

رسالة محمد



دانشکده مهندسی برق

پایان نامه کارشناسی ارشد مهندسی مخابرات سیستم

ماتریدایی تصویر به کمک بازنمایی هر می تصویر در شرایط نامعلوم بودن هسته تار ی

نگارنده: امیر اقتدائی

استاد راهنما

دکتر علیرضا احمدی فرد

بهمن ماه ۱۴۰۰

در این صفحه صورت جلسه دفاع را قرار دهید. لازم است پس از صحافی این صفحه مجدداً توسط دانشکده مهر گردد و استاد راهنما با امضای خود اصلاحات پایان نامه را تایید کند.

تقدیم اثر

به پاس قدردانی از قلبی آکنده از عشق و معرفت،

به پاس تعبیر عظیم و انسانی شان از کلمه ایثار و گذشت،

به پاس عاطفه سرشار و گرمای امیدبخش وجودشان که در این سردترین روزگاران بهترین پشتیبان
است،

به پاس قلب‌های بزرگ شان که فریادرس است و سرگردانی و ترس در پناه شان به شجاعت می‌گراید،

و به پاس محبت‌های بی دریغ شان که هرگز فروکش نمی‌کند،

این مجموعه را به ارزشمندترین آموزگاران زندگی‌ام، پدر و مادر عزیزم تقدیم می‌کنم.

تشکر و قدردانی

خدا
من کلمه فخر از بی خودی دادم
که تو در عرش پر یاری
من چون تو یی داری
و چون خود

ضمن ابراز قدردانی از تمامی معلمان و اساتیدی که توفیق دانش‌آموزی و دانشجویی در محضرشان را داشتم، بر خود لازم می‌دانم از زحمات و تلاش بی‌دریغ استاد عالی‌قدر جناب آقای دکتر علیرضا احمدی‌فرد که در تمامی مراحل انجام این پژوهش از راهنمایی‌های مدبرانه ایشان استفاده نمودم، صمیمانه تشکر کنم و توفیقات روزافزون ایشان را توأم با صحت و سعادت خواستارم.

تعهد نامه

اینجانب امیر اقتدائی دانشجوی دوره کارشناسی ارشد رشته مهندسی مخابرات سیستم دانشکده مهندسی برق و رباتیک دانشگاه صنعتی شاهرود نویسنده پایان نامه ماتزدایی تصویر به کمک بازنمایی هرمی تصویر در شرایط نامعلوم بودن هسته تاری تحت راهنمایی آقای دکتر علیرضا احمدی فرد متعهد می شوم:

- تحقیقات در این پایان نامه 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 پایان نامه 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 می باشد 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 پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، 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 می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

تصاویر هنگام ثبت، معمولاً در اثر نویز و مات‌شدگی تخریب می‌شوند. مات‌شدگی تصویر، اغلب زمانی رخ می‌دهد که در حین پرتودهی به حسگر، دوربین نسبت به صحنه در حرکت باشد و یا عدسی دوربین تطابق درست نداشته باشد. یکی از مسائل پرکاربرد در حوزه پردازش تصاویر، رفع ماتی از تصویر می‌باشد. هدف از مات‌زدایی، بازیابی یک تصویر واضح از تصویری است که ممکن است به هر دلیلی مات شده باشد. اگر هسته تارکننده شناخته‌شده باشد، مات‌زدایی غیرکور و در غیر این صورت، مات‌زدایی کور نامیده می‌شود.

در این پایان‌نامه، مسئله مات‌زدایی کور مورد مطالعه قرار گرفته‌است. مات‌زدایی کور، بسیار چالش‌برانگیزتر از مات‌زدایی غیرکور است، چرا که فقط یک ورودی تک تصویر مات در دسترس است و معمولاً به صورت مستقیم یا غیرمستقیم به دنبال تخمین هسته مات‌کننده تصویر، از روی تصویر مات هستیم. در نهایت، با تخمین هسته تاری، برای رفع ماتی از روش‌های واپیچش استفاده می‌شود.

در این پایان‌نامه، از ساختار پنهان چندمقیاسه (MSLS) برای تخمین هسته تاری و رفع ماتی تصویر استفاده می‌نمائیم. در تابع هدفی که به منظور بازسازی وضوح تصویر پیشنهاد داده‌ایم، برای بهبود وضوح تصویر بازسازی‌شده و کاهش آلایه، یک جمله که هسته تاری را مجبور به یکپارچگی می‌نماید اضافه نموده‌ایم. نتایج ارزیابی روش پیشنهادی نشان می‌دهد که کیفیت رفع تاری، در بسیاری از موارد بهبود چشمگیری داشته و روی پایگاه داده مورد استفاده، میانگین PSNR و SSIM به ترتیب برابر $28/4163$ و $0/8672$ به دست آمده‌است. این درحالی است که روش پیشنهادی در مقایسه با بسیاری از روش‌های موجود، از سرعت خوبی نیز برخوردار است.

کلمات کلیدی: مات‌زدایی تصویر، واپیچش کور، تخمین هسته تاری، بازنمایی هرمی تصویر

لیست مقالات مستخرج از پایان نامه

۱-

۲-

۳-

فهرست مطالب

فصل اول: مقدمه

۱

۱-۱- مقدمه ۲

۱-۲- بیان مسئله و چالش‌ها ۲

۱-۳- تخریب تصویر ۳

۱-۴- انواع مات‌شدگی ۴

۱-۴-۱- مات‌شدگی گاوسی ۴

۱-۴-۲- مات‌شدگی حرکتی ۵

۱-۴-۳- تاری خارج از تمرکز ۶

۱-۵- ارزیابی کیفیت تصویر ۶

۱-۵-۱- معیار میانگین مربع خطا ۷

۱-۵-۲- معیار نسبت اوج سیگنال به نویز ۷

۱-۵-۳- معیار شباهت ساختاری ۸

۱-۵-۴- شباهت هسته تاری ۹

۱-۶- ساختار گزارش ۹

۱-۷- نتیجه‌گیری ۱۰

فصل دوم: مروری بر کارهای پیشین

۱۱

۲-۱- مقدمه ۱۲

۲-۲- مفاهیم پیش‌نیاز ۱۳

۲-۲-۱- تابع نقطه گستر ۱۳

۲-۲-۲- منظم‌سازی ۱۳

۱۴.....	۲-۲-۳- نرْم ماتريس
۱۴.....	۲-۲-۴- كانال تاريك
۱۵.....	۲-۲-۵- تقريب رتبه پائين
۱۶.....	۲-۲-۶- تُنكي ماتريس
۱۶.....	۲-۲-۷- توزيع دُم سنگين
۱۶.....	۲-۲-۸- گراف
۱۷.....	۲-۲-۹- آلايه‌هاي حلقه‌اي
۱۸.....	۲-۳- کارهاي مرتبط
۱۹.....	۲-۳-۱- مات‌زدايي با دانش پيشين دُم سنگين
۲۴.....	۲-۳-۲- مات‌زدايي با گراديان L_0
۳۲.....	۲-۳-۳- دانش پيشين كانال تاريك
۳۸.....	۲-۳-۴- دانش پيشين رتبه پائين
۴۶.....	۲-۳-۵- دانش پيشين مبتني بر گراف
۵۲.....	۲-۳-۶- دانش پيشين ساختار پنهان چندمقياسه (MSLS)
۵۹.....	۴-۲- نتيجه‌گيري
۶۱	فصل سوم: مباني نظري روش پيشنهادي
۶۲.....	۳-۱- مقدمه
۶۲.....	۳-۲- دانش پيشين ساختار پنهان چندمقياسه (MSLS)
۶۵.....	۳-۳- دانش پيشين پيوستگي هسته تاري
۶۶.....	۳-۴- فيلتر شوک
۶۷.....	۳-۵- نتيجه‌گيري

- ۴-۱- مقدمه ۷۰
- ۴-۲- روش پیشنهادی اول ۷۱
- ۴-۳- روش پیشنهادی دوم ۷۴
- ۴-۳-۱- شناسایی تکرارشونده پشتیبان ۷۴
- ۴-۳-۲- نقشه پیوستگی ۷۶
- ۴-۴- روش پیشنهادی سوم ۷۹
- ۴-۵- نتیجه گیری ۸۲

- ۵-۱- مقدمه ۸۴
- ۵-۲- ارزیابی روش پیشنهادی اول ۸۵
- ۵-۳- ارزیابی روش پیشنهادی دوم ۹۰
- ۵-۳-۱- شناسایی تکرارشونده پشتیبان ۹۰
- ۵-۳-۲- نقشه پیوستگی ۹۲
- ۵-۴- ارزیابی روش پیشنهادی سوم ۹۳
- ۵-۵- نتیجه گیری ۱۰۲

- ۶-۱- نتیجه گیری ۱۰۴
- ۶-۲- پیشنهاد برای ادامه کار ۱۰۶

فهرست شکل‌ها

شکل (۱-۱): مدل ماتی تصویر.....	۳
شکل (۲-۱): مات‌شدگی گاوسی تصویر MRI.....	۵
شکل (۳-۱): مات‌شدگی حرکتی تصویر MRI.....	۵
شکل (۴-۱): ماتی خارج از تمرکز تصویر MRI.....	۶
شکل (۱-۲): توزیع دُم سنگین.....	۱۶
شکل (۲-۲): آلایه‌های حلقه‌ای در واپیچش تصویر [۲۲].....	۱۷
شکل (۳-۲): مدل دانش پیشین دُم سنگین روی گرادیان تصویر.....	۲۰
شکل (۴-۲): MSE هسته‌های تخمینی در ۳۲ مثال آزمایشی.....	۲۳
شکل (۵-۲): هسته‌های تخمینی تصویر شماره ۱ مجموعه داده Levin.....	۲۴
شکل (۶-۲): هیستوگرام تصاویر متنی [۸].....	۲۴
شکل (۷-۲): نتایج مراحل فرآیند تخمین هسته تاری با روش منظم‌شده L_0 [۸].....	۲۹
شکل (۸-۲): نمونه‌های واپیچش غیرکور.....	۳۰
شکل (۹-۲): مقایسه روش [۸].....	۳۰
شکل (۱۰-۲): مات‌زدایی یک تصویر مات حاوی متن و پس‌زمینه شلوغ [۸].....	۳۱
شکل (۱۱-۲): یک مثال ناموفق روش [۸].....	۳۱
شکل (۱۲-۲): کانال تاریک تصاویر مات و واضح [۱۱].....	۳۲
شکل (۱۳-۲): محاسبه کانال تاریک $D(I)$	۳۴
شکل (۱۴-۲): مراحل فرآیند تخمین هسته تاری روش کانال تاریک به روش کل به جزء.....	۳۶
شکل (۱۵-۲): مات‌زدایی تصویر متنی.....	۳۷
شکل (۱۶-۲): رابطه رتبه تصاویر مات و میانی [۱۰].....	۳۹
شکل (۱۷-۲): خروجی مراحل فرآیند تخمین هسته تاری دانش پیشین رتبه پائین [۱۰].....	۴۵
شکل (۱۸-۲): اثربخشی دانش پیشین رتبه پائین.....	۴۵
شکل (۱۹-۲): عدم موفقیت الگوریتم رتبه پائین [۱۰].....	۴۶
شکل (۲۰-۲): توزیع دوقله‌ای وزن یال‌های گراف.....	۴۷
شکل (۲۱-۲): مثالی از مات‌زدایی کور.....	۵۲
شکل (۲۲-۲): بازنمایی هرمی بازسازی اولیه در مقیاس‌های بزرگ [۱۲].....	۵۴
شکل (۲۳-۲): نمودار بازسازی نهائی در کوچک‌ترین مقیاس [۱۲].....	۵۶
شکل (۲۴-۲): تصاویر مات و مات‌زدایی‌شده.....	۵۸

- شکل (۲-۲۵): نتیجه نامطلوب مات‌زدایی کور..... ۵۹
- شکل (۳-۱): مقایسه نمونه‌کاهی تصاویر..... ۶۳
- شکل (۳-۲): فراتفکیک‌پذیری مرجع [۱۵]..... ۶۴
- شکل (۳-۳): تولید نقشه پیوستگی هسته تاری..... ۶۶
- شکل (۳-۴): نتایج اعمال فیلتر شوک..... ۶۷
- شکل (۴-۱): ایده‌ها و روش‌های پیشنهادی پایان‌نامه..... ۷۱
- شکل (۴-۲): تصاویر واضح میانی روش پیشنهادی اول..... ۷۳
- شکل (۴-۳): گرادیان تصاویر واضح میانی روش پیشنهادی اول..... ۷۳
- شکل (۴-۴): نمودار اندازه اختلاف dj ۷۵
- شکل (۴-۵): محاسبه پشتیبان هسته تاری..... ۷۶
- شکل (۴-۶): مقایسه نقشه شدت روشنایی و نقشه پیوستگی..... ۷۷
- شکل (۴-۷): نتایج بازسازی هسته قبل و بعد از ماسک‌گذاری..... ۷۸
- شکل (۴-۸): شمای کلی روش پیشنهادی سوم..... ۸۲
- شکل (۵-۱): مجموعه داده Levin [۲۵]..... ۸۵
- شکل (۵-۲): مقایسه معیار شباهت هسته برای روش پیشنهادی اول..... ۸۵
- شکل (۵-۳): مقایسه بصری روش پیشنهادی اول..... ۸۸
- شکل (۵-۴): ارزیابی بصری روش پیشنهادی اول..... ۸۸
- شکل (۵-۵): ارزیابی روش پیشنهادی اول روی تصویر متنی..... ۸۹
- شکل (۵-۶): ارزیابی بصری روش ماسک پشتیبان هسته تاری..... ۹۰
- شکل (۵-۷): مقایسه بصری روش پشتیبان هسته..... ۹۱
- شکل (۵-۸): مقایسه هسته‌های تخمین زده شده روش پشتیبان هسته تاری..... ۹۱
- شکل (۵-۹): مقایسه معیار شباهت هسته برای روش ماسک پیوستگی..... ۹۲
- شکل (۵-۱۰): مقایسه موارد موفق و ناموفق روش ماسک نقشه پیوستگی..... ۹۲
- شکل (۵-۱۱): مراحل تخمین هسته تاری پیشنهاد سوم در هر مقیاس..... ۹۵
- شکل (۵-۱۲): هسته تخمین زده شده از تصویر شماره ۱ در مجموعه داده Levin..... ۹۶
- شکل (۵-۱۳): مقایسه بصری نتیجه مات‌زدایی تصویر توربین در [۳۲]..... ۹۷
- شکل (۵-۱۴): مات‌زدایی تصویر متنی با یک هسته تاری 31×31 از مجموعه داده [۳۱]..... ۹۸
- شکل (۵-۱۵): مقایسه نتایج رفع ماتی چند تصویر مات متنی چالش‌برانگیز از [۹]..... ۹۸
- شکل (۵-۱۶): نتیجه مات‌زدایی تصاویر مات مصنوعی از یک هسته چالش‌برانگیز 75×75 ۹۹
- شکل (۵-۱۷): رفع ماتی تصویر مات طبیعی، با واپیچش غیر کور [۶]..... ۱۰۰

- شکل (۵-۱۸): مقایسه ایده‌های پیشنهادی ۱۰۱
- شکل (۵-۱۹): موارد شکست روش‌های پیشنهادی ۱۰۲

فهرست جدول‌ها

- جدول (۱-۲): ارزیابی‌های کمی مات‌زدایی سریع [۲۶] و کانال تاریک [۱۱] ۳۷
- جدول (۲-۲): مقایسه‌های کمی روش‌های [۲۴]، [۲۶]، [۱۱]، [۳۴] و [۱۳] ۵۲
- جدول (۱-۵): مقایسه PSNR و SSIM پیشنهاد اول روی مجموعه داده Levin ۸۶
- جدول (۲-۵): مقایسه نسبت خطا و RMSE روش مرجع [۱۲] و روش پیشنهادی اول ۸۷
- جدول (۳-۵): مقایسه روش مرجع [۱۲] و پیشنهاد اول و روش پشتیبان هسته ۹۰
- جدول (۴-۵): ارزیابی‌های کمی روی مجموعه داده Levin ۹۳
- جدول (۵-۵): مقایسه PSNR و شباهت هسته روی مجموعه داده Levin ۹۴

فصل اول

مقدمه

۱-۱- مقدمه

مات‌شدگی تصویر یکی از تخریب‌های اجتناب‌ناپذیری است که معمولاً در اثر ثبت تصویر یا انتقال آن رخ می‌دهد. اخیراً مات‌زدایی تصویر^۱ در بینایی رایانه‌ای^۲ توجه بسیاری را به خود جلب کرده‌است و روش‌های متعددی برای رفع ماتی از تصاویر پدید آمده‌اند. همچنین به جهت اهمیت مسئله و کاربرد آن در حوزه‌های نظامی، پزشکی، ستاره‌شناسی و تصاویر میکروسکوپی، طیف گسترده‌ای از تکنیک‌های پردازش تصویر برای مقابله با چالش‌های موجود به کار گرفته شده‌اند. این فصل، به مرور برخی مفاهیم اساسی در زمینه رفع ماتی از تصاویر می‌پردازد و همچنین مدل تخریب، انواع مختلف تاری و معیارهای ارزیابی تصاویر بهبودیافته مورد بحث قرار گرفته‌است.

۱-۲- بیان مسئله و چالش‌ها

ماتی حرکتی، نوع خاصی از مات‌شدگی است و زمانی رخ می‌دهد که دوربین یا صحنه، در حین زمان ورود نور به دریچه دوربین، نسبت به هم در حرکت باشند. از طرفی، ثبت تصویر در معرض محدودیت‌های فیزیکی، مانند نور کم، لرزش دوربین، و متمرکز نبودن عدسی^۳ قرار دارد. نویز حسگر دوربین نیز از کیفیت تصویر ثبت‌شده می‌کاهد. بنابراین، اغلب تصاویر ثبت‌شده، حاوی مقداری مات‌شدگی و نویز هستند. لرزش دوربین، که باعث تصویربرداری‌های تار می‌شود، یک مشکل دیرینه برای عکاسان است. البته با استفاده از پرتوهای سریع‌تر، می‌توان اثر لرزش را کاهش داد، اما این امر، منجر به تاریکی تصویر و افزایش نویز حسگر در سیستم تصویربرداری می‌شود.

¹ Image deblurring

² Computer Vision

³ Lens

⁴ Exposure

لرزش دوربین را می‌توان به صورت یک هسته تاری^۱ مدل کرد که مسیر حرکت دوربین حین ثبت تصویر را توصیف می‌کند. با در نظر گرفتن فرآیند مات‌شدگی تصویر به صورت یک سیستم خطی، تصویر مات‌شده، نتیجه پیچش^۲ تصویر واضح با هسته مات‌کننده می‌باشد و از بین بردن اثر ماتی، شکلی از عملیات واپیچش^۳ خواهد بود. دو نوع واپیچش به صورت کور و غیرکور^۴ وجود دارد؛ در واپیچش غیرکور، علاوه بر تصویر مات، هسته تاری نیز در دسترس است و تنها خروجی الگوریتم، تصویر واضح بازیابی شده است. یکی از معروف‌ترین الگوریتم‌های غیرکور، الگوریتم لوسی-ریچاردسون [۱] است. اما در واپیچش کور که بسیار چالش‌برانگیزتر است و این پایان‌نامه به آن می‌پردازد، تنها تصویر مات‌شده در دسترس است و هیچ اطلاعاتی از هسته تاری وجود ندارد. در واقع، هدف از مات‌زدایی کور، ابتدا تخمین هسته تاری و به دنبال آن بازیابی تصویر واضح است.

۳-۱- تخریب تصویر

فرآیند مات‌شدگی تصویر واضح x را می‌توان به صورت رابطه (۱-۱) مدل‌سازی کرد:

$$b = x \otimes k + n \quad (1-1)$$

که در آن k هسته تاری یا تابع نقطه گستر^۵ (PSF)، n نویز تصادفی جمع‌شونده و $\otimes$ نشان‌دهنده عملگر پیچش دوبعدی است. شکل (۱-۱) مدل مات‌شدگی تصویر را نشان می‌دهد.



شکل (۱-۱): مدل ماتی تصویر.

^۱ Blur kernel

^۲ Convolution

^۳ Deconvolution

^۴ Blind and Non-blind

^۵ Point Spread Function

از آنجا که فقط تصویر مات شده b در دسترس است و هیچ دانشی از تابع نقطه گستر وجود ندارد، لذا این مشکل، بسیار بدحالت^۱ است؛ زیرا تعداد بی شماری x و k وجود دارد، که یک تصویر مات را ایجاد می کنند. به عنوان مثال، پیچش تصویر مات و هسته دلتا دیراک^۲ نیز تصویر مات را ایجاد خواهد کرد. بنابراین برای محدود کردن راه حل ها، نیاز به اطلاعات اضافی داریم. یعنی، راه حل های عملی باید فرضیات پیشینی موثری را بر روی هسته تاری، تصویر مورد بازیابی و یا هر دو اعمال کنند. فرآیند مات زدایی کور را می توان طی دو مرحله انجام داد؛ ابتدا هسته تاری را از روی تصویر مات، تخمین زده و سپس با انجام عملیات واپیچش بین هسته تاری تخمینی و تصویر ورودی مات شده، تصویر هدف را بازیابی کرد. اکثر روش های واپیچش کور، یک فرآیند تکرارشونده را انجام می دهند تا به طور متناوب و نوبتی، هسته تاری و تصویر واضح نهفته را بهینه کنند.

۱-۴- انواع مات شدگی

مات شدگی یک تصویر ممکن است دلایل متفاوتی از جمله متمرکز نبودن عدسی دوربین، آشفته گی های جوی (در تصاویر هوایی و سنجش از راه دور) و حرکت نسبی دوربین نسبت به صحنه داشته باشد. بعضاً می توان با شناخت مدل های مات شدگی، راه حل مناسب را جهت رفع ماتی به کار برد. در ادامه به بررسی چند مورد از مهم ترین انواع مات شدگی می پردازیم.

۱-۴-۱- مات شدگی گاوسی

مات شدگی گاوسی^۳ نتیجه اعمال یک فیلتر پائین گذر است که به صورت رابطه (۱-۲) تعریف شده است [۲]:


$$h(x, y; \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (۲-۱)$$

^۱ Ill-posed

^۲ Dirac delta

^۳ Gaussian blur

که σ پارامتر گاوسی است و در آمار، انحراف معیار نامیده می‌شود. این نوع مات‌شدگی، می‌تواند در تصاویر هوایی بر اثر آشفتگی جوی ایجاد شود. و یا به دلیل تطابق نادرست عدسی، تصویر صحنه به درستی بر روی حسگر تصویربردار قرار نگیرد. نتیجه این فیلتر پائین‌گذر، ماتی تصویر به خصوص در لبه‌ها و جزئیات تصویر می‌باشد. شکل (۲-۱) تصویر MRI مغز را در نتیجه ماتی با هسته گاوسی نشان می‌دهد.



شکل (۲-۱): مات‌شدگی گاوسی تصویر [۳] MRI. (چپ) تصویر واضح اصلی. (راست) تصویر مات‌شدگی گاوسی.

۱-۴-۲- مات‌شدگی حرکتی

زمانی که دوربین یا اشیاء در صحنه، در طول ثبت تصویر و پرتودهی، نسبت به هم در حرکت باشند،


یک تصویر مات‌شده حرکتی تحت تابع^۱ (۳-۱) تولید می‌گردد [۲]:

$$h(x,y; L, \phi) = \begin{cases} \frac{1}{L} & \sqrt{x^2 + y^2} \leq \frac{L}{2} \text{ and } \frac{x}{y} = -\tan \phi \\ 0 & \text{elsewhere} \end{cases} \quad (3-1)$$

که در آن L و ϕ ، طول و زاویه حرکت هستند. ماتی حرکتی می‌تواند به صورت جابه‌جایی، چرخش یا

تغییر مقیاس باشد که رابطه (۳-۱)، ماتی حاصل از جابه‌جایی خطی را مدل می‌کند. شکل (۳-۱) نشان

می‌دهد که تصویر MRI به دلیل آلاینده‌ها یا آثار تصنعی ناشی از حرکت سر، تار شده است.



شکل (۳-۱): مات‌شدگی حرکتی تصویر [۳] MRI. (چپ) تصویر واضح اصلی. (راست) تصویر مات‌شده حرکتی.

¹ Motion blur


² Artifact

۱-۴-۳- تاری خارج از تمرکز

تاری خارج از تمرکز به عمق اجسام در صحنه مرتبط است و زمانی اتفاق می‌افتد که فقط بخشی از صحنه در تمرکز عدسی دوربین قرار بگیرد. تابع PSF این مدل به صورت رابطه (۴-۱) خواهد بود [۲]:

$$h(x,y;r) = \begin{cases} \frac{1}{\pi r^2} & \sqrt{(x - c_x)^2 + (y - c_y)^2} \leq r \\ 0 & \text{elsewhere} \end{cases} \quad (4-1)$$

که در آن r شعاع و (c_x, c_y) مرکز PSF مات‌شدگی خارج از تمرکز است. نمونه‌ای از این ماتی در شکل (۴-۱) ارائه شده است.



شکل (۴-۱): ماتی خارج از تمرکز تصویر [۳] MRI. چپ) تصویر واضح. راست) تصویر مات‌شدگی خارج از تمرکز.

۱-۵- ارزیابی کیفیت تصویر

تصاویر بهبودیافته را می‌توان به دو روش اساسی کیفی و کمی ارزیابی کرد که در روش ارزیابی کیفی، تصاویر با استفاده از ناظر انسانی ارزیابی می‌شوند. این روش، با وجود قابل اعتماد و دقیق بودن، زمان‌بر و پرهزینه می‌باشد و برای کاربردهای بلادرنگ آقابل اجرا نیست، لذا در ادامه چند روش ارزیابی کمی را بررسی می‌کنیم.

¹ Out-of-focus blur

² Real-time

۱-۵-۱- معیار میانگین مربع خطا

یکی از ساده‌ترین معیارهای ارزیابی کیفیت تصویر، میانگین مربع خطا^۱ است که از طریق رابطه (۵-۱) قابل محاسبه است. هر چه مقدار این معیار کوچک‌تر باشد، به معنای شباهت بیشتر تصویر مات‌زدایی‌شده و تصویر واضح اصلی است. همچنین می‌توان از معیار RMSE که جذر MSE است نیز استفاده کرد.

$$MSE = \frac{1}{MN} \sum_{i=1}^N \sum_{j=1}^M (x(i,j) - y(i,j))^2 \quad (5-1)$$

در رابطه (۵-۱)، x تصویر مات‌زدایی‌شده و y تصویر واضح مرجع است. از مهم‌ترین مشکلات این معیار، نیاز به تصویر واضح مرجع است که ممکن است همیشه در دسترس نباشد. علاوه‌براین، چنانچه تصویر مات‌زدایی‌شده در اثر واپیچش با هسته تاری نامناسب، نسبت به تصویر مرجع در راستای سطرها و یا ستون‌ها جابه‌جا شده‌باشد، حتی اگر مات‌زدایی به‌خوبی صورت گرفته باشد، این معیار خطای بزرگی را نشان می‌دهد.

۱-۵-۲- معیار نسبت اوج سیگنال به نویز

یکی دیگر از معیارهای کمی سنجش کیفیت تصویر که مرتبط با معیار قبلی است، نسبت اوج سیگنال به نویز^۲ است و به‌صورت رابطه (۶-۱) تعریف می‌شود که L محدوده مجاز روشنایی تصویر است:

$$PSNR = 10 \log_{10} \frac{L^2}{MSE} \quad (6-1)$$

^۱ Mean Squared Error (MSE)

^۲ Peak Signal to Noise Ratio (PSNR)

۱-۵-۳- معیار شباهت ساختاری

معیار شباهت ساختاری^۱، تصویر ماتزدایی شده x و تصویر واضح اصلی y را با استخراج سه ویژگی

روشنایی^۲، تباین^۳ و ساختار^۴ مقایسه می کند. توابع محاسبه این ویژگی ها به ترتیب l ، c و s هستند [۴]:

$$l(x,y) = \frac{2\bar{x}\bar{y} + C_1}{(\bar{x}^2 + \bar{y}^2 + C_1)}, \quad C_1 = (K_1 L)^2 \quad (۷-۱)$$

$$c(x,y) = \frac{(2\sigma_x\sigma_y + C_2)}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad C_2 = (K_2 L)^2 \quad (۸-۱)$$

$$s(x,y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (۹-۱)$$

که L محدوده روشنایی تصویر و C_1 ، C_2 ، C_3 ، K_1 و K_2 اعداد ثابت هستند. $\bar{x}$ میانگین و σ_x انحراف

معیار تصویر x و همچنین $\bar{y}$ میانگین و σ_y انحراف معیار تصویر y می باشند [۴]:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (۱۰-۱)$$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \quad (۱۱-۱)$$

$$\sigma_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (۱۲-۱)$$

$$\sigma_y^2 = \frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2 \quad (۱۳-۱)$$

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) \quad (۱۴-۱)$$

که x_i روشنایی پیکسل i ام سیگنال تصویر x و σ_{xy} همبستگی متقابل است. با این تعاریف، شباهت

ساختاری با رابطه (۱۵-۱) محاسبه می شود:

$$SSIM = [l(x,y)]^\alpha \cdot [c(x,y)]^\beta \cdot [s(x,y)]^\gamma \quad (۱۵-۱)$$

^۱ Structural Similarity (SSIM)

^۲ Luminance

^۳ Contrast

^۴ Structure

در رابطه (۱۵-۱)، $\alpha > 0$ ، $\beta > 0$ و $\gamma > 0$ نشان‌دهنده اهمیت نسبی هر یک از ویژگی‌ها است. برای ساده‌سازی رابطه (۱۵-۱)، می‌توان با فرض $\alpha = \beta = \gamma = 1$ و $C_3 = \frac{C_2}{2}$ معیار شباهت ساختاری را به صورت رابطه (۱۶-۱) محاسبه کرد [۴]:

$$SSIM = \frac{(2\bar{x}\bar{y} + C_1)(2\sigma_{xy} + C_2)}{(\bar{x}^2 + \bar{y}^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (۱۶-۱)$$

بازه‌ی SSIM بین ۰ و ۱ است. هر چه مقدار اندازه‌گیری شده به عدد یک نزدیک‌تر باشد، تصویر مات‌زدایی شده به تصویر مرجع نزدیک‌تر بوده و کیفیت بهتری خواهد داشت.

۱-۵-۴- شباهت هسته تاری

برای ارزیابی میزان تشابه دو هسته تاری، از معیار شباهت هسته^۱ (KSIM) به کار گرفته شده در مرجع [۱۰] استفاده شده است. به این صورت که ابتدا دو هسته با نرمال‌سازی به بردار واحد تبدیل شده و سپس در هم ضرب می‌شوند. حاصل عددی بین صفر و یک است که هر چه به عدد یک نزدیک‌تر باشد، نشان‌دهنده شباهت بیشتر و هر چه به صفر نزدیک‌تر باشد بیانگر عدم شباهت دو هسته تاری است.

۱-۶- ساختار گزارش

در این فصل، به بیان مسئله و چالش‌های پیش‌رو پرداختیم و انواع مات‌شدگی و معیارهای ارزیابی تصاویر بازسازی شده را معرفی نمودیم. در فصل دوم پایان‌نامه، مروری خواهیم داشت بر روش‌های اخیر مسئله مات‌زدایی کور تصویر و هر یک را مورد ارزیابی قرار می‌دهیم. فصل سوم مبانی نظری روش‌های پیشنهادی را تعریف می‌کند و در فصل چهارم به تشریح ایده‌های پیشنهادی این پژوهش می‌پردازیم. در نهایت در فصل پنجم روش‌های پیشنهادی را با روش‌های اخیر مقایسه و ارزیابی می‌نمائیم.

^۱ Kernel Similarity (KSIM)

۱-۷- نتیجه‌گیری

در این فصل، مسئله مات‌زدایی کور مورد بحث، تعریف گردید و به چالش‌ها و کاربردهای آن اشاره شد. همچنین انواع مات‌شدگی و معیارهای ارزیابی تصاویر بازسازی‌شده نیز معرفی گردید.

ما در این پایان‌نامه سعی داریم یک تصویر واضح و بدون ماتی را از یک تصویر مات مشاهده‌شده، در شرایط نامعلوم بودن هسته تاری بازیابی کنیم. ایده اصلی به‌کار گرفته‌شده در روش‌های پیشنهادی، مبتنی بر دانش پیشین ساختار پنهان چندمقیاسه تصویر است که در فصل مبانی نظری به‌طور کامل تعریف شده‌است. بر اساس این ایده پیشنهادی، نسخه نمونه‌گاهی‌شده یک تصویر مات، واضح‌تر به‌نظر می‌رسد؛ لذا با تشکیل یک هرم از تصاویر نمونه‌گاهی‌شده از روی تصویر مات ورودی، قصد داریم در هر مقیاس، با بازسازی یک تصویر واضح میانی از طریق فرآیند فراتفکیک‌پذیری، روشی برای تخمین دقیق هسته تاری و مات‌زدایی تصویر معرفی کنیم. برای این منظور با الهام از این ایده مات‌زدایی چندمقیاسه که از سرعت اجرای خوبی برخوردار است، پیشنهاداتی جهت انتخاب لبه‌های مهم تصویر، پاکسازی هسته تاری تخمینی از نویز و همچنین اعمال قید پیوستگی عناصر هسته تاری ارائه می‌گردد.

نتایج ارزیابی‌های کمی و کیفی انجام‌شده نشان می‌دهد که الگوریتم پیشنهادی توانسته در بسیاری از موارد نتیجه خوبی ارائه دهد و در عین حال، سرعت اجرای قابل قبولی هم داشته‌باشد.

فصل دوم

مروری بر کارهای پیشین

۲-۱- مقدمه

برای رسیدگی به مسئله رفع ماتی کور تصویر، اغلب روش‌های اخیر مبتنی بر بهینه‌سازی و مبتنی بر یادگیری هستند. روش‌های بهینه‌سازی [۵-۱۳] به کمک دانش‌های پیشین^۱ درصد بازیابی هسته تاری و تصویر واضح پنهان هستند، و روش‌های یادگیری اخیر [۱۶-۱۹]، عمدتاً مبتنی بر شبکه‌های عصبی پیچشی^۲ (CNN) هستند.

مرجع [۱۹] برای مات‌زدایی تصویر، به‌منظور بازیابی لبه‌های تیز از تصاویر مات، یک شبکه عصبی پیچشی ایجاد می‌کند. مشکل اصلی این روش این است که نیاز به پایگاه داده وسیع و جامعی دارد. مرجع [۱۸] با استفاده از یک شبکه عصبی پیچشی، روشی را برای یادگیری فیلترهای لبه‌آگاه^۳ اتخاذ می‌کند. اما این رویکرد را نمی‌توان به‌طور مستقیم برای بازیابی لبه‌های قوی تصاویر مات اعمال کرد. مرجع [۱۷] مبتنی بر رویکرد MAP^۴ یک شبکه عمیق را برای تخمین هسته تاری آموزش داده و با استفاده از واپیچش غیرکور، تصویر واضح را بازیابی می‌کند. در مرجع [۱۶] یک الگوریتم چندمقیاسه مبتنی بر CNN برای رفع ماتی تصاویر پیشنهاد شده و موفقیت آن به‌دلیل همین معماری چندمقیاسه است که پیچیدگی مسئله را کاهش می‌دهد. با این وجود، برای هسته‌های پیچیده با ماتی بزرگ، همچنان رویکردهای مبتنی بر بهینه‌سازی، عملکرد بهتری نسبت به شبکه‌های پیچشی دارند.

این پژوهش به روش‌های مبتنی بر بهینه‌سازی پرداخته‌است و در این فصل، ابتدا اصطلاحات کلیدی در ادبیات مات‌زدایی معرفی می‌شود تا درک کارهای پیشین راحت‌تر باشد، سپس در ادامه به بیان تئوری‌های به‌کار رفته در کارهای گذشته خواهیم پرداخت. همچنین نتایج الگوریتم‌های معرفی‌شده را بررسی کرده و به ارزیابی کمی و کیفی آن‌ها می‌پردازیم تا نقاط قوت و ضعف هر روش شناخته شود.

¹ Prior knowledge

² Convolutional Neural Network

³ Edge-aware filter

⁴ Maximum A Posteriori

۲-۲- مفاهیم پیش نیاز

۲-۲-۱- تابع نقطه گستر

هر سیستم یک پاسخ به ورودی یک تابع ضربه‌ای حقیقی (یعنی منبع نقطه‌ای) دارد. در سیستم‌های خطی، دانستن پاسخ ضربه سیستم کافی است تا رفتار و عملکرد سیستم شناسایی شود. در این سیستم‌ها خروجی به هر ورودی دیگری برابر با پیچش آن ورودی با پاسخ ضربه می‌باشد. در سیستم‌های تصویربرداری، پاسخ ضربه سیستم را تابع نقطه گستر^۱ می‌نامند. تابع نقطه گستر یک سیستم فرآیند مات‌شدگی تصویر، همان هسته تاری^۲ نامیده می‌شود که در مدل تاری (۱-۱) باعث ماتی تصویر می‌گردد. هسته تاری نشان‌دهنده نحوه حرکت دوربین و عدم تطابق عدسی در مدت زمان تصویربرداری می‌باشد. منظور از مدت زمان تصویربرداری، مدت زمانی است که دریچه دوربین باز است و حسگر تصویربردار، ثبت اطلاعات تصویری می‌نماید.

۲-۲-۲- منظم‌سازی

با توجه به بدحالت بودن مسئله رفع ماتی کور، تعداد بی‌شماری هسته تاری و تصویر واضح وجود دارند که نتیجه پیچش آن دو، تصویر مات مورد نظر است. منظم‌سازی^۳، فرآیند افزودن قیدهایی است که پاسخ مسئله را محدود به جواب مورد نظر می‌نماید. برای این منظور در مسائل بدحالت، جهت حذف پاسخ‌های نادرست، جملات تنظیم‌کننده‌ای به تابع هدف مسئله اضافه می‌شود. جملات تنظیم‌کننده در مسئله بهینه‌سازی معمولاً با نِرم‌های L_1 و یا L_2 قیدی که می‌خواهیم آن را کمینه یا بیشینه کنیم بیان می‌شوند.

¹ Point Spread Function (PSF)

² Blur kernel

³ Regularization

۲-۲-۳- نرم ماتریس

در جبرخطی برای محاسبه اندازه یک بردار یا ماتریس از عبارت نرم استفاده می‌شود. نرم p یک بردار به صورت رابطه (۱-۲) تعریف می‌گردد:

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} \quad (1-2)$$

که به ازای p های مختلف، نرم‌های مختلف خواهیم داشت. پرکاربردترین آن‌ها نرم‌های L_0 ، L_1 و L_2 هستند. حاصل نرم L_0 برابر با تعداد عناصر غیرصفر بردار است. نرم L_1 برابر با مجموع قدر مطلق عناصر بردار خواهد بود و نرم L_2 برابر با طول بردار با معیار فاصله اقلیدسی می‌باشد. نرم L_2 برای ماتریس‌ها نرم فروبنیوس^۲ نامیده می‌شود.

۲-۲-۴- کانال تاریک

به تصویری که از جای‌گذاری کوچک‌ترین مقدار در یک همسایگی محلی از تصویر، به دست می‌آید کانال تاریک^۳ گفته می‌شود. هنگامی که یک تصاویر مات می‌شود، در حقیقت، یک میانگین‌گیری بین پیکسل‌های تاریک و پیکسل‌های همسایه با روشنایی بیشتر انجام می‌گیرد که سبب افزایش روشنایی پیکسل‌های تاریک در تصویر مات می‌شود.

برای ایجاد تصویر کانال تاریک، تصویر مات شده به پنجره‌هایی همپوشان تقسیم می‌شود. در هر یک از این پنجره‌ها، از هر سه کانال R ، G و B در یک تصویر رنگی RGB ، کمترین مقدار پیکسل محاسبه و جایگزین پیکسل مرکز آن پنجره می‌شود. برای تصویر I ، کانال تاریک از رابطه (۲-۲) محاسبه می‌شود:

$$D(I)(x) = \min_{y \in \mathcal{N}(x)} \left(\min_{c \in \{r, g, b\}} I^c(y) \right) \quad (2-2)$$

^۱ Norm

^۲ Frobenius

^۳ Dark Channel

که در آن x و y مکان‌های پیکسل را نشان می‌دهند، $N(x)$ یک وصله از تصویر به طول و عرض w و مرکز x است و I^c کانال رنگ c ام است. اگر I ، یک تصویر خاکستری باشد، در رابطه (۲-۲)، کمینه مقدار روشنایی در همسایگی یک پیکسل در کانال تاریک جایگزین پیکسل وسط وصله می‌شود [۱۱].

۲-۲-۵- تقریب رتبه پائین

رتبه‌ی یک ماتریس برابر با تعداد سطرها یا ستون‌های ماتریس است که نسبت به هم استقلال خطی دارند. برای تقریب یک ماتریس با یک ماتریس رتبه پائین‌تر، می‌توان از تجزیه مقادیر منفرد^۱ ماتریس A با تعریف ارائه‌شده در رابطه (۳-۲) استفاده کرد:

$$A = U \Sigma V^T \quad (۳-۲)$$

که U و V ماتریس‌های متعامد و Σ یک ماتریس قطری با مقادیر منفرد ماتریس A هستند. در مسئله تقریب رتبه پائین، هدف، یافتن ماتریسی مانند B با رتبه $k < r$ است، به‌طوری‌که $\|A - B\|_F$ کمینه گردد. اگر رابطه (۳-۲) را به‌صورت (۴-۲) در نظر بگیریم:

$$A = \left[U_{1a} \mid U_{1b} \mid U_2 \right] \begin{bmatrix} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_k \\ \hline & & 0 & \sigma_{k+1} & 0 \\ 0 & & 0 & \ddots & \\ \hline 0 & & 0 & 0 & \sigma_r \\ \hline 0 & & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} V_{1a}^T \\ V_{1b}^T \\ V_2^T \end{bmatrix}, \quad (۴-۲)$$

چون می‌خواهیم ماتریس A را با یک ماتریس رتبه پائین‌تر تقریب بزنیم، لذا اگر مقادیر منفرد σ_{k+1} به بعد، مقدار کوچکی داشته باشند، نقش چندانی در ایجاد ماتریس A ندارند و قابل صرف نظر هستند [۱۰].


^۱ Singular Value Decomposition (SVD)

۲-۲-۶- تنگی ماتریس

ماتریسی که عناصر صفر آن زیاد است و نسبتاً تعداد کمی عنصر غیرصفر دارد را ماتریس تنگ یا خلوت می‌نامند. روش طبیعی نمایش ماتریس‌ها در حافظه به صورت یک آرایه‌های دوبعدی، برای این گونه ماتریس‌ها مناسب نیست، لذا برای جلوگیری از اشغال حافظه می‌توان تنها عناصر غیرصفر را ذخیره کرد.

۲-۲-۷- توزیع دم سنگین

اصطلاح دم سنگین^۲ در توزیع آماری یک متغیر تصادفی به این معنی است که رخداد مقادیر بسیار بزرگ برای متغیر تصادفی احتمال قابل توجهی دارد. در نظریه احتمالات، به توزیع‌هایی دم سنگین گفته می‌شود که قسمت انتهایی توزیع آن‌ها نسبت به توزیع نمایی بالاتر باشد (مانند شکل ۱-۲).



شکل (۱-۲): توزیع دم سنگین.

۲-۲-۸- گراف

یک گراف $G(V, E, W)$ متشکل از مجموعه متناهی V از N گره (پیکسل تصویر) و مجموعه $E \subset V \times V$ از M یال است. هر یال $(i, j) \in E$ بدون جهت با وزن متناظر w_{ij} است که شباهت بین

^۱ Sparse

^۲ Heavy-tailed


گره‌های i و j را اندازه می‌گیرد. وزن‌ها را می‌توان با استفاده از هسته گاوسی به صورت رابطه (۵-۲) محاسبه کرد [۱۳]:

$$[W]_{i,j} = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (۵-۲)$$

که W یک ماتریس همجواری با اندازه $N \times N$ ، x_i و x_j مقادیر شدت روشنایی پیکسل i و j تصویر x ، و σ یک پارامتر کنترل‌کننده شعاع همجواری است. $0 \leq w_{ij} \leq 1$ و هر چه w_{ij} بزرگ‌تر باشد، گره‌های i و j شباهت بیشتری به یکدیگر دارند.

۹-۲-۲- آلاینه‌های حلقه‌ای

یکی از مشکلات اصلی در بازسازی تصویر واضح، وجود آلاینه‌های حلقه‌ای^۱ است، مانند آنچه در شکل (۲-۲) نشان داده شده است. آلاینه‌های حلقه‌ای، سایه‌های حلقه‌ای شکل تیره و روشن هستند که پس از واپیچش، در نزدیکی لبه‌های قوی ظاهر می‌شوند.



شکل (۲-۲): آلاینه‌های حلقه‌ای در واپیچش تصویر [۲۲]. الف) نتیجه واپیچش کور. ب) آلاینه‌های حلقه‌ای در لبه‌های قوی.

در مرجع [۲۲] نشان داده شده است که آلاینه‌های حلقه‌ای در اثر نویز تصویر که به درستی مدل نشده و یا هسته تاری که به درستی تخمین زده نشده، به وجود می‌آید.

^۱ Ringing artifact

پس از آشنایی با برخی مفاهیم و تعاریف مهم در فرآیند رفع ماتی از تصاویر، در ادامه روش‌های مهم پیشنهادشده در سال‌های اخیر در حوزه مات‌زدایی را مرور می‌کنیم.

۲-۳- کارهای مرتبط

موفقیت روش‌های مات‌زدایی اخیر، به‌طور مستقیم [۲۳، ۲۴، ۲۶] و یا غیرمستقیم [۲۱، ۲۲] به تخمین‌های تصویر پنهان میانی بستگی دارد. برای این‌که این مسئله از حالت بدحالت خارج شود، اغلب روش‌های موجود معمولاً آن را در به‌عنوان یک رویکرد بیشینه احتمال پسین^۱ (MAP) در نظر گرفته و مطابق رابطه (۶-۲) از دانش‌های پیشین آماری تصاویر طبیعی $P(x)$ و هسته‌های ماتی $P(k)$ استفاده می‌کنند. از جمله دانش‌های پیشین به‌کار گرفته شده، توزیع گرادیان دُم سنگین [۲۱، ۲۲، ۲۵] و گرادیان منظم‌شده L_0 [۵] یا ترکیبی از دانش پیشین شدت روشنایی و گرادیان [۸، ۹] می‌باشند.

در واقع سعی بر این است که با در نظر گیری مدل تخریب تصویر در معادله (۱-۱)، تصویر مات‌زدایی‌شده میانی (پنهان) و هسته تاری به‌طور همزمان و نوبتی بازیابی شوند:

$$P(x, k|b) \propto P(b|x, k)P(x)P(k) \quad (۶-۲)$$

$$P(b|x, k) \propto \exp\left(-\frac{\gamma}{2}\|x \otimes k - b\|^2\right) \quad (۷-۲)$$

$$\{\hat{x}, \hat{k}\} = \arg \max_{x, k} P(x, k|b) = \arg \max_{x, k} P(b|x, k)P(x)P(k) \quad (۸-۲)$$

که در رابطه (۸-۲) عبارت اول، درست‌نمایی و $P(k)$ و $P(x)$ به‌ترتیب دانش پیشین هسته تاری و تصویر پنهان هستند. همچنین، بیشینه‌سازی عبارت $P(x, k|b)$ معادل با کمینه‌سازی منفی لگاریتم آن می‌باشد [۷]. لذا با اعمال منفی لگاریتم به این رابطه، داریم:

$$\{\hat{x}, \hat{k}\} = \arg \min_{x, k} \ell(x \otimes k, b) + \gamma\phi(k) + \lambda\varphi(x) \quad (۹-۲)$$

^۱ Maximum A Posteriori

^۲ Likelihood

عبارت اول در رابطه (۲-۹)، عبارت همانندی داده است، به این معنی که خروجی پیچش یک تصویر بازیابی شده با هسته تاری، باید با مشاهده b همخوانی داشته باشد. شکل آن بستگی به توزیع فرضی از مدل نویز (مثلاً گاوسی) دارد و معمولاً اختلاف بین $k \otimes x$ و b را با استفاده از نرم دو به صورت رابطه (۲-۷) جریمه می‌کند. دو عبارت دیگر، قیدهای هسته تاری و تصویر پنهان هستند با وزن‌های مثبت γ و λ .


روش‌های مختلف، سعی دارند با استفاده از اعمال دانش‌های پیشین موثر و کاربردی، تصویر پنهان و هسته تاری را بازیابی کنند. تصویر پنهان به دست آمده در این مرحله، تصویر میانی پنهان نامیده می‌شود. با عمل واپیچش غیرکوار بر روی تصویر مات با توجه به هسته تاری به دست آمده، تصویر پنهان (تصویر مات‌زدایی شده) به دست می‌آید. در این فصل، به برخی از این روش‌ها و دانش‌های پیشین پیشنهادی آن‌ها می‌پردازیم.

۲-۳-۱- مات‌زدایی با دانش پیشین دُم سنگین

توزیع گرادیان یک تصویر واضح، دُم سنگین‌تر از توزیع گرادیان تصویر مات متناظرش است. لذا در این روش، دانش پیشین دُم سنگین، L_p , $p < 1$ روی گرادیان تصویر استفاده شده است که دارای دو مزیت است؛ اول، قله قدرتمندی در اطراف صفر دارد، که به عنوان یک تنظیم‌کننده قوی عمل می‌کند و دوم این‌که، برای مقادیر بیشینه کمینه^۲ مشتقات تصویر، احتمال نسبتاً بالا یا جریمه کمی در نظر می‌گیرد، که برای بازسازی لبه‌های تیز ضروری است. شکل (۲-۳) مدل دانش پیشین توزیع آماری دُم سنگین را روی گرادیان یک تصویر بر اساس نرم‌های مختلف نشان می‌دهد [۷].

^۱ Data fidelity

^۲ Extremum



شکل (۲-۳): مدل دانش پیشین دُم سنگین روی گرادیان تصویر برای نُرم p های مختلف (مقیاس لگاریتمی) [۷].

اگر x تصویر واضح، b تصویر مات و k هسته تاری باشند، داریم:

$$L(x, k) = -\log(P(x, k|b)) = \frac{\gamma}{2} \|x \otimes k - b\|_2^2 + Q(x) + R(k) \quad (۱۰-۲)$$

$$Q(x) = -\log P(x) \quad , \quad R(k) = -\log P(k) \quad (۱۱-۲)$$

$$Q(x) = \Phi(D_x x, D_y x) = \sum_i ([D_x x]_i^2 + [D_y x]_i^2)^{\frac{p}{2}} \quad , \quad 0 \leq p \leq 1$$

$$R(k) = \sum_i \psi(k_i) \quad , \quad \psi(k_i) = \begin{cases} k_i & k_i \geq 0 \\ +\infty & k_i < 0 \end{cases}$$

$$L(x, k) = \frac{\gamma}{2} \|x \otimes k - b\|_2^2 + \sum_i ([D_x x]_i^2 + [D_y x]_i^2)^{\frac{p}{2}} + \sum_i \psi(k_i) + const \quad (۱۲-۲)$$

که D_x و D_y عملگرهای مشتق جزئی هستند. برای یافتن راه حل x و k ، معادله (۱۰-۲)، به کمک

روش لاگرانژین تکمیلی^۱ (ALM) به صورت نوبتی و پشت سرهم نسبت به x یا k درحالی که دیگری

ثابت نگه داشته می شود، کمینه می گردد [۷].

▪ کمینه سازی نسبت به x

$$\min_x \frac{\gamma}{2} \|Kx - b\|^2 + \Phi(D_x x, D_y x) \quad (۱۳-۲)$$

$$\min_{x,v} \frac{\gamma}{2} \|Kx - b\|^2 + \Phi(v_x, v_y) \quad s.t. \quad \begin{aligned} v_x &= D_x x \\ v_y &= D_y x \end{aligned} \quad (۱۴-۲)$$

^۱ Augmented Lagrangian Method

روش ALM برای هر قید، به روش لاگرانژین یک عبارت جریمه درجه دو اضافه می کند که منجر به رابطه (۱۵-۲) می شود:

$$L_x(x, v_x, v_y) = \frac{\gamma}{2} \|Kx - b\|^2 + \Phi(v_x, v_y) + \frac{\alpha}{2} \|D_x x - v_x - a_x\|^2 + \frac{\alpha}{2} \|D_y x - v_y - a_y\|^2 \quad (۱۵-۲)$$

که در آن متغیرهای جدید a_x و a_y ضرایب لاگرانژ قیدهای متناظر هستند. عبارت $\|Kx - b\|^2$ و تنظیم کننده $\Phi(v_x, v_y)$ را می توان به طور جداگانه کمینه کرد. کمینه سازی L_x ، از طریق نزول مختصات به طور متناوب حل می شود [۷]. یعنی درحالی که سایر متغیرها ثابت نگه داشته شده اند، مشتق نسبت به یک متغیر محاسبه و معادله کمینه سازی می شود، بدین ترتیب می توان آن متغیر را به روزرسانی کرد و سپس با تعداد کافی از تکرارها، سراغ متغیر بعدی رفت. پس از مشتق گرفتن L_x نسبت به x و برابر با صفر قرار دادن، باید در مرحله ۳ از الگوریتم (۱-۲)، تصویر x را از طریق رابطه (۱۶-۲) محاسبه کرد. بنابراین، راه حل x را می توان مستقیماً به کمک تبدیل فوریه به دست آورد.

$$\begin{aligned} \frac{dL_x}{dx} &= \gamma \|Kx - b\| \|K\| + \alpha \|D_x x - v_x - a_x\| \|D_x\| + \alpha \|D_y x - v_y - a_y\| \|D_y\| = 0 \\ \gamma(K^T K - K^T b) + \alpha(D_x^T D_x x - D_x^T(v_x + a_x)) + \alpha(D_y^T D_y x - D_y^T(v_y + a_y)) &= 0 \\ x &= \frac{K^T b + \frac{\alpha}{\gamma}(D_x^T(v_x + a_x) + D_y^T(v_y + a_y))}{K^T K + \frac{\alpha}{\gamma}(D_x^T D_x + D_y^T D_y)} \end{aligned} \quad (۱۶-۲)$$

¹ Coordinate descent

الگوریتم (۱-۲): تخمین x [۷]
۱. تنظیم اولیه $v_x^0 = 0, v_y^0 = 0, a_x^0 = 0, a_y^0 = 0, j = 0$
۲. حلقه تکرار تا رسیدن به معیار توقف
۳. حل $x^{j+1} = \frac{K^T b + \frac{\alpha}{\gamma} (D_x^T (v_x^j + a_x^j) + D_y^T (v_y^j + a_y^j))}{K^T K + \frac{\alpha}{\gamma} (D_x^T D_x + D_y^T D_y)}$
۴. $\{[v_x^{j+1}]_i, [v_y^{j+1}]_i\} = \text{LUT}_p([D_x x^{j+1} - a_x^j]_i, [D_y x^{j+1} - a_y^j]_i)$
۵. $a_x^{j+1} = a_x^j - D_x x^{j+1} + v_x^{j+1}$
۶. $a_y^{j+1} = a_y^j - D_y x^{j+1} + v_y^{j+1}$
۷. $j = j + 1$
۸. پایان حلقه
۹. بازگشت x^j

▪ کمینه‌سازی نسبت به k

کمینه‌سازی نسبت به k نیز به روش مشابه انجام می‌شود.

$$\min_{k, v_k} \frac{\gamma}{2} \|Xk - b\|^2 + R(v_k) \quad s.t. \quad k = v_k$$

$$L_k(k, v_k) = \frac{\gamma}{2} \|Xk - b\|^2 + R(v_k) + \frac{\beta}{2} \|k - v_k - \alpha_k\|^2 \quad (۱۷-۲)$$

که در آن α_k دوباره با روش ALM مرتبط است و با ضریب لاگرانژ قید مشخص شده، متناسب است.

این تابع را می‌توان با الگوریتم نزول مختصات (۲-۲) کمینه کرد:

الگوریتم (۲-۲): تخمین k [۷]
۱. تنظیم اولیه $v_k^0 = 0, a_k^0 = 0, j = 0$
۲. حلقه تکرار تا رسیدن به معیار توقف
۳. حل $k^{j+1} = \frac{X^T b + \frac{\beta}{\gamma} (v_k^j + a_k^j)}{X^T X + \frac{\beta}{\gamma} I}$
۴. $[v_k^{j+1}]_i = \max([k^{j+1} - a_k^j]_i - \frac{1}{\beta}, 0)$
۵. $a_k^{j+1} = a_k^j - k^{j+1} + v_k^{j+1}$
۶. $j = j + 1$
۷. پایان حلقه
۸. بازگشت k^j

مشابه الگوریتم (۱-۲)، در مرحله ۳ الگوریتم (۲-۲) نیز، با مشتق‌گیری تابع هدف L_k نسبت به k و اعمال تبدیل فوریه دوبعدی روی نتیجه، هسته تار k از طریق رابطه (۱۸-۲) به‌روزرسانی می‌شود. در این رابطه، I ماتریس همانی است.

$$\frac{dL_k}{dh} = \gamma \|Xk - b\| \|X\| + \beta \|k - v_k - \alpha_k\| = 0$$


$$\gamma(X^T X k - X^T b) + \beta(k - v_k - \alpha_k) = 0$$

$$k = \frac{X^T b + \frac{\beta}{\gamma}(v_k + \alpha_k)}{X^T X + \frac{\beta}{\gamma} I} \quad (۱۸-۲)$$

علاوه بر روش فوق، در مرجع [۲۲] نیز، با الحاق دو تابع پیوسته چند ضابطه‌ای به‌منظور برازش با توزیع لگاریتمی گرادیان تصاویر طبیعی و استفاده از آن برای مات‌زدایی تصویر، روشی معرفی شده‌است که در آن، دانش پیشین تصویر، از دو دانش پیشین محلی و سراسری منتج می‌شود.

❖ نتایج


الگوریتم [۷]، روی مجموعه داده Levin ارائه‌شده در [۲۵] شامل چهار تصویر خاکستری و هشت هسته تار، که منجر به ۳۲ تصویر می‌شود، آزمایش شده‌است. شکل (۴-۲) نتیجه محاسبه خطای MSE تخمین هشت هسته اندازه‌گیری شده نسبت به هسته صحیح مبنا^۱ را نشان می‌دهد. مقدار MSE کمتر یعنی عملکرد بهتر و ملاحظه می‌شود که در اغلب موارد، روش [۷] برتر است.



شکل (۴-۲): MSE هسته‌های تخمینی در ۳۲ مثال آزمایشی (۴ تصویر و ۸ هسته تار) [۷].

^۱ Ground-truth


شکل (۲-۵) هسته‌های تخمین زده شده را برای تصویر شماره ۱ مجموعه داده Levin نشان می‌دهد. ملاحظه می‌شود که روش [۷] بهترین تخمین هسته تاری را در مقایسه با روش [۲۴] و [۲۱] دارد.



شکل (۲-۵): هسته‌های تخمینی تصویر شماره ۱ مجموعه داده Levin. سطرها از بالا به پایین) هسته تاری مرجع یا صحیح مبنا، نتایج روش [۷]، روش [۲۴]، روش [۲۱].

۲-۳-۲- مات‌زدایی با گرادیان L_0

تصاویر متنی، ویژگی‌های خاصی دارند که آن‌ها را از سایر تصاویر متمایز می‌کند، لذا لازم است روش‌های مات‌زدایی مخصوصی برای آن‌ها ابداع نمود. دانش پیشین در مرجع [۸] مبتنی بر نرم صفر روشنایی و گرادیان تصویر بر اساس این مشاهده ایجاد شده که حروف متن و نواحی پس‌زمینه در تصاویر متنی واضح، معمولاً دارای هیستوگرام روشنایی یکنواخت هستند. برای درک بهتر مثالی در شکل (۲-۶) ارائه شده است.



شکل (۲-۶): هیستوگرام تصاویر متنی [۸]. (الف) تصویر متنی واضح. (ب) هیستوگرام روشنایی تصویر (الف). (ج) هیستوگرام گرادیان افقی تصویر (الف). (د) تصویر مات. (ه) هیستوگرام روشنایی تصویر (د). (و) هیستوگرام گرادیان افقی تصویر (د).

شکل (۲-۶) نشان می‌دهد که روشنایی تصویر متن واضح، حول دو قله (نزدیک ۰ و ۲۵۵) است، درحالی‌که برای تصویر مات‌شده متناظرش این‌طور نیست. ملاحظه می‌شود که هیستوگرام روشنایی تصویر مات بسیار گسترده بوده و قله صفر ندارد. از آنجا که مقادیر شدت روشنایی یک تصویر متن واضح، تقریباً دو رنگ هستند و با توجه به این‌که مات‌شدگی، نوعی متوسط‌گیری با پیکسل‌های همسایه است، لذا گرادیان‌های پیکسل باید مقادیر غیرصفر داشته باشند، یعنی مقادیر غیرصفر گرادیان‌های تصویر مات، متراکم‌تر از گرادیان‌های نسخه واضح متناظر تصویر متن هستند. این ویژگی می‌تواند به‌عنوان یک عبارت منظم‌سازی در رابطه (۲-۹) مورد استفاده قرار گیرد. برای تصویر x ، رابطه (۲-۱۹) را داریم که در آن $\|x\|_0$ ، تعداد مقادیر غیرصفر x را می‌شمارد:

$$P_t(x) = \|x\|_0 \quad (۲-۱۹)$$

در نهایت، دانش پیشین روی روشنایی و گرادیان، برای مات‌زدایی تصویر متن به‌صورت رابطه (۲-۲۰) تعریف می‌شود:

$$P(x) = \sigma P_t(x) + P_t(\nabla x) = \sigma \|x\|_0 + \|\nabla x\|_0 \quad (۲-۲۰)$$

با اضافه کردن دانش پیشین به رابطه قراردادی مات‌زدایی تصویر (۲-۹)، تابع هدف به‌صورت بهینه‌سازی (۲-۲۱) خواهد بود:

$$\min_{x, k} \|x \otimes k - b\|_2^2 + \gamma \|k\|_2^2 + \lambda P(x) \quad (۲-۲۱)$$

رابطه بهینه‌سازی (۲-۲۱) را می‌توان به دو زیرمسئله تبدیل کرد تا x و k به‌صورت نوبتی محاسبه شوند:

$$\min_x \|x \otimes k - b\|_2^2 + \lambda P(x) \quad (۲-۲۲)$$

$$\min_k \|x \otimes k - b\|_2^2 + \gamma \|k\|_2^2 \quad (۲-۲۳)$$

▪ تخمین تصویر میانی x با k

کمینه‌سازی با توجه به نرم L_0 دارای پیچیدگی است، لذا به کمک روش کمینه‌سازی جداسازی نیمه-درجه دو^۱ [۲۷] و معرفی متغیرهای کمکی u و $g = (g_h, g_v)^T$ متناظر با x و ∇x ، تابع هدف به صورت بهینه‌سازی (۲۴-۲) بازنویسی می‌شود:

$$\min_{x,u,g} \|x \otimes k - b\|_2^2 + \beta \|x - u\|_2^2 + \mu \|\nabla x - g\|_2^2 + \lambda (\sigma \|u\|_0 + \|g\|_0) \quad (24-2)$$

حالا می‌توان با کمینه‌سازی متناوب x ، u و g با ثابت نگه داشتن سایر متغیرها، بهینه‌سازی (۲۴-۲) را حل کرد. یعنی در هر تکرار، x از طریق رابطه (۲۵-۲) محاسبه می‌گردد:

$$\min_x \|x \otimes k - b\|_2^2 + \beta \|x - u\|_2^2 + \mu \|\nabla x - g\|_2^2 \quad (25-2)$$

رابطه (۲۵-۲)، به کمک کمینه‌سازی کمترین مربعات^۲، منتج به راه‌حل فرم بسته (۲۶-۲) می‌شود [۸]:

$$2\|kx - b\|\|k\| + 2\beta\|x - u\| + 2\mu\|\nabla x - g\| = 0$$

$$kxk^T - k^T b + \beta x - \beta u + \mu \nabla x - \mu g = 0$$

$$x = F^{-1} \left(\frac{\overline{F(k)}F(b) + \beta F(u) + \mu F_G}{\overline{F(k)}F(k) + \beta + \mu \overline{F(\nabla)}F(\nabla)} \right) \quad (26-2)$$

که در آن $F(\cdot)$ و $F^{-1}(\cdot)$ به ترتیب تبدیل فوریه سریع^۳ (FFT) و تبدیل فوریه معکوس را نشان می‌دهند؛ $\overline{F(\cdot)}$ عملگر مزدوج مختلط است و $F_G = \overline{F(\nabla_h)}F(g_h) + \overline{F(\nabla_v)}F(g_v)$ که در آن ∇_v و ∇_h به ترتیب عملگرهای دیفرانسیلی افقی و عمودی را نشان می‌دهند. با توجه به x ، می‌توان u و g را به‌طور جداگانه محاسبه کرد:

$$\min_u \beta \|x - u\|_2^2 + \lambda \sigma \|u\|_0 \quad (27-2)$$

$$\min_g \mu \|\nabla x - g\|_2^2 + \lambda \|g\|_0 \quad (28-2)$$

¹ Half-quadratic splitting

² Least squares minimization

³ Fast Fourier Transform

معادلات (۲۷-۲) و (۲۸-۲)، مسئله کمینه‌سازی پیکسل محور^۱ هستند، بنابراین راه‌حل‌های u و g بر مبنای [۲۷] به دست می‌آیند:

$$u = \begin{cases} x & |x|^2 \geq \frac{\lambda\sigma}{\beta} \\ 0 & elsewhere \end{cases} \quad (۲۹-۲)$$

$$g = \begin{cases} \nabla x & |\nabla x|^2 \geq \frac{\lambda}{\mu} \\ 0 & elsewhere \end{cases} \quad (۳۰-۲)$$

▪ تخمین هسته k با x

حالا با توجه به x ، رابطه (۲۳-۲) یک کمینه‌سازی کمترین مربعات است که با FFT محاسبه می‌شود. راه‌حل این معادله بهینه‌سازی، بر اساس روشی تصویری، صحیح نیست، لذا هسته تار k در فضای گرادینان تخمین زده می‌شود:

$$\min_k \|\nabla x \otimes k - \nabla b\|_2^2 + \gamma \|k\|_2^2 \quad (۳۱-۲)$$

پس از به دست آمدن k ، عناصر منفی آن صفر شده و طوری نرمال می‌شود که مجموع عناصرش ۱ باشد. دو الگوریتم (۳-۲) و (۴-۲) مراحل اصلی روش [۸،۹] را نشان می‌دهند.

الگوریتم (۳-۲): تخمین هسته تار [۸]

ورودی: تصویر مات نمونه‌کاهی شده b

۱. مقداردهی اولیه هسته با نمونه‌افزایی هسته مقیاس قبلی (در مقیاس اول هسته دلتا دیراک می‌باشد).

۲. حلقه با ۵ تکرار:

۳. بازسازی تصویر میانی x با الگوریتم (۴-۲)

۴. تخمین هسته تار k با بهینه‌سازی (۳۱-۲)

۵. $\lambda \leftarrow \max\{\lambda/1.1, 1e^{-4}\}$

۶. پایان حلقه

خروجی: هسته تار k و تصویر پنهان میانی x

¹ Pixel-wise minimization

الگوریتم (۲-۴): حل رابطه بهینه‌سازی (۲-۲۴) [۷]

ورودی : تصویر مات b و هسته تار k

$$x \leftarrow y, \beta \leftarrow 2\lambda\sigma$$

۲. حلقه تکرار تا زمانی که $\beta > \beta_{max}$:

۳. محاسبه u با معادله (۲-۲۹)

$$\mu \leftarrow 2\lambda$$

۵. حلقه تکرار تا زمانی که $\mu > \mu_{max}$:

۶. محاسبه g با معادله (۲-۳۰)

۷. محاسبه x با معادله (۲-۲۶)

$$\mu \leftarrow 2\mu$$

۹. پایان حلقه

$$\beta \leftarrow 2\beta$$


۱۱. پایان حلقه

خروجی : تصویر پنهان میانی x

برای عملکرد قابل اطمینان، فرآیند تخمین هسته، در چند مقیاس از کل به جزء انجام می‌گیرد. برای مثال با در نظر گرفتن ۵ مقیاس، در مقیاس بزرگ اول (مقیاس کل)، تصویر مات اصلی طوری نمونه‌کاهی می‌شود که در مقیاس کوچک آخر (مقیاس جزء) به اندازه تصویر اصلی برسد. هسته اول، هسته‌ی کوچک و معمولاً تابع دلتا دیراک^۲ بوده تا در مقیاس آخر به تخمین با اندازه درست همگرا شود. شکل (۲-۷) نتایج مراحل این فرآیند را نشان می‌دهد.

^۱ Coarse-to-fine

^۲ Dirac delta function



شکل (۲-۷): نتایج مراحل فرآیند تخمین هسته تاری در هر مقیاس با روش منظم شده L_0 [۸].
اندازه تصویر میانی و هسته تاری در هر مقیاس مشخص شده است.


در بخش ماتزدایی غیرکور، برای این که این الگوریتم، علاوه بر تصاویر متنی، برای صحنه‌هایی با پس‌زمینه پیچیده نیز کارایی داشته باشد و به منظور حذف آلاینه‌های حلقه‌ای، از دانش پیشین لاپلاسیان که جزئیات ریز را حفظ می‌کند، استفاده شده است. به این صورت که ابتدا، تصاویر واضح پنهان x_l با دانش پیشین لاپلاسیان تخمین زده می‌شود، سپس با رابطه پیشنهادی (۲-۲۲) تصویر پنهان x_0 تولید می‌شود، اما فقط با گرادیان $P_t(\nabla x)$ (یعنی در معادله (۲-۲۴)، σ برابر با صفر خواهد شد). همانند مدل ارائه شده در مرجع [۲۲]، تفاوت این دو تصویر محاسبه می‌شود و آلاینه‌ها با فیلتر دوسویه^۱ حذف می‌گردند. در نهایت، اختلاف فیلترشده، از x_l کم می‌شود.

^۱ Bilateral Filter

❖ نتایج


الگوریتم گرادیان L_0 می‌تواند با سرکوب آلاینه‌های حلقه‌ای، مات‌زدایی تصاویر را بیشتر بهبود دهد.

نتیجه در شکل (۸-۲) (ه) نشان می‌دهد که این رویکرد برای تصاویر متنی و طبیعی به‌خوبی عمل می‌کند، و در برابر روش سرکوب آلاینه‌های حلقه‌ای، عملکرد مطلوبی دارد.



شکل (۸-۲): نمونه‌های واپیچش غیرکور. (الف) تصاویر مات و هسته‌های تخمینی حاصل از روش [۸].
 (ب) نتیجه مات‌زدایی [۶] با دانش پیشین لاپلاسیان. (ج) نتیجه رابطه (۲۲-۲) که $\sigma = 0$.
 (د) حذف آثار حلقه‌ای با روش مرجع [۲۲]. (ه) نتیجه روش [۸].

روش‌های مات‌زدایی تصاویر طبیعی، عملکرد خوبی روی تصاویر متنی ندارند و نتیجه مات‌زدایی شده شامل آلاینه‌های حلقه‌ای می‌باشد. در صورتی که با روش گرادیان و روشنایی منظم‌شده L_0 [۸]، روی تصاویر متنی نتایج بهتری حاصل می‌گردد. مثالی در شکل (۹-۲) ارائه شده‌است.



شکل (۹-۲): مقایسه روش [۸].

برای تصاویر حاوی متن زیاد و پس‌زمینه شلوغ، یک مثال در شکل (۲-۱۰) ارائه شده است. شکل (۲-۱۰) (ج) و (د) نتایج الگوریتم [۸] را فقط با استفاده از $P_t(\nabla x)$ و فقط با استفاده از $P_t(x)$ نشان می‌دهد و ملاحظه می‌شود که تصاویر تیز را نمی‌توان فقط با استفاده از دانش پیشین گرادیان یا شدت روشنایی به دست آورد، که نشان می‌دهد که دانش پیشین پیشنهادی $P(x)$ نقش مهمی در مات‌زدایی تصویر متنی ایفا می‌کند.



هـ) نتیجه [8] د) نتیجه [8] با $P_t(x)$ ج) نتیجه [8] با $P_t(\nabla x)$ ب) نتیجه [26] الف) تصویر مات

شکل (۲-۱۰): مات‌زدایی یک تصویر مات حاوی متن و پس‌زمینه شلوغ [۸].

این الگوریتم، نیاز به هیچ یک از روش‌های انتخاب لبه، که برای روش‌های موجود مبتنی بر لبه ضروری هستند، ندارد اما هنگامی که یک تصویر مات‌شده، حاوی مقدار زیادی نویز باشد، روش [۸] با شکست مواجه خواهد شد؛ زیرا رابطه (۲-۲۱)، مبتنی بر نرم L_2 است که نسبت به نویز زیاد حساس بوده و تاثیر آن را در نتایج میانی تشدید می‌کند. مثالی از این عدم موفقیت در شکل (۲-۱۱) نشان داده شده است.



الف

ب

ج

شکل (۲-۱۱): یک مثال ناموفق روش [۸]. الف) تصویر مات. ب) تصویر میانی. ج) نتیجه مات‌زدایی شده و هسته تازی.

۲-۳-۳- دانش پیشین کانال تاریک

ایده اصلی این روش مبتنی بر این مشاهده است که کانال تاریک (کمترین مقدار روشنایی در یک همسایگی محلی) تصاویر مات، نسبت به تصاویر واضح متناظرش، تُنکی^۱ یا تیرگی کمتری دارد. در واقع، هنگامی که یک پیکسل تاریک در تصویر واضح، در طی فرآیند مات‌شدگی با پیکسل‌های با روشنایی بالا متوسط گرفته می‌شود، روشنایی‌اش افزایش می‌یابد. این تغییر در تُنکی کانال تاریک، یک ویژگی ذاتی فرآیند ماتی است. در شکل (۲-۱۲) تُنکی کانال تاریک تصاویر مات نسبت به تصاویر واضح نشان داده شده است [۱۱].



شکل (۲-۱۲): کانال تاریک تصاویر مات و واضح [۱۱]. ردیف بالا) تصاویر مات و واضح. ردیف پایین) کانال تاریک به دست آمده با انتخاب پنجره 35×35 .


در شکل (۲-۱۲)، ملاحظه می‌شود که تُنکی تصویر واضح بیشتر است و تصویر مات نواحی روشن بیشتری دارد. برای توضیح این که چرا کانال تاریک تصاویر مات، دارای تُنکی کمتری است، برخی ویژگی‌های عملگر ماتی (پیچش) را بررسی می‌کنیم. برای سیگنال‌های گسسته (تصاویر)، پیچش به صورت مجموع حاصل ضرب دو سیگنال، تعریف می‌شود:

$$B(x) = \sum_{z \in \Omega_k} I\left(x + \left\lfloor \frac{S}{2} \right\rfloor - z\right) k(z) \quad (2-32)$$

¹ Sparsity

که در آن Ω_k و S ، ناحیه و اندازه هسته تازی k را مشخص می کنند، $k(z) \geq 0$ ، $\sum_{z \in \Omega_k} k(z) = 1$ و $[.]$ عملگر گرد کردن را مشخص می کند. مجموع وزن دار مقادیر پیکسل در یک همسایگی محلی، بزرگ تر از حداقل مقدار پیکسل در همسایگی است. همان طور که در زیر نشان داده شده است:

$$B(x) \geq \min_{y \in \mathcal{N}(x)} I(y)$$



با توجه به این که $D(B)(x)$ و $D(I)(x)$ ، به ترتیب کانال تاریک پیکسل x در تصاویر مات و واضح بوده و نرم L_0 عناصر غیر صفر را می شمارد، لذا دو ویژگی تعریف شده در نامعادلات (۳۳-۲) و (۳۴-۲)، برای توصیف تغییرات ناشی از مات شدگی تصاویر توسط پیچش، حاصل می گردد:

$$D(B)(x) \geq D(I)(x) \quad (۳۳-۲)$$

$$\|D(B)(x)\|_0 > \|D(I)(x)\|_0 \quad (۳۴-۲)$$

این ویژگی برای انواع تصویر صادق است، بنابراین می توان یک عبارت منظم سازی برای اعمال تنکی کانال های تاریک در تصاویر پنهان معرفی کرد. اگر از نرم $\|D(x)\|_0$ برای اندازه گیری تنکی کانال های تاریک تصویر x استفاده گردد، با اعمال این قید به رابطه استاندارد مات زدایی تصویر، تابع هدف به صورت رابطه (۳۵-۲) خواهد بود:

$$\min_{x,k} \|x \otimes k - b\|_2^2 + \gamma \|k\|_2^2 + \mu \|\nabla x\|_0 + \lambda \|D(x)\|_0 \quad (۳۵-۲)$$

که عبارت سوم در گرادیان های تصویر، گرادیان های بزرگ را حفظ و جزئیات را حذف می کند. برای کمینه سازی (۳۵-۲)، باید معادلات (۳۶-۲) و (۳۷-۲)، به طور متناوب یا نوبتی حل شوند:

$$\min_x \|x \otimes k - b\|_2^2 + \mu \|\nabla x\|_0 + \lambda \|D(x)\|_0 \quad (36-2)$$

$$\min_k \|x \otimes k - b\|_2^2 + \gamma \|k\|_2^2 \quad (37-2)$$

▪ تخمین تصویر پنهان x


با روش جداسازی نیمه-درجه دو [۲۷] و متغیرهای کمکی u برای $D(x)$ و $g = (g_h, g_v)$ متناظر با گرادیانهای تصویر در جهت‌های افقی و عمودی، تابع هدف (۳۶-۲) به صورت زیر بازنویسی می‌شود که در آن α و β پارامترهای جریمه هستند:

$$\min_{x,u,g} \|x \otimes k - b\|_2^2 + \alpha \|\nabla x - g\|_2^2 + \beta \|D(x) - u\|_2^2 + \mu \|g\|_0 + \lambda \|u\|_0 \quad (38-2)$$

$$\min_x \|x \otimes k - b\|_2^2 + \alpha \|\nabla x - g\|_2^2 + \beta \|D(x) - u\|_2^2 \quad (39-2)$$

نکته‌ای که وجود دارد این است که $D(x)$ با توجه به عملگر $\min$ ، غیرخطی^۱ بوده، لذا برای بهینه‌سازی تابع هدف به یک عملگر خطی مثل M نیاز است. فرض کنید $y = \arg \min_{z \in N(z)} I(z)$ ، آنگاه:

$$M(x, z) = \begin{cases} 1 & z = y \\ 0 & \text{otherwise} \end{cases} \quad (40-2)$$



شکل (۲-۱۳): محاسبه کانال تاریک $D(I)$ یک تصویر I با عملگر غیرخطی $\min$ و خطی‌سازی آن [۱۱]. سه پنجره رنگی در تصویر اول، قطعات مورد محاسبه را نشان می‌دهند.

^۱ Non-linear

با توجه به شکل (۲-۱۳) و رابطه (۲-۴۰)، ابتدا کانال تاریک $D(I)$ و سپس با آن، u بر اساس (۲-۴۲) تولید می‌شود. حال برای هر قطعه‌ی تصویر میانی I اول، اگر کمترین پیکسل آن دقیقاً در همان جایگاه در u بود، همان مقدار کمترین را در ماتریس چهارم $M^T u$ قرار می‌دهیم. در غیر این صورت، کمترین مقدار در u ، در ماتریس $M^T u$ قرار می‌گیرد. در نهایت، با توجه به ماتریس M ، تصویر I که در تابع هدف (۲-۳۹) همان x است، به دست می‌آید:

$$\min_x \|T_k x - b\|_2^2 + \alpha \|\nabla x - g\|_2^2 + \beta \|Mx - u\|_2^2$$

$$x = F^{-1} \left(\frac{\overline{F(T_k)} F(b) + \beta F(u) + \mu F_G}{\overline{F(T_k)} F(T_k) + \beta + \mu \overline{F(V)} F(V)} \right) \quad (۲-۴۱)$$

که در آن T_k ، یک ماتریس Toeplitz (پیچش) از k ، تصویر مات، و u همان کانال تاریک خطی شده است. ماتریس Toeplitz را می‌توان با استفاده از تبدیل سریع فوریه (FFT) به دست آورد. با توجه به x ، u و g نیز به صورت جداگانه محاسبه می‌شوند:

$$u = \begin{cases} D(x) & |D(x)|^2 \geq \frac{\lambda}{\beta} \\ 0 & otherwise \end{cases} \quad (۲-۴۲)$$

$$g = \begin{cases} D(x) & |\nabla x|^2 \geq \frac{\mu}{\alpha} \\ 0 & otherwise \end{cases} \quad (۲-۴۳)$$

▪ تخمین هسته تاری k

مشابه رویکردهای موجود، تخمین هسته مبتنی بر گرادیان، دقیق‌تر بوده و راه حل (۲-۴۴) با FFT به روش کل به جزء حاصل می‌گردد.

$$\min_k \|\nabla x \otimes k - \nabla b\|_2^2 + \gamma \|k\|_2^2 \quad (۲-۴۴)$$

چارچوب این روش در هر مقیاس، مطابق با الگوریتم (۲-۳) می‌باشد، منتها در گام ۳ برای بازسازی تصویر پنهان میانی، بر اساس الگوریتم (۲-۵) عمل می‌کنیم.

الگوریتم (۵-۲): حل معادله بهینه‌سازی (۳۸-۲) [۱۱]

ورودی : تصویر مات b و هسته تاری k

$$x \leftarrow b, \beta \leftarrow \beta_0$$

۲. حلقه تکرار تا زمانی که $\beta > \beta_{max}$:

۳. محاسبه کانال تاریک و ساخت ماتریس M بر اساس (۴۰-۲)

۴. محاسبه u با معادله (۴۲-۲)

$$\alpha \leftarrow \alpha_0$$

۶. حلقه تکرار تا زمانی که $\alpha > \alpha_{max}$:

۷. محاسبه g با معادله (۴۳-۲)

۸. محاسبه x با معادله (۴۱-۲)

$$\alpha \leftarrow 2\alpha$$


۱۰. پایان حلقه

$$\beta \leftarrow 2\beta$$

۱۲. پایان حلقه

خروجی : تصویر پنهان میانی x


در شکل (۱۴-۲) ورودی و خروجی مقیاس‌های اول و آخر نشان داده شده‌است.



شکل (۱۴-۲): مراحل فرآیند تخمین هسته تاری روش کانال تاریک به روش کل به جزء.

❖ نتایج

روش کانال تاریک [۱۱]، با این که به دلیل محاسبات، زمان زیادی را صرف می کند، اما نتایج بصری بسیار موافقی ارائه می دهد و تصاویر به دست آمده از کیفیت مطلوبی برخوردار هستند (شکل ۲-۱۵).



الف) تصویر ورودی

ب) مات زدایی به روش کانال تاریک

شکل (۲-۱۵): مات زدایی تصویر متنی. روش [۱۱] در تصاویر متنی نیز نتایج قابل قبولی ایجاد می کند. با این حال، در این روش فرض بر این است که کانال تاریک تصویر اصلی به جای صفر، تُنک است. متأسفانه، برای تصاویر واضحی که هیچ پیکسل تاریکی ندارند، دانش پیشین کانال تاریک با احتمال کمتری به تخمین هسته تاری کمی می کند. علاوه بر این، این روش فرض می کند که فقط فرآیند مات شدگی باعث تغییر تنکی کانال تاریک می شود ولی ممکن است نویز نیز بر پیکسل های تاریک یک تصویر اثر بگذارد، که بر این اساس می تواند در تخمین هسته مشکل ایجاد کند. این روش بدون دانش پیشین کانال تاریک، معادل روش مات زدایی [۵] خواهد بود. همچنین جدول (۲-۱) نتایج PSNR روش [۱۱] و [۲۶] را نشان می دهد که ملاحظه می شود متوسط PSNR روش کانال تاریک، ۴ دسی بل بیشتر از روش مات زدایی سریع است.

جدول (۲-۱): ارزیابی های کمی مات زدایی سریع [۲۶] و کانال تاریک [۱۱].

	روش [۲۶]	روش [۱۱]
PSNR (db)	23.80	27.94

۲-۳-۴- دانش پیشین رتبه پائین

در این روش با ترکیب دانش پیشین رتبه پائین^۱ قطعات مشابه، هم از تصویر مات و هم از گرادیان متناظرش، یک دانش پیشین پیشرفته برای ماتزدایی تصویر معرفی شده است. همچنین برای اثربخشی بیشتر، یک روش کمینه سازی نُرم هسته‌ی وزن دار^۲ (WNNM) به کار گرفته شده تا با حفظ لبه‌های قوی و از بین بردن بافت ضعیف و لبه‌های نازک در تصاویر میانی، به تخمین بهتر هسته تاری کمک کند.


روش‌های تقریب ماتریس رتبه پائین^۳ (LRMA) از جمله رویکرد کمینه سازی نُرم هسته^۴ (NNM) و کمینه سازی نُرم هسته‌ی وزن دار [۱۴]، پیش از این در نویززدایی به کار برده شدند. روش ماتزدایی مبتنی بر رتبه پائین [۱۰]، در مقایسه با روش WNNM که به طور خاص برای رفع نویز طراحی شده است، یک الگوریتم جدید برای تخمین وزن‌ها پیشنهاد می‌کند. شکل (۲-۱۶) نشان می‌دهد که متوسط رتبه ماتریس قطعات مشابه غیرمحلی در تصاویر میانی، کمتر از قطعات مشابه غیرمحلی یک تصویر مات است. زیرا تمامی قطعات با بافت‌های غنی و لبه‌های ضعیف، طوری صاف و هموار شده‌اند که تنها لبه‌های غالب حفظ می‌شوند؛ در نتیجه، متوسط رتبه قطعات میانی، کمتر از قطعات مات مشابه است. این تصاویر میانی با لبه‌های برجسته برای تخمین هسته، بسیار ضروری هستند [۱۰].

¹ Low Rank Prior

² Weighted Nuclear Norm Minimization

³ Low Rank Matrix Approximation

⁴ Nuclear Norm Minimization



شکل (۲-۱۶): رابطه رتبه تصاویر مات و میانی [۱۰]. (الف) ورودی مات و هسته. (ب) تصاویر میانی تخمین زده شده. (ج) توزیع متوسط مقادیر منفرد قطعات مشابه غیرمحملی به ترتیب از (الف) و (ب). (د) نتایج مات زدایی شده نهایی. رتبه ماتریس‌های غیرمحملی در تصاویر میانی کمتر از تصاویر مات است.

کمینه‌سازی نُرم هسته‌ی وزن‌دار

روش^۱ NNM یکی از روش‌های تقریب ماتریس رتبه پائین است. نُرم هسته ماتریس X به صورت $\|X\|_*$ نشان داده می‌شود که برابر با مجموع مقادیر منفرد آن یعنی $\|X\|_* = \sum_i |\sigma_i(X)|_1$ است که در آن، $\sigma_i(X)$ مقدار منفرد i ام X است. NNM قصد دارد Y را با X تخمین بزند، درحالی‌که نُرم هسته X را کمینه می‌کند. از طرف دیگر، اثبات شده‌است که مسئله تقریب ماتریس رتبه پائین مبتنی بر NNM با نُرم فروبنیوس عبارت همانندی داده، می‌تواند به راحتی با یک آستانه‌گذاری روی مقادیر منفرد ماتریس مشاهده‌شده حل شود. یعنی راه‌حل رابطه (۲-۴۵) زیر:

$$\hat{X} = \arg \min_X \|Y - X\|_F^2 + \lambda \|X\|_* \quad (۲-۴۵)$$

که در آن λ یک ثابت مثبت است. رابطه (۲-۴۵) می‌تواند با راه‌حل (۲-۴۶) به دست آید:

$$\hat{X} = US_\lambda(\Sigma)V^T \quad (۲-۴۶)$$

^۱ Nuclear Norm Minimization

که $Y = U\Sigma V^T$ تجزیه مقادیر منفرد Y و $S_\lambda(\Sigma)$ تابع آستانه‌گذاری روی ماتریس قطری Σ با پارامتر λ است. برای هر عنصر قطری Σ_{ii} در Σ داریم:

$$S_\lambda(\Sigma)_{ii} = \max(\Sigma_{ii} - \lambda, 0) \quad (47-2)$$

ولی این روش معایبی دارد. عملگر آستانه‌گذاری در (45-2)، هر مقدار منفرد را با مقدار λ یکسان اصلاح می‌کند، درحالی‌که مقادیر منفرد از اهمیت متفاوتی برخوردار هستند و نمی‌توانند با آستانه یکسان حذف شوند. مقادیر منفرد بزرگ‌تر عموماً بیانگر ساختارهای اصلی تصویر هستند، لذا بهتر است برای حفظ مؤلفه‌های اصلی تصویر، کمتر حذف شوند. لذا برای بهبود کارایی، نرم هسته وزن‌دار پیشنهاد شده و به‌صورت رابطه (48-2) تعریف می‌شود:

$$\|X\|_{w,*} = \sum_i |w_i \sigma_i(X)|_1 \quad (48-2)$$

که $w = [w_1 \dots w_n]$ و $w_i \geq 0$ وزنی نامنفی است که به $\sigma_i(X)$ اختصاص داده شده‌است. مسئله WNNM معادل رابطه (49-2) خواهد بود که در آن $\|x\|_{w,*}$ نرم هسته‌ی وزن‌دار است:

$$\min_X \|y - x\|_F^2 + \|X\|_{w,*} \quad (49-2)$$

$$\hat{X} = US_w(\Sigma)V^T$$

مشابه مرجع [14]، بردار وزن w به‌صورت رابطه (50-2) تعریف می‌شود:

$$w_j = \frac{2\sqrt{2m}}{(\sigma_j(.) + \epsilon)} \quad (50-2)$$

در رابطه (50-2)، $\sigma_j(.)$ نشان‌دهنده $\sigma_j(x_i)$ و $\sigma_j(\nabla x_i)$ به‌ترتیب برای (59-2) و (60-2) است که $\sigma_j(x_i)$ برابر j امین مقدار منفرد x_i و $\sigma_j(\nabla x_i)$ برابر j امین مقدار منفرد ∇x_i است. m تعداد ستون‌های ماتریس x_i یا ∇x_i است؛ یعنی تعداد قطعات مشابه انتخاب‌شده، و ϵ عددی بی‌نهایت کوچک است. در رابطه (50-2)، $\sigma_j(x_i)$ اولیه را می‌توان به‌صورت رابطه (51-2) تخمین زد:

$$\hat{\sigma}_j^{(1)}(x_i) = \sqrt{\max(\sigma_j^2(b_i) - ms^2, 0)} \quad (51-2)$$

که در آن s اندازه هسته است. در تکرارهای متوالی، مشابه مرجع [۱۴]، $\sigma_j^{(t)}(x_i)$ به صورت زیر تخمین زده می شود:

$$\hat{\sigma}_j^{(t)}(x_i) = \eta \sqrt{s^2 - (\sigma_j(b_i) - \sigma_j(x_i^{(t-1)}))} \quad (52-2)$$

که t شاخص تکرار است. با استفاده از بردار وزن w ، مقادیر منفرد $\hat{x}_i$ توسط عملگر آستانه گذاری تعمیم یافته $S_w(\Sigma)_{ii}$ اصلاح می شوند:

$$S_w(\Sigma)_{ii} = \max(\Sigma_{ii} - w_j, 0) \quad (53-2)$$

تعریف $\sigma_j(\nabla x_i)$ هم مشابه با $\sigma_j(x_i)$ است. بردار وزن پیشنهادی w و عملگر آستانه گذاری $S_w(\Sigma)_{ii}$ نقش مهمی در حذف جزئیات بافت و لبه های ریز دارند. روند کار در الگوریتم (۶-۲) ارائه شده است [۱۴].

الگوریتم (۶-۲): بازسازی تصویر با WNNM معادله (۴۹-۲) [۱۴]

ورودی : تصویر تخریب شده $\mathcal{Y}$

۱. مقداردهی اولیه $y^{(0)} = \mathcal{Y}$, $\hat{x}^{(0)} = y$

۲. حلقه با K تکرار:

۳. منظم سازی تکرارشونده : $y^k = \hat{x}^{(k-1)} + \delta(y - \hat{y}^{(k-1)})$

۴. برای هر قطعه $\mathcal{Y}_j$ در $\mathcal{Y}^{(k)}$ انجام بده :

۵. یافتن قطعات مشابه و گروه بندی در $\mathcal{Y}_j$

۶. تخمین بردار وزن w

۷. تجزیه مقدار منفرد: $[U, \Sigma, V] = \text{svd}(\mathcal{Y}_j)$

۸. تخمین $\hat{X}_j = U S_w(\Sigma) V^T$

۹. پایان حلقه

۱۰. تجميع $\hat{X}_j$ برای تولید تصویر واضح $\hat{x}^{(k)}$

۱۱. پایان حلقه

خروجی : تصویر واضح $\hat{x}^{(K)}$

با اعمال الگوریتم (۶-۲) به هر قطعه از روشنایی و به طور مشابه گرادیان تصویر، می توان شدت روشنایی تصویر میانی $\hat{x}$ و گرادیان $\nabla \hat{x}$ آن را بازسازی کرد.

▪ تابع هدف

با گروه‌بندی بردارهای تشکیل شده توسط قطعات مشابه غیرمحلی در یک ماتریس، پیکسل‌های نویزی و مات را می‌توان با صرف نظر کردن از مقادیر منفرد در فرآیند LRMA حذف کرد. مدل پیشنهادی مات‌زدایی کور تصویر در این روش به صورت بهینه‌سازی (۵۴-۲) تنظیم شده است:

$$\{\hat{x}, \hat{k}\} = \arg \min_{x, k} \|x \otimes k - b\|_1 + \gamma \|k\|_2^2 + \lambda \sum_i \|x_i\|_{w,*} + \sigma \sum_i \|\nabla x_i\|_{w,*} \quad (54-2)$$

که در آن $\nabla = (\nabla_h, \nabla_v)^T$ نشان‌دهنده عملگر گرادیان تصویر است. علاوه بر این، x_i و ∇x_i به ترتیب ماتریس‌های انباشته شده با تصویر مشابه غیرمحلی و قطعات گرادیان را نشان می‌دهند. بردار وزن w باید با مقادیر منفرد x یا ∇x_i ، یعنی $\sigma(x_i)$ یا $\sigma(\nabla x_i)$ رابطه معکوس داشته باشد.

بر اساس روش جداسازی نیمه-درجه دو^۱ تصاویر پنهان میانی و هسته‌های تاری به نوبت و با این فرض که یکی از آن‌ها معلوم باشد، تخمین زده می‌شوند.

▪ به‌روزرسانی تصاویر پنهان

در این زیرمسئله، هسته تاری k را ثابت فرض کرده و مسئله بهینه‌سازی (۵۴-۲) به صورت زیر خواهد بود:

$$\hat{x} = \arg \min_{x, k} \|x \otimes k - b\|_1 + \lambda \sum_i \|x_i\|_{w,*} + \sigma \sum_i \|\nabla x_i\|_{w,*} \quad (55-2)$$

برای حل رابطه (۵۵-۲)، از روش جداسازی نیمه-درجه دو استفاده می‌شود [۲۷]. با معرفی متغیرهای کمکی d ، p و $g = (g_h, g_v)^T$ ، تابع هزینه (۵۵-۲)، به صورت بهینه‌سازی (۵۶-۲) بازنویسی می‌شود:

$$\begin{aligned} \hat{x} = \arg \min_{x, k} & \|x \otimes k - b - d\|_2^2 + \beta \|x - p\|_2^2 + \tau \|\nabla x - g\|_2^2 + \eta \|d\|_1 \\ & + \lambda \sum_i \|p_i\|_{w,*} + \sigma \sum_i \|g_i\|_{w,*} \end{aligned} \quad (56-2)$$

¹ Half-quadratic splitting

رابطه (۵۶-۲) را می توان برای حل جداگانه x, d, p و g به چهار زیرمسئله تقسیم کرد. راه حل x از طریق FFT، با رابطه (۵۷-۲) قابل حل است:

$$x = F^{-1} \left(\frac{\overline{F(k)}F(b+d) + \beta F(p) + \tau F_g}{\overline{F(k)}F(k) + \beta + \tau \overline{F(\nabla)}F(\nabla)} \right) \quad (۵۷-۲)$$

که $F_g = \overline{F(\nabla_h)}F(g_h) + \overline{F(\nabla_v)}F(g_v)$ بر اساس x می توان d را با کمینه سازی زیر محاسبه کرد:

$$\hat{d} = \arg \min_d \|x \otimes k - b - d\|_2^2 + \eta \|d\|_1$$

$$d = \text{sign}(x \otimes k - b) \max(\|x \otimes k - b\| - \eta, 0) \quad (۵۸-۲)$$

و همچنین زیرمسئله های مربوط به p و g هر کدام می توانند با حل روابط زیر تخمین زده شوند:

$$\hat{p} = \arg \min_p \beta \|x - p\|_2^2 + \lambda \sum_i \|p_i\|_{w,*} \quad (۵۹-۲)$$

$$\hat{g} = \arg \min_g \tau \|\nabla x - g\|_2^2 + \sigma \sum_i \|g_i\|_{w,*} \quad (۶۰-۲)$$

که مطابق آنچه در الگوریتم (۴-۲) گفته شد، محاسبه می شوند.

▪ تخمین هسته های تاری

در این زیرمسئله، تصویر پنهان x را ثابت فرض کرده و برای عملکرد و پایداری بهتر، از روش ماتریدایی سریع [۲۶] برای تخمین هسته تاری بر اساس گرادیان تصاویر و نرم دو عبارت همانندی داده استفاده می شود:

$$\hat{k} = \arg \min_k \|k \otimes \nabla x - \nabla b\|_2^2 + \gamma \|k\|_2^2 \quad (۶۱-۲)$$

که یک کمینه سازی کمترین مربعات با منظم سازی تیخونوف است و منجر به یک راه حل فرم بسته برای k می شود [۱۰]:

$$\hat{k} = F^{-1} \left(\frac{\overline{F(\nabla x)}F(\nabla b)}{\overline{F(\nabla x)}F(\nabla x) + \gamma} \right) \quad (۶۲-۲)$$

ساختار هرمی $\{b_0, b_1, \dots, b_n\}$ ، برای یک تصویر مات مشاهده شده b_0 ایجاد می‌شود و فرآیند تخمین هسته تاری از سطح b_n تا سطح وضوح کامل b_0 ، انجام می‌گیرد. در سطوح میانی $\{b_1, \dots, b_n\}$ از روش [۵] برای تخمین هسته‌های ماتی و تصاویر پنهان استفاده شده و الگوریتم [۱۰] برای تخمین نهائی هسته تاری در سطح وضوح کامل b_0 به‌کار می‌رود. مراحل اصلی و نتایج مات‌زدایی در الگوریتم (۷-۲) و شکل (۱۷-۲) ارائه شده‌است.

الگوریتم (۷-۲): مات‌زدایی با دانش پیشین رتبه پائین [۱۰]

ورودی: نمونه‌کاهی تصویر مات b برای تولید هرم تصاویر $\{b_0, b_1, \dots, b_n\}$

۱. تخمین هسته $\hat{k}_i$ و تصویر پنهان $\hat{x}_i$ ($i = 1, \dots, n$) در لایه‌های میانی با روش مرجع [۵] و خروجی $\hat{k}_1$

۲. نمونه‌افزایی $\hat{k}_1$ و تولید هسته تاری k_0 برای تصویر وضوح کامل b_0

۳. حلقه با ۵ تکرار:

۴. محاسبه d با معادله (۵۸-۲)

۵. $\beta \leftarrow 2\sigma$

۶. حلقه تکرار تا زمانی که $\beta > \beta_{max}$:

۷. محاسبه p با رابطه (۵۹-۲)

۸. $\tau \leftarrow 2\lambda$

۹. حلقه تکرار تا زمانی که $\tau > \tau_{max}$:

۱۰. محاسبه g با معادله (۶۰-۲)

۱۱. محاسبه x با معادله (۵۷-۲)

۱۲. $\tau \leftarrow 3\tau$

۱۳. پایان حلقه

۱۴. $\beta \leftarrow 3\beta$


۱۵. پایان حلقه

۱۶. تخمین هسته تاری k با معادله (۶۲-۲)

۱۷. $\lambda \leftarrow 0.9\lambda$, $\sigma \leftarrow 0.9\sigma$

۱۸. پایان حلقه


خروجی: به روش واپیچش مرجع [۳۵]، با آخرین هسته k تخمینی، تصویر واضح نهائی x حاصل می‌شود.



شکل (۲-۱۷): خروجی مراحل فرآیند تخمین هسته تاری کل به جزء با دانش پیشین رتبه پائین [۱۰]. اندازه تصویر میانی و هسته تاری در هر مقیاس مشخص شده است.


❖ نتایج

برای اثبات اثربخشی دانش پیشین رتبه پائین [۱۰]، نتایج در شکل (۲-۱۸) مقایسه شده است. شکل (۲-۱۸) (ب) نشان می‌دهد که تصاویر واضح را نمی‌توان فقط با استفاده از ویژگی‌های درجه پائین گرادیان یا فقط شدت روشنایی به دست آورد، ولی تصویر مات‌زدایی شده با ویژگی‌های درجه پائین شدت روشنایی و گرادیان، دارای کیفیت بصری و PSNR بالایی است [۱۰]. این نتایج نشان می‌دهد که دانش پیشین پیشنهادی نقش مهمی در مات‌زدایی تصویر ایفا می‌کند.



شکل (۲-۱۸): اثربخشی دانش پیشین رتبه پائین [۱۰]. (الف) تصویر مات ورودی. (ب) نتیجه مات‌زدایی شده فقط مبتنی بر گرادیان ($\|\nabla x_i\|_{w,*}$). (ج) نتیجه مات‌زدایی شده فقط مبتنی بر شدت روشنایی ($\|x_i\|_{w,*}$). (د) نتیجه مات‌زدایی با استفاده از الگوریتم رتبه پائین [۱۰].

با اینکه روش رتبه پائین، محاسبات را ساده‌تر و نتایج قابل قبول‌تری ارائه کرده‌است، اما از آنجا که مقادیر منفرد کوچک که بیانگر بافت‌های تصویر است را حذف می‌کند، لذا در صورتی که یک تصویر تار، حاوی بافت‌های پیچیده باشد، به‌خوبی عمل نمی‌کند؛ زیرا اکثر بافت‌ها حذف خواهند شد و تعداد کمی از لبه‌های تیز برای تخمین هسته باقی می‌ماند. در شکل (۲-۱۹)، به این دلیل که تصویر تار حاوی بافت‌های پیچیده (مثل چمن) است، روش [۱۰] نمی‌تواند نتایج موفقی تولید کند.



(الف) تصویر مات



(ب) نتیجه روش [۱۰]

شکل (۲-۱۹): عدم موفقیت الگوریتم رتبه پائین [۱۰].

۲-۳-۵- دانش پیشین مبتنی بر گراف


روش مبتنی بر گراف [۱۳]، سعی دارد با تخمین یک تصویر اسکلت^۱ که گرادیان‌های قوی را حفظ و جزئیات را هموار می‌کند، تخمین دقیقی از هسته تار ارائه دهد. در نهایت، با استفاده از هسته تار محاسبه شده، می‌توان الگوریتم‌های مات‌زدایی غیرکور را برای بازیابی تصویر هدف به کار برد.

در این ایده، پیکسل‌ها به‌عنوان گره‌هایی با یال‌های وزن‌دار که شباهت‌های بین پیکسلی را نشان می‌دهند، مدل شده‌اند. مشاهده شده که در تصویر اسکلت، وزن‌های یال‌های یک گراف، توزیع دوقله‌ای منحصر به فردی دارند، بر خلاف تصویر مات. بنابراین، یک دانش پیشین تغییرات کلی گراف بازموزون^۲ (RGTV) برای تقویت توزیع دوقله‌ای مطلوب پیشنهاد شده‌است [۱۳].

^۱ Skeleton image

^۲ Reweighted Graph Total Variation

به عنوان یک مثال، برای هر یک از سه قطعه نمونه مشخص شده با کادر قرمز در شکل (۲-۲۰)، یک گراف همبند ساخته شده است. با بررسی توزیع وزن یال این گراف‌ها، که در آن وزن یال $w_{i,j}$ با استفاده از رابطه (۲-۵) محاسبه می‌شود، ملاحظه می‌شود که هم قطعه واضح و هم نسخه اسکلت آن، دارای توزیع دوقله‌ای وزن‌های یال هستند، در حالی که قطعات مات به دلیل اثر فیلتر پائین‌گذر در طول فرآیند ماتی، فاقد این ویژگی هستند.



شکل (۲-۲۰): توزیع دوقله‌ای وزن یال‌های گراف [۱۳]. (الف) تصویر واضح. (ب) تصویر مات. (ج) تصویر اسکلت. ردیف وسط، مربوط به قطعات مشخص شده در تصاویر ردیف اول می‌باشد و ردیف سوم، توزیع وزن یال این قطعات (هیستوگرام) را نمایش می‌دهد.

در نمودارهای ردیف آخر شکل (۲-۲۰)، محور x اختلاف بین پیکسلی گسسته $d = |x_i - x_j|$ برای وزن یال $w_{i,j}$ و محور y برای قطعات مختلف تصویر، وزن‌های مشخص d را نشان می‌دهد. توزیع دوقله‌ای به این معنی است که اختلافات بین پیکسلی در یک قطعه از تصویر، یا خیلی کم و یا خیلی زیاد هستند.

▪ دانش پیشین تغییرات کلی گراف بازموزون

برای تقویت توزیع دوقله‌ای وزن یال، یک دانش پیشین تغییرات کلی گراف بازموزون (RGTV) پیشنهاد شده‌است. ابتدا عملگر گرادیان سیگنال گراف x را تعریف می‌کنیم. عنصر j ام گرادیان گره $i \in V$ به صورت زیر تعریف می‌شود:

$$(\nabla_i x)_j \triangleq x_j - x_i \quad (۶۳-۲)$$

تغییرات کلی گراف^۱ (GTV) به صورت رابطه (۶۴-۲) تعریف شده‌است:

$$\|x\|_{GTV} = \sum_{i \in V} \|\text{diag}(W_{i,\cdot}) \nabla_i x\|_1 = \sum_{i=1}^N \sum_{j=1}^N w_{i,j} |x_j - x_i| \quad (۶۴-۲)$$

که $W_{i,\cdot}$ سطر i ام ماتریس همجواری W است. دانش پیشین GTV، W را با استفاده از رابطه (۵-۲) مقداردهی اولیه می‌کند و آن را ثابت نگه می‌دارد؛ از این رو، توزیع دوقله‌ای، وزن یال را تقویت نمی‌کند. بنابراین به جای استفاده از W ثابت، از دانش پیشین RGTV استفاده می‌شود که در آن وزن‌های گراف $W(x)$ نیز توابعی از x هستند [۱۳]:

$$\|x\|_{RGTV} = \sum_{i \in V} \|\text{diag}(W_{i,\cdot}(x)) \nabla_i x\|_1 = \sum_{i=1}^N \sum_{j=1}^N w_{i,j}(x_i, x_j) |x_j - x_i| \quad (۶۵-۲)$$

که $W_{i,\cdot}(x)$ ردیف i ام $W(x)$ است و $w_{i,j}(x_i, x_j)$ عنصر $W(x)(i, j)$ است. این پسوند تفاوت اساسی ایجاد می‌کند؛ زیرا تنظیم‌کننده جفت (i, j) اکنون $d \exp\left(-\frac{d^2}{\sigma^2}\right) w_{i,j}(x_i, x_j) |x_j - x_i|$ است. بنابراین، تنظیم‌کننده RGTV می‌تواند به طور موثر توزیع وزن یال مطلوب دوقله‌ای تصاویر واضح را ارتقا دهد. اکنون لاپلاسیان گراف بازموزون را می‌توان به صورت رابطه (۶۶-۲) در نظر گرفت [۱۳]:

$$x^T L(x) x = \sum_{i=1}^N \sum_{j=1}^N w_{i,j}(x_i, x_j) (x_j - x_i)^2 \quad (۶۶-۲)$$

^۱ Graph Total Variation

که در آن ماتریس $L(x)$ تابعی از x و $w_{i,j}(x_i, x_j)$ مشابه همان تعریف در رابطه (۶۵-۲) است. تنظیم‌کننده جفت (i, j) اکنون $w_{i,j}(x_i, x_j)(x_j - x_i)^2 = \exp\left(-\frac{d^2}{\sigma^2}\right) \cdot d^2$ می‌شود. به این ترتیب، لاپلاسیان گراف بازموزون، توزیع دوقله‌ای وزن یال مطلوب را نیز افزایش می‌دهد. مرجع [۱۳] با دیفرانسیل‌گیری از رابطه (۶۴-۲)، رابطه (۶۷-۲) را ارائه می‌دهد که c' ضریب مشتق شده از عملگر لاپلاسیان است:

$$(\partial \|x\|_{GTV})_i = c' \cdot \sum_{j=1}^N \gamma_{i,j} \cdot (x_i - x_j) = c' \cdot \left(\sum_{j=1}^N \gamma_{i,j} x_i - \sum_{j=1}^N \gamma_{i,j} x_j \right) \quad (۶۷-۲)$$

$$\gamma_{i,j} = \frac{w_{i,j}}{\max\{|x_j - x_i|, \epsilon\}} \quad (۶۸-۲)$$

که ϵ به عنوان یک ثابت کوچک معرفی می‌شود. با در نظر گرفتن $\gamma_{i,j}$ به عنوان یک وزن گراف، می‌توان یک ماتریس همجواری Γ جدید با تابع وزن جدید (۶۸-۲) تعریف کرد و (۶۷-۲) را برای GTV به شکل ماتریس به صورت زیر بازنویسی کرد که 1 برداری با درایه‌های یک است:

$$L_\Gamma \triangleq \text{diag}(\Gamma 1) - \Gamma \quad (۶۹-۲)$$

L_Γ که یک ماتریس مثبت معین^۱ است را ماتریس L_1 -Laplacian می‌نامند [۱۳].

$$L_\Gamma = U_\Gamma \Lambda_\Gamma U_\Gamma^T \quad (۷۰-۲)$$

که در آن Λ_Γ یک ماتریس قطری شامل فرکانس‌های گراف GTV و U_Γ دارای مؤلفه‌های فرکانس گراف متناظر با ستون‌ها است.

▪ الگوریتم مات‌زدایی کور تصویر

با استفاده از دانش پیشین RGTV پیشنهادی، تابع بهینه‌سازی به صورت رابطه (۷۱-۲) خواهد بود:

$$\hat{x}, \hat{k} = \arg \min_{x, k} \frac{1}{2} \|x \otimes k - b\|_2^2 + \beta \|x\|_{RGTV} + \mu \|k\|_2^2 \quad (۷۱-۲)$$

^۱ Positive Definite Matrix (PDM)

بهینه‌سازی (۷۱-۲) غیرمحدب^۱ و مشتق‌ناپذیر است، لذا برای حل آن، روش کل به جزء [۲۱] اعمال می‌شود. روش کار در هر مقیاس در الگوریتم (۸-۲) شرح داده شده است.

الگوریتم (۸-۲): مات‌زدایی کور در هر مقیاس [۱۳]

ورودی : تصویر مات b و اندازه هسته تار $h \times h$

۱. مقداردهی اولیه $\hat{k}$ با تابع دلتا یا مقیاس قبلی

۲. حلقه تکرار تا رسیدن به همگرایی :

۳. محاسبه $\hat{x}$ با حل معادله (۷۲-۲) (الگوریتم ۹-۲)

۴. محاسبه $\hat{k}$ با حل معادله (۷۵-۲)

۵. $\beta \leftarrow \beta/1.1$

۶. پایان حلقه

خروجی : هسته $\hat{k}$ تخمینی و تصویر اسکلت $\hat{x}$

که $\hat{k}$ به دست آمده، دوباره در همین الگوریتم برای مقیاس بعدی استفاده می‌شود، درحالی‌که تصویر اسکلت $\hat{x}$ بلااستفاده است و فقط برای تخمین $\hat{k}$ مورد استفاده قرار می‌گرفت. برای بازیابی تصویر واضح، می‌توان از الگوریتم‌های مات‌زدایی غیرکور تصویر، مانند [۹] و [۶] استفاده کرد.

▪ **بازسازی تصویر اسکلت**

با توجه به $\hat{k}$ ، بهینه‌سازی (۷۱-۲) برای حل x ، معادل بهینه‌سازی (۷۲-۲) خواهد بود:

$$\hat{x} = \arg \min_x \frac{1}{2} \|x \otimes \hat{k} - b\|_2^2 + \beta \|x\|_{RGTV} \quad (72-2)$$

RGTV یک دانش پیشین مشتق‌ناپذیر و غیرمحدب است، که در آن وزن یال‌ها تابعی از x هستند. برای حل (۷۲-۲)، ابتدا x را با L_Γ مقداردهی اولیه شده بهینه‌سازی کرده، سپس L_Γ با $L_\Gamma(\hat{x})$ به‌روزرسانی می‌شود و دوباره x بهینه‌سازی می‌گردد. این الگوریتم متناوب تا زمان همگرایی، به‌صورت تکرارشونده اجرا می‌شود. مراحل حل (۷۰-۲) در الگوریتم (۹-۲) خلاصه شده است. با تثبیت L_Γ و $\hat{k}$ برای حل x ، مسئله به یک مات‌زدایی تصویر غیرکور با یک تنظیم‌کننده لاپلاسیان گراف تبدیل خواهد شد:

¹ Non-convex

$$\hat{x} = \arg \min_x \frac{1}{2} \|x \otimes \hat{k} - b\|_2^2 + \beta \cdot x^T L_{\Gamma} x \quad (73-2)$$

از آنجا که (73-2) یک تابع بهینه‌سازی محدب است، معادل حل رابطه خطی (74-2) است:

$$(\hat{K}^T \hat{K} + 2\beta \cdot L_{\Gamma}) \hat{x} = \hat{K}^T b \quad (74-2)$$

که در آن $\hat{K}$ یک نمایش ماتریسی از پیچش با $\hat{k}$ است و می‌توان (74-2) را با استفاده از روش گرادیان مزدوج^۱ (CG) حل کرد [26].

الگوریتم (9-2): حل معادله (72-2) [13]
ورودی: تصویر مات b و هسته $\hat{k}$ تخمینی
۱. مقداردهی اولیه L_{Γ} به صورت لاپلاسیان گراف بدون وزن
۲. حلقه تکرار تا رسیدن به همگرایی:
۳. به‌روزرسانی $\hat{x}$ با حل معادله (74-2) با روش گرادیان مزدوج (CG)
۴. به‌روزرسانی $L_{\Gamma} = L_{\Gamma}(\hat{x})$ با معادلات (2-68) و (2-69)
۵. پایان حلقه
خروجی: تصویر اسکلت $\hat{x}$ بازسازی‌شده

▪ تخمین هسته تاری

برای جلوگیری از ظهور آلاینده‌ها، راه حل k از روی $\hat{x}$ ، در حوزه گرادیان به دست می‌آید. لذا بهینه‌سازی (71-2) برای تخمین هسته تاری به صورت زیر خواهد بود:

$$\hat{k} = \arg \min_k \frac{1}{2} \|\nabla \hat{x} \otimes k - \nabla b\|_2^2 + \mu \|k\|_2^2 \quad (75-2)$$

حل این رابطه از طریق FFT [26] انجام می‌شود. پس از به دست آوردن $\hat{k}$ ، مؤلفه‌های منفی برابر با صفر و k نرمال می‌شود تا شرط $\sum_i k_i = 1$ برقرار باشد.


¹ Conjugate Gradient

❖ نتایج

نتایج این روش، توسط سه معیار آماری برای نسبت‌های خطا، یعنی میانگین و بدترین نرخ خطا، و نرخ موفقیت در جدول (۲-۲) ارائه شده‌است. الگوریتم پیشنهادی نسبت به الگوریتم‌های دیگر، در هر سه معیار برتر است. علاوه بر ارزیابی کمی، شکل (۲-۲۱) برخی نمونه‌های کیفی از موارد چالش‌برانگیز را نشان می‌دهد. الگوریتم پیشنهادی در مقایسه با الگوریتم‌های رقیب، به نتایج قوی‌تری دست می‌یابد.

جدول (۲-۲): مقایسه‌های کمی روش‌های [۲۴]، [۲۶]، [۱۱]، [۳۴] و [۱۳] روی مجموعه داده Sun[۳۲].

Blind Deblurring Method	Mean error raito	Worst error raito	Success rate ($r \leq 5$)
Cho & Lee [26]	8.7	111.1	65.5 %
Krishnan <i>et al.</i> [34]	11.7	133.2	24.8 %
Michaeli & Irani [33]	2.6	9.3	95.9 %
Xu & Jia [24]	3.6	65.3	85.8 %
Pan <i>et al.</i> [11]	1.6	8.8	99.1 %
[13] + non-blind deconvolution[9]	1.5	5.1	99.8 %



شکل (۲-۲۱): مثالی از مات‌زدایی کور. (الف) تصویر مات و هسته تاری متناظر. (ب) نتیجه الگوریتم [۱۱]. (ج) نتیجه الگوریتم [۱۳].

۲-۳-۶- دانش‌پیشین ساختار پنهان چندمقیاسه (MSLS)

در این روش، یک تصویر مات با اندازه بزرگ، به‌عنوان یک دانش‌پیشین ساختار پنهان از تصویر واضح نامعلوم تعریف می‌شود. به این صورت که در یک هرم تصویر از بزرگ‌ترین مقیاس به کوچک‌ترین مقیاس، تصاویر واضح از تصویر مات بازسازی می‌شوند و دانش‌پیشین تصویر با استفاده از تصویر واضح

بازسازی شده جدید به روزرسانی می شود. از این دانش پیشین کل به جزء به عنوان ساختار پنهان چندمقیاسه^۱ (MSLS) یاد می شود. در واقع اگر یک تصویر واضح و نسخه مات متناظر آن را چند بار نمونه کاهی کنیم، این جفت تصویر، به تدریج به هم شبیه تر می شوند. به عبارت دیگر، تصویری که از یک مشاهده مات نمونه کاهی می شود، تقریباً یک نسخه با وضوح پائین از تصویر واضح پنهان است [۱۲].

▪ بازسازی اولیه در مقیاس های بزرگ

با شروع از بزرگ ترین مقیاس، دانش پیشین تصویر، برای بازیابی کور یک تصویر واضح در مقیاس کوچک تر به کار گرفته می شود. به این ترتیب که آخرین تصویر واضح بازسازی شده در مقیاس فعلی، به عنوان دانش پیشین ساختار پنهان مقیاس کوچک تر بعدی مورد استفاده قرار می گیرد. این راهکار به تدریج از بزرگ ترین مقیاس به کوچک ترین مقیاس ادامه می یابد. در مرجع [۱۲]، به جای منظم سازی پیچیده و غیرمحدب x در بازسازی تصویر واضح، از دانش پیشین MSLS پیشنهادی و راهکار تطبیق خودمثال محلی^۲ [۱۵] استفاده شده است. این فرآیند در هر مقیاس بزرگ،^۳ شامل سه مرحله است که در الگوریتم (۲-۱۰) تشریح شده است.


الگوریتم (۲-۱۰): بازسازی اولیه در هر مقیاس بزرگ [۱۲]
ورودی : تصویر مات b در مقیاس فعلی، تصویر پیشین x_{pr} و اندازه هسته $h \times h$
خروجی : هسته تخمینی $\hat{k}$ و تصویر واضح پنهان x_l
۱. مقداردهی اولیه تصویر پنهان $x_l = b$ و $\hat{k} = \delta$
۲. حلقه تکرار $iter = 1 \rightarrow max_iteration$
(a) تخمین $\hat{x}$ با استفاده از x_l و x_{pr}
(b) کمینه سازی معادله (۲-۷۸) برای تخمین $\hat{k}$ با $\hat{x}$
(c) کمینه سازی معادله (۲-۸۱) برای به روزرسانی x_l با $\hat{k}$
پایان حلقه
۳. بازگشت $\hat{k}$ و x_l

¹ Multi-Scale Latent Structure

² Local self-example matching

³ Coarse

در مرحله (a)، یک تصویر واضح با تطبیق خودمثال محلی سریع به کمک قطعات تصویر مقیاس قبلی به صورت کور بازسازی می شود. مرحله (b) و (c) معادل تخمین هسته جدید با جبران خطا و یک ماتزدایی غیرکور تصویر هستند، که هر دو بهینه سازی محدب هستند و می توان با تبدیل فوریه سریع (FFT) آن ها را حل کرد. دانش پیشین تصویر، ابتدا با تصویر بزرگ ترین مقیاس x_α مقداردهی اولیه می شود. بعد از انجام فرآیند در یک مقیاس، دانش پیشین تصویر، با نتایج ماتزدایی شده جدید به روزرسانی می شود و بازسازی مقیاس کوچک بعدی ادامه می یابد. نمودار بازسازی اولیه در شکل (۲۲-۲) نشان داده شده است.



شکل (۲۲-۲): بازنمایی هرمی بازسازی اولیه در مقیاس های بزرگ [۱۲]. (a) بازسازی تصویر واضح. (b) تخمین هسته. (c) ماتزدایی غیرکور. برای ساخت هرم تصویر چندمقیاسه از فاکتور مقیاس $\beta = \log_2 3$ استفاده شده است.

مرحله (a) - بازسازی تصویر واضح با تطبیق خودمثال محلی: تصویر واضح پنهان مقیاس

کوچک تر با راهکار تطبیق خودمثال محلی سریع، الهام گرفته از [۱۵] بازسازی می شود. تصویر واضح پنهان x_l در ابتدا با تصویر مات b مقداردهی اولیه می شود. تصویر پنهان x_l به قطعات هم پوشانیده شده کوچک تقسیم می شود، سپس هر قطعه i نزدیک ترین همسایه اش را در منطقه محلی مربوطه تصویر دانش پیشین مقیاس بزرگ تر x_{pr} پیدا می کند. اختلاف قطعات از رابطه (۷۶-۲) محاسبه می شود:

$$d(i, j) = \|P_i x_l - P_j x_{pr}\|_2, \quad j \in \mathcal{N}(i') \quad (76-2)$$

که P_i عملگر استخراج قطعه i ام است. i' یک حالت روی تصویر دانش پیشین x_{pr} است. $\mathcal{N}(i')$ همسایگی محلی حالت i' را نشان می‌دهد. $d(i, j)$ نشان‌دهنده اختلاف میان قطعه i و j است. در نهایت، قطعات مشابه جستجو شده، با محاسبه میانگین وزن‌دار در مناطق همپوشانی شده، به‌منظور جلوگیری از آثار بلوکی^۱ با هم ترکیب می‌شوند.

مرحله (b) - تخمین هسته با جبران خطا: پس از بازسازی تصویر واضح $\hat{x}$ ، هسته تاری بر اساس آن تخمین زده می‌شود. از آنجا که تصویر واضح مقیاس کوچک‌تر، از تصویر دانش پیشین مقیاس بزرگ‌تر بازسازی شده است، لذا یک خطای اجتناب‌ناپذیر بین تصویر بازسازی شده و صحیح مبنا وجود دارد. به همین دلیل به‌منظور جبران خطا در این مرحله، یک مدل مات‌شدگی جدید برای تخمین هسته پیشنهاد شده است:

$$b = k \otimes (\hat{x} + x_c) + n \quad (77-2)$$

که در آن $\hat{x}$ تصویر بازسازی شده و x_c یک لایه جبرانی است و $\hat{x} + x_c$ می‌تواند معادل تصویر واضح پنهان x باشد تا هسته تخمینی $\hat{k}$ دقیق‌تری حاصل شود. با توجه به $\hat{x}$ و مدل (77-2)، محاسبه $\hat{k}$ و x_c منجر به حل مسئله بهینه‌سازی (78-2) می‌شود:

$$\arg \min_{k, x_c} \frac{1}{2} \|k \otimes \nabla(\hat{x} + x_c) - \nabla b\|_2^2 + \lambda_1 \|k\|_2^2 + \lambda_2 \|x_c\|_1 \quad (78-2)$$

در اینجا یک تغییر متغیر، برای محدب‌سازی اعمال می‌شود. یعنی جایگزینی $k \otimes \nabla x_c$ با متغیر جدید v . بنابراین با فرض تنک بودن x_c و $k \otimes \nabla x_c$ ، می‌توان $\|v\|_1$ را جایگزین $\|x_c\|_1$ کرد. اکنون تابع هدف (78-2) به‌صورت یک مسئله بهینه‌سازی محدب (79-2) تنظیم می‌گردد:

$$\arg \min_{k, v} \frac{1}{2} \|k \otimes \nabla \hat{x} + v - \nabla b\|_2^2 + \lambda_1 \|k\|_2^2 + \lambda_2 \|v\|_1 \quad (79-2)$$

¹ Blocking artifact

$\nabla = \{\nabla_x, \nabla_y\}$ به ترتیب عملگرهای مشتق در جهتهای افقی و عمودی هستند. $v = \{v_x, v_y\}$

لایه‌های متناظر جهتهای افقی و عمودی هستند و با صفر مقداردهی اولیه می‌شوند. برای حل سریع

k ، راه حل آن در حوزه فرکانس محاسبه می‌شود:

$$k = F^{-1} \left(\frac{\overline{F(\nabla \hat{x})} F(\nabla b) - \overline{F(\nabla \hat{x})} F(v)}{\overline{F(\nabla \hat{x})} F(\nabla \hat{x}) + 2\lambda_1} \right) \quad (۸۰-۲)$$

مرحله (c) - مات‌زدایی غیرکور تصویر: بعد از تخمین هسته $\hat{k}$ ، برای به‌روزرسانی تصویر پنهان

x_l ، مات‌زدایی غیرکور انجام می‌گیرد. برای این کار از الگوریتم غیرکور منظم‌سازی تغییرات کلی^۱ (TV)،

که به‌صورت زیر تنظیم شده‌است استفاده می‌شود که در آن μ یک پارامتر تنظیم است:

$$\arg \min_x \frac{1}{2} \|\hat{k} \otimes x - b\|_2^2 + \mu \|\nabla x\|_1 \quad (۸۱-۲)$$


▪ بازسازی نهائی در کوچک‌ترین مقیاس

بازسازی اولیه در تخمین مقیاس‌های بزرگ به سرعت انجام می‌شود، اما ممکن است منجر به ظهور

آلایه‌ها شود. لذا یک بازسازی نهائی در کوچک‌ترین مقیاس، با الهام از [۲۴] انجام می‌گیرد. با توجه به

تصویر بازسازی شده مقدماتی $\tilde{x}$ به‌عنوان مقداردهی اولیه، فرآیند بازسازی نهائی در کوچک‌ترین مقیاس

در شکل (۲۳-۲) نشان داده شده‌است.



شکل (۲۳-۲): نمودار بازسازی نهائی در کوچک‌ترین مقیاس [۱۲]. (a) به‌روزرسانی دانش پیشین.

(b) بازسازی تصویر واضح. (c) تخمین هسته. (d) مات‌زدایی غیرکور.

¹ Total Variation

از آنجا که بازسازی نهائی در کوچک‌ترین مقیاس به کار گرفته می‌شود، هیچ دانش پیشینی از تصویر در مقیاس‌های کل^۱ یا بزرگ‌تر به‌روزرسانی نشده‌است، بنابراین، دانش پیشین تصویر، با فیلترکردن و نمونه‌کاهی تصویر بازیابی‌شده، در هر تکرار به‌روزرسانی شده و از یک فیلتر هدایت‌شونده برای حفظ لبه‌ها و کاهش آلایه‌های احتمالی استفاده می‌شود. علاوه‌براین، مشتقاتی از درجه بالاتر در عبارت همانندی داده به کار برده می‌شود تا محدودیت‌های بیشتری برای تخمین دقیق هسته ایجاد شود:

$$\arg \min_{k,v} \frac{1}{2} \|k \otimes \nabla_* \hat{x} + v_* - \nabla_* b\|_2^2 + \lambda_3 \|k\|_2^2 + \lambda_4 \|v_*\|_1 \quad (۸۲-۲)$$

که در آن $\nabla_* = \{\nabla_x, \nabla_y, \nabla_{xx}, \nabla_{yy}, \nabla_{xy}\}$ و $v_* = \{v_x, v_y, v_{xx}, v_{yy}, v_{xy}\}$ روند کار در الگوریتم (۱۱-۲) خلاصه شده‌است.

الگوریتم (۱۱-۲): بازسازی نهائی در کوچک‌ترین مقیاس [۱۲]

ورودی: تصویر مات b و تخمین حاصل از بازسازی اولیه $\tilde{x}$ و اندازه هسته $h \times h$

خروجی: هسته اصلاح‌شده $\hat{k}$ و تصویر واضح پنهان x_l

۱. مقداردهی اولیه تصویر پنهان $x_l = \tilde{x}$

۲. حلقه تکرار $iter = 1 \rightarrow max_iteration$

(a) به‌روزرسانی تصویر پیشین x_{pr} با فیلترکردن و نمونه‌کاهی x_l

(b) تخمین $\hat{x}$ با استفاده از x_l و x_{pr}

(c) کمینه‌سازی معادله (۸۲-۲) برای به‌روزرسانی $\hat{k}$ با $\hat{x}$

(d) کمینه‌سازی معادله (۸۱-۲) برای به‌روزرسانی x_l با $\hat{k}$

پایان حلقه

۳. بازگشت $\hat{k}$ و x_l

❖ نتایج


روش‌های قبلی [۵، ۸-۱۳، ۲۰، ۲۱، ۳۸] مات‌زدایی کور را به‌عنوان یک مسئله بهینه‌سازی مشترک در

نظر می‌گرفتند و دانش‌های پیشین تصویر را معرفی کردند، که می‌تواند مات‌شدگی تصویر را جریمه

^۱ Coarse

^۲ Guided filter

کند و وضوح تصویر را افزایش دهد. عدم استفاده از دانش‌های پیشینی که غیرمحدب هستند یا از نظر محاسباتی پرهزینه هستند، موجب شده این الگوریتم نسبتاً سریع، نتایج قابل قبولی ارائه دهد. مثالی از عملکرد آن در شکل (۲-۲۴) نشان داده شده است.




شکل (۲-۲۴): تصاویر مات و مات‌زدایی شده. (الف) تصاویر مات و هسته‌های تاری صحیح مبنا. (ب). نتیجه [۲۴]. (ج) نتیجه [۱۲].

اما در این رویکرد، برخلاف سایر روش‌های معرفی شده در این پایان‌نامه، برای بازسازی یک تصویر واضح میانی از نمونه‌برداری^۱ و فراتفکیک‌پذیری^۲ استفاده شده است. به همین منظور احتمال ظهور آلاینده‌ها در تخمین هسته تاری افزایش می‌یابد و از طرفی، باید در تصویر مات ورودی، اشیائی وجود داشته باشند که اندازه آن‌ها بزرگ‌تر از هسته تاری باشد، در غیر این صورت اشیاء بعد از نمونه‌کاهی حذف خواهند شد. در این حالت، عبارت همانندی داده ناموفق بوده و به یک هسته نامطمئن همگرا خواهد شد. برای مثال در شکل (۲-۲۵)، نمونه‌ای از یک نتیجه مات‌زدایی کور نامطلوب نشان داده شده است.

^۱ Sampling

^۲ Super-resolution

در شکل (۲-۲۵)، بخش عمده تصویر را آسمان صاف تشکیل می‌دهد و فقط یک توربین بادی و تپه داریم که توربین‌های بادی کوچک در پس‌زمینه پس از نمونه‌کاهی، حذف خواهند شد.



شکل (۲-۲۵): نتیجه نامطلوب مات‌زدایی کور. (الف) یک تصویر مات و هسته تاری حقیقی. (ب) نتیجه الگوریتم [۱۲].

۲-۴- نتیجه‌گیری

در این فصل، مفاهیم و اصطلاحات اولیه مات‌زدایی را معرفی نموده و سعی کردیم به مزایا، معایب و کاربردهای روش‌های اخیر مات‌زدایی تصویر بپردازیم و نتایج هر یک را مقایسه و ارزیابی کنیم. در استفاده از روش‌های مات‌زدایی، باید این نکته را در نظر گرفت که به‌عنوان مثال در تشخیص‌های پزشکی، کیفیت نسبت به سرعت، بسیار حائز اهمیت بوده، لذا از الگوریتم‌های دارای نتایج باکیفیت استفاده می‌شود. همچنین در کاربردهایی نظیر تشخیص پلاک خودروها، به الگوریتم‌های سریع‌تر و نسبتاً باکیفیت نیاز است. ارزیابی‌های کمی و کیفی نشان می‌دهند که هر یک از روش‌های ذکرشده، کاربردهای خاص خود را دارند که بسته به حوزه مورد نظر، مورد استفاده قرار می‌گیرند.

فصل سوم

مبانی نظری روش پیشنهادی



۳-۱- مقدمه

در این فصل قصد داریم مهم‌ترین مفاهیم نظری به کار گرفته شده در روش‌های پیشنهادی این پایان‌نامه را تشریح کنیم. روش‌های متداول مات‌زدایی کور تصویر، همواره سعی داشتند با اعمال دانش‌های پیشین، مناسب‌ترین تصویر واضح میانی را بازسازی کنند تا بتوانند هسته تاری مطمئنی تخمین بزنند. این پژوهش نیز، دانش پیشین ساختار پنهان چندمقیاسه (MSLS) [۱۲] و دانش پیشین پیوستگی هسته تاری [۲۸] را برای مسئله مات‌زدایی کور تصویر مورد استفاده قرار داده‌است. لذا برای درک و آشنایی بهتر با این دو ایده، در ادامه به تعریف هر یک می‌پردازیم.

۳-۲- دانش پیشین ساختار پنهان چندمقیاسه (MSLS)

مرجع [۱۲] برای پرداختن به مسئله مات‌زدایی کور تصویر، با الهام از دانش پیشین خودمثال [۱۵] و فراتفکیک‌پذیری تصویر، یک دانش پیشین تصویر ساختار پنهان چندمقیاسه پیشنهاد کرده‌است. در فراتفکیک‌پذیری تصویر، دانش پیشین خودمثال، از طریق نمونه‌کاهی تصویر به دست می‌آید. مشاهده شده که اگر یک تصویر مات، در چند مقیاس به صورت هر می نمونه‌کاهی شود، آنگاه این تصویر به اندازه کافی نمونه‌کاهی شده، تقریباً یک نسخه با وضوح پائین از تصویر واضح پنهان مقیاس متناظرش است. برای درک بهتر این فرضیه، شکل (۳-۱) را در نظر بگیرید. در قسمت (الف)، دو تصویر مات و واضح به ابعاد 255×255 در مقیاس یا سطح ابتدایی هرم قرار گرفته‌اند. ملاحظه می‌شود که با نمونه‌کاهی و کاهش ابعاد در مقیاس‌های بعدی، این دو تصویر متناظر، هم از نظر بصری و هم از نظر معیار MSE، به تدریج شباهت بیشتری به هم پیدا می‌کنند. همچنین در قسمت (ب)، پروفایل روشنایی پیکسل‌های سطر اول تصاویر رسم شده‌است که نشان می‌دهد تصویر مات نمونه‌کاهی شده، یک نسخه با وضوح پائین از تصویر واضح متناظر است.

¹ Self-example prior



ب) پروفایل روشنایی تصاویر

الف) نمونه‌کاهی تصاویر

شکل (۳-۱): مقایسه نمونه‌کاهی تصاویر. الف) نمونه‌کاهی تصاویر مات (ستون راست) و واضح متناظر (ستون چپ) در مقیاس‌های مختلف. ب) پروفایل روشنایی پیکسل‌های ردیف اول تصاویر مات (منحنی قرمز) و واضح متناظر (منحنی آبی).

بر اساس این دانش پیشین، اگر بتوان با روش‌های مبتنی بر فراتفکیک‌پذیری، فرآیند این هرم تصویر را به‌صورت معکوس تکرار کرد، می‌توان تصویر واضح مات‌زدایی‌شده را بازیابی کرد.


روش فراتفکیک‌پذیری که ما در این پایان‌نامه مورد استفاده قرار دادیم مبتنی بر روش پیشنهادی مرجع [۱۵] می‌باشد. در این راهکار، برای بازسازی یک تصویر با مقیاس بزرگ‌تر و وضوح بهتر از یک تصویر مقیاس کوچک‌تر، از فرضیه خودمشابهت محلی^۱ استفاده می‌شود. این فرضیه بیان می‌دارد که برای هر وصله از تصویر، در یک همسایگی محدود، قطعات مشابهی وجود دارد. از طرفی تصویری که افزایش مقیاس می‌یابد، در اثر نمونه‌افزایی، بخشی از محتوای فرکانس بالای خود را از دست می‌دهد و کمی مات می‌شود. مرجع [۱۵] با استناد بر فرضیه خودمشابهت محلی، برای هر وصله از تصویر نمونه‌افزایی‌شده، در یک همسایگی محدود در تصویر مقیاس کوچک‌تر، به دنبال شبیه‌ترین وصله

^۱ Local self-similarity

می‌گردد تا محتوای فرکانس بالای وصله برگزیده را برای افزایش وضوح وصله مات، مورد استفاده قرار دهد. این معیار شباهت بین وصله‌ها از رابطه (۱-۳) سنجیده می‌شود. برای درک این فرآیند، مثالی در شکل (۲-۳) ارائه شده‌است.

$$d(i,j) = \|P_i x_l - P_j x_s\|_2, \quad j \in \mathcal{N}(i') \quad (1-3)$$

در رابطه (۱-۳)، عملگر استخراج وصله i است و i' یک حالت روی تصویر کوچک‌تر x_s است. $\mathcal{N}(i')$ همسایگی محلی قطعه i ام تصویر نمونه‌افزایی شده x_l در x_s را نشان می‌دهد. برای هر وصله i از تصویر x_l ، باید j وصله در تصویر مقیاس کوچک‌تر اصلی x_s بررسی شود تا هر دو وصله که کمترین اختلاف $d(i,j)$ را دارند، به‌عنوان وصله‌های مشابه انتخاب شوند.



شکل (۲-۳): فراتفکیک‌پذیری مرجع [۱۵]. روش مورد استفاده برای بازسازی تصویر واضح میانی در روش پیشنهادی. در شکل (۲-۳) که مرحله بازسازی تصویر واضح میانی در الگوریتم‌های (۲-۱۰) و (۲-۱۱) را نشان می‌دهد، ملاحظه می‌شود که برای هر وصله از تصویر بزرگ‌تر، شبیه‌ترین وصله در یک همسایگی محلی در تصویر کوچک‌تر جستجو می‌شود تا محتوای فرکانس بالای وصله تصویر بزرگ‌تر تقویت گردد و در پایان، تصویری با حداکثر وضوح حاصل شود. در طرح پیشنهادی ما، x_s همان دانش پیشین x_{pr} خواهد بود.

۳-۳- دانش پیشین پیوستگی هسته تاری

از آنجایی که هسته تاری حرکتی مسیر لرزش دوربین را توصیف می‌کند، بنابراین، علاوه بر T_k ، باید پیوسته نیز باشد. مرجع [۲۸] برای منظم‌سازی و تقویت پیوستگی^۱ و T_k هسته‌های تاری، یک قید به‌عنوان دانش پیشین پیوستگی هسته^۲ معرفی کرده‌است که با افزودن آن به تابع هزینه تخمین هسته، سعی دارد روش تخمین بهتری ارائه دهد.

برای یافتن عناصری از هسته تاری که به مسیر حرکت دوربین تعلق دارند، ابتدا یک آستانه سراسری T_g برای نادیده گرفتن عناصر غیرصفر در نظر گرفته می‌شود و سپس با استفاده از یک پنجره لغزان^۳ با اندازه $r \times r$ ، از میان عنصر وسط پنجره و همسایگان آن، عناصری که از یک آستانه محلی T_l بیشترند، به‌عنوان عدد n شمارش می‌شوند. بنابراین با توجه به ابعاد این پنجره، مقدار عدد n می‌تواند بین ۰ تا $r \times r$ باشد؛ یعنی برای یک پنجره به ابعاد 3×3 ، مقدار عدد n بین ۰ و ۹ خواهد بود. مقدار n بزرگ‌تر، به این معنی است که عنصر مورد نظر عناصر متصل بیشتری داشته و با احتمال بیشتری به مسیر حرکت دوربین تعلق دارد.

پس از بررسی تمام عناصر هسته تاری، یک نقشه پیوستگی^۴ $M(k)$ متشکل از n های محاسبه‌شده تولید می‌شود. مراحل تولید نقشه پیوستگی در شکل (۳-۳) و روند پیاده‌سازی دقیق آن در الگوریتم (۳-۱) نشان داده شده‌است. با مقایسه شکل (۳-۳) (ب) و (د)، می‌توان دریافت که عناصر اصلی هسته صحیح مبنا در هسته نویزی هم به‌درستی تشخیص داده شده‌اند و سایر عناصر نویزی شناسایی شده باید حذف گردند.


¹ Continuity

² Sparsity

³ Kernel Continuity Prior

⁴ Sliding window

⁵ Continuity map



شکل (۳-۳): تولید نقشه پیوستگی هسته تار. (الف) هسته تار صحیح مبنا. (ب) نقشه پیوستگی هسته (الف) در مقیاس رنگی. (ج) هسته تار (الف) با افزودن نویز. (د) نقشه پیوستگی هسته (ج) در مقیاس رنگی.

الگوریتم (۳-۱): محاسبه نقشه پیوستگی هسته تار [۲۸]

ورودی: هسته تار $k \in \mathbb{R}^{f \times f}$ ، آستانه سراسری T_g ، آستانه سراسری T_l ، اندازه پنجره r

۱. حلقه تکرار $h = 1:f$

۲. حلقه تکرار $v = 1:f$

۳. اگر $k > T_g$

۴. انتخاب قطعه $r \times r$ به مرکز (h, v) .

۵. شمارش n عنصری که از T_l بزرگتر هستند.

۶. $M(h, v) = n$

۷. پایان شرط

۸. پایان حلقه

۹. پایان حلقه

خروجی: نقشه پیوستگی $M(k)$

۳-۴- فیلتر شوک

استفاده از فیلتر شوک [۲۹]، یکی از روش‌های موثری است که می‌توان به منظور بازسازی لبه‌های

برجسته تصویر مات، به کار برد. فیلترهای شوک به صورت تکراری عمل می‌کنند. به این صورت که ابتدا

¹ Shock Filter


طبق رابطه (۲-۳)، تصویر ورودی I_{input} ، از یک فیلتر گاوسی G_σ عبور کرده تا تصویر I^0 به عنوان ورودی اولیه، برای به روزرسانی مکرر مورد استفاده قرار گیرد [۲۹]:

$$I^0 = G_\sigma \otimes I_{input} \quad (2-3)$$

بعد از مقداردهی اولیه، نتیجه فیلتر شوک I در تکرار $t + 1$ ام، از روی I^t به صورت (۳-۳) بیان می شود:

$$I^{t+1} = I^t - \text{sign}(\Delta I^t) \|\nabla I^t\| \quad (3-3)$$

که Δ و ∇ عملگرهای لاپلاسیان و گرادیان هستند. $\nabla I = (I_x, I_y)'$ و $\Delta I = I_x^2 I_{xx} + 2I_x I_y I_{xy} + I_y^2 I_{yy}$ به ترتیب مشتقات مرتبه اول و دوم هستند. شکل (۴-۳) مثالی از اعمال فیلتر شوک را نشان می دهد.



(الف)

(ب)

(ج)

شکل (۴-۳): نتایج اعمال فیلتر شوک [۲۹]. با توجه به تصویر مات ورودی (الف)، خروجی فیلتر شوک در تکرار اول (ب) و تکرار دوم (ج) نمایش داده شده است.

۳-۵- نتیجه گیری

در این فصل، به معرفی فیلتر شوک و تعریف مبانی نظری و دانش های پیشین به کار گرفته شده در روش های پیشنهادی پرداختیم و مراحل تولید هر یک را تشریح کردیم تا درک الگوریتم مات زدایی کور پیشنهادی در این پژوهش تسهیل گردد. در فصل بعدی روش های پیشنهادی معرفی خواهند شد.

فصل چهارم

روش پیشنهادی

۴-۱- مقدمه

در این فصل، پیشنهادات این پایان نامه که منجر به بهبود عملکرد روش مرجع [۱۲] می گردد را ارائه می نمائیم. همان طور که در فصل قبل اشاره شد، روش [۱۲] از سرعت خوبی برخوردار است و در عین حال، کیفیت تصویر ماتزدایی شده قابل قبول می باشد. با توجه به اینکه در این روش، برای ساخت یک تصویر واضح میانی، از فراتفکیک پذیری تصویر استفاده می شود، ممکن است در اثر تخمین نادرست هسته تاری، آلایه ها و یا نویز تقویت گردد و در همگرایی الگوریتم خلل ایجاد کند. لذا یک ایده ی پیشنهادی جهت تخمین پایدار هسته تاری، استخراج لبه های مهم تصویر بازسازی شده به منظور تخمین هسته تاری می باشد. در واقع با مقایسه ی لبه های تصویر واضح میانی و تصویر مات، می توان در هر مقیاس از هرم تصویر، هسته تاری بهتری را نسبت به مقایسه ی کل تصویر تخمین زد.

پیشنهاد دوم این پایان نامه، پاکسازی محلی هسته تاری در هر مقیاس است. در مقاله مرجع [۱۲]، اندازه اولیه هسته تاری برای طیف وسیعی از تصاویر، یک مقدار ثابت در نظر گرفته می شود (برای مثال 69×69 یا 55×55). ادعای [۱۲] بر این است که این الگوریتم به اندازه اولیه هسته تاری حساس نیست، در صورتی که نتایج تجربی نشان می دهد که اگر اندازه هسته تاری واقعی کوچک باشد، این الگوریتم برای تخمین هسته تاری با این اندازه شکست خواهد خورد؛ زیرا برای هسته های کوچک، ممکن است تصویر مات نمونه کاهی شده، حاوی اطلاعات کافی نباشد و منتج به تخمین یک هسته تاری مخدوش شود. برای رفع این مشکل، پیشنهاد ما پاکسازی محلی هسته تاری در هر مقیاس است. برای این کار، هم از روشیابی عناصر هسته و هم از نقشه پیوستگی هسته، مطابق مرجع [۲۸] استفاده نموده ایم.

در پیشنهاد آخر، ما از ایده جدید دانش پیشین پیوستگی هسته، در تابع هزینه تخمین هسته تاری روش مرجع [۱۲] بهره گرفتیم. در بهینه سازی تابع هدف، سعی شده تا اضافه کردن قید جدید، بار محاسباتی الگوریتم را چندان تغییر ندهد. این ایده ها و روش های پیشنهادی پایان نامه، در شکل (۴-۱) نمایش داده شده است که در ادامه ی این فصل، هر یک از این سه روش مجزا را تشریح می نمائیم.



شکل (۱-۴): ایده‌ها و روش‌های پیشنهادی پایان‌نامه.

۲-۴- روش پیشنهادی اول

استخراج لبه‌های برجسته تصویر میانی برای تخمین هسته تاری:

لبه‌های ضعیف، تخمین هسته تاری را در برابر نویز آسیب‌پذیر می‌کنند [۲۴] و از طرفی، لزوماً لبه‌های قوی همیشه فرآیند تخمین هسته تاری را بهبود نمی‌بخشند. برعکس، اگر مقیاس اشیاء در تصویر، از اندازه هسته تاری کوچک‌تر باشد، اطلاعات لبه می‌تواند منجر به تخمین نادرست هسته تاری شود.

لذا در این بخش، با الهام از این فرضیه، سعی شده است پس از تکمیل بازسازی تصویر میانی در هر دو الگوریتم (۲-۱۰) و (۲-۱۱) مقاله مرجع [۱۲]، از لبه‌های مهم تصویر واضح میانی، در بازیابی هسته تاری استفاده شود. در ادامه به جزئیات کار می‌پردازیم.

ابتدا به منظور انتخاب لبه‌های مهم و نقاط با گرادیان‌های بزرگ برای تخمین هسته تاری، از معیار پیشنهادی مرجع [۲۴] استفاده شده است. لذا یک ماسک بنام $r\text{-map}$ به ابعاد تصویر، از طریق رابطه (۱-۴) ساخته می‌شود [۲۴]:

$$r(x) = \frac{\|\sum_{y \in N_h(x)} \nabla B(y)\|}{\sum_{y \in N_h(x)} \|\nabla B(y)\| + 0.5} \quad (1-4)$$

که B تصویر مات است و $N_h(x)$ یک پنجره $h \times h$ با مرکزیت پیکسل x است. $\sum_{y \in N_h(x)} \|\nabla B(y)\|$ مجموع قدرمطلق گرادیان در $N_h(x)$ است. مقدار r در پیکسل x کوچک است اگر این پیکسل در یک ناحیه هموار از تصویر قرار گیرد و برعکس، r بزرگ نشان می‌دهد که پیکسل در ناحیه‌ای با یک تغییر ناگهانی روشنایی نسبت به همسایگانش واقع شده است. سپس پیکسل‌های با مقدار r کوچک، با استفاده از ماسک تعریف شده در رابطه (۲-۴)، کنار گذاشته می‌شوند. زیرا ما به دنبال لبه‌های مهم هستیم، درحالی‌که این پیکسل‌ها در نواحی هموار تصویر قرار داشته یا جزء لبه‌های ضعیف هستند، که کمکی به فرآیند تخمین هسته تاری نخواهند کرد و حتی ممکن است منجر به تخمین هسته نویزی گردند [۳۰]. اندازه پنجره مناسب به صورت تجربی 5×5 به دست آمده است.

$$M = H(r - \tau_r) \quad (2-4)$$

در رابطه (۲-۴)، $H(\cdot)$ تابع پله است که برای مقادیر کمتر از τ_r ، صفر و در غیر این صورت، عدد یک را تولید می‌کند. τ_r یک آستانه است که $0/1$ تنظیم شده است. در نهایت، لبه‌های نهائی انتخاب شده برای تخمین هسته تاری، از طریق رابطه (۳-۴) تعیین می‌شوند:

$$\nabla I^s = \nabla \tilde{I} \cdot H(M \|\nabla \tilde{I}\|_2 - \tau_s) \quad (3-4)$$

که $\tilde{I}$ نشان دهنده تصویری است که از فیلتر شوک عبور کرده و τ_s یک مقدار آستانه برابر با $0/0.5$ است. این معادله بخشی از گرادیان‌ها را حذف می‌کند و در رابطه (۲-۷۸) منتج به تخمین هسته تاری مطمئن‌تری می‌شود. در شکل (۲-۴)، برای یک تصویر مات نمونه، نقشه r -map، ماسک M و تصویر حاصل از فیلتر شوک نمایش داده شده است.

¹ Heaviside



(الف)



(ب)




(ج)




(د)

شکل (۲-۴): تصاویر واضح میانی روش پیشنهادی اول. الف) تصویر مات. ب) نقشه $r\text{-map}$. ج) ماسک M .
 د) تصویر $\tilde{I}$ حاصل از اعمال فیلتر شوک.

پس از محاسبه نقشه $r\text{-map}$ ، ماسک M و خروجی فیلتر شوک، باید گرادیان‌های مهم ∇I^s تصویر را به‌منظور تخمین هسته تاری، مطابق با رابطه (۳-۴) محاسبه کرد که برای مثال فوق، به‌صورت شکل (۳-۴) خواهد بود.



(الف)



(ب)

شکل (۳-۴): گرادیان تصاویر واضح میانی روش پیشنهادی اول. الف) گرادیان مهم در جهت X تصویر واضح میانی. ب) گرادیان مهم در جهت Y تصویر واضح میانی.

۴-۳- روش پیشنهادی دوم

ماسک‌گذاری روی هسته تاری تخمینی در هر تکرار از هر مقیاس:

از آنجا که دانش پیشین ما بر یک نسخه‌ی نمونه‌گاهی شده از تصویر مات متکی است، لذا با توجه به تکرارشونده بودن الگوریتم، در فرآیند تخمین هسته تاری، شاهد نویز و آلاینه خواهیم بود. به همین منظور، پیشنهاد ما الگوریتمی است که در هر تکرار، هسته تخمینی را بازسازی کند، به این صورت که از هسته حاصل، یک ماسک استخراج گردد تا نواحی نویزی را سرکوب کند. ما دو روش را برای یافتن یک ماسک مناسب آزمایش کردیم که در ادامه، نتایج و فرآیند آن‌ها را خواهیم دید.

۴-۳-۱- شناسایی تکرارشونده پشتیبان

در این قسمت، برای تشخیص ماسک مناسب، از روش پیشنهادی مرجع [۲۴،۳۱] الهام گرفته شده است. به این صورت که به جای آستانه‌گذاری مستقیم، در هر تکرار پس از تخمین هسته، از روی هسته حاصل شده، یک ماسک طراحی کرده تا با قرارگیری روی آن، نویزهای ایجادشده را تا حد امکان کاهش دهد. با توجه به تکرارشونده بودن الگوریتم، در نهایت، یک هسته تمیز و بدون نویز خواهیم داشت که برای هسته تاری ناشی از حرکت، فقط شامل عناصر مسیر لرزش دوربین خواهد بود.

ایده اصلی در این راهکار که به عنوان روش شناسایی تکرارشونده پشتیبان^۱ (ISD) یاد می‌شود، به این صورت است که در هر تکرار، از روی هسته تخمین زده شده k^i ، یک پشتیبان تولید می‌شود. یعنی عناصر با مقدار بزرگ، در یک مجموعه S^i که به صورت زیر محاسبه می‌شود، قرار می‌گیرند:


$$S^i \leftarrow \{j: k_j^i > \epsilon^s\} \quad (4-4)$$

که j عناصر موجود در هسته k^i و ϵ^s یک عدد آستانه مثبت است که ماسک پشتیبان را تشکیل می‌دهد. برای تعیین مقدار ϵ^s از قانون "اولین پرش بزرگ" استفاده شده است [۳۹]. به طوری که ابتدا

^۱ Iterative Support Detection


همه مقادیر هسته k^i را به ترتیب صعودی در یک بردار مرتب کرده و سپس اختلاف $d_0, d_1, \dots$ بین هر دو عنصر نزدیک محاسبه می‌شود. در نهایت، این اختلافات را به ترتیب بررسی می‌کنیم و به دنبال اولین عنصری خواهیم بود که شرط $d_j > \max(k^i)/(5 \times h \times i)$ را برآورده کند، که h اندازه هسته تاری است. سپس مقدار بردار هسته در موقعیت j را به ϵ^s اختصاص می‌دهیم تا برای ساخت ماسک مورد استفاده قرار گیرد [۳۰].

به عنوان مثال، در شکل (۴-۴)، برای یک هسته 5×5 ، مقادیر اختلاف d_j نمایش داده شده است و بعد از محاسبه دریافتیم که اولین پرش بزرگ در $j = 16$ رخ داده است (میل قرمز رنگ)، لذا مقدار آستانه برابر با مقدار j ام بردار هسته تاری خواهد بود.



شکل (۴-۴): نمودار اندازه اختلاف d_j .

همچنین در نمونه‌هایی از پشتیبان‌های شناسایی شده که در شکل (۴-۵) (ب) ارائه شده است، ملاحظه می‌شود که با توجه به تکرار شونده بودن فرآیند، می‌توان به تدریج ماسک پشتیبان را به روزرسانی کرد و نویز ایجاد شده در هسته تاری را کاهش داد.




شکل (۴-۵): محاسبه پشتیبان هسته تاری. الف) تصویر مات. ب) هسته تاری و ماسک پشتیبان محاسبه شده در تکرارهای مختلف. ج) تصویر مات زدایی شده از روش پشتیبان هسته (ISD).

۴-۳-۲- نقشه پیوستگی

در این بخش، برای یافتن یک ماسک مناسب تر و تشخیص دقیق تر عناصر نوپیزی هسته تاری، از روش پیشنهادی مرجع [۲۸] استفاده شده است. بر این اساس که در زمان پرتودهی و ثبت تصویر، مسیر لرزش یا حرکت دوربین دارای پیوستگی است، در نتیجه، عناصر غیر صفر هسته باید متصل و پیوسته باشند تا ساختار اصلی مربوط به مسیر حرکت دوربین را تشکیل دهند. در این فرآیند، همه ی عناصر هسته به منظور یافتن مسیر حرکت دوربین، به صورت افقی و محلی بررسی می شوند. خروجی این کار یک نقشه پیوستگی هسته خواهد بود که در ادامه به تعریف آن می پردازیم.

ابتدا باید برای هر عنصر از هسته تاری مورد نظر، بررسی شود که شدت این عنصر از یک آستانه سراسری $T_g = a \times k_{max}$ بیشتر باشد. که $0 < a < 1$ و k_{max} بیشترین مقدار در هسته تاری k است. با این شرط می توان عناصر صفر را نادیده گرفت و دامنه جستجو را محدود کرد و یا با یک مقدار T_g کم، تمام عناصر ممکن برای ارزیابی را در نظر گرفت. در اینجا مطابق الگوریتم [۲۸]، ما $a = 0.05$ را در نظر گرفتیم، که یک آستانه تجربی است.


مرحله بعدی، اعمال یک پنجره لغزان^۱ به اندازه $r \times r$ است تا همسایگان متصل هر عنصر از هسته را شناسایی کند. این کار به کمک یک آستانه محلی $T_l = b \times k_c$ ، که $0 < b < 1$ و k_c شدت عنصر مرکزی در پنجره است، انجام می‌گیرد. بدین ترتیب که همسایگان با شدت روشنایی بیشتر از T_l شمارش می‌شوند و به عنوان عدد n که معیار پیوستگی است، در موقعیت عنصر مرکز قرار می‌گیرند. مقدار T_l را باید برای شناسایی و حذف عناصر نویزی، یک مقدار نسبتاً بالاتر در نظر گرفت، پس $b = 0.1$ انتخاب شده است و همچنین اندازه پنجره $r = 3$ تنظیم شده است. مقدار عدد n می‌تواند از صفر تا تعداد درایه‌های پنجره باشد و n بزرگ‌تر به این معناست که این عنصر، همسایگان متصل بیشتری داشته و با احتمال بیشتری به مسیر حرکت دوربین تعلق دارد. در نهایت، نقشه پیوستگی هسته $M(k) \in \mathbb{R}^{f \times f}$ تشکیل می‌شود. شکل (۴-۶) مقایسه بین نقشه‌های شدت روشنایی و نقشه‌های پیوستگی هسته‌ها را با وجود نویز و بدون نویز نشان می‌دهد. ملاحظه می‌شود که در نقشه پیوستگی، همه عناصر نویزی نسبت به عناصر اصلی، مقادیر کمتری دارند. بنابراین، با استفاده از نقشه پیوستگی می‌توان حتی اگر نویز، شدت بالاتری هم داشته باشد، آن را به راحتی تشخیص داد و حذف کرد.



شکل (۴-۶): مقایسه نقشه شدت روشنایی و نقشه پیوستگی. (الف) و (ب) دو هسته نمونه هستند که در آن‌ها ستون اول هسته صحیح مبنا و ستون دوم هسته نویزی هستند. ردیف اول) هسته‌های صحیح مبنا و هسته‌های نویزی متناظر. ردیف دوم) هسته‌های متناظر ردیف اول با نمایش رنگی. ردیف سوم) نقشه‌های پیوستگی متناظر با نمایش رنگی.

¹ Sliding window

بعد از استخراج نقشه پیوستگی مطابق الگوریتم (۳-۱)، که برای $r = 3$ مقادیری بین ۰ تا ۹ دارد، ما به صورت تجربی مقادیر $t_1=2$ و $t_2=3$ را به ترتیب به عنوان آستانه مرحله مقدماتی و نهایی در نظر گرفتیم. با این آستانه گذاری، نویزهای شناسایی شده از هسته تخمینی حذف خواهند شد. سپس این نقشه دودویی^۱ در هسته ضرب شده و مجدداً هسته نرمال سازی می شود تا مجموع عناصر آن برابر یک باشد. به این ترتیب، نویزهای اضافی خارج از مسیر حرکت تخمینی دوربین، که همگرایی الگوریتم را کند می کرد، در هر مقیاس حذف خواهند شد و مانع از اختلال در روند تخمین هسته تاری می شود. به منظور درک بهتر روند تأثیر ماسک بر تخمین هسته، می توان در شکل (۴-۷) نتیجه اعمال ماسک را در هر مقیاس ملاحظه کرد. پس از یافتن ماسک مناسب و ضرب نقطه ای آن با هسته تاری، به یک هسته نهایی تمیز و بدون نویز دست خواهیم یافت.



شکل (۴-۷): نتایج بازسازی هسته قبل و بعد از ماسک گذاری. الف) هسته های اولیه قبل از ماسک گذاری. ب) ماسک به دست آمده از الگوریتم (۳-۱). ج) هسته های تاری بعد از ماسک گذاری.

¹ Binary

۴-۴- روش پیشنهادی سوم

اعمال دانش پیشین پیوستگی به رابطه تخمین هسته تاری:

در دو روش پیشنهادی قبل، به دنبال استخراج لبه‌های قوی از تصویر و همچنین پاکسازی نویز از هسته‌های تاری بودیم. اما در این روش، همچنان نیاز به یک قید موثر در تابع بهینه‌سازی تخمین هسته احساس می‌شود. همان‌طور که قبلاً اشاره شد، در فرآیند تخمین هسته‌ی مقاله مرجع [۱۲]، تنکی و پیوستگی هسته تاری حفظ نمی‌شود؛ زیرا بازسازی تصویر واضح میانی، متکی بر فراتفکیک‌پذیری تصویر واضح بازیابی‌شده در مقیاس قبلی است. به همین دلیل، در صورتی که تصویر خروجی مقیاس قبلی، حاوی آثار تصنعی یا حلقه‌ای باشد، با توجه به تکرارشونده بودن الگوریتم، این آثار تصنعی در تصویر جدید تشدید شده و منجر به تخمین یک هسته تاری نویزی می‌گردد. لذا درصدد اعمال یک قید پیوستگی به رابطه تخمین هسته هستیم.

در پیشنهاد سوم قصد داریم با الهام از مرجع [۲۸]، قید پیوستگی هسته را به بهینه‌سازی هسته تاری اضافه کنیم. روند کار مشابه الگوریتم (۲-۱۰) و (۲-۱۱) است، ولی تابع هدف تخمین هسته تغییر می‌کند. اگر قید پیوستگی هسته را به رابطه (۲-۷۸) اضافه کنیم، رابطه (۴-۵) حاصل خواهد شد:

$$\arg \min_{k, x_c} \frac{1}{2} \|k \otimes \nabla(\hat{x} + x_c) - \nabla b\|_2^2 + \gamma \|k\|_2^2 + \lambda \|x_c\|_1 + \alpha \|M(k)\|_0 \quad (۵-۴)$$

که در آن γ ، λ و α پارامترهای وزن و تعادل عبارات هستند. مطابق آنچه در فصل قبل اشاره شد، برای محدب‌سازی رابطه (۴-۵)، از جایگزینی $k \otimes \nabla x_c$ با متغیر جدید v استفاده شده است. از طرفی نقشه پیوستگی $M(\cdot)$ ، یک تابع غیرخطی است که نرم غیرمحدب L_0 هم به آن اعمال می‌شود. برای حل این مشکل، می‌توان با استفاده از روش جداسازی نیمه-درجه دو [۲۷]، و معرفی یک متغیر کمکی u ، تابع هزینه را به صورت رابطه (۴-۶) بازنویسی کرد:

$$\arg \min_{k, v, u} \frac{1}{2} \|k \otimes \nabla \hat{x} + v - \nabla b\|_2^2 + \gamma \|k\|_2^2 + \lambda \|v\|_1 + \beta \|M(k) - u\|_2 + \alpha \|u\|_0 \quad (۶-۴)$$

رابطه (۴-۶) را می توان به صورت نوبتی برای هر یک از سه متغیر، با ثابت در نظر گرفتن سایر متغیرها به سه زیرمسئله تقسیم کرد. $\nabla = \{\nabla_x, \nabla_y\}$ به ترتیب عملگرهای مشتق در جهتهای افقی و عمودی هستند و $v = \{v_x, v_y\}$ لایه های متناظر جهتهای افقی و عمودی هستند که با ماتریس صفر مقداردهی اولیه می شوند.

به عنوان زیرمسئله اول، با ثابت در نظر گرفتن متغیرهای u و v ، رابطه تخمین هسته (۴-۷) حاصل می شود:

$$\arg \min_k \frac{1}{2} \|k \otimes \nabla \hat{x} + v - \nabla b\|_2^2 + \gamma \|k\|_2^2 + \beta \|M(k) - u\|_2 \quad (۷-۴)$$

که پارامتر β در واقع یک پارامتر جریمه است. از آنجا که عبارات مربوط به k همگی درجه دوم هستند، بنابراین یک راه حل فرم بسته برای k وجود دارد. به علاوه، می توان برای حل سریع، راه حل آن را در حوزه فرکانس به وسیله FFT محاسبه کرد [۲۸]:

$$k = F^{-1} \left(\frac{\overline{F(\nabla \hat{x})} F(\nabla b) - \overline{F(\nabla \hat{x})} F(v) + \beta F(M^T u)}{\overline{F(\nabla \hat{l})} F(\nabla \hat{l}) + 2\gamma + \beta} \right) \quad (۸-۴)$$

که در آن $F(\cdot)$ ، $F^{-1}(\cdot)$ و $\overline{F(\cdot)}$ به ترتیب بیانگر تبدیل فوری، معکوس فوری و مزدوج مختلط مقادیر تبدیل فوری هستند. همچنین $\nabla \hat{x}$ و ∇b شامل گردایان لبه های مهم تصویر مات و تصویر واضح می باشند. برای محاسبه v که یک مسئله بهینه سازی مبتنی بر نرم L_1 است، از نگاشت پروکسیمال [۴۰] استفاده شده است، که در نهایت می توان آن را به یک آستانه گذاری تبدیل کرد [۱۲]:

$$\arg \min_v \frac{1}{2} \|k \otimes \nabla \hat{x} + v - \nabla b\|_2^2 + \lambda \|v\|_1 \quad (۹-۴)$$

$$v = \text{syn}(z). \max\{0, |z| - \lambda\} \quad (۱۰-۴)$$

که در آن $z = \nabla b - (k \otimes \nabla \hat{x})$ است. پس از تثبیت k و v ، می توان $M(k)$ را محاسبه کرد و سپس تخمین u به یک مسئله مشابه آنچه در [۸] مطرح شد تبدیل می شود:

¹ Proximal

$$\arg \min_u \beta \|M(k) - u\|_2 + \alpha \|u\|_0 \quad (11-4)$$

$$u = \begin{cases} M(k) & |M(k)|^2 \geq \frac{\alpha}{\beta} \\ 0 & otherwise \end{cases} \quad (12-4)$$

به همین ترتیب، در بازسازی نهائی نیز، قید پیوستگی هسته به رابطه (۸۲-۲) اضافه می گردد. مراحل اصلی فرآیند تخمین هسته پیشنهادی در الگوریتم (۱-۴) بیان شده است.

الگوریتم (۱-۴): حل رابطه (۶-۴) تخمین هسته تاری

ورودی: تصویر مات b ، تصویر واضح میانی $\hat{x}$

مقداردهی اولیه: $M^T u = \text{upsample}\{k_{prev}\}$

خروجی: هسته تاری تخمینی k

۱. حلقه تکرار $j = 1:5$

تخمین k با حل رابطه (۸-۴)

محاسبه v با حل رابطه (۱۰-۴)


محاسبه u با حل رابطه (۱۲-۴)

$\beta = \beta \times 4$

پایان حلقه

۳. بازگشت k

شمای کلی الگوریتم پیشنهادی سوم در شکل (۸-۴) نشان داده شده است. ملاحظه می شود که در هر مقیاس i ، برای بازسازی اولیه ی تصویر واضح میانی $\hat{x}$ ، از یک تصویر پنهان واضح که در مقیاس قبلی بازیابی شده x_{pr}^{i-1} به عنوان دانش پیشین استفاده می شود. در واقع، در تکرار اول $max_iter = 1$ ، تصویر x_{pr} نمونه افزایی می شود و تصویر x_l را شکل می دهد و سپس با فرآیند فراتفکیک پذیری، تصویر واضح میانی $\hat{x}$ تولید می گردد (گام ۱). در گام ۲، از مقایسه $\hat{x}$ و تصویر مات نمونه کاهی شده برای مقیاس فعلی، یک هسته تاری تخمین زده می شود که می توان با واپیچش غیرکور بین این هسته تخمینی و تصویر مات مقیاس فعلی یک تصویر پنهان واضح x_l را بازیابی کرد (گام ۳). با جایگزین کردن x_l به دست آمده به جای x_l نمونه افزایی شده، می توان این فرآیند را چند مرتبه تکرار کرد تا در نهایت تصویر واضح x حاصل گردد.



شکل (۴-۸): شمای کلی روش پیشنهادی سوم.

در بازسازی نهائی که در مقیاس آخر انجام می شود، می توان مطابق الگوریتم (۲-۱۱)، دانش پیشین x_{pr} را نیز به روزرسانی کرد. به طوری که تصویر x_I بازیابی شده در مقیاس فعلی، نمونه کاهی می شود و به عنوان x_{pr} در همین مقیاس مورد استفاده قرار می گیرد. به عبارت دیگر فرآیند فراتفکیک پذیری در مقیاس آخر به کمک تصویر x_I و نسخه نمونه کاهی شده متناظرش انجام می شود (مطابق شکل ۲-۲۳).

۴-۵- نتیجه گیری

در این فصل، برای ماتزدایی کور تصویر، سه روش پیشنهادی مبتنی بر دانش پیشین ساختارپنهان چندمقیاسه ارائه گردید. در پیشنهاد اول، سعی شده است به جای کل تصویر، از گرادیان لبه های مهم تصویر، برای تخمین هسته تاری مطمئن استفاده شود. در پیشنهاد دوم، هسته تاری به دو روش تولید پشتیبان هسته و نقشه پیوستگی، پاکسازی شده است تا آلاینده های تصاویر واضح بازیابی شده کاهش یابد. در پیشنهاد سوم، قید پیوستگی هسته تاری به تابع هدف تخمین هسته اضافه گردید و همچنین لبه های مهم تصویر واضح میانی به منظور تخمین یک هسته تاری تمیز و پیوسته، مورد استفاده قرار گرفت. در فصل بعدی، نتایج روش های پیشنهادی با نتایج روش های پیشرفته اخیر، مورد ارزیابی قرار می گیرد.

فصل پنجم

ارزیابی نتایج

۵-۱- مقدمه

در این فصل، نتایج کمی و کیفی به دست آمده از الگوریتم پیشنهادی، مورد بررسی و تحلیل قرار خواهند گرفت. روش پیشنهادی ارائه شده برای بازسازی تصویر واضح میانی، به جای استفاده از دانش های پیشین پیچیده معرفی شده، از ساختار پنهان چندمقیاسه استفاده می کند که سبب افزایش سرعت اجرای الگوریتم می شود. از طرفی، به منظور افزایش دقت بازیابی، یک دانش پیشین جدید مبتنی بر پیوستگی هسته تاری مورد استفاده قرار گرفته است تا تخمین دقیق تری از هسته تاری ارائه شود.

مجموعه داده اصلی به کار گرفته شده در این پژوهش، مجموعه داده ساختگی پرکاربرد [۲۵] Levin، مورد استفاده در [۵-۱۱، ۲۴، ۲۸، ۳۰، ۳۸] است که شامل ۳۲ تصویر مات، متشکل از چهار تصویر خاکستری به ابعاد 255×255 و هشت هسته تاری حرکتی با اندازه های مختلف نشان داده شده در شکل (۵-۱) می باشد. همچنین برای ارائه نتایج بصری، به صورت موردی از تصاویر با ابعاد بزرگ تر مجموعه داده [۹]، [۳۱] و Sun [۳۲] که شامل ۶۴۰ تصویر مات می باشد، استفاده شده است. مجموعه داده [۳۱]، متشکل از ۲۵ تصویر رنگی با ابعاد بزرگ است که توسط چهار هسته تاری مات شده اند^۱. دادگان مورد استفاده حاوی انواع تصاویر منظره، چهره و متنی هستند و ارزیابی های صورت گرفته، بر طبق معیارهای PSNR، SSIM، RMSE و KSIM می باشد که در فصل های گذشته تعریف شده اند. همچنین معیار نسبت خطا^۲ پیشنهادی مرجع [۲۵] که در ادامه معرفی می گردد.

شبیه سازی الگوریتم پیشنهادی در محیط نرم افزار MATLAB R2020b انجام شده است. مشخصات رایانه مورد استفاده به صورت Intel(R) Core(TM) i7-8550U CPU و 12 GB RAM بوده است. همچنین برای مقایسه عادلانه، برای تمام روش های مورد ارزیابی، از یک روش واپیچش غیرکور نهائی [۶] استفاده گردید. در آزمایش های انجام گرفته روی روش پیشنهادی، فاکتور نمونه کاهی برای ساخت هرم

^۱ http://vllab.ucmerced.edu/wlai24/cvpr16_deblur_study/

^۲ Error ratio


تصویر $\log_2 3$ و سایر پارامترها به صورت $\mu = 0.01$, $\lambda = \lambda_4 = 0.05$, $\gamma = \lambda_3 = 5$, $\beta = 1$, $\alpha = 16$ و $r = 3$ تنظیم شده‌اند. ما از اولین مقیاس کل، با یک تابع دلتا دیراک به اندازه 3×3 و کوچک‌ترین تصویر مات نمونه‌گاهی شده شروع می‌کنیم. برای تعادل بین سرعت و دقت، تعداد تکرار الگوریتم‌ها در بازیابی مقدماتی و نهائی به ترتیب $max_iteration = 2$ و $max_iteration = 3$ در نظر گرفته شده‌است.



شکل (۵-۱): مجموعه داده Levin [۲۵]. (الف) تصاویر خاکستری واضح صحیح مبنا. (ب) هسته‌های تاری حرکتی صحیح مبنا. (به ترتیب از چپ به راست شماره گذاری می‌شوند).

۵-۲- ارزیابی روش پیشنهادی اول

به منظور مقایسه روش پیشنهادی اول با روش مرجع [۱۲]، معیار شباهت هسته تاری روی مجموعه داده Levin در شکل (۵-۲) گزارش شده‌است.



شکل (۵-۲): مقایسه معیار شباهت هسته (KSIM) روی نتایج روش مرجع [۱۲] (ستون آبی) و روش پیشنهادی اول (ستون قرمز) برای چهار تصویر Image 1~4 و هشت هسته تاری k1~8 مجموعه داده Levin.

با توجه به ستون آخر شکل (۵-۲)، میانگین شباهت هسته برای روش پیشنهادی اول ۰/۶۴ و برای روش مرجع [۱۲] برابر ۰/۴۴ است. بنابراین روش پیشنهادی، هسته‌های دقیق‌تری تخمین زده‌است. همچنین در جدول (۵-۱) نتایج مقایسه کمی پیشنهاد اول با روش‌های اخیر، بر اساس معیارهای PSNR و SSIM گزارش شده‌است.

جدول (۵-۱): مقایسه PSNR و SSIM پیشنهاد اول روی مجموعه داده Levin با روش‌های [۸]، [۱۳]، [۱۱] و [۱۲] با استفاده از الگوریتم واپیش‌غیرکور [۶].

هسته / تصویر		L0 text [8]		Graph [13]		Pan et al. [11]		MSLS [12]		پیشنهاد اول	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
تصویر 1	هسته 1	28.27	0.87	27.69	0.85	29.09	0.88	28.71	0.87	28.32	0.87
	هسته 2	29.35	0.88	27.74	0.85	29.32	0.88	28.94	0.88	29.30	0.89
	هسته 3	29.66	0.90	29.46	0.89	31.56	0.91	29.86	0.90	30.91	0.90
	هسته 4	26.77	0.82	27.81	0.83	27.21	0.84	27.24	0.83	26.11	0.82
	هسته 5	29.54	0.92	29.67	0.91	31.76	0.94	30.79	0.93	30.04	0.92
	هسته 6	29.12	0.90	27.52	0.87	31.24	0.92	27.94	0.88	28.95	0.90
	هسته 7	30.65	0.91	26.27	0.85	29.39	0.90	28.81	0.89	26.98	0.87
	هسته 8	27.43	0.86	27.41	0.85	30.15	0.90	28.41	0.88	28.29	0.88
تصویر 2	هسته 1	27.84	0.85	25.56	0.77	28.94	0.86	25.7	0.79	26.91	0.81
	هسته 2	26.45	0.84	24.85	0.75	28.70	0.86	25.9	0.79	26.43	0.81
	هسته 3	27.03	0.84	28.11	0.83	29.02	0.86	28.23	0.85	29.35	0.87
	هسته 4	26.72	0.79	24.08	0.70	27.65	0.81	22.41	0.65	26.08	0.78
	هسته 5	27.72	0.89	27.58	0.86	30.36	0.91	29.17	0.89	27.92	0.87
	هسته 6	25.68	0.86	25.71	0.81	27.86	0.87	28.12	0.87	29.70	0.89
	هسته 7	27.27	0.85	22.82	0.77	28.36	0.86	27.06	0.83	24.80	0.80
	هسته 8	25.42	0.83	26.87	0.82	29.20	0.88	25.71	0.81	26.56	0.81
تصویر 3	هسته 1	29.67	0.91	27.88	0.88	28.58	0.90	29.33	0.90	28.56	0.89
	هسته 2	29.69	0.90	26.97	0.86	29.88	0.91	27.59	0.88	27.60	0.88
	هسته 3	31.47	0.94	32.67	0.94	32.54	0.95	30.42	0.93	32.92	0.96
	هسته 4	29.44	0.89	25.11	0.80	20.40	0.65	25.39	0.81	26.69	0.84
	هسته 5	31.68	0.95	29.20	0.92	31.08	0.94	32.75	0.96	28.95	0.93
	هسته 6	30.30	0.92	28.80	0.90	30.34	0.93	29.5	0.91	30.10	0.92
	هسته 7	30.41	0.95	27.31	0.88	31.29	0.94	27.13	0.87	27.31	0.88
	هسته 8	29.14	0.91	28.74	0.89	30.26	0.93	28.96	0.89	29.09	0.90
تصویر 4	هسته 1	28.28	0.87	26.82	0.84	29.56	0.89	27.95	0.86	28.52	0.87
	هسته 2	27.43	0.85	24.31	0.75	28.90	0.88	24.59	0.76	25.49	0.80
	هسته 3	29.69	0.91	30.76	0.92	31.31	0.93	31.84	0.93	33.15	0.94
	هسته 4	18.43	0.54	18.28	0.49	18.67	0.53	26.17	0.81	26.79	0.83
	هسته 5	28.99	0.91	30.07	0.92	30.75	0.93	31.84	0.94	30.92	0.95
	هسته 6	26.95	0.87	27.54	0.87	31.41	0.93	28.33	0.88	27.65	0.88
	هسته 7	25.11	0.83	23.88	0.80	30.09	0.92	24.44	0.82	26.23	0.86
	هسته 8	25.46	0.84	22.48	0.72	31.04	0.92	24.66	0.81	24.25	0.78
میانگین		28.03	0.87	26.87	0.83	29.24	0.88	27.93	0.86	28.15	0.87

با بررسی سطر آخر جدول (۵-۱) که میانگین نتایج را نشان می‌دهد، می‌توان دریافت که روش پیشنهادی اول در بحث PSNR و SSIM تصویر واضح نهائی، عملکرد خوبی داشته و نسبت به مقاله مرجع [۱۲] نیز، بهبود کیفیت حاصل شده اما کمی از نتیجه مرجع [۱۱] ضعیف‌تر است.

علاوه بر این، کیفیت تصاویر مات‌زدایی شده با استفاده از معیار نسبت خطا [۲۵]، در جدول (۵-۲) گزارش شده است. در واقع، به کمک این معیار، می‌توان تاثیر الگوریتم‌های مختلف مات‌زدایی غیرکور نهائی که برای بازیابی تصاویر واضح پنهان مورد استفاده قرار می‌گیرند را حذف کرد و یک مقایسه عادلانه انجام داد. نسبت خطا از طریق رابطه (۵-۱) قابل محاسبه است [۲۵]:

$$r = \frac{\|x - x_{\hat{k}}\|^2}{\|x - x_k\|^2} \quad (۵-۱)$$


که در آن $x_{\hat{k}}$ نتیجه مات‌زدایی شده محاسبه شده با استفاده از هسته تخمینی $\hat{k}$ ، x_k نتیجه مات‌زدایی شده محاسبه شده با استفاده از هسته صحیح مبنا k و x تصویر واضح صحیح مبنا است. اگر $r = 1$ باشد، به این معنی است که کیفیت نتیجه مات‌زدایی شده کور با کیفیت نتیجه بازیابی شده با استفاده از هسته صحیح مبنا برابری می‌کند و هر چه r کوچک‌تر و به عدد یک نزدیک‌تر باشد، تصویر مات‌زدایی شده بهتری حاصل شده است.

جدول (۵-۲): مقایسه نسبت خطا و RMSE روش مرجع [۱۲] و روش پیشنهادی اول روی مجموعه داده Levin.

	روش مرجع [۱۲]	روش پیشنهادی اول
Error ratio	2.8398	2.5889
RMSE	0.0415	0.0392


پس از بررسی نتایج عددی، در ادامه به بررسی بصری وضوح تصاویر بازیابی شده می‌پردازیم. در شکل (۵-۳)، روش مرجع [۱۲] با روش پیشنهادی اول مقایسه شده و مشاهده می‌شود که روش پیشنهادی در موارد ناموفق روش مرجع، عملکرد بهتری داشته و در تصویر سطر دوم، آلايه کمتری تولید کرده است.

¹ Error ratio



شکل (۳-۵): مقایسه بصری روش پیشنهادی اول. (الف) تصویر ورودی مات. (ب) نتایج حاصل از MSLS [۱۲].
(ج) نتایج حاصل از روش پیشنهادی اول.

شکل (۴-۵) نتایج مات‌زدایی روش مرجع [۱۲] و پیشنهاد اول را روی یک تصویر مات طبیعی نشان می‌دهد. با بزرگنمایی تصویر روی کادر قرمز مشخص‌شده، ملاحظه می‌شود که هسته تاری روش پیشنهادی، منجر به تصویر با وضوح بهتری شده‌است.



شکل (۴-۵): ارزیابی بصری روش پیشنهادی اول. (چپ) نتایج حاصل از MSLS [۱۲].
(راست) نتایج حاصل از روش پیشنهادی اول.


در شکل (۵-۵)، نتایج مات‌زدایی یک تصویر متنی از مجموعه داده [۳۱] مقایسه شده‌است. با تطابق تصویر (ب) و (د) می‌توان دریافت که روش پیشنهادی اول نسبت به روش مرجع [۱۲] عملکرد بهتری داشته‌است.




(الف)



(ب)



(ج)



(د)

شکل (۵-۵): ارزیابی روش پیشنهادی اول روی تصویر متنی. الف) تصویر واضح و هسته صحیح مبنا. ب) هسته صحیح مبنا و تصویر ناشی از آن با واپیچش غیرکوریلاپلاسن [۶]. ج) تصویر و هسته حاصل از روش مرجع [۱۲]. د) تصویر و هسته حاصل از روش پیشنهادی اول.

مقایسه‌ها نشان می‌دهد که لبه‌های بیشتر، لزوماً منجر به تخمین هسته دقیق‌تر نمی‌شوند و می‌توانند به‌خصوص در تکرارهای اولیه مانع از همگرایی بهینه‌سازی شوند. بنابراین فرآیند انتخاب لبه تصویر برای کاهش سردرگمی بسیار حیاتی است. اما از محدودیت‌های روش‌های مبتنی بر انتخاب لبه می‌توان به این نکته اشاره کرد که اگر تصویر مات ورودی فاقد لبه باشد، فرآیند مات‌زدایی عملکرد مطلوب حاضر را نخواهد داشت.

۵-۳- ارزیابی روش پیشنهادی دوم


۵-۳-۱- شناسایی تکرارشونده پشتیبان

به عنوان ارزیابی کمی روش پشتیبان هسته تار، نسبت خطا و RMSE نتایج روش مرجع [۱۲] و پیشنهاد اول در جدول (۵-۳) گزارش شده است. ماسک پشتیبان توانسته نسبت به دو روش رقیب، عملکرد بهتری داشته باشد.



جدول (۵-۳): مقایسه نسبت خطا و RMSE روش مرجع [۱۲] و پیشنهاد اول و روش پشتیبان هسته روی داده [۲۵].

روش پیشنهادی دوم	روش پیشنهادی اول	روش مرجع [۱۲]	
2.4582	2.5889	2.8398	Error ratio
0.0362	0.0392	0.0415	RMSE

مقایسه‌های بصری در شکل (۵-۶) و (۵-۷) انجام گرفته است. در شکل (۵-۶) یک مقایسه بصری بین روش مرجع [۱۲] و روش پشتیبان هسته ارائه شده است که نشان می‌دهد پاکسازی هسته تار می‌تواند آلاینده‌ها را در فرآیند مات‌زدایی کاهش داده و منجر به تصاویر با کیفیت‌تری گردد.



شکل (۵-۶): ارزیابی بصری روش ماسک پشتیبان هسته تار. (الف) تصویر مات. (ب) نتیجه روش MSLS [۱۲]. (ج) نتیجه روش ماسک پشتیبان.



(الف)

(ب)

(ج)

شکل (۵-۷): مقایسه بصری روش پشتیبان هسته. (الف) تصویر مات. (ب) نتیجه روش MSLS [۱۲].

(ج) نتیجه روش ماسک پشتیبان.

نتایج شکل (۵-۷) نشان می‌دهد که ماسک پشتیبان توانسته آلاینده‌های تصاویر مات‌زدایی شده را کاهش

دهد. در شکل (۵-۸)، هسته تاری حاصل از روش پشتیبان هسته با سایر روش‌ها مقایسه شده‌است.

ملاحظه می‌شود که مشابهت هسته‌های روش پیشنهادی به هسته‌های صحیح مبنا بیشتر است.



(الف)


(ب)

(ج)

(د)

(ه)

(و)




شکل (۵-۸): مقایسه هسته‌های تخمین زده شده روش پشتیبان هسته تاری. (الف) تصویر واضح شماره ۱ از مجموعه

Levin [۲۵]. (ب) هسته تاری صحیح مبنا. (ج) هسته تاری مرجع [۳۴]. (د) هسته تاری L_0 text [۸].


(ه) هسته تاری MSLS [۱۲]. (و) هسته تاری روش ماسک پشتیبان.

۵-۳-۲- نقشه پیوستگی

برای بررسی نتیجه روش پاکسازی هسته مبتنی بر نقشه پیوستگی، در شکل (۵-۹) معیار شباهت هسته روی مجموعه داده Levin مورد ارزیابی قرار گرفته است که در مجموع، نشان از بهبود جزئی دارد. اما در بعضی موارد عملکرد ضعیف تری نسبت به مرجع [۱۲] گزارش شده است. همچنین مثالی از نتایج بصری در شکل (۵-۱۰) نمایش داده شده است.



شکل (۵-۹): مقایسه معیار شباهت هسته (KSIM) روی نتایج روش مرجع [۱۲] (ستون آبی) و روش ماسک پیوستگی (ستون قرمز) برای چهار تصویر Image 1~4 و هشت هسته تاری k1~8 مجموعه داده Levin.



ج) نتایج روش ماسک نقشه پیوستگی (ب) نتایج روش روش MSLS [۱۲] (الف) تصویر مات و هسته تاری صحیح مبنا

شکل (۵-۱۰): مقایسه موارد موفق و ناموفق روش ماسک نقشه پیوستگی. ردیف اول: تصویر دوم و هسته تاری چهارم از مجموعه داده Levin. ردیف دوم: تصویر سوم و هسته تاری هفتم از مجموعه داده Levin.

در شکل (۵-۱۰)، مطابق با نتایج کمی نمودار شکل (۵-۹)، مواردی از مات‌زدایی موفق و ناموفق روش پیشنهادی ارائه شده‌است. در ردیف اول ملاحظه می‌شود که روش پیشنهادی ماسک نقشه پیوستگی، هسته تاری دقیق‌تری را تخمین زده که منجر به تصویر شفاف‌تری شده‌است. اما نتایج ردیف دوم نشان می‌دهد که روش پیشنهادی نتوانسته فرآیند تخمین هسته تاری و رفع ماتی را به‌خوبی روش مرجع [۱۲] انجام دهد.

یکی از محدودیت‌های روش پاکسازی به‌صورت وقتی و محلی، استفاده از یک آستانه‌گذاری ثابت است که یا باید برای همه‌ی تصاویر مات ورودی مورد استفاده قرار گیرد، و یا برای هر تصویر مات ورودی به‌صورت مجزا تغییر کند تا مقدار آستانه‌ی مناسب برای حذف نویز هسته تاری مشخص گردد. در غیر این صورت ممکن است آستانه انتخابی، عناصر اصلی هسته تاری را نیز حذف کند و هسته تخمین زده شده، تصاویر مطلوبی ارائه نکند.

۴-۵- ارزیابی روش پیشنهادی سوم

جدول (۵-۴)، یک مقایسه عددی را بین روش پیشنهادی سوم و روش‌های مات‌زدایی اخیر نشان می‌دهد. در سطر اول، نتایج حاصل از مقایسه تصویر مات و تصویر واضح صحیح مبنا (بدترین حالت) و در سطر دوم نتایج حاصل از مقایسه تصویر مات و تصویر واضح بازبازی شده با هسته صحیح مبنا (بهترین حالت) گزارش شده‌است.

جدول (۵-۴): ارزیابی‌های کمی روی مجموعه داده Levin [۲۵] با یک الگوریتم واپیچش غیر کور یکسان [۶].


Methods	PSNR	SSIM	RMSE	KSIM	Error Ratio	Run Time (s)
Blur input	22.8280	0.6900	0.0750	-	9.3623	-
Known k	32.1186	0.9215	0.0253	1	1	-
Pan <i>et al.</i> [36]	28.4760	0.8716	0.0395	0.3891	2.6789	1095.12
Graph [13]	26.8741	0.8310	0.0478	0.4702	3.9974	409.47
L_0 text [8]	28.0333	0.8692	0.0415	0.5197	3.1186	532.54
Krishnan <i>et al.</i> [34]	24.6242	0.7638	0.0624	0.3720	6.4377	202.85
Pan <i>et al.</i> [11]	29.2475	0.8806	0.0369	0.5024	2.4887	3696.4
MSLS [12]	27.9391	0.8587	0.0415	0.4403	2.8398	368.82
Proposed method 3	28.4163	0.8672	0.0393	0.5255	2.6334	395.59

با بررسی جدول (۴-۵)، مشاهده می‌شود که روش پیشنهادی توانسته به نتایج قابل قبولی دست پیدا کند و حتی با روش موفق [۱۱] هم قابل رقابت است. افزودن یک قید به تابع هدف، کمی روی سرعت الگوریتم تاثیر داشته‌است اما روش پیشنهادی ما، هنوز از روش‌های موفق اخیر سریع‌تر بوده و نتایج خوبی به دست آورده‌است. جزئیات این نتایج در جدول (۵-۵) گزارش شده‌است.

جدول (۵-۵): مقایسه PSNR و شباهت هسته روی مجموعه داده Levin. نتایج روش پیشنهادی سوم و روش‌های [۸]، [۱۳]، [۱۱] و [۱۲] با یک الگوریتم واپیچش غیرکوریکن [۶].






هسته / تصویر		L ₀ text [8]		Graph [13]		Pan <i>et al.</i> [11]		MSLS [12]		پیشنهاد سوم	
		PSNR	KSIM	PSNR	KSIM	PSNR	KSIM	PSNR	KSIM	PSNR	KSIM
تصویر 1	هسته 1	28.27	0.67	27.69	0.57	29.09	0.74	28.71	0.73	29.45	0.44
	هسته 2	29.35	0.77	27.74	0.66	29.32	0.76	28.94	0.50	27.90	0.66
	هسته 3	29.66	0.72	29.46	0.64	31.56	0.68	29.86	0.64	30.18	0.61
	هسته 4	26.77	0.30	27.81	0.32	27.21	0.25	27.24	0.23	27.57	0.24
	هسته 5	29.54	0.84	29.67	0.66	31.76	0.88	30.79	0.61	29.43	0.83
	هسته 6	29.12	0.31	27.52	0.32	31.24	0.31	27.94	0.37	30.42	0.38
	هسته 7	30.65	0.20	26.27	0.29	29.39	0.14	28.81	0.12	28.68	0.41
	هسته 8	27.43	0.44	27.41	0.45	30.15	0.49	28.41	0.53	30.32	0.55
تصویر 2	هسته 1	27.84	0.61	25.56	0.48	28.94	0.59	25.7	0.40	26.40	0.59
	هسته 2	26.45	0.73	24.85	0.69	28.70	0.82	25.9	0.53	25.85	0.64
	هسته 3	27.03	0.73	28.11	0.69	29.02	0.75	28.23	0.56	29.10	0.76
	هسته 4	26.72	0.25	24.08	0.47	27.65	0.19	22.41	0.09	25.82	0.72
	هسته 5	27.72	0.82	27.58	0.75	30.36	0.78	29.17	0.63	29.80	0.74
	هسته 6	25.68	0.32	25.71	0.39	27.86	0.29	28.12	0.46	29.00	0.28
	هسته 7	27.27	0.30	22.82	0.14	28.36	0.10	27.06	0.06	26.76	0.26
	هسته 8	25.42	0.48	26.87	0.57	29.20	0.40	25.71	0.06	29.87	0.55
تصویر 3	هسته 1	29.67	0.64	27.88	0.62	28.58	0.66	29.33	0.73	28.60	0.69
	هسته 2	29.69	0.77	26.97	0.73	29.88	0.80	27.59	0.42	28.18	0.81
	هسته 3	31.47	0.70	32.67	0.70	32.54	0.65	30.42	0.71	32.97	0.72
	هسته 4	29.44	0.29	25.11	0.27	20.40	0.02	25.39	0.42	26.08	0.21
	هسته 5	31.68	0.85	29.20	0.71	31.08	0.81	32.75	0.61	31.59	0.80
	هسته 6	30.30	0.35	28.80	0.31	30.34	0.32	29.5	0.23	29.79	0.32
	هسته 7	30.41	0.11	27.31	0.41	31.29	0.17	27.13	0.24	28.90	0.52
	هسته 8	29.14	0.46	28.74	0.31	30.26	0.54	28.96	0.57	28.54	0.61
تصویر 4	هسته 1	28.28	0.58	26.82	0.20	29.56	0.59	27.95	0.47	28.39	0.48
	هسته 2	27.43	0.66	24.31	0.48	28.90	0.72	24.59	0.4	24.68	0.53
	هسته 3	29.69	0.66	30.76	0.67	31.31	0.60	31.84	0.24	31.24	0.62
	هسته 4	18.43	0.13	18.28	0.14	18.67	0.18	26.17	0.38	25.76	0.19
	هسته 5	28.99	0.75	30.07	0.79	30.75	0.80	31.84	0.83	32.20	0.84
	هسته 6	26.95	0.35	27.54	0.25	31.41	0.32	28.33	0.39	28.73	0.47
	هسته 7	25.11	0.33	23.88	0.17	30.09	0.29	24.44	0.14	25.10	0.23
	هسته 8	25.46	0.48	22.48	0.16	31.04	0.43	24.66	0.60	22.00	0.15
میانگین		28.03	0.51	26.87	0.47	29.24	0.50	27.93	0.44	28.42	0.53

همچنین برای نشان دادن قدرت روش پیشنهادی، در شکل (۵-۱۱) جزئیات مرحله به مرحله فرآیند تخمین هسته تاری در هر مقیاس نمایش داده شده است. ملاحظه می شود که در هر سطح از هرم ماتزداپی، هسته تاری اولیه چطور پاکسازی می شود تا در نهایت یک هسته تمیز با کمترین میزان نویز حاصل گردد.



شکل (۵-۱۱): مراحل تخمین هسته تاری پیشنهاد سوم در هر مقیاس. الف) هسته تخمینی اولیه. ب) نقشه پیوستگی ساخته شده از (الف). ج) حذف نویز از هسته و تولید u . د) هسته تخمینی با کاهش نویز.

در شکل (۵-۱۲)، مقایسه‌ای بین هسته‌های تخمینی روش‌های اخیر و روش پیشنهادی انجام گرفته‌است که نشان می‌دهد هسته‌های به‌دست‌آمده از روش ما، کمترین میزان نویز و بیشترین شباهت را به هسته صحیح مبنا دارند.

هسته	صحیح مبنا	$L_0 \text{ text}$ [۸]	Graph [۱۳]	Pan et al. [۱۱]	MSLS [۱۲]	پیشنهاد سوم
هسته ۱						
هسته ۲						
هسته ۳						
هسته ۴						
هسته ۵						
هسته ۶						
هسته ۷						
هسته ۸						

شکل (۵-۱۲): هسته تخمین زده شده از تصویر شماره ۱ در مجموعه داده Levin توسط الگوریتم واپیچش غیرکور یکسان [۶]. از چپ به راست: هسته تاری صحیح مبنا و هسته حاصل از روش‌های $L_0 \text{ text}$ [۸]، مرجع [۱۳]، مرجع [۱۱]، مرجع [۱۲] و روش پیشنهادی سوم. از بالا به پایین: هسته شماره ۱ تا هسته شماره ۸.

شکل (۵-۱۳)، (۵-۱۴) و (۵-۱۵) به ترتیب نمونه مات‌زدایی‌هایی از مجموعه داده [۳۲]، [۳۱] و [۹] را نمایش می‌دهند. مقایسه نتایج نشان می‌دهد که روش پیشنهادی بهترین عملکرد را در بین روش‌های موجود داشته‌است.



(الف)




(ب)



(ج)



(د)



(ه)




(و)

شکل (۵-۱۳): مقایسه بصری نتیجه مات‌زدایی تصویر توربین در [۳۲]. الف) تصویر مات. ب) نتیجه مرجع [۳۴].


ج) نتیجه مرجع [۳۶]. د) نتیجه مرجع [۱۳]. ه) نتیجه مرجع [۱۲]. و) روش پیشنهادی سوم. تصاویر ارائه شده در وضوح کامل خود نمایش داده شده‌اند و با بزرگنمایی جزئیات قابل رؤیت است.

ملاحظه می‌شود که روش پیشنهادی توانسته بر خلاف سایر روش‌ها، یک تصویر واضح با کمترین

میزان آلايه ارائه دهد و حتی در بازسازی توربین‌های دوردست تصویر هم موفق بوده‌است.




(الف)



(ب)




(ج)



(د)





(ه)





(و)



شکل (۵-۱۴): مات‌زدایی تصویر متنی با یک هسته تاری 31×31 از مجموعه داده [۳۱] با واپیچش غیرکور [۶]. (الف) تصویر مات. (ب) نتیجه مات‌زدایی با هسته تاری صحیح مبنا. (ج) نتیجه روش [۱۳]. (د) نتیجه روش [۱۱]. (ه) نتیجه روش [۱۲]. (و) نتیجه روش پیشنهادی سوم.





(الف)



(ب)



(ج)



(د)

شکل (۵-۱۵): مقایسه نتایج رفع ماتی چند تصویر متنی چالش برانگیز از [۹]. (الف) تصویر مات. (ب) نتیجه روش [۱۳]. (ج) نتیجه روش [۱۲]. (د) نتیجه پیشنهاد سوم. (تصاویر با وضوح کامل نمایش داده شده‌اند و با بزرگنمایی جزئیات قابل رؤیت است).

همچنین در شکل (۵-۱۶)، روش پیشنهادی را روی تصاویر مات ساختگی ناشی از هسته تاری بزرگ و چالش برانگیز مجموعه داده [۳۱] مورد ارزیابی قرار دادیم. با اینکه نتایج به دست آمده حاوی آلاینده است اما همچنان نسبت به سایر روش‌های موجود، تصاویر بهتری ارائه شده است. ملاحظه می‌شود که حتی روش‌های موفق و در عین حال از نظر محاسباتی پرهزینه، مانند روش مبتنی بر کانال تاریک [۱۱] و روش مبتنی بر منظم شده L_0 [۸] نیز، قادر به مات زدایی این تصاویر نشده‌اند.



(الف)

(ب)

(ج)

(د)

شکل (۵-۱۶): نتیجه مات زدایی تصاویر مات مصنوعی از یک هسته چالش برانگیز 75×75 توسط الگوریتم واپیش غیر کور [۶]. (الف) تصویر مات و هسته تاری. (ب) نتیجه روش [۱۱]. (ج) نتیجه روش [۸]. (د) نتیجه روش پیشنهادی. (تصاویر با وضوح کامل نمایش داده شده‌اند و با بزرگنمایی جزئیات قابل رؤیت است).

مقایسه نتایج مات زدایی شده در شکل (۵-۱۷) (د) و (و) نشان می‌دهد که روش ما توانسته در مدت زمان کمتر، تصویر واضح باز یابی شده‌ای ارائه دهد که با نتیجه روش [۱۱] قابل رقابت باشد.



(الف)



(ب)



(ج)



(د)




(ه)




(و)

شکل (۵-۱۷): رفع ماتی تصویر مات طبیعی، با واپیچش غیر کور [۶]. الف) تصویر مات. ب) نتیجه مرجع [۸]. ج) نتیجه مرجع [۳۶]. د) نتیجه مرجع [۱۱]. ه) نتیجه مرجع [۱۲]. و) نتیجه پیشنهاد سوم.

مقایسه نتایج پیشنهادی: مثالی از مجموعه داده [۳۱] در شکل (۵-۱۸) نمایش داده شده که در آن نتایج حاصل از روش‌های پیشنهادی به صورت گمی و کیفی مورد بررسی قرار گرفته است. ملاحظه می‌شود که روی این تصویر ورودی، پیشنهاد سوم عملکرد بهتری نسبت به سایر روش‌ها داشته اما روش ماسک پشتیبان به دلیل آستانه‌های نامناسب، هسته تاری درستی تخمین نزده و موفق به رفع ماتی نشده است.




(الف) PSNR=19.883



(ب) PSNR=26.136



(ج) PSNR=20.101




(د) PSNR=26.491



(ه) PSNR=26.7424

شکل (۵-۱۸): مقایسه ایده‌های پیشنهادی. الف). تصویر مات و هسته تاری صحیح مبنا. ب) نتیجه پیشنهاد اول. ج) نتیجه پیشنهاد دوم (ماسک پشتیبان). د) نتیجه پیشنهاد دوم (ماسک نقشه پیوستگی). ه) نتیجه پیشنهاد سوم.

موارد ناموفق: شکل (۵-۱۹) دو مثال از نتایج مات‌زدایی شده روش‌های پیشنهادی را نشان می‌دهد. از آنجایی که این تصاویر مات ورودی، دارای اندازه کوچک با بافت‌های غنی (تصویر ردیف اول) یا هسته نسبتاً بزرگ یا پیچیده (تصویر ردیف دوم) هستند، لذا ایده‌های پیشنهادی در رفع ماتی عملکرد قابل قبولی نداشتند.



(الف)

(ب)

(ج)

(د)

شکل (۵-۱۹): موارد شکست روش‌های پیشنهادی. الف) تصاویر مات به اندازه 265×247 (بالا) و 126×123 (پائین) با هسته تاری به اندازه 45×45 (بالا) و 23×23 (پائین). ب) نتایج روش پیشنهادی اول. ج) نتایج روش ماسک پشتیبان. د) نتایج روش پیشنهادی سوم.

۵-۵- نتیجه‌گیری

در این فصل الگوریتم‌های پیشنهادی را مورد بررسی کمی و کیفی قرار دادیم و نتایج هر یک را با روش‌های اخیر در حوزه مات‌زدایی کور تصویر مقایسه کرده‌ایم. پیشنهاد اول که مبتنی بر انتخاب لبه‌های مهم تصویر بود نتایج خوبی ارائه کرده اما در مواردی که تصویر مات ورودی دارای لبه‌های مهم نباشد این الگوریتم عملکرد مطلوب را نخواهد داشت. در پیشنهاد دوم که مبتنی بر پاکسازی هسته تاری هستند نیز هسته‌های تمیزی تخمین زده شده و نتایج مات‌زدایی شده، از کیفیت خوبی برخوردار بودند. در پیشنهاد سوم که مربوط به افزودن قید پیوستگی به فرآیند تخمین هسته است، با توجه به اینکه تصاویر واضح میانی و هسته‌های تاری، در یک ساختار هرمی، به صورت تکرار شونده و نوبتی بازیابی می‌شوند، لذا نتایج قابل قبولی در مدت زمان کمتری حاصل می‌گردد که می‌تواند با نتایج روش‌های پیشرفته اخیر رقابت کند.

فصل هشتم

نتیجه‌گیری و پیشنهادات برای ادامه کار

۶-۱- نتیجه‌گیری

در این پایان‌نامه، فرآیند رفع ماتی کور از تصاویر مورد بررسی قرار گرفته‌است. ماتی تصویر می‌تواند در اثر حرکت نسبی دوربین و صحنه اتفاق افتد و یا اینکه به دلیل عدم تطابق عدسی دوربین، بخش یا تمام صحنه در تصویر ثبت شده تار شود. مسئله رفع تاری اهمیت زیادی در حوزه پردازش تصویر دارد. ما در این پایان‌نامه سعی نمودیم تا کیفیت تصویر بازسازی شده را نسبت به روش‌های پیشین بهبود بخشیم. در فصل اول این پایان‌نامه، به بیان مسئله و معرفی کاربردها و چالش‌های آن اشاره شد. همچنین انواع مات‌شدگی و معیارهای ارزیابی تصاویر مات‌زدایی شده نیز معرفی گردید. مسئله رفع ماتی کور، به دلیل ناشناخته بودن عامل ماتی و در دسترس نبودن هسته تاری، بسیار چالش‌برانگیز است و در سال‌های اخیر، روش‌های متعددی به آن پرداخته‌اند، که در فصل دوم مهم‌ترین راهکارهای پیشنهاد شده در ادبیات موضوع، معرفی و ارزیابی شد. در فصل سوم، مبانی نظری مورد نیاز برای درک روش پیشنهادی توضیح داده شد.

هدف اصلی این پژوهش، استفاده از ایده هرم تصویر مات و دانش پیشین پیوستگی هسته تاری به منظور انجام یک فرآیند مات‌زدایی سریع و دقیق است. روش مات‌زدایی به کمک هرم تصویر بر این ایده استوار است که با کاهش ابعاد یک تصویر مات در هرم تصویر، وضوح تصویر بهتر به نظر می‌رسد، لذا از اطلاعات وصله‌های تصویر در سطوح مختلف استفاده می‌شود تا تصویری واضح‌تر نسبت به تصویر مات ساخته شود. روش مات‌زدایی به کمک هرم تصویر نسبت به اکثر روش‌های مات‌زدایی از سرعت خوبی برخوردار است، اما بعضاً در مات‌شدگی‌های پیچیده، هسته تاری مطمئنی تخمین نمی‌زند و این هسته‌های حاوی نویز، منتج به تصاویر حاوی آلایه می‌شوند.

در پیشنهاد اول سعی شده‌است در مرحله تخمین هسته، به جای استفاده از گرادیان کل تصویر، از گرادیان لبه‌های مهم تصویر واضح میانی استفاده شود و لبه‌های ضعیف که اطلاعات درستی در تخمین هسته تاری در اختیار نمی‌گذارد، نادیده گرفته شوند. همان‌طور که در فصل نتایج نشان داده شد، این

فرآیند منجر به هسته‌های تاری دقیق‌تری شده و حتی در مواردی که روش‌های اخیر در بازسازی تصویر واضح ناموفق عمل نموده‌اند، روش پیشنهادی عملکرد بهتری داشته‌است.

در پیشنهاد دوم، به پاکسازی محلی هسته تخمین زده شده در هر تکرار از هر مقیاس پرداختیم. در فرآیند تخمین هسته تاری، المانهای مزاحمی به وجود می‌آید که در تصویر بازسازی‌شده، ایجاد اثرات مصنوعی می‌نماید. برای پاکسازی هسته از این عوامل مزاحم، هم روش شناسایی تکرار شونده پشتیبان و هم روش نقشه پیوستگی مطرح شده‌است. این پردازش وفقی هسته تاری با حذف نویزهای احتمالی، هسته‌های مطمئن‌تر و بدون نویزی ارائه می‌کند. ارزیابی‌های انجام‌شده نشان می‌دهد که این ایده پیشنهادی، نتایج قابل قبولی ارائه می‌دهد و هسته‌های به دست آمده، شباهت بیشتری به هسته‌های صحیح مبنا دارند.

مشاهدات نشان می‌دهد که تنکی و پیوستگی، از ویژگی‌های اصلی هسته‌های تاری هستند که در روش هرم تصویر، این ویژگی‌ها به دلیل بازسازی تصویر واضح میانی از یک نسخه‌ی نمونه‌کاهی شده از تصویر مات، حفظ نمی‌شوند. لذا قید پیوستگی هسته تاری را به رابطه بهینه‌سازی مسئله اضافه نمودیم تا هسته‌های تخمین زده شده به هسته‌های حقیقی نزدیک‌تر باشند و در نتیجه تصویر بازیابی شده وضوح بهتری داشته‌باشد. همچنین در رابطه تخمین هسته از گرادیان‌های مهم استفاده شده‌است. قید پیوستگی، کمی سرعت اجرای فرآیند را کاهش داده اما در بخش نتایج نشان داده شده که همچنان از سرعت قابل قبولی برخوردار است و قادر به رفع ماتی‌های پیچیده‌ای است که روش‌های پیشرفته اخیر در مات‌زدایی آن‌ها ناموفق بوده‌اند. ضمن اینکه پیاده‌سازی الگوریتم پیشنهادی به زبان نرم‌افزاری C++ و یا استفاده از GPU می‌تواند بهبود بیشتری به سرعت اجرا آن بدهد.

ارزیابی‌ها نشان می‌دهد که روش پیشنهادی در تصاویر با اندازه کوچک مات شده با هسته‌های پیچیده، عملکرد خوبی ندارد. دلیل آن این است که در تصاویر با اندازه کوچک، به دلیل عملیات نمونه‌کاهی تصویر

مات، اطلاعات مفید برای تخمین هسته تاری از بین می‌رود و هیچ داده‌ای برای تخمین دقیق هسته تاری وجود نخواهد داشت.

۶-۲- پیشنهاد برای ادامه کار

یکی از چالش‌هایی که همواره در مسئله مات‌زدایی وجود داشته‌است، دانستن اندازه هسته ماتی است. اگر اندازه هسته تاری متناسب با اندازه مات‌شدگی تصویر نباشد، فرآیند تخمین هسته همگرا نخواهد شد. برای هسته‌های بزرگ‌تر از اندازه حقیقی، افزایش نویز بیشتری خواهیم داشت و برای اندازه هسته‌های کوچک‌تر، تخمین صحیحی انجام نمی‌گیرد.

اخیراً روش‌هایی پیشنهاد شده‌اند که اندازه هسته تاری را تخمین زده تا به عنوان ورودی الگوریتم‌های رفع ماتی به کار گرفته شوند. ضمن اینکه روش پیشنهادی نسبت به اندازه هسته ورودی حساسیت زیادی ندارد، اما قصد داریم در کار بعدی از روش جدید تخمین اندازه هسته تاری مبتنی بر فاز تصویر [۳۷] برای تقویت روش پیشنهادی استفاده کنیم.

همچنین پیشنهاد بعدی، استفاده از روش‌های فراتفکیک‌پذیری موثرتر به جای روش هرم تصویر جهت بازسازی تصاویر واضح میانی می‌باشد. در روش پیشنهادی، ابتدا تصویر بازسازی شده میانی به کمک هرم تصویر تولید می‌شود و سپس به کمک بهینه‌سازی تابع هدف در مدل ماتی، هسته تاری تخمین زده می‌شود و نهایتاً به کمک هسته تاری، تصویر واضح نهایی بازسازی می‌شود. هر چه تصویر بازسازی شده میانی اعوجاج کمتری داشته باشد فرآیند تخمین هسته تاری سریع‌تر همگرا می‌شود و هسته تاری دقیق‌تر تخمین زده می‌شود.

همان‌طوری که در پایان‌نامه اشاره شد، یکی از چالش‌های مهم مات‌زدایی تصویر، آلاینده‌ها هستند. از دیگر ایده‌هایی که به دنبال آن هستیم تشخیص خودکار آلاینده در خروجی بازسازی شده تصویر است. با

تشخیص خودکار آلاینده می‌توان ابعاد هسته تاری اولیه را به گونه‌ای اصلاح نمود که نتیجه بازسازی شده
دچار اعوجاج کمتری شود.

مراجع

- [1] W. H. Richardson, "Bayesian-based iterative method of image restoration," *JoSA*, vol. 62, no. 1, pp. 55-59, 1972.
- [2] R. L. Lagendijk and J. Biemond, "Chapter 14 - Basic Methods for Image Restoration and Identification," *The Essential Guide to Image Processing*, Academic Press, 2009, pp. 323-348.
- [3] A. Debnath, H. Mohan Rai, C. Yadav, A. Agarwal, and A. Bhatia, "Deblurring and denoising of magnetic resonance images using blind deconvolution method," *International Journal of Computer Applications*, vol. 81, no. 10, pp. 7-12, 2013.
- [4] Zhou Wang, A. C. Bovik, H. R. Sheikh and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600-612, 2004.
- [5] L. Xu, S. Zheng and J. Jia, "Unnatural L_0 Sparse Representation for Natural Image Deblurring," *2013 IEEE Conference on Computer Vision and Pattern Recognition*, 2013, pp. 1107-1114.
- [6] D. Krishnan and R. Fergus, "Fast image deconvolution using hyper-Laplacian priors," *Proceedings of the 22nd International Conference on Neural Information Processing Systems*, 2009, pp. 1033-1041.
- [7] J. Kotera, F. Šroubek, and P. Milanfar, "Blind deconvolution using alternating maximum a posteriori estimation with heavy-tailed priors," *Computer Analysis of Images and Patterns*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, pp. 59-66.
- [8] J. Pan, Z. Hu, Z. Su and M. Yang, "Deblurring Text Images via L_0 -Regularized Intensity and Gradient Prior," *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 2901-2908.
- [9] J. Pan, Z. Hu, Z. Su, and M.-H. Yang, " L_0 -regularized intensity and gradient prior for deblurring text images and beyond," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 2, pp. 342-355, 2017.
- [10] W. Ren, X. Cao, J. Pan, X. Guo, W. Zuo, and M.-H. Yang, "Image deblurring via enhanced low-rank prior," *IEEE Transactions on Image Processing*, vol. 25, no. 7, pp. 3426-3437, 2016.
- [11] J. Pan, D. Sun, H. Pfister, and M.-H. Yang, "Blind image deblurring using dark channel prior," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 1628-1636.
- [12] Y. Bai, H. Jia, M. Jiang, G. Cheung, X. Liu, X. Xie and W. Gao, "Single-image blind deblurring using multi-scale latent structure prior," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 30, no. 7, pp. 2033-2045, 2020.
- [13] Y. Bai, G. Cheung, X. Liu, and W. Gao, "Graph-based blind image deblurring from a single photograph," *IEEE Transactions on Image Processing*, vol. 28, no. 3, pp. 1404-1418, 2019.

- [14] S. Gu, L. Zhang, W. Zuo and X. Feng, “Weighted Nuclear Norm Minimization with Application to Image Denoising,” *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 2862-2869.
- [15] G. Freedman and R. Fattal, “Image and video upscaling from local self-examples,” *ACM Transactions on Graphics*, vol. 30, no. 2, pp. 1-11, 2011.
- [16] S. Nah, T. H. Kim, and K. M. Lee, “Deep multi-scale convolutional neural network for dynamic scene deblurring,” *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 3883-3891.
- [17] C. J. Schuler, M. Hirsch, S. Harmeling, and B. Scholkopf, “Learning to Deblur,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 7, pp. 1439-1451, 2016.
- [18] Xu, Li, Jimmy Ren, Qiong Yan, Renjie Liao, and Jiaya Jia. “Deep edge-aware filters,” *International Conference on Machine Learning*, 2015, pp. 1669-1678.
- [19] J. Pan, W. Ren, Z. Hu, and M.-H. Yang, “Learning to deblur images with exemplars,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 41, no. 6, pp. 1412-1425, 2019.
- [20] T. F. Chan and Chiu-Kwong Wong, “Total variation blind deconvolution,” *IEEE Transactions on Image Processing*, vol. 7, no. 3, pp. 370-375, 1998.
- [21] R. Fergus, B. Singh, A. Hertzmann, S. T. Roweis, and W. T. Freeman, “Removing camera shake from a single photograph,” *ACM Transactions on Graphics*, vol. 25, no. 3, pp. 787-794, 2006.
- [22] Q. Shan, J. Jia, and A. Agarwala, “High-quality motion deblurring from a single image,” *ACM Transactions on Graphics*, vol. 27, no. 3, pp. 1-10, 2008.
- [23] N. Joshi, R. Szeliski and D. J. Kriegman, “PSF estimation using sharp edge prediction,” *2008 IEEE Conference on Computer Vision and Pattern Recognition*, 2008, pp. 1-8.
- [24] L. Xu and J. Jia, “Two-phase kernel estimation for robust motion deblurring,” *European Conference on Computer Vision*, Berlin, Heidelberg, 2010, pp. 157-170.
- [25] A. Levin, Y. Weiss, F. Durand and W. T. Freeman, “Understanding and evaluating blind deconvolution algorithms,” *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 1964-1971.
- [26] S. Cho and S. Lee, “Fast motion deblurring,” *ACM Transactions on Graphics*, vol. 28, no. 5, pp. 1-8, 2009.
- [27] L. Xu, C. Lu, Y. Xu, and J. Jia, “Image smoothing via L_0 gradient minimization,” *ACM Transactions on Graphics*, vol. 30, no. 6, pp. 1-12, 2011.
- [28] X. Chen, Y. Zhu, J. Sun and Y. Zhang, “Robust motion blur kernel estimation by kernel continuity prior,” *IEEE Access*, vol. 8, pp. 46162-46175, 2020.

- [29] A. Rajagopalan and R. Chellappa, *Motion Deblurring: Algorithms and Systems*. Cambridge, UK: Cambridge University Press, 2014.
- [30] S. Sun, H. Zhao, B. Li, M. Hao, and J. Lv, "Kernel estimation for robust motion deblurring of noisy and blurry images," *Journal of Electronic Imaging*, vol. 25, no. 3, p. 033019, 2016.
- [31] W. -S. Lai, J. -B. Huang, Z. Hu, N. Ahuja and M. -H. Yang, "A Comparative Study for Single Image Blind Deblurring," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 1701-1709.
- [32] L. Sun, S. Cho, J. Wang and J. Hays, "Edge-based blur kernel estimation using patch priors," *IEEE International Conference on Computational Photography (ICCP)*, 2013, pp. 1-8.
- [33] T. Michaeli and M. Irani, "Blind deblurring using internal patch recurrence," *European Conference on Computer Vision*, 2014, pp. 783-798.
- [34] D. Krishnan, T. Tay and R. Fergus, "Blind deconvolution using a normalized sparsity measure," *CVPR 2011*, 2011, pp. 233-240.
- [35] W. Dong, L. Zhang and G. Shi, "Centralized sparse representation for image restoration," *2011 International Conference on Computer Vision*, 2011, pp. 1259-1266.
- [36] J. Pan, R. Liu, Z. Su, and X. Gu, "Kernel estimation from salient structure for robust motion deblurring," *Signal Processing: Image Communication*, vol. 28, no. 9, pp. 1156-1170, 2013.
- [37] L. Pan, R. Hartley, M. Liu and Y. Dai, "Phase-Only Image Based Kernel Estimation for Single Image Blind Deblurring," *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 6034-6043.
- [38] T. A. Javaran, H. Hassanpour, and V. Abolghasemi, "Blind motion image deblurring using an effective blur kernel prior," *Multimedia Tools and Applications*, vol. 78, no. 16, pp. 22555-22574, 2019.
- [39] Y. Wang and W. Yin, "Sparse signal reconstruction via iterative support detection," *SIAM Journal on Imaging Sciences*, vol. 3, no. 3, pp. 462-491, 2010.
- [40] N. Parikh and S. Boyd, "Proximal algorithms," *Foundations and Trends in Optimization*, vol. 1, no. 3, pp. 127-239, 2014.

Abstract

Images are usually corrupted by noise and blur when recording. Blurriness is typically originated from common sources, including out-of-focus, atmospheric turbulence, camera shake, or object motion. One of the most widely used issues in the field of image processing is removing blur from a blurry image. Image deblurring aims to recover a clear image from an image that may have been blurred for any reason. If the blur kernel is known, this process is called non-blind deblurring; otherwise, it is called blind deblurring.

In this dissertation, the problem of blind deblurring has been studied. Blind deblurring is much more challenging than non-blind deblurring, as only a single input blurry image is available, and we usually directly or indirectly seek to estimate the blur kernel from the blurred image. Finally, non-blind deconvolution methods are used to estimate the blur kernel to remove blurriness.

In this dissertation, we use Multi-Scale Latent Structure (MSLS) prior to estimate the blur kernel and recover a sharp latent image. In the objective function we have proposed to restore the sharpness of the blurry image, we have added a term that encourages the blur kernel continuity and improves the sharpness of the reconstructed image and reduces the artifact. The evaluation results of the proposed method show that the quality of blur removal has improved significantly in many cases and for the database used, the mean of PSNR and SSIM are 28.4163 and 0.8672, respectively. This is while the proposed method is much faster than the state-of-the-art methods.

Keywords: Image deblurring, Blind deconvolution, Blur kernel estimation, Image pyramid representation



Shahrood University of
Technology

Faculty of Electrical Engineering

M.Sc. Thesis in Communication Systems Engineering

Blind Image Deblurring Using Image Pyramid Representation

By:
Amir Eqtedaei

Supervisor:
Dr. Alireza Ahmadyfard

February 2022