحیه استفاده نماییم. همانطوریکه نتایج نشان می دهد این ایده خطای مدل سازی را کاهش داده و تخمین تصویر وضوح بالا را بهبود می بخشد. علاوه بر این، ما فرایند جداگانه ای برای یادگیری وصله های با مرکزیت لبه و غیر لبه ارائه می نماییم. چرا که این وصله ها ماهیت متفاوتی دارند.

در ادامه، این مقاله بدین صورت سازماندهی می شود. در بخش های ۲ تا ۴ جزییات روش پیشنهادی از قبیل ساخت دو هرم

⁸Manifold Approximation

⁹ Locally Linear Embedding (LLE)

Archive of SID

که هر وصله دیگر را می‌توان از ترکیب خطی وصله‌های پایه موجود در دیکشنری بازسازی کرد. فرض کنید $D \in \mathbb{R}^{Q \times K}$ ، یک دیکشنری فوق کامل با K عنصر (وصله) و اندازه‌ی هر عنصر (وصله) Q ، باشد. برای استخراج ضرایب α_i و وصله‌ی i معنی $p_{e_i} \in \mathbb{R}^Q$ نیاز به حل مساله بهینه‌سازی رابطه ۲ است [۱۲].

$$\min \frac{1}{2} \|D\alpha_i - p_{e_i}\|_2^2 + \lambda \|\alpha_i\|_1 \quad (2)$$

در رابطه ۲، D ، یک دیکشنری فوق کامل از وصله‌های مجموعه P_E ، یک عضو مجموعه P_E ، λ ، ضریب لاگرانژ برای ایجاد تعادل مابین میزان تنگ بودن (صفر بودن) ضرایب و مقدار خطای موجود در بازسازی وصله است. $\alpha_i \in \mathbb{R}^K$ ، یک بردار با تعداد بسیار اندک ضریب غیر صفر است که بردار ضرایب تنگ (ویژگی) وصله‌ی p_{e_i} خوانده می‌شود.


در روش پیشنهادی، بردار حاصل از گرادیان‌های مرتبه اول و مرتبه دوم^{۱۱} پیکسل‌های هر وصله در مجموعه 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 [۱۶]. اگر $G(i, j)$ بردار ویژگی گرادیان‌های مرتبه اول و دوم در پیکسل (i, j) از تصویر I باشد، بردار گرادیان در این پیکسل، $I(i, j)$ ، مطابق رابطه ۳ محاسبه می‌شود [۱۶].

$$G(i, j) = \begin{bmatrix} I(i+1, j) - I(i-1, j) \\ I(i, j+1) - I(i, j-1) \\ I(i+2, j) - 2 \times I(i, j) + I(i-2, j) \\ I(i, j+2) - 2 \times I(i, j) + I(i, j-2) \end{bmatrix} \quad (3)$$

بردار گرادیان تعریف شده در رابطه ۳ شامل چهار عنصر است که به ازای هر پیکسل موجود در وصله محاسبه می‌شود. بنابراین، به ازای یک وصله با پیکسل، اندازه‌ی بردار ویژگی گرادیان وصله، $Q \times 4$ است.

همانگونه که اشاره شد، هر لبه در سطوح مختلف هرم وضوح پایین متناظر با یک وصله متناظر است که دو دسته ویژگی از آن استخراج می‌شود: ضرایب تنگ در بازنمایی وصله به کمک دیکشنری آموزش دیده و بردار گرادیان معرفی شده. در فرایند یادگیری بدنال آن هستیم تا رابطه‌ی بین ویژگی‌های استخراج شده از هر لبه (ضرایب تنگ و گرادیان) در هر سطح هرم وضوح پایین و روشنایی پیکسل متناظر در تصویر هم سطح آن در هرم وضوح بالا برقرار کنیم. برای این منظور از رگرسیون بردار پشتیبان مطابق مرجع [۲۱] استفاده می‌کنیم.

به کمک مدل یادگیری شده، تخمین مناسبی برای ارزش پیکسل‌ها در نسخه فراتفکیک شده بدست می‌آوریم. در این مقاله، برای یادگیری ارتباط بین ارزش پیکسل مرکزی تمامی وصله‌ی وضوح بالای متناظر با وصله‌های مجموعه‌ی ویژگی-



شکل ۱ هرم تصویر وضوح پایین برای تصویر lena پس از قطعه‌بندی (شروع قطعه‌بندی از تصویر I_{-2})

چنانچه ناحیه بندی بر روی تصویر بالاترین سطح هرم انجام می‌شد با تعمیم آن به سطوح پایین‌تر، برخی نواحی در پایین‌ترین سطح هرم از بین می‌رفتند بنابراین تعداد نواحی در سطوح مختلف هرم ثابت نمی‌ماند.

۳ فاز آموزش

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

۳-۱ آموزش پیکسل‌های لبه

ابتدا، پیکسل‌های لبه در تمامی سطوح هرم وضوح پایین استخراج می‌شوند. سپس، مجموعه‌ای از وصله‌ها به ابعاد با مرکزیت این پیکسل‌ها بدست می‌آید که روشنایی پیکسل‌های هر وصله بصورت یک بردار ستونی p_{e_i} نمایش داده شده و مجموعه حاصل بصورت $P_E = \{p_{e_1}, p_{e_2}, \dots, p_{e_N}\} \in \mathbb{R}^{Q \times N}$ ، تعداد وصله‌ها و Q ، تعداد پیکسل‌های هر وصله در نظر گرفته شده است. برای مدل سازی رابطه بین وصله‌ها از بازنمایی تنگ استفاده می‌نماییم. ویژگی‌های تنگ بدست آمده برای بازنمایی هر وصله بعنوان ویژگی وصله در فرایند یادگیری استفاده خواهد شد. برای بازنمایی تنگ وصله‌ها یک دیکشنری فوق کامل^{۱۰} از روی وصله‌های مجموعه P_E می‌بایست ساخته شود. دیکشنری فوق کامل شامل تعداد قابل توجهی وصله بعنوان وصله‌های پایه است

¹¹first-order and second-order gradients

¹⁰Over-complete Dictionary

Archive of SID

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

۳-۲ آموزش پیکسل‌های غیرلبه

همانطور که در ابتدای بخش ۳ بیان شد، تصاویر سطوح مختلف هرم وضوح پایین به تعداد یکسانی از نواحی، ناحیه بندی می‌شوند. پیکسل‌های هر ناحیه رنگ و روشنایی مشابهی دارند. این ناحیه بندی هم در فاز آموزش و هم در فاز آزمون پیکسل‌های غیرلبه مورد استفاده قرار می‌گیرد.

در فاز آموزش، پیکسل‌های غیرلبه در هر ناحیه از سطوح مختلف هرم تصویر در نظر گرفته می‌شود. سپس، وصله‌هایی به ابعاد $Q = q \times q$ با مرکزیت هر یک از پیکسل‌های غیرلبه از هر ناحیه گردآوری شده که آنرا مجموعه‌ی $P_{Neg,r} = \{p_{n_1}, p_{n_2}, \dots, p_{n_{M_r}}\} \in \mathbb{R}^{Q \times M_r}$ می‌نامیم. M_r مجموع وصله‌های ناحیه‌ی r ام در تمامی سطوح هرم می‌باشد. مطابق آنچه برای پیکسل‌های لبه در بخش ۳-۱ گفته شد، از هر وصله ضرایب α و بردار گرادینان مربوط به وصله با مرکزیت پیکسل غیر لبه استخراج می‌گردد. از روی ضرایب α و وصله‌ها و به کمک مدل رگرسیون بردار پشتیبان، رابطه بین وصله‌های وضوح پایین هر ناحیه و روشنایی پیکسل‌های متناظر در هرم وضوح بالا یادگیری می‌شود. بطور مشابه از روی بردار گرادینان وصله‌ها و به کمک مدل رگرسیون بردار پشتیبان، رابطه بین وصله‌های وضوح پایین هر ناحیه و روشنایی پیکسل‌های متناظر در هرم وضوح بالا یادگیری می‌شود. لذا برای هر ناحیه در هرم وضوح پایین دو مدل رگرسیونی یادگیری می‌شود. برای تخمین هر یک از مدل‌های یادگیری شده برای هر ناحیه، خطا در تخمین روشنایی به کمک رگرسیون بردار پشتیبان مدل سازی می‌شود. لذا برای هر ناحیه در هرم یک مدل مبتنی بر ضرایب α و برای هر یک از این مدل‌ها، خطای تخمین نیز مدل سازی می‌گردد [۴]. لذا برای ناحیه r مدل‌های تخمین روشنایی و خطای تخمین روشنایی به ازای بردارهای ضرایب α و گرادینان مطابق رابطه ۹، آموزش داده می‌شود:

$$\begin{aligned} \alpha^l(i, j) &\xrightarrow{SVR_{NE\alpha}} y^l(i, j) \\ \forall (i, j) \in Non_Edges, \quad l \in N_{PyramidLevels} \\ G^l(i, j) &\xrightarrow{SVR_{NEG}} y^l(i, j) \\ \forall (i, j) \in Non_Edges, \quad l \in N_{PyramidLevels} \end{aligned} \quad (9)$$

به کمک مدل‌های فوق برای هر ناحیه تخمین روشنایی پیکسل‌های داخل ناحیه صورت می‌گیرد:

$$\begin{aligned} \hat{y}_{NE\alpha}^l(i, j) &= SVR_{NE\alpha}(\alpha^l(i, j)) \\ \hat{y}_{NEG}^l(i, j) &= SVR_{NEG}(G^l(i, j)) \end{aligned} \quad (10)$$

برای یادگیری دو مدل خطای تخمین مدل‌های $SVR_{NE\alpha}$ و SVR_{NEG} ، از اختلاف مقدار ارزش پیکسل وضوح بالای واقعی در هرم وضوح بالا، $y^l(i, j)$ و مقادیر تخمین زده شده $\hat{y}_{NE\alpha}^l(i, j)$ و $\hat{y}_{NEG}^l(i, j)$ مطابق رابطه ۱۱، استفاده می‌شود.

های α و گرادینان وصله‌های مجموعه‌ی P_E ، از رگرسیون بردار پشتیبان مطابق با مرجع [۲۱] استفاده می‌کنیم.

رگرسیون بردار پشتیبان یک روش برگرفته از الگوریتم ماشین بردار پشتیبان است. در فاز یادگیری، بدنال بردار w که نرم تابع نگاشت غیر خطی مدل و b افست مدل، هستیم. برای رسیدن به این پارامترها رابطه ۴ با قید ۵ می‌بایست کمینه شود. در رابطه ۵، بردار ویژگی وصله i α و y_i ارزش پیکسل وضوح بالا متناظر با مرکز وصله i ام می‌باشد. برای جزییات بیشتر این الگوریتم به [۲۲] ارجاع می‌گردد.

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i, \xi_i^*) \quad (4)$$

$$\begin{aligned} y_i - \langle w, \alpha_i \rangle - b &\leq \varepsilon + \xi_i, \\ \langle w, \alpha_i \rangle + b - y_i &\leq \varepsilon + \xi_i^*, \\ \xi_i, \xi_i^* &\geq 0, \quad i = 1, \dots, n. \end{aligned} \quad (5)$$

بنابراین، پس از استخراج ضرایب α و بردار گرادینان مرتبه اول و دوم، با استفاده از الگوریتم SVR دو مدل آموزش داده می‌شود. یک مدل براساس ضرایب α و وصله‌های مرتبط با لبه، $SVR_{E\alpha}$ ، و مدلی دیگر براساس گرادینان مرتبه اول و دوم، SVR_{EG} ، این وصله‌ها آموزش داده می‌شود. مطابق رابطه ۶ در این مدل سازی از تمام پیکسل‌های لبه $(i, j) \in Edges$ در سطوح مختلف هرم تصویر وضوح پایین، $l \in N_{PyramidLevels}$ ، استفاده می‌شود تا ارتباط بین ارزش پیکسل وضوح بالا در سطح l ام، $y^l(i, j)$ ، و ویژگی‌های وصله مرتبط وضوح پایین برقرار گردد.

$$\begin{aligned} \alpha^l(i, j) &\xrightarrow{SVR_{E\alpha}} y^l(i, j) \\ \forall (i, j) \in Edges, \quad l \in N_{PyramidLevels} \\ G^l(i, j) &\xrightarrow{SVR_{EG}} y^l(i, j) \\ \forall (i, j) \in Edges, \quad l \in N_{PyramidLevels} \end{aligned} \quad (6)$$

پس از یادگیری، تخمین ارزش پیکسل وضوح بالا به کمک این دو مدل، مقادیر $\hat{y}_{EG}^l(i, j)$ و $\hat{y}_{E\alpha}^l(i, j)$ می‌باشند.

$$\begin{aligned} \hat{y}_{E\alpha}^l(i, j) &= SVR_{E\alpha}(\alpha^l(i, j)) \\ \hat{y}_{EG}^l(i, j) &= SVR_{EG}(G^l(i, j)) \end{aligned} \quad (7)$$

برای ارزیابی خطای تخمین در دو مدل SVR بدست آمده، رابطه اختلاف مقدار ارزش پیکسل وضوح بالای واقعی در هرم وضوح بالا، $y^l(i, j)$ ، و مقادیر تخمین زده شده از دو مدل $SVR_{E\alpha}$ و SVR_{EG} ، به ترتیب $\hat{y}_{EG}^l(i, j)$ و $\hat{y}_{E\alpha}^l(i, j)$ را با بردارهای ویژگی استفاده شده در این مدل‌ها، یادگیری می‌کنیم. این یادگیری بصورت زیر فرموله می‌شوند.

$$\begin{aligned} \alpha^l(i, j) &\xrightarrow{SVR_{EE\alpha}} |y^l(i, j) - \hat{y}_{E\alpha}^l(i, j)| \\ \forall (i, j) \in Edges, \quad l \in N_{PyramidLevels} \\ G^l(i, j) &\xrightarrow{SVR_{EEG}} |y^l(i, j) - \hat{y}_{EG}^l(i, j)| \\ \forall (i, j) \in Edges, \quad l \in N_{PyramidLevels} \end{aligned} \quad (8)$$

این ایده از مرجع [۴] اقتباس شده است.

Archive of SID

آموزش یادگیری شده است. وصله اطراف پیکسل، استخراج و بردارهای تُنک به کمک دیکشنری ناحیه و بردار گرادیان وصله استخراج می‌گردد. به کمک بردارهای بدست آمده و مدل های SVR ضرایب تُنک $SVR_{NE\alpha}^r$ ، و گرادیان SVR_{NEG}^r ، دو مقدار روشنایی برای پیکسل غیر لبه (i, j) تخمین زده می‌شود:

(۱۴)

$$I_{+1}^{NE\alpha}(i, j) = SVR_{NE\alpha}^r(\alpha(i, j)) \forall (i, j) \in Non_Edges$$

$$I_{+1}^{NEG}(i, j) = SVR_{NEG}^r(G(i, j)) \forall (i, j) \in Non_Edges$$

برای تخمین مقدار نهایی پیکسل غیر لبه، از بین دو مقدار کاندیدا، مقداری با کمترین خطای تخمین انتخاب می‌شود:

(۱۵)

$$\begin{array}{l} \text{if } SVR_{ENE\alpha}(\alpha(i, j)) \\ \quad < SVR_{ENEG}(G(i, j)) \\ \quad I_{+1}(i, j) \leftarrow I_{+1}^{NE\alpha}(i, j) \\ \text{else } I_{+1}(i, j) \leftarrow I_{+1}^{NEG}(i, j) \\ \text{end} \end{array}$$

بدین ترتیب روشنایی تک تک پیکسل های تصویر فراتفکیک شده تخمین زده می‌شود.

۵ نتایج آزمایشات

در این بخش، خروجی روش پیشنهادی برای چندین تصویر سطح خاکستری و تصاویر رنگی 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. هرمد 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 را به سطوح بالاتر تعمیم می‌دهیم. در پیاده‌سازی روش پیشنهادی، برای آموزش و آزمون مدل‌ها از $libsvm-3.21^{12}$ و برای ناحیه بندی تصاویر از SRM [۲۰] 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 شده‌است. 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 شکل ۲، هشت تصویر برای آزمون نشان داده شده است. مجموعه کامل تصاویر در پایگاه $USC-SIP1^{13}$ قرار دارد.

$$\begin{array}{l} \alpha^l(i, j) \xrightarrow{SVR_{ENE\alpha}} |y^l(i, j) - \hat{y}_{NE\alpha}^l(i, j)| \\ \forall (i, j) \in Non_Edges, \quad l \in N_{PyramidLevels} \\ G^l(i, j) \xrightarrow{SVR_{ENEG}} |y^l(i, j) - \hat{y}_{NEG}^l(i, j)| \\ \forall (i, j) \in Non_Edges, \quad l \in N_{PyramidLevels} \end{array} \quad (11)$$

لذا، با فرض n ناحیه متناظر در هرم وضوح پایین، $4 \times n$ مدل رگرسیون بردار پشتیبان آموزش داده می‌شود.

۴ فاز آزمون

برای تخمین روشنایی پیکسل ها در تصویر بالاترین سطح هرم وضوح بالا، I_{+1} ، از مدل های آموزش داده شده و تصویر بالاترین سطح هرم وضوح پایین \hat{I}_{+1} ، استفاده می‌کنیم. ابتدا الگوریتم لبه یابی را بر روی تصویر وضوح پایین \hat{I}_{+1} اعمال نموده تا پیکسل های لبه مشخص شوند. سپس، با استفاده از مدل های آموزش داده شده در بخش ۳، ارزش هر پیکسل در تصویر وضوح بالای خروجی I_{+1} تخمین زده می‌شود.

۴-۱ تخمین روشنایی پیکسل های لبه

مدل های تعریف شده در رابطه ۶ برای تخمین روشنایی پیکسل لبه در مختصات (i, j) تصویر وضوح بالا I_{+1} ، مورد استفاده قرار می‌گیرند. وصله ای به ابعاد $q \times q$ در اطراف پیکسل (i, j) از تصویر \hat{I}_{+1} استخراج می‌شود. بردار ضرایب تُنک وصله به کمک دیکشنری یادگیری شده از وصله های اطراف پیکسل های لبه استخراج شده و سپس بردار گرادیان وصله نیز محاسبه گردیده و به کمک مدل های SVR آموزش دیده شده، دو تخمین برای روشنایی پیکسل در مختصات (i, j) مطابق رابطه ۱۲ بدست می‌آید:

$$\begin{array}{l} I_{+1}^{E\alpha}(i, j) = SVR_{E\alpha}(\alpha(i, j)) \forall (i, j) \in Edges \\ I_{+1}^{EG}(i, j) = SVR_{EG}(G(i, j)) \forall (i, j) \in Edges \end{array} \quad (12)$$

بردار های ضرایب تُنک و گرادیان بدست آمده به مدل های خطای یادگیری شده (رابطه ۸) نیز داده می‌شود تا خطای دو تخمین بدست آید. هر یک از مدل ها که خطای کمتری ایجاد نمود، تعیین کننده روشنایی پیکسل (i, j) مربوطه است:

(۱۳)

$$\begin{array}{l} \text{if } SVR_{EE\alpha}(\alpha(i, j)) < SVR_{EE\alpha}(G(i, j)) \\ \quad I_{+1}(i, j) \leftarrow I_{+1}^{E\alpha}(i, j) \\ \text{else } I_{+1}(i, j) \leftarrow I_{+1}^{EG}(i, j) \\ \text{end} \end{array}$$

۴-۲ تخمین پیکسل های غیر لبه

در مرحله آزمون پیکسل های غیر لبه، تصویر وضوح پایین \hat{I}_{+1} به n ناحیه تقسیم می‌شود. سپس، مراحل زیر برای تخمین روشنایی پیکسل غیر لبه (i, j) 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

¹²<https://www.csie.ntu.edu.tw/~cjlin/libsvm/>

¹³<http://sipi.usc.edu/database>

Archive of SID

بازنمایی تنک، رگرسیون بردار پشتیبان، نتایج استخراج شده به ترتیب با نتایج روش‌های افزایش تفکیک پذیری تک تصویر خودی‌گیرنده [۴]، درونیابی دومکعبی، افزایش تفکیک پذیری مبتنی بر تقریب منیفلد (الگوریتم تعبیه شده خطی محلی) [۱۶]، افزایش تفکیک پذیری از طریق بازنمایی تنک [۱۲] و افزایش تفکیک پذیری مبتنی بر بازنمایی تنک با استفاده از رگرسیون بردار پشتیبان [۵] با استفاده از معیارهای PSNR و SSIM در جدول ۱ مقایسه شده است.

در این مقاله، برای اجرای روش‌های مراجع [۴]، [۵] و [۱۲] از کد بهمراه پایگاه تصاویر قرار داده شده در صفحات شخصی و یا آزمایشگاه نویسندگان با انجام تنظیمات در matlab R2016a استفاده شده است.



شکل ۲ مجموعه تصاویر برای آزمون (از چپ به راست و بالا به پایین):
airplane, boat, peppers, susan, house, lena, tree
baboon

بدلیل استفاده روش پیشنهادی این مقاله از تفکیک پذیری خودی‌گیرنده، اطلاعات همسایگی (ناحیه‌بندی براساس رنگ)،


جدول ۱ مقایسه‌ی روش‌های افزایش تفکیک پذیری تصویر با استفاده از معیارهای PSNR و SSIM

میانگین	baboon	airplane	boat	peppers	susan	house	lena	tree	تصویر روش SR
۳۱,۴۴۱۹ ۰,۸۸۵۲	۲۴,۹۶۱۵ ۰,۷۲۵۵	۳۲,۶۸۴۴ ۰,۹۴۵۰	۲۹,۹۴۷۲ ۰,۸۵۴۱	۳۳,۱۷۴۱ ۰,۹۰۲۴	۳۴,۷۱۱۴ ۰,۹۴۶۶	۳۲,۲۱۲۱ ۰,۹۰۳۴	۳۵,۴۴۷۱ ۰,۹۳۱۷	۲۸,۳۹۷۷ ۰,۸۷۳۰	Bicubic
۳۰,۱۶۵۷ ۰,۸۵۵۵	۲۳,۳۸۴۳ ۰,۶۸۵۴	۳۱,۱۵۵۶ ۰,۹۲۱۱	۲۹,۷۹۱۹ ۰,۸۳۳۴	۳۱,۷۱۷۸ ۰,۸۶۶۰	۳۳,۷۵۶۰ ۰,۹۲۹۰	۳۰,۹۲۱۵ ۰,۸۶۹۳	۳۳,۶۵۷۹ ۰,۸۹۸۶	۲۶,۹۴۰۵ ۰,۸۴۱۰	SISR [۴]
۲۸,۵۲۷۷ ۰,۸۲۲۹	۲۲,۹۴۸۷ ۰,۶۶۳۰	۲۹,۶۸۷۵ ۰,۹۱۲۲	۲۴,۲۷۹۴ ۰,۶۲۱۴	۳۰,۶۴۲۷ ۰,۸۶۶۹	۳۱,۸۴۰۴ ۰,۹۲۳۹	۲۹,۴۹۹۵ ۰,۸۶۴۶	۳۳,۴۹۸۱ ۰,۹۰۵۶	۲۵,۸۲۵۱ ۰,۸۲۵۷	LLE [۱۶]
۳۲,۰۷۰۴ ۰,۸۹۸۵	۲۵,۴۹۴۷ ۰,۷۸۰۹	۳۳,۳۵۳۱ ۰,۹۴۸۴	۳۰,۶۴۴۸ ۰,۸۷۱۴	۳۳,۵۹۵۳ ۰,۹۰۴۶	۳۵,۳۷۸۶ ۰,۹۴۸۰	۳۲,۷۲۶۶ ۰,۹۰۷۹	۳۶,۲۴۴۱ ۰,۹۳۸۰	۲۹,۱۲۶۵ ۰,۸۸۸۷	ScSR [۱۲]
۳۰,۱۷۴۳ ۰,۸۴۶۳	۲۳,۶۵۲۴ ۰,۶۶۶۳	۳۱,۶۶۰۵ ۰,۹۲۴۲	۳۰,۲۷۲۸ ۰,۸۴۶۱	۳۱,۳۹۵۹ ۰,۷۹۲۴	۳۲,۱۰۶۶ ۰,۹۳۹۱	۳۱,۰۲۷۰ ۰,۸۸۴۱	۳۳,۸۸۲۹ ۰,۹۰۶۲	۲۷,۳۹۶۲ ۰,۸۱۲۲	LsSR [۵]
۳۱/۷۳۲۸ ۰/۸۹۵۷	۲۵/۲۹۹۶ ۰/۷۵۵۵	۳۳/۰۵۹۵ ۰/۹۴۷۲	۲۸/۵۶۴۰ ۰/۸۷۰۹	۳۳/۸۲۳۲ ۰/۹۱۹۵	۳۵/۷۳۴۲ ۰/۹۵۱۰	۳۳/۱۳۸۲ ۰/۹۰۸۸	۳۵/۷۳۸۷ ۰/۹۳۴۶	۲۸/۵۰۸۹ ۰/۸۷۷۹	SINE [۱۹]
۳۲,۷۵۷۹ ۰,۹۰۷۴	۲۵,۷۰۱۴ ۰,۷۸۸۶	۳۴,۲۰۴۱ ۰,۹۵۶۱	۳۲,۱۸۳۳ ۰,۸۹۰۵	۳۴,۶۵۴۲ ۰,۹۱۳۱	۳۵,۵۷۲۱ ۰,۹۵۳۸	۳۳,۴۶۹۴ ۰,۹۱۵۹	۳۶,۶۳۸۵ ۰,۹۴۲۵	۲۹,۶۴۰۳ ۰,۸۹۸۸	روش پیشنهادی

تصویر با مربع قرمز مشخص شده است. بخش منتخب با جزئیات بیشتر در بخش دیگری از تصویر نشان داده می‌شود.


همانطور که در جدول ۱ مشاهده می‌شود، روش پیشنهادی این مقاله بهترین عملکرد را براساس معیارهای PSNR و SSIM نسبت به سایر روش‌ها داشته است. در اشکال ۳ تا ۵، تصویر هدف و تصاویر خروجی روش‌های Bicubic، SISR [۴]، LLE [۱۶]، ScSR [۱۲]، LsSR [۵]، SINE [۱۹] و روش پیشنهادی به ترتیب برای تصاویر ورودی susan، house و tree نشان داده شده است. برای مقایسه‌ی بهتر، بخشی از

Arch: house



شکل ۳ نتایج SR برای تصویر house با ضریب افزایش ۲ (کاهش اثرات تارشدگی و اثرات مصنوعی) (به ترتیب از چپ بر راست و بالا به پائین)

الف: تصویر هدف
 ج: bicubic (PSNR=۳۲,۲۱۲۱ و SSIM=۰,۹۰۳۴)
 د: LLE [۱۶] (PSNR=۲۹,۴۹۹۵ و SSIM=۰,۸۶۴۶)
 ه: ScSR [۱۲] (PSNR=۳۲,۷۲۶۶ و SSIM=۰,۹۰۷۹)
 ز: SINE [۱۹] (PSNR=۳۳,۱۳۸۲ و SSIM=۰,۹۰۸۸)
 ب: SISR [۴] (PSNR=۳۰,۹۲۱۵ و SSIM=۰,۸۶۹۳)
 و: LsSR [۵] (PSNR=۳۱,۰۲۷۰ و SSIM=۰,۸۸۴۱)
 ح: روش پیشنهادی (PSNR=۳۳,۴۶۹۴ و SSIM=۰,۹۱۵۹)



شکل ۴ نتایج SR برای تصویر susan با ضریب افزایش ۲ (کاهش اثرات مصنوعی و غیرطبیعی) (به ترتیب از چپ بر راست و بالا به پائین)

الف: تصویر هدف
 ج: SISR [۴] (PSNR=۳۳,۷۵۶۰ و SSIM=۰,۹۲۹۰)
 د: LLE [۱۶] (PSNR=۳۱,۸۴۰۴ و SSIM=۰,۹۲۳۹)
 ه: ScSR [۱۲] (PSNR=۳۵,۳۷۸۶ و SSIM=۰,۹۴۸۰)
 ز: SINE [۱۹] (PSNR=۳۵,۷۳۴۲ و SSIM=۰,۹۵۱۰)
 ب: bicubic (PSNR=۳۴,۷۱۱۴ و SSIM=۰,۹۴۶۶)
 و: LsSR [۵] (PSNR=۳۲,۱۰۶۶ و SSIM=۰,۹۳۹۱)
 ح: روش پیشنهادی (PSNR=۳۵,۵۷۲۱ و SSIM=۰,۹۵۳۸)

Art. I. SSIM




شکل ۵ نتایج SR برای تصویر tree با ضریب افزایش ۲ (کاهش اثرات تارشدگی و اثرات مصنوعی) (به ترتیب از چپ بر راست و بالا به پایین)

الف: تصویر هدف
 ج: bicubic (PSNR=۲۸,۳۹۷۷ و SSIM=۰,۸۷۳۰)
 د: LLE [۱۶] (PSNR=۲۵,۸۲۵۱ و SSIM=۰,۸۲۵۷)
 و: LsSR [۵] (PSNR=۲۷,۳۹۶۲ و SSIM=۰,۸۱۲۲)
 ح: روش پیشنهادی (PSNR=۲۹,۶۴۰۳ و SSIM=۰,۸۹۸۸)
 الف: تصویر هدف
 ج: bicubic (PSNR=۲۸,۳۹۷۷ و SSIM=۰,۸۷۳۰)
 د: LLE [۱۶] (PSNR=۲۵,۸۲۵۱ و SSIM=۰,۸۲۵۷)
 و: LsSR [۵] (PSNR=۲۷,۳۹۶۲ و SSIM=۰,۸۱۲۲)
 ح: روش پیشنهادی (PSNR=۲۹,۶۴۰۳ و SSIM=۰,۸۹۸۸)
 ز: SINE [۱۹] (PSNR=۲۵,۵۰۸۹ و SSIM=۰,۸۷۷۹)

برای مقایسه‌ی بهتر، در شکل ۶، اختلاف بین پیکسل‌های تصویر هدف و تصاویر خروجی روش‌های Bicubic، روش پیشنهادی [۱۹] SINE، [۱۶] LLE، [۱۲] ScSR، [۵] LsSR و [۴] SISR را نشان داده شده است.

بر اساس این اشکال، 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 حالی‌که در سایر روش‌ها (بخصوص روش [۱۲] ScSR) اثرات مصنوعی بر لبه‌های تصویر مشهود است.



شکل ۶ اختلاف بین تصویر هدف و تصاویر خروجی روش‌های- الف- روش پیشنهادی، ب: Bicubic، ج: LLE [۱۶]، د: SISR [۴]، و: ScSR [۱۲]، ز: SINE [۱۹] برای تصویر tree

Archive of SID

داده شده است. همانطور که در شکل ۷ نشان داده شده است، روش پیشنهادی برای نواحی هموار بخوبی عمل کرده و بیشترین اختلاف مربوط به نواحی غیریکنواخت و پیکسل‌های لبه است.

کاهش اختلاف بین تصویر خروجی و تصویر هدف، یعنی کاهش خطای تخمین روشنایی پیکسل‌ها است. همانطوریکه از شکل ۶ ملاحظه می‌گردد خطای تخمین روش پیشنهادی کمتر از سایر روش‌ها است. با ملاحظه این نتایج می‌توان دید که روش پیشنهادی توانسته است بهبود قابل ملاحظه‌ای در نواحی هموار نسبت به لبه‌های تصویر داشته باشد که در شکل ۷ نشان



شکل ۷ اختلاف بین پیکسل‌های تصویر هدف و تصاویر خروجی روش پیشنهادی برای تصاویر baboon، tree، susan، peppers و house (از چپ به راست)

۶ نتیجه‌گیری

در این مقاله یک روش افزایش تفکیک پذیری تک تصویر ارائه شده است که تعداد مدل‌های آموزشی آن براساس محتوی تصویر ورودی مشخص می‌شود. در اغلب روش‌های مطرح در زمینه افزایش تفکیک پذیری تک تصویر، پس از استخراج وصله‌های تصاویر آموزشی، از تشابه وصله‌های بدست آمده برای فرایند افزایش تفکیک پذیری استفاده می‌شود. در روش پیشنهادی برای نواحی همگن تصویر مدل‌های یادگیری مجزایی ارائه می‌شود تا بتوان ساختار هر ناحیه را با دقت بهتری مدل کرد. برای این منظور ابتدا تصویر پایین‌ترین سطح هرم تصویر ناحیه بندی شده و سپس ارتباط بین وصله‌های وضوح پایین و روشنایی تصویر وضوح بالا برای هر ناحیه یادگرفته می‌شود. ارتباط بین وصله‌های وضوح پایین و روشنایی مرکز وصله‌ها در تصاویر وضوح بالا به کمک رگرسیون بردار پیشین مدل می‌گردد. برای این منظور از وصله‌های تصاویر هرم ویژگی‌های گرادیان و ضرایب تُنک استخراج می‌گردد. برای کاهش اثر تارشدگی تصویر خروجی در لبه‌ها، پیکسل‌های لبه و غیرلبه را در تصویر ورودی جدا نموده و مدل‌های یادگیری متفاوتی برای هر گروه ارائه می‌نماییم. براساس نتایج آزمایشات انجام شده، روش پیشنهادی با توجه به معیارهای PSNR و SSIM عملکرد بهتری نسبت به سایر روش‌ها دارد.

مراجع

- [1] Bevilacqua, M., Roumy, A., Guillemot, C., Morel, M.L.A., "Single-image Super-resolution via Linear Mapping of Interpolated Self-examples", IEEE Transactions on Image Processing, Vol. 23, No.12, pp. 5334-5347, 2014.
- [2] Baker, S., Kanade, T., "Limits on Super-Resolution and How to Break Them", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 24, No. 9, pp. 1167-1183, 2002.
- [3] Yang, C.Y., Huang, J.B., Yang, M.H., "Exploiting Self-similarities for Single Frame Super-resolution", in Proceedings of the Asian Conference Computer Vision, pp. 497-510, 2010.
- [4] Yang, M.C., Wang, Y.C., "A Self-Learning Approach to Single Image Super-resolution", IEEE Transactions on Multimedia, Vol. 15, No. 3, pp. 498-508, 2013.
- [5] Yang, M.C., Chu, C.T., Wang, W.C.F., "Learning Sparse Image Representation with Support Vector Regression for Single-image Super-resolution", in Proceedings of the IEEE International Conference on Image Processing, 2010.
- [6] Dong, C., Loy, C., He, K., Tang, X., "Image Super-resolution using Deep Convolutional Networks", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 38, no. 2, pp. 295-307, 2016.
- [7] Kim, J., Lee, J.K., Lee, K.M., "Deeply-recursive Convolutional Network for Image Super-resolution", In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 1637-1645, 2016.

- [21] Chang, C. C., Lin, C. J., "Libsvm: A Library for Support Vector Machines", ACM Transactions on Intelligent Systems and Technology, Vol. 2, No. 3, pp. 1-27, 2011.
- [22] Smola A. J., Schölkopf B., "A Tutorial on Support Vector Regression", Statistics and Computing, Vol. 14 No. 3, pp. 199-222, 2004.



ملیحه حبیبی در سال ۱۳۸۱ مدرک کارشناسی مهندسی کامپیوتر گرایش نرم افزار خود را از دانشگاه خوارزمی و در سال ۱۳۸۵ مدرک کارشناسی ارشد مهندسی کامپیوتر گرایش هوش مصنوعی خود را از دانشگاه صنعتی شریف دریافت نموده است. نامبرده هم‌اکنون دانشجوی مقطع دکترای مهندسی کامپیوتر گرایش هوش مصنوعی است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش تصاویر و پویانمایی چهره.



علیرضا احمدی فرد تحصیلات خود را در مقطع کارشناسی در سال ۱۳۶۸ از دانشگاه صنعتی اصفهان در مهندسی الکترونیک و کارشناسی ارشد خود را در سال ۱۳۷۳ از دانشگاه صنعتی امیرکبیر در مهندسی مخابرات اخذ نموده‌اند. ایشان مدرک دکتری تخصصی را در سال

۱۳۸۱ اخذ نمودند. دکتر احمدی فرد هم‌اکنون در دانشگاه Surrey CVSSP در زمینه پردازش تصویر و ماشین بینایی از مرکز رییس دانشکده مهندسی برق و رباتیک دانشگاه صنعتی شاهرود می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان، پردازش سیگنال، پردازش تصاویر و شناسایی الگو می‌باشد.



حمید حسن پور مدرک کارشناسی خود را در سال ۱۳۷۲ در گرایش سخت افزار از دانشگاه علم و صنعت ایران و مدرک کارشناسی ارشد خود را در گرایش هوش ماشین در سال ۱۳۷۵ از دانشگاه صنعتی امیرکبیر اخذ نموده‌اند. ایشان مدرک دکتری خود را از دانشگاه صنعتی

کوئینزلند استرالیا در گرایش پردازش سیگنال در سال ۱۳۸۳ دریافت نموده‌اند. دکتر حسن پور در طی سالهای ۱۳۸۴ تا ۱۳۸۶ به عنوان عضو هیئت علمی در دانشکده مهندسی برق و کامپیوتر دانشگاه صنعتی بابل فعالیت داشتند. سپس به دانشکده کامپیوتر و فناوری اطلاعات دانشگاه صنعتی شاهرود منتقل یافتند و هم‌اکنون استاد تمام این دانشکده هستند. زمینه‌های علمی مورد علاقه نامبرده عبارتند از: پردازش تصاویر و پردازش سیگنال، تجزیه و تحلیل سیگنال در حوزه زمان و فرکانس

- [8] Dong, C., Loy, C., He, K., Tang, X., "Learning a Deep Convolutional Network for Image Super-resolution", in Proceedings of the European Conference on Computer Vision, pp. 184-199, 2014.
- [9] Wang, Z., Liu, D., Yang, J., Han, W., Huang, T., "Deeply Improved Sparse Coding for Image Super-resolution", In International Conference on Computer Vision (ICCV), pp. 370-378, 2015.
- [10] Glasner, D., Bagon, S., Irani, M., "Super-resolution from a Single Image", In International Conference on Computer Vision (ICCV), vol. 1, pp. 349-356, 2009.
- [11] Nazzal, M., Yeganli, F., Ozkaramanli, H., "Single Image Super-Resolution via Sparse Representation over Directionally Structured Dictionaries Based on the Patch Gradient Phase Angle", In Proceedings of the 2014 European Modeling Symposium, pp. 209-214, 2014.
- [12] Yang, J., Wright, J., Huang, T., Ma, Y., "Image Super-resolution via Sparse Representation", IEEE Transaction on Image Processing, Vol. 19, No. 11, pp. 2861-2873, 2010.
- [13] Yang, I., Wright, J., Huang, J.S., Ma, Y., "Image Super-resolution as Sparse Representation of Raw Image Patches", In Proceeding IEEE Conference Computer Vision and Pattern Recognition, Vol. 19, No. 11, pp. 2861-2873, 2008.
- [14] Zhang, H., Zhang, Y., Huang, T., "Efficient Sparse Representation Based Image Super Resolution via Dual Dictionary Learning", in IEEE International Conference on Multimedia and Expo (ICME), Barcelona, Spain, pp. 1-6, 2011.
- [15] Freeman WT, Jones T.R., Pasztor, E.C., " Example-based Super-resolution", IEEE Computer Graphics and Applications, Vol. 22, No. 2, pp. 56-65, 2002.
- [16] [16] Chang, H., Yeung, D.Y., Xiong, Y., "Super-resolution through Neighbor Embedding", in Proceedings of the IEEE International Conference Computer Vision and Pattern Recognition, pp. 275-282, 2004.
- [17] Dang, C., Radha, H., "Fast Image Super-resolution via Selective Manifold Learning of High-resolution Patches", IEEE International Conference on Image Processing (ICIP), pp. 1319-1323, 2015.

[۱۸] حبیبی، ملیحه، احمدی فرد، علیرضا، حسن پور، حمید، افزایش وضوح تک تصویری با در نظر گرفتن بخش‌های مجاور بازسازی شده، کنفرانس بین‌المللی مهندسی کامپیوتر و فناوری اطلاعات، بهار ۱۳۹۵.

[۱۹] حبیبی، ملیحه، احمدی فرد، علیرضا، حسن پور، حمید، 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، تابستان ۱۳۹۷.

- [20] Nock R, Nielsen F., "Statistical Region Merging", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 26, No. 11, pp. 1452-1458, 2004.