

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی کامپیوتر و فناوری اطلاعات

رساله دکتری هوش مصنوعی

# استفاده از اطلاعات تاری تصویر برای تولید تصاویر با تفکیک پذیری بالا

نگارنده: سید جلال سیدیزدی

استاد راهنما

دکتر حمید حسن پور

استاد مشاور

دکتر علیرضا احمدی فرد

بهمن ۱۳۹۸

شماره: ۲۷۷ طرف

تاریخ: ۵، ۱۳، ۹۸

ویرایش:

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره ۱۱: صورت جلسه نهایی دفاع از رساله دکتری (Ph.D)

بدینوسیله گواهی می شود آقای/خانم سید جلال سیدیزدی دانشجوی دکتری رشته مهندسی کامپیوتر هوش مصنوعی به شماره دانشجویی ۹۰۲۳۲۸۵ و ورودی ۱۳۹۰ در تاریخ ۹۸/۱۱/۳۰ از رساله نظری/ عملی خود با عنوان: استفاده از اطلاعات تاری تصویر برای تولید تصاویر با تفکیک پذیری بالا دفاع و با اخذ نمره ..... به درجه: ..... نائل گردید.

الف) درجه عالی: نمره ۱۹-۲۰  (ب) درجه خیلی خوب: نمره ۱۸/۹۹-۲۷   
ج) درجه خوب: نمره ۱۶/۹۹-۱۵  (د) مردود: کمتر از ۱۵

ردیف	هیئت داوران	نام و نام خانوادگی	مرتبیه علمی	امضاء
۱	دکتر حمید حسن پور	استاد راهنما	استاد	
۲	دکتر علیرضا احمدی فرد	مشاور	دانشیار	
۳	دکتر فرزین یغمائی	استاد مدعو خارجی	دانشیار	
۴	دکتر حسین مروی	استاد مدعو داخلی	دانشیار	
۵	دکتر حسین خسروی	استاد مدعو داخلی	استادیار	
۶	دکتر فاطمه جعفری نژاد	سرپرست (نماینده) تحصیلات تکمیلی دانشکده	استادیار	

مدیر محترم تحصیلات تکمیلی دانشگاه:

ضمن تأیید مراتب فوق مقرر فرمائید اقدامات لازم در خصوص انجام مراحل دانش آموختگی آقای سید جلال سیدیزدی بعمل آید.

نام و نام خانوادگی رئیس دانشکده:  
تاریخ و امضاء و مهر دانشکده:

تقدیم به آقا امام زمان (عج)

---

---

## سپاس‌گزاری

فضل خدای را که تواند شمار کرد؟  
شکر کدام فضل به جای آورد کسی؟  
سر چیست تا به طاعت او بر زمین نهند؟  
بخشنده‌ای که سابقه‌ی فضل و رحمتش  
یا کیست آنکه شکر یکی از هزار کرد؟  
حیران بماند هر که درین افتکار کرد  
جان در رهش دریغ نباشد نثار کرد  
ما را به حسن عاقبت امیدوار کرد

مَنّت خدای را عز و جل که طاعتش موجب قربت است و به شکر اندرش مزید نعمت. قبل از هر چیز خدایم را شاکرم که توفیق قدم نهادن در راه علم و دانش را به من عنایت کرد. از همسر عزیزم و دختر نازنینم که در این سال‌ها با صبر و تحمل در کنار من بودند صمیمانه سپاس‌گزاری می‌کنم.

از خانواده خود و خانواده همسر که با حمایت‌های خود یاری‌گرم‌ان بودند، نهایت قدردانی را دارم. از استاد راهنمای خود، جناب آقای دکتر حمید حسن‌پور که با صبر و تحمل مرا از راهنمایی‌ها و حمایت‌های خویش بهره‌مند نمودند، صمیمانه قدردانی و تشکر می‌نمایم. از جناب آقای دکتر علیرضا احمدی فرد که وقت خود را برای مشاوره به اینجانب اختصاص دادند کمال امتنان را دارم.

از داوران گرامی رساله که زحمت داوری و تصحیح این رساله را به عهده داشتند کمال تشکر را دارم. و در پایان برای همه‌ی اساتید و کارکنان دانشگاه صنعتی شاهرود و همچنین دوستان و هم‌کلاسی‌هایم آرزوی عافیت و حسن عاقبت دارم.

الهی سینه‌ای ده آتش افروز  
بده گرمی دل افسرده‌ام را  
ندارد راه فکرم روشنایی  
به راه این امید پیچ در پیچ  
در آن سینه دلی وان دل همه سوز  
فروزان کن چراغ مرده‌ام را  
ز لطف پرتوی دارم گدایی  
مرا لطف تو می‌باید، دگر هیچ

سید جلال سیدیزدی

بهمن ۱۳۹۸

## تعهد نامه

اینجانب سید جلال سیدیزدی دانشجوی دکتری رشته هوش مصنوعی مهندسی کامپیوتر و فناوری اطلاعات دانشگاه شاهرود، نویسنده رساله با عنوان استفاده از اطلاعات تاری تصویر برای تولید تصاویر با تفکیک پذیری بالا، تحت راهنمایی جناب آقای دکتر حمید حسن پور متعهد می‌شوم:

- تحقیقات در این رساله توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش‌های دیگر پژوهش‌گران، به مرجع مورد استفاده استناد شده است.
- مطالب این رساله، تا کنون توسط خود، یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ‌جا رایج نشده است.
- حقوق معنوی این اثر، به دانشگاه صنعتی شاهرود تعلق دارد، و مقالات مستخرج با نام “دانشگاه صنعتی شاهرود” یا “Shahrood University of Technology” به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به‌دست آوردن نتایج اصلی رساله تاثیرگذار بوده‌اند، در مقالات مستخرج از رساله رعایت می‌گردد.
- در تمام مراحل انجام این رساله، در مواردی که از موجود زنده (یا بافت‌های آن‌ها) استفاده شده است، ضوابط و اصول اخلاقی رعایت شده است.
- در تمام مراحل انجام این رساله، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته (یا استفاده شده است)، اصل رازداری و اصول اخلاق انسانی رعایت شده است.

سید جلال سیدیزدی

بهمن ۱۳۹۸

### مالکیت نتایج و حق نشر

- تمام حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه‌های رایانه‌ای، نرم‌افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی، در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در این رساله بدون ذکر منبع مجاز نمی‌باشد.

## چکیده

ابرتفکیک‌پذیری فنی است که با ترکیب اطلاعات موجود در چندین تصویر کم دقت از صحنه، تصویری با تفکیک‌پذیری بیشتر یا به عبارت دیگر تخمینی از تصویر ایده‌آل صحنه را تولید می‌کند. یکی از عواملی که شدیداً بر کیفیت تصاویر تولید شده توسط الگوریتم‌های ابرتفکیک‌پذیری تاثیر می‌گذارد، تخمین درست میزان تار شدگی تصاویر کم دقت ورودی است. در بسیاری از تحقیقات انجام شده، تنها عامل تاری این تصاویر، خاصیت انتگرال‌گیری حسگر دوربین فرض شده است. در حالی که در عمل عوامل دیگری نیز وجود دارند که باعث تاری این تصاویر می‌شوند. در این رساله فرض شده است خاصیت انتگرال‌گیری حسگر دوربین تنها دلیل تاری تصاویر کم دقت ورودی نبوده و عوامل دیگری نیز در این امر دخیل هستند. از این رو در صدد برآمدیم تاری اعمال شده بر روی تصویر ایده‌آل صحنه را برآورد کنیم.

در بخش اول تحقیقات، هسته تاری اعمال شده بر روی تصویر ایده‌آل صحنه، از روی هسته تاری تصاویر ورودی برآورد می‌شود. این کار توسط شبکه عصبی و یادگیری عمیق انجام شده است. بدین منظور هسته تاری تصاویر کم دقت برآورد شده و به شبکه عصبی آموزش دیده اعمال می‌گردد. شبکه عصبی هسته تاری اعمال شده بر روی تصویر پر دقت را تعیین می‌کند. از این هسته‌ی تاری در ابرتفکیک‌پذیری استفاده می‌گردد. بر مبنای این ایده دو روش مجزا پیشنهاد می‌گردد. در روش اول شبکه عصبی به عنوان دسته‌بند، هسته‌ی تاری مطلوب را از میان هسته‌های تاری مفروض پیش‌بینی می‌کند. در روش دوم از شبکه عصبی در چارچوب رگرسیون استفاده می‌شود و هسته‌ی تاری مطلوب توسط آن ساخته می‌شود. نتایج آزمایش‌ها نشان می‌دهد استفاده از هسته‌ی تاری تعیین شده توسط شبکه عصبی در الگوریتم ابرتفکیک‌پذیری باعث افزایش کیفیت تصویر پر دقت خروجی می‌گردد.

در بخش دوم تحقیقات انجام شده، روشی برای ابرتفکیک‌پذیری تصاویری با تاری ناشی از عدم تمرکز عدسی با مقدار تاری نامعلوم پیشنهاد شده است. در این روش ابتدا تصویر پر دقت تار به دست می‌آید و سپس تصویر به دست آمده رفع تاری می‌گردد. از آنجا که پارامتر تاری مشخص نیست، رفع تاری از نوع کور می‌باشد. ابرتفکیک‌پذیری و رفع تاری، مسائلی معکوس و بد مطرح هستند و حل آن‌ها نیاز به اعمال منظم‌سازی دارد. از این رو تابع هزینه و منظم‌ساز مناسبی برای تعیین تصویر و هسته‌ی تاری نامعلوم پیشنهاد گردید. نتایج آزمایش‌ها بیانگر آن است که استفاده از منظم‌ساز پیشنهاد شده موجب افزایش کیفیت تصویر خروجی شده به گونه‌ای که معیار شباهت ساختاری نسبت به کار مقایسه شده تقریباً به میزان ۹۵٪ افزایش یافته است.

کلمات کلیدی: ابرتفکیک‌پذیری، مسائل معکوس، منظم‌سازی، هسته‌ی تاری، یادگیری عمیق، واپیچش کور.

## لیست مقالات مستخرج از رساله

۱. سیدیزدی سید جلال، حسن پور حمید. «ابرتفکیک پذیری: مروری بر روش‌های موجود»، نشریه علمی ترویجی محاسبات نرم، دوره ۲، شماره ۲، ۵۱-۳۶، ۱۳۹۲.
2. S. J. Seyyedyazdi and H. Hassanpour, "Improving Super-resolution Techniques via Employing Blurriness Information of the Image", International Journal of Engineering (IJE), IJE TRANSACTIONS B: Applications, vol. 31, no. 2, pp. 241-249, 2018.
۳. سید جلال سیدیزدی، حمید حسن پور و علیرضا احمدی فرد «روشی برای تخمین هسته تاری جهت بهبود کارایی الگوریتم‌های ابرتفکیک‌پذیری»، اولین کنفرانس علوم و تکنولوژی‌های نوین، بابل، شهریور ۱۳۹۷.
4. S. J. Seyyedyazdi and H. Hassanpour, "Super-resolution of Defocus Blurred Images", International Journal of Engineering (IJE), IJE TRANSACTIONS A: Basics, vol. 33, no. 4, pp. 539-545, 2020.



# فهرست مطالب

ش	فهرست تصاویر
ث	فهرست جداول
ذ	فهرست الگوریتم‌ها
ظ	فهرست اختصارات
۱	۱ ابر تفکیک پذیری
۴	۱-۱ مدل مشاهده یا مدل تخریب تصویر . . . . .
۷	۲-۱ تار و مدل‌های مختلف آن . . . . .
۹	۱-۲-۱ تاثیر کاهش تعداد نمونه بر تار . . . . .
۹	۳-۱ مسائل معکوس و بدمطرح . . . . .
۱۱	۴-۱ هدف رساله . . . . .
۱۲	۵-۱ نوآوری‌ها و دست‌آوردهای رساله . . . . .
۱۳	۶-۱ ساختار رساله . . . . .
۱۳	۷-۱ جمع‌بندی . . . . .
۱۵	۲ کارهای پیشین
۱۶	۱-۲ ابر تفکیک‌پذیری در حوزه فرکانس . . . . .
۱۷	۲-۲ ابر تفکیک‌پذیری چند تصویری در حوزه مکان . . . . .
۱۷	۱-۲-۲ روش پس افکنش تکراری . . . . .
۱۹	۲-۲-۲ پالایش تطبیقی تکراری . . . . .
۱۹	۳-۲-۲ روش‌های مبتنی بر درون‌یابی . . . . .
۲۰	۴-۲-۲ روش‌های افکنش بر مجموعه‌های محدب . . . . .
۲۱	۵-۲-۲ رهیافت مبتنی بر منظم‌سازی . . . . .
۲۴	۶-۲-۲ روش‌های مبتنی بر چارچوب بیز . . . . .

۲۶	.....	رهیافت مبتنی بر یادگیری	۷-۲-۲
۲۷	.....	تخمین تاری	۳-۲
۲۸	.....	تغییرات هندسی و روش‌های ثبت تصویر	۴-۲
۲۹	.....	جمع‌بندی	۵-۲
۳۱	<b>تعیین تاری اعمال شده بر تصویر پر دقت با شبکه عصبی</b>		
۳۱	.....	مقدمه	۱-۳
۳۲	.....	چالش مسئله	۲-۳
۳۳	.....	تعیین تاری با شبکه عصبی	۳-۳
۳۴	.....	ساختار و آموزش شبکه عصبی	۴-۳
۳۵	.....	ارزیابی روش پیشنهادی و نتایج آزمایش‌ها	۵-۳
۴۱	.....	جمع‌بندی	۶-۳
۴۳	<b>تعیین تاری اعمال شده بر تصویر پر دقت با یادگیری عمیق</b>		
۴۳	.....	مقدمه	۱-۴
۴۴	.....	تخمین هسته‌ی تاری تصویر پر دقت	۲-۴
۴۵	.....	ساختار شبکه‌های عصبی	۳-۴
۴۸	.....	آموزش شبکه‌های عصبی	۴-۴
۴۸	.....	تولید داده‌های آموزشی	۱-۴-۴
۵۰	.....	حذف هسته‌های پرت	۲-۴-۴
۵۱	.....	استفاده از روش پیشنهادی	۵-۴
۵۱	.....	نتایج آزمایش‌ها	۶-۴
۵۳	.....	جمع‌بندی	۷-۴
۵۵	<b>ابرتفکیک‌پذیری تصاویر با تاری ناشی از عدم تمرکز عدسی</b>		
۵۵	.....	مقدمه	۱-۵
۵۵	.....	الگوریتم بهینه‌یابی ADMM	۲-۵
۵۷	.....	روش پیشنهادی	۳-۵
۵۸	.....	تخمین تصویر پر دقت تار	۱-۳-۵
۵۹	.....	تاری‌زدایی تصویر پر دقت تار	۲-۳-۵
۶۱	.....	تخمین تصویر پر دقت	۴-۵
۶۳	.....	تخمین هسته‌ی تاری	۵-۵
۶۴	.....	نتایج آزمایش‌ها	۶-۵
۷۱	.....	جمع‌بندی	۷-۵

۷۳	جمع‌بندی و کارهای آینده	۶
۷۳	مقدمه	۱-۶
۷۳	جمع‌بندی روش‌های پیشنهادی در رساله	۲-۶
۷۶	کارهای آینده	۳-۶
۸۱	واژه نامه انگلیسی به فارسی	
۸۵	واژه نامه فارسی به انگلیسی	
۹۱	مراجع	

# فهرست تصاویر

۱-۱	مفهوم تفکیک‌پذیری. میزان تفکیک‌پذیری در تصاویر از راست به چپ افزایش پیدا کرده است. . . . .	۲
۲-۱	نمونه‌ای از آرایه $4 \times 4$ از دوربین‌ها. . . . .	۳
۳-۱	فاصله زیرپیکسلی. الف) عدم وجود فاصله‌ی زیرپیکسلی بین دو دوربین. (فاصله‌ی دو دوربین دقیقاً مضربی از اندازه‌ی سلول‌های حسگر است.) ب) وجود فاصله‌ی زیرپیکسلی بین دو دوربین. . . . .	۴
۴-۱	مثالی از اعمال مدل مشاهده‌ی warp-blur . . . . .	۶
۵-۱	مثالی از اعمال مدل مشاهده‌ی blur-warp . . . . .	۷
۶-۱	تاثیر کاهش تعداد نمونه بر تاری. سیگنال اصلی (خط ممتد) دارای تاری متفاوتی نسبت به سیگنال کاهش تعداد نمونه (خط چین) است. . . . .	۱۰
۱-۲	نمونه‌ای از دیکشنری شامل ۵۱۲ وصله‌ی پر دقت با اندازه $9 \times 9$ . . . . .	۲۶
۱-۳	مدل warp-blur . . . . .	۳۱
۲-۳	خروجی الگوریتم تخمین هسته بر روی چهار تصویر LR. تصاویر LR با استفاده از مدل مشاهده، از روی یک تصویر HR و با اعمال تاری یکسان و تغییرات هندسی متفاوت ایجاد شده‌اند. . . . .	۳۲
۳-۳	نمودار روش پیشنهادی . . . . .	۳۳
۴-۳	فرآیند آموزش شبکه عصبی . . . . .	۳۵
۵-۳	تعدادی از تصاویر استفاده شده برای آموزش شبکه عصبی . . . . .	۳۶
۶-۳	تعدادی از تصاویر استفاده شده برای آزمون شبکه عصبی . . . . .	۳۶
۷-۳	نتیجه روش پیشنهادی در بازسازی تصاویر کم دقت تار. در هر مجموعه از تصاویر، ردیف بالا یکی از تصاویر کم دقت و ردیف پایین تصویر پر دقت بازسازی شده را نشان می‌دهد. ستون‌ها به ترتیب از چپ به راست معادلند با هسته‌های تاری ۱ تا ۶. معیار SSIM تصاویر باز یافت شده در زیر شکل‌ها نشان داده شده است. . . . .	۳۹

۸-۳	نتیجه روش پیشنهادی در بازسازی تصاویر کم دقت تاری. در هر مجموعه از تصاویر، ردیف بالا یکی از تصاویر کم دقت و ردیف پایین تصویر پر دقت بازسازی شده را نشان می‌دهد.
۴۰	ستون‌ها به ترتیب از چپ به راست معادلند با هسته‌های تاری ۱ تا ۶. . . . .
۴۰	تاثیر انتخاب درست هسته‌ی تاری در حاصل الگوریتم ابرتفکیک‌پذیری. . . . .
۴۵	ساختار شبکه عصبی عمیق . . . . .
۴۶	بلوک Inception-ResNet مورد استفاده در شبکه عصبی عمیق . . . . .
۴۷	ساختار شبکه عصبی پیچشی . . . . .
۴۷	روال آموزش دو شبکه عصبی عمیق . . . . .
۵۱	نمودار بلوکی استفاده از روش پیشنهادی . . . . .
۵۱	تصویر اصلی مورد استفاده در نتایج نشان داده شده در شکل ۴-۷. . . . .
۷-۴	نتیجه اعمال روش پیشنهادی. ردیف بالا: ابرتفکیک‌پذیری تصاویر تاری شده با هسته‌ی گوسی، ردیف پایین: ابرتفکیک‌پذیری تصاویر تاری شده با هسته‌ی دیسک. هر یک از شکل‌های (ج) و (و) شامل دو هسته‌ی تاری اصلی و برآورد شده می‌باشند که برای مقایسه به صورت یک بعدی نمایش داده شده‌اند. . . . .
۵۲	نمونه‌ای از خطای ایجاد شده در بازسازی تصویر HR. . . . .
۵۳	تعدادی از تصاویر استفاده شده در آزمایش اول . . . . .
۶۴	مقایسه نتایج روش پیشنهادی بر روی داده‌های تاری شده با هسته‌ی تاری $7 \times 7$ . . . . .
۶۷	مقایسه نتایج روش پیشنهادی بر روی داده‌های تاری شده با هسته‌ی تاری $11 \times 11$ . . . . .
۶۸	مقایسه نتایج روش پیشنهادی بر روی داده‌های تاری شده با هسته‌ی تاری $15 \times 15$ . . . . .
۶۹	نمودار معیار SSIM تصویر بازسازی شده در تکرارهای مختلف الگوریتم ۳-۵ . . . . .
۷۰	

# فهرست جداول

۳۴	.....	مشخصات هسته‌های تاری آموزشی	۱-۳
۳۷	.....	ماتریس در هم ریختگی قبل از اعمال رای گیری	۲-۳
۳۷	.....	ماتریس در هم ریختگی بعد از اعمال رای گیری	۳-۳
۳۸	.....	میانگین معیارهای شباهت ساختاری و میانگین مربع خطا	۴-۳
۶۶	..	معیار SSIM مربوط به نتایج روش پیشنهادی بر روی ۱۰ تصویر آزمون و مقایسه‌ی آن	۱-۵
۷۰	.....	مقایسه‌ی نتایج الگوریتم پیشنهادی بر روی ۶۰ تصویر آزمون	۲-۵

## فهرست الگوریتم‌ها

۴۴	الگوریتم پیشنهادی برای تخمین هسته‌ی تار	۱-۴
۵۰	الگوریتم حذف هسته‌های پرت	۲-۴
۵۶	الگوریتم ADMM	۱-۵
۵۸	الگوریتم کاهش گرادیان برای حل رابطه‌ی (۵-۵)	۲-۵
۵۹	الگوریتم واپیچش کور مورد استفاده	۳-۵

# فهرست اختصارات

## L

LABTV . Locally Adaptive Bilateral Total Variation  
LR..... Low Resolution

## M

MAP..... Maximum a Posteriori  
ML..... Maximum Likelihood  
MRF ..... Markov Random Field  
MSE..... Mean Square Error

## P

POCS ..... Projection onto Convex Sets  
PSF..... Point Spread Function  
PSNR ..... Peak Signal-to-Noise Ratio

## S

SAR..... Simultaneous Autoregressive  
SGW..... Second Generation Wavelet  
SIFT ..... Scale Invariant Feature Transform  
SR ..... Super Resolution  
SSIM..... Structural Similarity  
SVD..... Singular Value Deconvolution

## A

Adam ..... Adaptive Moment Estimation  
ADMM Alternating Direction Method of Multipliers

## B

BTB..... Bilateral Total Variation

## C

CNN..... Convolutional Neural Network

## D

DNN..... Deep Neural Network

## H

HMRF..... Huber Markov Random Field  
HR..... High Resolution

## I

IBP..... Iterative Back Projection



**T**

TV ..... Total Variation

# فصل ۱

## ابرتفکیک پذیری


امروزه کاربرد تصاویر دیجیتال در صنعت، پزشکی، سیستم‌های امنیتی و نظامی و دیگر جنبه‌های زندگی بسیار متداول گردیده است. بدیهی است که کارایی تصاویر مورد استفاده به میزان کیفیت آن‌ها بستگی دارد. یکی از عوامل موثر در کیفیت تصاویر، میزان دقت یا تفکیک‌پذیری<sup>۱</sup> تصویر است.<sup>۲</sup> منظور از تفکیک‌پذیری، جزئیاتی است که یک تصویر داراست. هر چه تفکیک‌پذیری تصویر بیشتر باشد، جزئیات تصویر بیشتر است. در شکل ۱-۱ مفهوم تفکیک‌پذیری به تصویر کشیده شده است. با توجه به اهمیت تفکیک‌پذیری، روش‌هایی برای افزایش آن ابداع شده است. به طور کلی دو رهیافت برای افزایش میزان تفکیک‌پذیری تصویر وجود دارد: رهیافت سخت‌افزاری و رهیافت نرم‌افزاری. در رهیافت سخت‌افزاری تعداد سلول‌های فتوالکترونیک<sup>۳</sup> حسگر<sup>۴</sup> تصویر در دستگاه تصویربرداری افزایش داده می‌شود. بدین ترتیب جزئیات بیشتری از صحنه توسط حسگر ثبت می‌شود. اما این روش دارای معایبی است. اولین عیب این روش افزایش هزینه است. هر چه تعداد سلول‌های حسگر بیشتر

<sup>1</sup>Resolution

<sup>۲</sup> در ادامه‌ی رساله کلمات «دقت» و «تفکیک‌پذیری» مترادف هم به کار می‌روند.

<sup>3</sup>Photoelectric Cell

<sup>4</sup>Sensor



شکل ۱-۱: مفهوم تفرکیک پذیری. میزان تفرکیک پذیری در تصاویر از راست به چپ افزایش پیدا کرده است.

شود قیمت آن بیشتر می شود. البته افزایش قیمت تنها مشکل در رهیافت سخت افزاری نیست. برای داشتن سلول بیشتر بر روی حسگر تصویر یا باید اندازه حسگر بزرگتر شود و یا اندازه سلول ها کوچک تر گردد که هر دو روش مشکلات فیزیکی خاص خود را به دنبال دارد. بزرگتر کردن حسگر، خاصیت خازنی آن را زیاده تر کرده و باعث اعمال محدودیت بر نرخ انتقال بار الکتریکی و در نتیجه افزایش تاخیر زمانی آن می گردد [۱]. از طرف دیگر کوچک کردن اندازه ی سلول های حسگر سبب می شود میزان نور دریافت شده توسط هر یک از آن ها کاهش یابد و این خود موجب کاهش نسبت سیگنال به نویز و کاهش کیفیت تصویر می شود [۲].

در مقابل روش سخت افزاری، روشی نرم افزاری تحت عنوان ابرتفکیک پذیری<sup>۱</sup> یا افزایش تفرکیک پذیری<sup>۲</sup> وجود دارد. ابرتفکیک پذیری فنی است که با ترکیب اطلاعات موجود در تعدادی تصویر کم دقت<sup>۳</sup> از صحنه، تصویری پر دقت<sup>۴</sup> یا به عبارت دیگر تخمینی از تصویر ایده آل صحنه ایجاد می کند.<sup>۵</sup> برای تهیه تصاویر کم دقت، هم می توان از چندین دستگاه اخذ تصویر که با فاصله ی اندکی از هم قرار دارند استفاده کرد و هم از تنها یک دوربین. در حالت دوم قبل از اخذ هر تصویر مکان و یا زاویه دوربین اندکی تغییر داده می شود. بدین ترتیب با آنکه تصاویر شبیه به هم هستند، یکسان نبوده و اطلاعات

<sup>۱</sup> Superresolution (SR)

<sup>۲</sup> Resolution Enhancement (RE)

<sup>۳</sup> Low Resolution (LR)

<sup>۴</sup> High Resolution (HR)

<sup>۵</sup> تعریف بیان شده مربوط به ابرتفکیک پذیری چند تصویری (Multi Image SR) است. علاوه بر

ابرتفکیک پذیری چند تصویری، ابرتفکیک پذیری تک تصویری (Single Image SR) هم وجود دارد که در آن ورودی سیستم تنها یک تصویر است و خروجی، تصویری است با جزئیات بیشتر. در این رساله تمرکز ما بر روی ابرتفکیک پذیری چند تصویری است.



شکل ۱-۲: نمونه‌ای از آرایه  $4 \times 4$  از دوربین‌ها. تصویر از مرجع [۳] اخذ شده است.

ضبط شده در این تصاویر با هم متفاوت است. به عنوان تمثیل می‌توان هر تصویر کم دقت را با دیدن صحنه از پشت یک آبکس مقایسه کرد. با تغییر مکان و چرخش آبکس، نقاط دیگری از صحنه نمایان می‌شود. در شکل ۱-۲ نمونه‌ای از سیستم اخذ تصویر با چند دوربین نمایش داده شده است.

هدف از استفاده از چند دوربین و یا اعمال تغییرات هندسی در زمان استفاده از یک دوربین، ایجاد جابجایی زیرپیکسل<sup>۱</sup> یا کسری از پیکسل در تصاویر اخذ شده است. این اختلاف فاصله اساس کار SR می‌باشد. این موضوع در شکل ۱-۳ نشان شده است. در تمثیل آبکس، اگر جابجایی باعث شود سوراخ‌های آبکس دقیقاً در مکان سوراخ‌های قبلی قرار گیرد، اطلاعات جدیدی به دست نمی‌آید. اما جابجایی کمی کمتر یا بیشتر از آن اطلاعات جدیدی در اختیار قرار می‌دهد.

الگوریتم‌های ابرتفکیک‌پذیری بعد از تراز کردن<sup>۲</sup> تصاویر کم دقت (برای جبران تغییرات هندسی<sup>۳</sup>)، اطلاعات موجود در این تصاویر را با هم ترکیب کرده و تصویری با دقتی بیشتر از تصاویر ورودی تولید می‌کنند. عمل تراز کردن تصاویر با استفاده از الگوریتم‌های ثبت تصویر<sup>۴</sup> انجام می‌شود.

در اینجا مقایسه‌ای مختصر بین روش‌های بزرگ‌نمایی تصویر<sup>۵</sup> [۵، ۶] و ابرتفکیک‌پذیری ضروری به نظر می‌رسد. در روش‌های بزرگ‌نمایی تصویر نیز همانند SR تعداد پیکسل‌های تصویر بیشتر می‌شود؛ با این تفاوت که در روش‌های بزرگ‌نمایی، اطلاعات موجود در پیکسل‌های جدید با استفاده


<sup>1</sup>Subpixel Displacement

<sup>2</sup>Alignment

<sup>3</sup>Warping

<sup>4</sup>Image Registration

<sup>5</sup>Image Zooming



(ب)

(الف)

شکل ۱-۳: فاصله زیرپیکسلی. (الف) عدم وجود فاصله‌ی زیرپیکسلی بین دو دوربین. (فاصله‌ی دو دوربین دقیقاً مضربی از اندازه‌ی سلول‌های حسگر است.) (ب) وجود فاصله‌ی زیرپیکسلی بین دو دوربین. تصاویر از مرجع [۴] آورده شده‌اند.

از روش‌های درون‌یابی از روی پیکسل‌های موجود به دست می‌آید [۷]. در نتیجه هیچ گونه اطلاعات فرکانس بالایی بازیابی نمی‌شود. در مقابل در ابرتفکیک‌پذیری اطلاعات پیکسل‌های جدید از چندین تصویر مختلف به دست آمده و اطلاعات فرکانس بالا بازسازی می‌گردد [۸].

## ۱-۱ مدل مشاهده یا مدل تخریب تصویر

از آنجا که دستگاه‌های تصویربرداری ایده‌آل نیستند، در فرایند اخذ تصویر چندین تخریب<sup>۱</sup> بر روی اطلاعات نوری وارد شده به دستگاه تصویربرداری اعمال می‌شود. مدلی که این تخریب‌ها را نمایش می‌دهد به مدل مشاهده<sup>۲</sup> یا مدل تخریب<sup>۳</sup> معروف است. در تحقیقات انجام شده بیشتر از دو مدل warp-blur و blur-warp استفاده شده است که در ادامه معرفی می‌شوند. در مدل warp-blur فرض می‌شود ابتدا تغییرات هندسی به تصویر ایده‌آل اعمال می‌گردد و سپس تصویر تار می‌شود. اما در مدل blur-warp ابتدا تصویر تار شده و سپس تغییرات هندسی بر آن اعمال می‌گردد. در مرجع [۹] این دو مدل با هم مقایسه شده‌اند.

<sup>1</sup>Degradation

<sup>2</sup>Observation Model

<sup>3</sup>Degradation Model

با فرض اینکه بردار  $\mathbf{x}$  با اندازه  $PN \times 1$  تصویر ایده‌آل و بردار  $\mathbf{y}_k$  با اندازه  $N \times 1$ ،  $k$  امین تصویر خروجی دستگاه اخذ تصویر باشند، طبق مدل warp-blur ارتباط ورودی و خروجی مطابق رابطه (۱-۱) خواهد بود.<sup>۱</sup>

$$\mathbf{y}_k = \mathbf{D}(P) \times \mathbf{H}_k(\mathbf{h}_k) \times \mathbf{W}_k(\mathbf{s}_k) \times \mathbf{x} + \mathbf{n}_k, \quad k = 1, \dots, L. \quad (1-1)$$

که در آن ماتریس  $\mathbf{W}_k(\mathbf{s}_k)$  با اندازه  $PN \times PN$  عملگر تغییرات هندسی است که تابعی از پارامترهای تغییرات هندسی یعنی بردار  $\mathbf{s}_k$  است؛ ماتریس  $\mathbf{H}_k(\mathbf{h}_k)$  با اندازه  $PN \times PN$  عملگر تاری است که تابعی از هسته‌ی تاری  $\mathbf{h}_k$  است؛ ماتریس  $\mathbf{D}(P)$  با اندازه  $N \times PN$  عملگر کاهش تعداد نمونه<sup>۲</sup> است که تابعی از ضریب کاهش تعداد نمونه  $P$  است؛ بردار  $\mathbf{n}_k$  نویز اعمال شده به تصویر و  $L$  تعداد تصاویر کم دقت است.

طبق رابطه‌ی (۲-۱) تصویر ایده‌آل به علت جابجایی و تغییر زاویه‌ی دوربین ابتدا تحت تاثیر تغییرات هندسی (مانند جابجایی و چرخش) قرار گرفته، سپس به دلیل خاصیت انگرال‌گیری حسگر دوربین و دیگر عوامل دچار تاری شده، آنگاه به علت محدود بودن تفکیک‌پذیری حسگر تصویر قسمتی از اطلاعات آن از بین می‌رود و در آخر به آن نویز اضافه می‌گردد.

در ادامه برای سادگی، پارامترهای مورد استفاده در رابطه (۱-۱) حذف می‌گردد. بدین ترتیب رابطه‌ی مربوط به مدل warp-blur به صورت رابطه‌ی (۲-۱) خواهد شد. مثالی از اعمال این مدل در شکل ۴-۱ نشان داده شده است.


$$\mathbf{y}_k = \mathbf{D} \times \mathbf{H}_k \times \mathbf{W}_k \times \mathbf{x} + \mathbf{n}_k, \quad k = 1, \dots, L. \quad (2-1)$$

رابطه (۳-۱) ارتباط ورودی و خروجی دستگاه اخذ تصویر در مدل blur-warp را مشخص می‌کند.


در این رابطه ترتیب عملگرهای تغییرات هندسی و تاری نسبت به مدل قبل عوض شده است. مثالی

<sup>۱</sup> در این نمایش تصاویر که به آن نمایش lexicographic گویند، عناصر تصویر به صورت سطری

یا ستونی در بردار قرار داده می‌شوند.  
<sup>۲</sup>Down-sampling Operator



(ب) اعمال تغییرات هندسی ( $Wx$ )



(الف) تصویر پر دقت  $x$



(ه) اعمال نویز  
( $DHWx + n$ )



(د) کاهش تعداد نمونه  
( $DHWx$ )



(ج) اعمال تاری ( $HWx$ )

شکل ۴-۱: مثالی از اعمال مدل مشاهده‌ی warp-blur



(ب) اعمال تاری (Hx)



(الف) تصویر پر دقت x



(ج) اعمال تغییرات هندسی (WHx)



(ه) اعمال نویز (DWHx + n)



(د) کاهش تعداد نمونه (DWHx)

شکل ۱-۵: مثالی از اعمال مدل مشاهده‌ی blur-warp

از اعمال این مدل در شکل ۱-۵ نشان داده شده است.

$$y_k = D \times W_k \times H_k \times x + n_k, \quad k = 1, \dots, L. \quad (3-1)$$

## ۲-۱ تاری و مدل‌های مختلف آن

همانطور که پیشتر بیان شد، یکی از تخریب‌هایی که ممکن است بر تصاویر اخذ شده اعمال شود، تاری است. تصویر دیجیتال در پیکسل‌هایی دارای تاری است که تصویر چندین نقطه از صحنه در آن‌ها افکنده شود. تاری در تصاویر انواع مختلفی دارد که تعدادی از انواع مهم تاری در ادامه تشریح



می گردد [۱۰].

• تاری حرکتی<sup>۱</sup>

این تاری به دلیل حرکت جسم یا دوربین در زمان اخذ تصویر ایجاد می شود. در ساده ترین حالت، حرکت به صورت خطی است. تاری حرکتی خطی در راستای افق را می توان به صورت زیر مدل کرد.

$$h(\mathbf{u}) = \begin{cases} \frac{1}{L+1}, & -\frac{L}{2} \leq u_1 \leq \frac{L}{2}, u_2 = 0 \\ 0, & \text{در غیر این صورت} \end{cases} \quad (4-1)$$

در رابطه ی بالا  $\mathbf{u} = (u_1, u_2)$  مختصات عناصر هسته ی تاری بوده و  $L$  طول حرکت می باشد که زوج فرض شده است.

• تاری ناشی از اغتشاشات جوی<sup>۲</sup>

این نوع تاری در سنجش از راه دور<sup>۳</sup> و تصویربرداری فضایی متداول است. تاری ناشی از پرتوگیری<sup>۴</sup> طولانی مدت از جو با تابع نقطه گستر<sup>۵</sup> گوسی زیر مدل می شود.

$$h(\mathbf{u}) = K \exp\left(-\frac{|\mathbf{u}|^2}{2\sigma^2}\right) \quad (5-1)$$

که در آن  $K$  ضریب نرمال سازی است و واریانس  $\sigma^2$  شدت تاری را تعیین می کند.

• تاری ناشی از عدم تمرکز عدسی<sup>۶</sup>

دلیل وجود این تاری به مفهومی به نام عمق میدان<sup>۷</sup> در تصویربرداری مرتبط است. عمق میدان فاصله ی بین نزدیکترین و دورترین نقطه از صحنه نسبت به دوربین است که تصویر آن ها تار نبوده و یا دارای تاری جزئی باشد. اندازه عمق میدان به فاصله ی کانونی عدسی، قطر روزنه<sup>۸</sup> و فاصله ی نقطه ی تمرکز عدسی تا دوربین وابسته است. هر چه روزنه بزرگتر باشد عمق میدان

<sup>1</sup>Motion Blur

<sup>2</sup>Atmospheric Turbulence Blur

<sup>3</sup>Remote Sensing

<sup>4</sup>Exposure

<sup>5</sup>Point Spread Function (PSF)

<sup>6</sup>Out-of-Focus Blur

<sup>7</sup>Depth of Field

<sup>8</sup>Aperture

کمتر است و برعکس. مثلاً در تصاویر ورزشی که هدف تصویربرداری از ورزشکار است، از عدسی‌های عریض<sup>۱</sup> استفاده می‌شود و نتیجه تصویری است که در آن سوژه بدون تاری بوده ولی پس زمینه (تصویر تماشاگران) تار است.

مدل دقیق تاری عدم تمرکز به پارامترهای زیادی مانند فاصله‌ی کانونی عدسی، اندازه و شکل روزنه‌ی دوربین، فاصله‌ی بین شی و دوربین، طول موج نور وارد شده و شکست نور وابسته است. زمانی که تاری به خاطر عدم تمرکز عدسی زیاد باشد، مدل PSF یکنواخت دایره‌ای (دیسک) به عنوان تخمینی از این تاری استفاده می‌شود:

$$h(\mathbf{u}) = \begin{cases} \frac{1}{\pi r^2}, & |\mathbf{u}| \leq r \\ 0, & \text{در غیر این صورت} \end{cases} \quad (6-1)$$

### ۱-۲-۱ تاثیر کاهش تعداد نمونه بر تاری

طبق مدل‌های مشاهده (۱-۲) و (۱-۳) در فرآیند اخذ تصویر، عمل کاهش تعداد نمونه بعد از اعمال تاری اتفاق می‌افتد. از این رو تاری تصویر  $x$  با تاری تصاویر کم دقت یکسان نیست. این موضوع در شکل ۱-۶ بر روی سیگنال فرضی یک بُعدی نشان داده شده است. در این شکل سیگنال تار که با خط ممتد نشان داده شده است، با تار کردن سیگنال پله ایجاد شده است و سیگنال خط چین با اعمال عملگر کاهش تعداد نمونه بر روی سیگنال تار به دست آمده است. همان طور که در شکل مشاهده می‌شود شیب دو سیگنال که متأثر از میزان تاری آن‌هاست با هم متفاوت است.


### ۱-۳ مسائل معکوس و بدمطرح

مدل مشاهده، بیانگر مسئله‌ی مستقیم<sup>۲</sup> یافتن تصاویر کم دقت با داشتن تصویر پر دقت و معلوم بودن پارامترهای فرایند اخذ تصویر است. در مقابل، ابرتفکیک‌پذیری که هدف آن تخمین تصویر ایده‌آل  $x$  از روی تصاویر  $y_k$  است، مسئله‌ای معکوس<sup>۳</sup> است.

<sup>1</sup>Wide

<sup>2</sup>Forward Problem

<sup>3</sup>Inverse Problem



شکل ۱-۶: تاثیر کاهش تعداد نمونه بر تاری. سیگنال اصلی (خط ممتد) دارای تاری متفاوتی نسبت به سیگنال کاهش تعداد نمونه (خط چین) است.

یک مسئله مستقیم را می توان با رابطه ی زیر مدل کرد.

$$d = A(f) + n \quad (۷-۱)$$

در اصطلاحات رایج مربوط به مسائل معکوس، به خروجی مسئله مستقیم یعنی  $d$  در رابطه ی (۷-۱)،

داده<sup>۱</sup> و به ورودی آن یعنی  $f$ ، تصویر<sup>۲</sup> گفته می شود [۱۱].

مسئله یافتن  $f$  با داشتن  $d$  مسئله ی معکوس است. مسائل معکوس به دو دسته خوش مطرح<sup>۳</sup> و

بدمطرح<sup>۴</sup> تقسیم می شوند. یک مسئله معکوس توسط هادامارد خوش مطرح نامیده شد اگر سه شرط

زیر برقرار باشد [۱۲]:

۱. به ازای هر داده ی  $d$  در فضای داده، جوابی در فضای تصویر وجود داشته باشد.

۲. جواب در فضای تصویر یکتا باشد.

۳. نگاشت معکوس  $f \mapsto d$  پیوسته باشد.

مسئله ای که هر یک از شرایط بالا را نداشته باشد، توسط هادامارد بدمطرح نامیده شد. بنابراین مسئله

بدمطرح مسئله ای است که یا جواب ندارد، یا جواب آن یکتا نیست و یا تغییر اندکی در داده موجب

تغییر بزرگی در تصویر می گردد.

<sup>۱</sup>Data

<sup>۲</sup>Image

<sup>۳</sup>Well-posed Problem

<sup>۴</sup>Ill-posed Problem

SR مسئله‌ای معکوس و بدمطرح است؛ بدین معنی که با داشتن تصویر کم دقت، تصاویر پر دقت زیادی می‌توان داشت که همگی در مدل مشاهده صدق کنند. از این رو برای اینکه جواب مسئله SR مفید باشد نیاز است قیودی بر روی جواب مسئله اعمال گردد. به اعمال این قیود اصطلاحاً منظم‌سازی<sup>۱</sup> گفته می‌شود [۱۳] که متناظر است با دانش پیشین<sup>۲</sup> در رهیافت‌های آماری [۱۴]. منظم‌سازی در بازسازی سیگنال و تصویر کاربرد فراوانی دارد [۱۵]. در بخش ۲-۲-۵ منظم‌سازهای مورد استفاده در ابرتفکیک‌پذیری بررسی شده‌اند.

## ۴-۱ هدف رساله

همان‌گونه که قبلاً بیان شد در بسیاری از تحقیقات انجام شده، تنها عامل تاری تصاویر کم دقت، خاصیت انتگرال‌گیری حسگر تصویر فرض شده است که با تاری میانگین یا تاری گوسی با پارامتر معلوم مدل شده است [۴]. این در حالی است که، همانگونه که در بخش ۱-۲ بیان شد، در عمل عواملی دیگر از قبیل اغتشاشات جوّی، تنظیم نبودن عدسی و حرکت جسم یا دوربین می‌توانند سبب تاری تصویر شوند.

در این رساله فرض کرده‌ایم تاری اعمال شده به همه‌ی تصاویر کم دقت یکسان اما نوع یا پارامتر

آن نامعلوم است. به عبارت دیگر در تولید تمام تصاویر کم دقت داریم:  $\mathbf{h}_k = \mathbf{h}$ .

فرض یکسان بودن تاری همه‌ی تصاویر کم دقت منصفانه است چرا که در عمل، تنظیمات دوربین در زمان اخذ هر یک از تصاویر کم دقت یکسان بوده و تصاویر در زمان کوتاهی اخذ می‌شوند. بدین ترتیب مدل‌های مشاهده warp-blur و blur-warp مورد استفاده در این رساله به ترتیب طبق روابط (۸-۱) و (۹-۱) خواهند بود.

$$\mathbf{y}_k = \mathbf{D} \times \mathbf{H} \times \mathbf{W}_k \times \mathbf{x} + \mathbf{n}_k, \quad k = 1, \dots, L. \quad (8-1)$$

$$\mathbf{y}_k = \mathbf{D} \times \mathbf{W}_k \times \mathbf{H} \times \mathbf{x} + \mathbf{n}_k, \quad k = 1, \dots, L. \quad (9-1)$$

<sup>1</sup>Regularization

<sup>2</sup>A Priori Knowledge

تفاوت دو رابطه‌ی فوق با روابط (۲-۱) و (۳-۱) جایگزینی  $H$  به جای  $H_k$  است. به این ترتیب تاری اعمال شده برای همه‌ی تصاویر کم دقت یکسان خواهد بود.

## ۵-۱ نوآوری‌ها و دست‌آوردهای رساله

در این رساله در ابتدا مطالعاتی در زمینه ابرتفکیک‌پذیری و مسائل معکوس انجام شد. حاصل این مطالعات در مقاله [۱۶] به چاپ رسیده است. سپس دو رهیافت برای تخمین تاری اعمال شده بر تصویر HR دنبال شده است که در ادامه به طور خلاصه تشریح می‌گردد.

در رهیافت اول، تاری اعمال شده بر تصویر پر دقت از روی تاری تصاویر کم دقت برآورد می‌گردد. برای این منظور ما از شبکه عصبی و یادگیری عمیق استفاده کرده‌ایم. روال کار بدین قرار است که ابتدا هسته‌های تاری تصاویر کم دقت با استفاده از یکی از روش‌های تخمین هسته‌ی تاری برآورد می‌گردد. سپس این هسته‌ها به شبکه عصبی آموزش دیده داده می‌شود. شبکه عصبی هسته‌ی تاری اعمال شده بر تصویر پر دقت را تعیین می‌کند. از این هسته‌ی تاری در الگوریتم SR برای ایجاد تصویر پر دقت استفاده می‌شود.

استفاده از شبکه عصبی برای تعیین هسته‌ی تاری با دو رویکرد مجزای دسته‌بندی<sup>۱</sup> و رگرسیون<sup>۲</sup> انجام شده است. در رویکرد دسته‌بندی، هسته‌ی تاری مطلوب از بین هسته‌های تاری مفروض انتخاب می‌گردد. در مقابل در رویکرد رگرسیون شبکه عصبی هسته‌ی تاری مطلوب را تولید می‌کند. نتایج حاصل از این رهیافت در مقالات [۱۷] و [۱۸] به چاپ رسیده است.

در رهیافت دوم این رساله، روشی برای ابرتفکیک‌پذیری تصاویر تاری ناشی از عدم تمرکز عدسی دوربین پیشنهاد شده است. در این رهیافت ابتدا تصویر تاری پر دقت برآورد می‌گردد و سپس تصویر حاصل تاری‌زدایی می‌شود.

تاری‌زدایی همانند ابرتفکیک‌پذیری مسئله‌ای معکوس و بدمطرح است. بدین معنی که با داشتن

<sup>۱</sup>Classification

<sup>۲</sup>Regression

تصویر تار، زوج (تصویر، هسته‌ی تاری) بی‌شماری می‌توان یافت که ترکیب آن دو معادل تصویر تار باشد. به عبارت دیگر در این مسئله‌ی معکوس جواب یکتا نیست. بنابراین برای اینکه تصویر حاصل مفید باشد، نیاز به اعمال منظم‌سازی است.

در روش پیشنهادی عمل منظم‌سازی هم بر تصویر و هم بر هسته‌ی تاری اعمال می‌گردد. برای یافتن منظم‌ساز مناسب جهت اعمال بر هسته‌ی تاری، به این نکته توجه کردیم که تاری ناشی از عدم تمرکز دوربین دارای ساختاری یکپارچه بوده و به جز در نواحی مرزی دارای مقادیری یکسان است. نتایج این روش در مقاله [۱۹] ارائه شده است.

## ۶-۱ ساختار رساله

ساختار رساله‌ی حاضر بدین گونه است که در فصل ۲ مروری بر روش‌های ابرتفکیک‌پذیری و مسائل مرتبط انجام شده است. سپس در فصل ۳ رهیافت اول یعنی تعیین تاری تصویر پر دقت از روی تاری تصاویر کم دقت با رویکرد دسته‌بندی تشریح می‌گردد. در ادامه در فصل ۴ رهیافت مذکور با رویکرد رگرسیون بیان می‌شود. در فصل ۵ رهیافت دوم یعنی ابرتفکیک‌پذیری تصاویر تاری ناشی از عدم تمرکز عدسی تشریح می‌گردد. در نهایت در فصل ۶ جمع‌بندی کارهای انجام شده و پیشنهادهای برای ادامه کار ارائه می‌شود.

## ۷-۱ جمع‌بندی

در این فصل ضمن معرفی مسئله‌ی ابرتفکیک‌پذیری، مفاهیم مدل مشاهده، مسئله معکوس، بدمطرح بودن و منظم‌سازی تشریح گردید. همچنین انواع تاری متداول در تصویربرداری و مدل‌های مربوطه بررسی شد. در پایان هدف از پژوهش حاضر، نوآوری‌های آن و ساختار رساله بیان گردید.



## فصل ۲

# کارهای پیشین

سنگ بنای ابرتفکیک‌پذیری چند تصویری در سال ۱۹۸۴ توسط Tsai و Huang بنا نهاده شد [۲۰]. قبل از آن Gerchberg در ۱۹۷۴ [۲۱] و Santis و Gori در ۱۹۷۵ [۲۲] روشی تکراری برای ابرتفکیک‌پذیری در حوزه فرکانس پیشنهاد داده بودند که می‌توانست طیف فرکانسی سیگنال ورودی را توسعه داده و در نتیجه تفکیک‌پذیری آن را افزایش دهد. با این حال روش آن‌ها مانند کار Tsai و Huang فراگیر نشد. در مقابل ابرتفکیک‌پذیری چند تصویری متداول گردید و از آن پس کارهای زیادی در این زمینه انجام شده است [۴، ۲۳، ۲۴، ۲۵].

الگوریتم‌های حل مسأله‌ی SR را می‌توان به دو دسته حوزه فرکانس و حوزه مکان تقسیم‌بندی کرد. در حوزه فرکانس از تبدیل فوریه، تبدیل کسینوسی و تبدیل موجک<sup>۱</sup> برای ابرتفکیک‌پذیری استفاده شده است. الگوریتم‌های ارائه شده در حوزه‌ی مکان را می‌توان به دو دسته‌ی ابرتفکیک‌پذیری چند تصویری و تک تصویری تقسیم‌بندی کرد.

در این فصل در ابتدا هر یک از دسته‌های مختلف ابرتفکیک‌پذیری و زیر مجموعه‌های آن مورد

---

<sup>1</sup>Wavelet Transform



بررسی قرار خواهد گرفت. در ادامه تحقیقات انجام شده در خصوص تاری در ابرتفکیک پذیری و مدل‌های مختلف تغییرات هندسی استفاده شده در کارهای انجام شده و الگوریتم‌های تخمین آن بررسی خواهد شد.

## ۱-۲ ابرتفکیک پذیری در حوزه فرکانس

همانطور که بیان شد، اولین تحقیق منتشر شده در زمینه‌ی ابرتفکیک‌پذیری چند تصویری توسط Huang و Tsai انجام شد. آن‌ها مسئله‌ی را در حوزه‌ی فرکانس و با استفاده از تبدیل فوریه حل کردند. الگوریتم آن‌ها بر این سه اصل استوار بود:

- خاصیت انتقال<sup>۱</sup> تبدیل فوریه
  - ارتباط بدنمایی<sup>۲</sup> بین تبدیل فوریه پیوسته‌ی تصویر HR و تبدیل فوریه گسسته‌ی تصویر LR،
  - فرض اینکه تصویر HR محدود باند<sup>۳</sup> است.
- مهمترین مزیت روش حوزه فرکانس سادگی آن است؛ بدین معنی که ارتباط بین تصاویر LR و تصویر HR به روشنی در حوزه فرکانس مشخص است. از دیگر مزایای این روش امکان پیاده‌سازی آن به صورت موازی است که موجب افزایش سرعت بازسازی تصویر HR می‌گردد. با این وجود در این روش تغییرات هندسی تصاویر فقط محدود به انتقال کلی<sup>۴</sup> است و تاری اعمال شده به تصاویر LR، خطی و نامتغیر با مکان<sup>۵</sup> فرض می‌شود. این در حالی است که در عمل ممکن است تغییرات هندسی پیچیده‌تری مانند چرخش، تغییر مقیاس و یا ترکیبی از آن‌ها به تصاویر اعمال شود. از دیگر معایب این روش این است که استفاده از دانش پیشین<sup>۶</sup> موجود در حوزه مکان، برای منظم‌سازی در حوزه فرکانس مشکل می‌باشد.

<sup>1</sup> Shifting Property

<sup>2</sup> Aliasing

<sup>3</sup> Bandlimited

<sup>4</sup> Global Translation

<sup>5</sup> Linear Space Invariant (LSI)

<sup>6</sup> Prior Knowledge

Rhee و Kang توانستند با استفاده از تبدیل کسینوسی گسسته به جای تبدیل فوریه میزان حافظه مورد نیاز و هزینه محاسبات را کاهش دهند [۲۶]. تبدیل موجک نیز در ابرتفکیک‌پذیری مورد استفاده قرار گرفته است. Ji و Fermüller برای بازسازی تصویر پر دقت از روشی تکراری مبتنی بر تبدیل موجک استفاده کردند که در مقابل نویز از مقاومت بالایی برخوردار است [۲۷]. Bose و همکاران از موجک‌های نسل دوم<sup>۱</sup> برای ابرتفکیک‌پذیری استفاده کردند [۲۸]. ایشان ادعا کرده‌اند SGW برای ابرتفکیک‌پذیری مناسبتر از موجک معمولی بوده و کارایی و سرعت بالاتری را نسبت به آن فراهم می‌آورد. ترکیب تبدیل فوریه و تبدیل موجک نیز برای ابرتفکیک‌پذیری استفاده شده است. Robinson و همکاران در [۲۹] روشی ارائه داده‌اند که در آن ابتدا با استفاده از تبدیل فوریه، تصویر پر دقت نویزی به دست آمده و سپس با اعمال آستانه‌گذاری موجک<sup>۲</sup> تصویر به دست آمده نویززدایی می‌گردد.

## ۲-۲ ابرتفکیک‌پذیری چند تصویری در حوزه مکان

به دلیل محدودیت‌های ابرتفکیک‌پذیری در حوزه فرکانس، تحقیقات انجام شده در زمینه‌ی ابرتفکیک‌پذیری در حوزه مکان بیشتر و متنوعتر است. در ادامه روش‌های ابرتفکیک‌پذیری چند تصویری در حوزه مکان معرفی و تشریح می‌گردد.

### ۱-۲-۲ روش پس افکنش تکراری<sup>۳</sup>

روش پس افکنش تکراری جزء اولین روش‌های ابرتفکیک‌پذیری در حوزه مکان است [۳۰]. با فرض استفاده از مدل (۱-۸)، این روش به دنبال کمینه کردن رابطه‌ی (۱-۲) است که به آن عبارت سازگاری داده<sup>۴</sup>، عبارت صحت داده<sup>۵</sup> یا عبارت باقیمانده<sup>۶</sup> گفته می‌شود.

$$\| \mathbf{D} \times \mathbf{H} \times \mathbf{W}_k \times \mathbf{x} - \mathbf{y}_k \|_2^2, \quad k = 1, \dots, L. \quad (1-2)$$

<sup>1</sup>Second Generation Wavelets (SGW)

<sup>2</sup>Wavelet Thresholding

<sup>3</sup>Iterative Back Projection (IBP)

<sup>4</sup>Data Consistency Term

<sup>5</sup>Data Fidelity Term

<sup>6</sup>Residual Term

بدین منظور ابتدا تخمین اولیه‌ای برای تصویر پر دقت  $x$  به دست آمده، سپس این تخمین اولیه به طور تکراری بهبود می‌یابد. یکی از روش‌های متداول برای ایجاد تخمین اولیه، ثبت تصاویر LR در مختصات تصویر پر دقت و میانگین‌گیری از آن‌ها است [۳۰، ۳۱، ۳۲].

برای دقیق‌تر کردن جواب در هر تکرار، از روی تصویر پر دقت برآورد شده‌ی جاری در هر مرحله، تصاویر LR شبیه‌سازی شده تولید می‌شود. این عمل بر طبق مدل مشاهده انجام می‌شود. سپس از اختلاف تصاویر کم دقت شبیه‌سازی شده با تصاویر کم دقت مشاهده شده برای بهبود جواب جاری استفاده می‌شود. این عمل به تعداد مشخص یا تا رسیدن به شرطی خاص تکرار می‌گردد.

همانطور که در بخش ۱-۳ بیان شد، به دلیل بد مطرح بودن SR، تصاویر پر دقت بی‌شماری ممکن است وجود داشته باشند که اعمال مدل مشاهده بر روی آن‌ها منجر به تصاویر LR مشاهده شده گردد. از این رو مشکل اصلی IBP این است که برخی مواقع به یکی از آن تصاویر پر دقت همگرا می‌شود و برخی مواقع بین آن‌ها نوسان می‌کند [۳۰].

برای حل مشکل فوق می‌توان جواب را با استفاده از منظم‌سازی مقید کرد [۲۵]. برای این کار به جای کمینه کردن رابطه‌ی (۱-۲) رابطه‌ی زیر کمینه می‌گردد.

$$\|\mathbf{D} \times \mathbf{H} \times \mathbf{W}_k \times \mathbf{x} - \mathbf{y}_k\|_2^2 + \lambda \|R(\mathbf{x})\|_2^2, \quad k = 1, \dots, L \quad (2-2)$$

در رابطه‌ی (۲-۲)  $R(\cdot)$  منظم‌ساز اعمال شده بر تصویر و  $\lambda$  ضریب منظم‌سازی است. در برخی از پژوهش‌های انجام شده، استفاده از نرم  $\ell_1$  به جای نرم  $\ell_2$  در هر دو عبارت رابطه (۲-۲) پیشنهاد شده است [۳۳، ۳۴]. این کار باعث مقاوم شدن الگوریتم در مقابل داده‌های پرت و خطای ثبت تصویر می‌گردد.

## ۲-۲-۲ پالایش تطبیقی تکراری<sup>۱</sup>

روش پالایش تطبیقی تکراری بیشتر برای ابرتفکیک‌پذیری فیلم<sup>۲</sup> استفاده شده است [۳۵]. در این روش مسئله‌ی SR به مسئله‌ی تخمین حالت<sup>۳</sup> تبدیل شده و از فیلتر کالمن<sup>۴</sup> [۳۶، ۳۷] و یا فیلتر تطبیقی کمترین میانگین مربعات<sup>۵</sup> [۳۸] برای حل آن استفاده شده است. بدین منظور در کنار مدل مشاهده مورد استفاده، رابطه‌ی بین تصویر پر دقت فعلی و تصویر پر دقت قبلی با استفاده از معادله حالت (۳-۲) مدل می‌گردد.

$$\mathbf{x}_k = \mathbf{B}_k \mathbf{x}_{k-1} + \epsilon_k \quad (3-2)$$

در رابطه‌ی (۳-۲)  $\mathbf{B}_k$  ارتباط بین تصاویر HR فعلی و قبلی را مدل می‌کند و  $\epsilon_k$  خطای تخمین  $\mathbf{B}_k$  است. در روش ارائه شده در [۳۹] علاوه بر معادله‌ی حالات مذکور، از ارتباط بین تصاویر LR نیز که طبق رابطه‌ی (۴-۲) مدل می‌شود، در بازسازی تصویر HR استفاده شده است.

$$\mathbf{y}_k = \mathbf{C}_k \mathbf{y}_{k-1} + u_k \quad (4-2)$$

در رابطه‌ی (۴-۲)  $\mathbf{C}_k$  ارتباط بین تصاویر LR فعلی و قبلی را مدل می‌کند و  $u_k$  خطای تخمین  $\mathbf{C}_k$  است.

## ۳-۲-۲ روش‌های مبتنی بر درون‌یابی

در این روش ابتدا یکی از تصاویر LR به عنوان تصویر مرجع انتخاب شده و بقیه تصاویر نسبت به آن تراز می‌گردند. این عمل با استفاده از الگوریتم‌های ثبت تصویر انجام می‌شود. سپس تصویر مرجع با ضریب مشخصی افزایش مقیاس داده شده و دیگر تصاویر LR با استفاده از پارامترهای ثبت مربوطه بر روی تصویر مرجع منطبق می‌گردند. در مرحله‌ی بعد تصویر HR با ترکیب تصاویر LR بزرگ شده ایجاد می‌شود. در برخی از کارهای انجام شده، تصویر HR به دست آمده در نهایت تازی زدایی می‌گردد.

<sup>1</sup>Iterative Adaptive Filtering

<sup>2</sup>Video to Video SR

<sup>3</sup>State Estimation Problem

<sup>4</sup>Kalman Filter

<sup>5</sup>Least Mean Square (LMS) Adaptive Filter

برای ترکیب تصاویر از روش‌های متفاوتی مانند فیلتر میانگین و میانه [۴۰] و فیلترهای مبتنی بر تجزیه مقادیر تکین<sup>۱</sup> [۴۱] استفاده شده است.

مرحله‌ی درون‌یابی نقشی کلیدی در این رهیافت بازی می‌کند. روش‌های مختلفی برای درون‌یابی موجود است. ساده‌ترین آن‌ها درون‌یابی نزدیکترین همسایه<sup>۲</sup> است که عیب آن ایجاد تصویری بلاکی است. روش دیگر درون‌یابی غیر یکنواخت<sup>۳</sup> [۴۲] است که از قضیه‌ی نمونه‌برداری چندکاناله‌ی تعمیم یافته<sup>۴</sup> [۴۳] استفاده می‌کند.

در مرجع [۴۴] از روش کمترین مربعات متحرک<sup>۵</sup> برای تخمین میزان روشنایی پیکسل‌های تصویر HR از روی پیکسل‌های معلوم توسط تقریب چند جمله‌ای استفاده شده است. در این روش درجه و ضرایب چند جمله‌ای برای هر پیکسل به طور تطبیقی تعیین می‌گردد. از مزایای روش مبتنی بر درون‌یابی بار محاسباتی پایین آن است که برای کارهای بلادرنگ<sup>۶</sup> مفید است. البته بهینه بودن این روش تضمین نمی‌شود چرا که خطای درون‌یابی در آن لحاظ نمی‌شود. همچنین خطای ثبت تصاویر می‌تواند به مراحل بعد انتشار پیدا کند.

## ۴-۲-۲ روش‌های افکنش بر مجموعه‌های محدب<sup>۷</sup>

روش‌های افکنش بر مجموعه‌های محدب [۴۵، ۴۶] جزء الگوریتم‌های تکراری هستند که دانش پیشین و قیدهای جواب را به صورت مجموعه‌های محدب<sup>۸</sup> فرمول‌بندی می‌کند. اشتراک این مجموعه‌ها جواب مسئله خواهد بود. برای مثال روابط ۲-۵ و ۲-۶ به ترتیب قید سازگاری داده (با استفاده از  $L$  مجموعه محدب) و قید هموار بودن تصویر HR را مدل می‌کنند.

$$\mathcal{C}_k = \{ \mathbf{x} \mid \| \mathbf{D} \times \mathbf{H} \times \mathbf{W}_k \times \mathbf{x} - \mathbf{y}_k \|_2^2 \leq \sigma^2 \}, k = 1, \dots, L. \quad (5-2)$$

$$\mathcal{C}_F = \{ \mathbf{x} \mid \| \mathbf{F}\mathbf{x} \|_p \leq \sigma \} \quad (6-2)$$

<sup>1</sup>Singular Value Decomposition (SVD) based Filtering

<sup>2</sup>Nearest Neighbor Interpolation

<sup>3</sup>Nonuniform Interpolation

<sup>4</sup>Generalized Multichannel Sampling Theorem

<sup>5</sup>Moving Least Square

<sup>6</sup>Real-time

<sup>7</sup>Projection onto Convex Sets (POCS)

<sup>8</sup>Convex Constraint Sets

با فرض وجود  $m$  مجموعه محدب، بر اساس قضیه مرکزی POCS، رابطه‌ی بازگشتی (۷-۲) به جواب مسئله که در مجموعه‌ی  $\mathcal{C}_s = \bigcap_{i=1}^m \mathcal{C}_i$  قرار دارد همگرا می‌شود.

$$\mathbf{x}^{(k+1)} = P_m P_{m-1} \dots P_1 P_1 \mathbf{x}^{(k)}, \quad \mathbf{x}^{(0)} \triangleq \mathbf{x}_0 \quad (7-2)$$

که در آن  $\mathbf{x}_0$  جواب اولیه بوده و عملگر افکنش  $P_i$  تصویر دلخواه  $\mathbf{x}$  را روی مجموعه محدب  $\mathcal{C}_i$  به ازای  $i = 1, \dots, m$  می‌افکند.

مسئله اساسی در روش POCS ایجاد عملگرهای افکنش  $P_i$  به ازای  $i = 1, \dots, m$  است. هر چند ممکن است یافتن این عملگرها کار ساده‌ای نباشد اما از یافتن  $P_s$  یعنی عملگری که در یک مرحله جواب اولیه را بر روی مجموعه جواب  $\mathcal{C}_s$  می‌افکند خیلی ساده‌تر است. از اشکالات روش POCS عدم تضمین یکتا بودن جواب و هزینه‌ی محاسباتی زیاد آن است.

## ۵-۲-۲ رهیافت مبتنی بر منظم‌سازی

همان گونه که در فصل ۱ بیان شد مساله‌ی SR یک مساله‌ی بدمطرح است [۴۷]. برای پایا ساختن مسائل معکوس بدمطرح از روش‌های منظم‌سازی استفاده می‌شود. با فرض استفاده از مدل (۸-۱) و معلوم بودن عملگر تغییرات هندسی و تاری، رهیافت مبتنی بر منظم‌سازی، مسئله‌ی SR را به صورت رابطه‌ی بهینه‌یابی زیر فرمول‌بندی می‌کند.

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \sum_{k=1}^L \|\mathbf{DHW}_k \mathbf{x} - \mathbf{y}_k\|^2 + \lambda R(\mathbf{x}) \quad (8-2)$$

در رابطه‌ی فوق  $R(\mathbf{x})$  تابع منظم‌سازی و  $\lambda$  ضریب منظم‌سازی است. تابع منظم‌سازی به گونه‌ای انتخاب می‌شود که مقدار آن برای جواب‌های مفید کم و برای جواب‌های نامفید زیاد باشد. به این ترتیب با کمینه کردن رابطه‌ی فوق جواب مسئله به سمت جوابی مطلوب سوق داده می‌شود.

تصاویر طبیعی در اغلب نقاط تصویر تقریباً هموار هستند و فقط در لبه‌های تصویر تغییرات قابل توجهی وجود دارد. از این رو هیستوگرام گرادیان تصاویر طبیعی دارای قله‌ای در اطراف صفر بوده اما به خاطر لبه‌های تصویر دارای دنباله‌ای طولانی است. برای ایجاد منظم‌ساز مناسب برای تصاویر

طبیعی معمولاً از این ویژگی استفاده می‌شود. در ادامه تعدادی از توابع منظم‌سازی تصویر مورد استفاده در تحقیقات انجام شده بررسی می‌گردد.

- **میدان تصادفی مارکوفی هوبر<sup>۱</sup>** منظم‌سازی محدب است با تابع انرژی (۲-۹) که به تصویر اجازه می‌دهد به طور تکه‌ای هموار باشد<sup>۲</sup>. از این رو این منظم‌ساز لبه‌های تصویر را حفظ می‌کند [۴۸، ۴۹].

$$\text{HMRF}(a) = \begin{cases} a^2 & |a| \leq \alpha \\ 2\alpha|a| - \alpha^2 & \text{در غیر این صورت} \end{cases} \quad (۹-۲)$$

که در آن  $a$  گرادیان مرتبه اول یا مرتبه دوم تصویر است و  $\alpha$  پارامتری است که با تعیین قسمت‌های خطی و درجه دوم تابع، جریمه‌ی اعمال شده بر عدم همواری تصویر را کنترل می‌کند.

- **تغییرات کلی<sup>۳</sup>** یکی از روش‌های متداول برای منظم‌سازی است که اولین بار توسط Rudin و همکاران برای نویززدایی تصویر مطرح شد [۵۰] و کاربرد زیادی در بازسازی سیگنال و تصویر دارد [۵۱]. این منظم‌ساز به صورت رابطه‌ی (۲-۱۰) تعریف می‌شود.

$$\text{TV}(\mathbf{x}) = \|\nabla \mathbf{x}\| = \sum_{i=1}^N \sqrt{(\Delta_i^h(\mathbf{x}))^2 + (\Delta_i^v(\mathbf{x}))^2} \quad (۱۰-۲)$$

که در آن عملگر گرادیان،  $\|\cdot\|$  نرم اقلیدسی،  $N$  تعداد نقاط تصویر بوده و  $\Delta_i^h(\mathbf{x})$  و  $\Delta_i^v(\mathbf{x})$  به ترتیب عملگرهای تفاضل مرتبه اول افقی و عمودی هستند. از آنجا که رابطه‌ی (۲-۱۰) نسبت به چرخش تغییرناپذیر است، به آن تغییرات کلی همسانگرد<sup>۴</sup> گفته می‌شود. در مقابل تغییرات کلی ناهمسانگرد<sup>۵</sup> نیز وجود دارد که در آن به جای نرم اقلیدسی از نرم  $l_1$  استفاده می‌شود و به صورت رابطه (۲-۱۱) تعریف می‌گردد.

$$\text{TV}_{\text{anisotropic}}(\mathbf{x}) = \|\nabla \mathbf{x}\|_1 = \sum_{i=1}^N \|\Delta_i^h(\mathbf{x})\|_1 + \sum_{i=1}^N \|\Delta_i^v(\mathbf{x})\|_1 \quad (۱۱-۲)$$

<sup>۱</sup>Huber Markov Random Field (HMRF)

<sup>۲</sup>Piecewise-smooth

<sup>۳</sup>Total Variation (TV)

<sup>۴</sup>Isotropic Total Variation

<sup>۵</sup>Anisotropic Total Variation

از ویژگی‌های منظم‌ساز TV این است که لبه‌های تصویر را حفظ کرده در حالی که هموار بودن را به آن تحمیل می‌کند. از این رو در تحقیقات زیادی در زمینه‌ی SR از این منظم‌ساز استفاده شده است [۵۲، ۵۳، ۳، ۵۴]. از اشکال‌های این منظم‌ساز ایجاد اثر پلکانی<sup>۱</sup> در تصویر است [۵۵].

- **منظم‌ساز خودهمبسته‌ی همزمان<sup>۲</sup>** منظم‌سازی از درجه دوم و غیر تَنک<sup>۳</sup> است که همواری یکنواختی به کل تصویر اعمال می‌کند. در نتیجه SAR لبه‌های تصویر را بیش از حد هموار می‌کند اما برای بازسازی بافت تصویر مناسب است [۵۳]. تابع این منظم‌ساز در رابطه‌ی (۱۲-۲) بیان شده است.

$$\text{SAR}(\mathbf{x}) = \|\mathbf{C}\mathbf{x}\|^2 \quad (12-2)$$

که در آن C عملگر لاپلاسی یعنی تفاضل مرتبه دوم است. در [۵۳] از ترکیب TV و نُرم  $\ell_1$  به همراه پیشین SAR به عنوان مدل تصویر استفاده شده است.

- **تغییرات کلی دو جهته<sup>۴</sup>** منظم‌سازی است که لبه‌های تصویر را حفظ می‌کند و با الهام از منظم‌ساز TV و فیلتر دوجهته ایجاد شده است [۵۶، ۳۴، ۵۷]. BTV طبق رابطه‌ی (۱۳-۲) تعریف می‌شود.

$$\text{BTV}(\mathbf{x}) = \sum_{\substack{l=-P \\ l+m \geq 0}}^P \sum_{m=0}^P \alpha^{|m|+|l|} \|\mathbf{x} - \mathbf{S}_h^l \mathbf{S}_v^m \mathbf{x}\|_1, \quad (13-2)$$

که در آن عملگرهای  $\mathbf{S}_h^l$  و  $\mathbf{S}_v^m$  تصویر  $\mathbf{x}$  را به اندازه‌ی  $l$  و  $m$  پیکسل به ترتیب در جهت افقی و عمودی جابجا می‌کنند و پارامتر  $\alpha \in (0, 1)$  برای تضعیف اثر پیکسل‌های دورتر در منظم‌سازی اعمال می‌شود.

Li و همکارانش در [۵۸] LABTV<sup>۵</sup> را که توسعه‌ی BTV است ارائه دادند که به طور افقی عمل

کرده و از آنتروپی فازی برای اندازه‌گیری همواری محلی تکه‌های تصویر استفاده می‌کند.

<sup>1</sup>Staircasing Effect

<sup>2</sup>Simultaneous Autoregressive (SAR)

<sup>3</sup>Non-sparse

<sup>4</sup>Bilateral Total Variation (BTV)

<sup>5</sup>Locally Adaptive Bilateral Total Variation (LABTV)



۶-۲-۲ روش‌های مبتنی بر چارچوب بیز<sup>۱</sup>

روش‌های مبتنی بر چارچوب بیز برای ابرتفکیک‌پذیری به دو دسته‌ی تخمینگرهای نقطه‌ای و تخمینگر بیز تقسیم می‌شود. در تخمینگرهای نقطه‌ای هدف یافتن جوابی است که تابع توزیع احتمال پسین<sup>۲</sup> را بیشینه کند در حالی که در تخمینگر بیز هدف یافتن خود تابع توزیع احتمال پسین یا تقریبی از آن است.

دو تخمینگر نقطه‌ای در چارچوب بیز عبارتند از بیشینه درست‌نمایی<sup>۳</sup> و بیشینه توزیع احتمال پسین<sup>۴</sup>. روش ML با حل رابطه‌ی (۱۴-۲) به دنبال جوابی است که درست‌نمایی را بیشینه کند.

$$\hat{x}_{ML} = \arg \max_{\mathbf{x}} P(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_L | \mathbf{x}) \quad (14-2)$$

حل رابطه‌ی (۱۴-۲) معادل است با کمینه کردن مجموع عبارت باقیمانده (عبارت اول در رابطه‌ی (۸-۲)) که منجر به جواب کمترین مربعات خطا می‌شود. این جواب به دلیل بد وضعیت<sup>۵</sup> بودن مسئله، به اغتشاشات کوچک از قبیل نویز و یا خطا در مدل کردن مسئله حساس است. به عبارت دیگر تغییرات کوچکی در ورودی موجب تغییر شدیدی در خروجی می‌گردد. برای حل این مشکل می‌توان تعداد تصاویر ورودی را (در صورت وجود) افزایش داد چرا که تعداد زیاد تصاویر ورودی جواب مسئله را مقید کرده و همانند منظم‌سازی عمل می‌کند. در چنین شرایطی روش ML به دلیل سادگی بر روش MAP ارجح است.

در مقابل روش MAP روشی کارا و انعطاف‌پذیر برای اعمال دانش پیشین (به صورت تابع توزیع احتمال پیشین) به مسئله می‌باشد که هدف آن یافتن تصویری است که توزیع احتمال پسین<sup>۶</sup> را طبق رابطه‌ی (۱۵-۲) بیشینه کند.

$$\hat{x}_{MAP} = \arg \max_{\mathbf{x}} P(\mathbf{x} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_L) \quad (15-2)$$

<sup>1</sup>Bayesian Approach<sup>2</sup>Posterior Probability Distribution<sup>3</sup>Maximum Likelihood (ML)<sup>4</sup>Maximum a Posteriori (MAP)<sup>5</sup>Ill-Conditioned<sup>6</sup>Posterior Probability

با اعمال قضیه بیز، گرفتن لگاریتم و قرینه کردن رابطه‌ی (۲-۱۵)، به رابطه‌ی زیر می‌رسیم.

$$\hat{\mathbf{x}}_{MAP} = \arg \min_{\mathbf{x}} \{-\ln P(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_L | \mathbf{x}) - \ln P(\mathbf{x})\} \quad (۲-۱۶)$$

که در آن  $P(\mathbf{x})$  توزیع پیشین بوده و با استفاده از آن می‌توان مدل یا منظم‌ساز مورد نظر را به تصویر اعمال کرد.

بر خلاف تخمینگرهای نقطه‌ای فوق‌الذکر، هدف تخمینگر بیز یافتن تابع توزیع احتمال پسین است. اما معمولاً انجام این کار نشدنی است چرا که طبق قضیه بیز علاوه بر درست‌نمایی و تابع توزیع احتمال پیشین، به تابع توزیع ورودی‌های مسئله یعنی تصاویر کم دقت نیاز است که در دسترس نیست. از این رو از روش‌های تقریبی مانند نمونه‌برداری<sup>۱</sup> [۵۹] یا تحلیل بیزی تغییراتی<sup>۲</sup> [۵۲] برای یافتن تقریبی از تابع توزیع احتمال پسین استفاده می‌شود.

همانطور که بیان شد، در روش‌های استفاده شده از تخمینگر بیز و MAP، دانش پیشین درباره تصویر به صورت توزیع پیشین مدل شده و استفاده می‌شود. ساده‌ترین انتخاب برای تابع توزیع پیشین، مقدار ثابت است که به همگی تصاویر HR ممکن احتمال یکسانی می‌دهد. اما گزینه‌های بهتر برای این تابع بر اساس منظم‌سازهای بیان شده در بخش ۲-۲-۵ مدل‌سازی می‌شود. مانند TV [۵۲، ۶۰]، ترکیب TV و نرم  $\ell_1$  به همراه SAR [۵۳]، ترکیب TV، توزیع گوسی و توزیع گاما [۶۱] و HMRF [۴۸، ۶۲]. همچنین روش‌های دیگری نیز مانند مدل نفوذ ناهمسان‌گرد<sup>۳</sup> [۶۳]، MRF<sup>۴</sup> [۶۴] روش‌های یادگیری [۶۵] و استفاده از تبدیل موجک [۶۶] برای مدل کردن توزیع پیشین تصاویر HR استفاده شده‌اند. همانگونه که پیشتر بیان شد، مطالعات نشان می‌دهد گرادیان تصاویر طبیعی تنک بوده و دارای توزیعی با دنباله طولانی<sup>۵</sup> است [۶۷، ۶۸]. از این رو در برخی از تحقیقات از توزیع فوق لاپلاس<sup>۶</sup> که مدلی مناسب برای توزیع مذکور است برای مدل کردن تصویر استفاده شده است [۶۹].

<sup>1</sup>Sampling Method


<sup>2</sup>Variational Bayesian Analysis

<sup>3</sup>Anisotropic Diffusion

<sup>4</sup>Markov Random Field (MRF)

<sup>5</sup>Heavy-tailed Distribution

<sup>6</sup>Hyper-Laplacian Distribution



شکل ۲-۱: نمونه‌ای از دیکشنری شامل ۵۱۲ وصله‌ی پر دقت با اندازه  $9 \times 9$

## ۲-۲-۷ رهیافت مبتنی بر یادگیری

روش‌های یادگیری نیز برای حل مساله‌ی SR پیشنهاد شده‌اند. در این رهیافت تنها یک تصویر LR وجود دارد و اطلاعات فرکانس بالای آن بر اساس ویژگی‌های محلی آن از روی تصاویر آموزشی به دست می‌آید. مرجع [۷۰] یک روش برای تولید جزئیات فرکانس بالای تصویر LR با استفاده از مجموعه داده‌ی آموزشی پیشنهاد کرده است. این الگوریتم دو مرحله دارد: مرحله‌ی یادگیری برون خط<sup>۱</sup> و مرحله‌ی بازسازی تصویر. در مرحله‌ی یادگیری، وصله‌های تصویر<sup>۲</sup> به عنوان تصاویر مرجع در نظر گرفته شده و با شبیه‌سازی سیستم تصویربرداری، از روی آن‌ها تصاویر با دقت پایین ایجاد می‌شود. به این ترتیب زوج وصله‌های LR و وصله‌های HR متناظر به صورت مجموعه‌ی داده جمع‌آوری می‌گردد. در مرحله‌ی بازسازی SR، وصله‌های تصویر LR استخراج شده و با وصله‌های داخل مجموعه‌ی داده مقایسه می‌گردد. سپس وصله‌ای با بهترین تطابق بر اساس معیار شباهتی مشخص انتخاب گردیده و وصله‌ی HR متناظر با آن برای ساخت تصویر HR استفاده می‌شود.

تحقیقات اخیر در زمینه‌ی مطالعه‌ی آماری تصویر نشان می‌دهد وصله‌های تصویر را می‌توان به

<sup>1</sup>Off-line

<sup>2</sup>Image Patch

صورت ترکیب خطی تنک<sup>۱</sup> از عناصر یک دیکشنری فوق کامل<sup>۲</sup> نمایش داد [۷۱، ۷۲، ۷۳]. با توجه به این نکته الگوریتم جدیدی ایجاد گردیده که هدف آن جستجو برای نمایش تنک هر وصله از ورودی LR و استفاده از آن برای تولید خروجی HR است. با آموزش دو دیکشنری برای وصله‌های LR و HR، نمایش تنک وصله‌ی LR با استفاده از دیکشنری LR ایجاد شده و به دیکشنری HR اعمال می‌گردد تا وصله‌ی HR ایجاد گردد. صحت این روش که نتایج امید بخشی در پی دارد از منظر تئوری یادگیری در [۷۴] به اثبات رسیده است. در شکل ۲-۱ نمونه‌ای از دیکشنری وصله‌های پر دقت نشان داده شده است. همانطور که در این شکل مشاهده می‌شود، عناصر دیکشنری شامل الگوهای پایه از قبیل لبه‌های مورب می‌باشد.

## ۳-۲ تخمین تاری

هدف تخمین تاری در SR رفع تاری از تصویر HR بازسازی شده است. در اغلب کارهای انجام شده، تاری اعمال شده به تصویر ایده‌آل صحنه معلوم فرض شده و با PSF خاصی مدل شده است. برای مثال در [۳۴، ۷۵] منبع تاری دستگاه اخذ تصویر فرض شده و میزان تاری آن با PSF گوسی  $5 \times 5$  با واریانس ۱ مدل شده است. اگر دستگاه اخذ تصویر موجود باشد ولی اطلاعاتی در مورد میزان تاری اعمال شده به تصویر توسط آن در دسترس نباشد، می‌توان با تصویر برداری از نقطه‌ای کوچک در زمینه‌ای سیاه تخمینی از آن به دست آورد [۳۲].

در صورتی که فقط تصاویر کم دقت موجود باشند می‌توان با استفاده از روش واپیچش کور<sup>۳</sup> تاری تصویر LR را برآورد کرد [۷۶]. در روش ارائه شده در [۳] تخمین تاری و بازسازی تصویر به طور یک‌درمیان<sup>۴</sup> انجام می‌شود.

اخیراً در ابر تفکیک‌پذیری تک تصویری تحقیقات گسترده‌تری بر روی تصاویر تار انجام شده است:

در [۷۷، ۷۸] تصاویر دارای تاری حرکتی و در [۷۹، ۸۰] تصاویر با تاری دلخواه بررسی شده‌اند.

<sup>1</sup>Sparse Linear Combination

<sup>2</sup>Over-Complete Dictionary

<sup>3</sup>Blind Deconvolution

<sup>4</sup>Alternatively

## ۴-۲ تغییرات هندسی و روش‌های ثبت تصویر

همان گونه که در فصل ۱ بیان شد، برای اینکه هر تصویر LR اطلاعات متفاوتی نسبت به دیگر تصاویر LR داشته باشد، قبل از اخذ تصویر مکان یا زاویه دوربین کمی تغییر داده می‌شود. این کار باعث ایجاد تغییرات هندسی بر روی تصاویر LR می‌گردد. از این رو برای انجام عمل SR ابتدا تصاویر کم دقت باید تراز شوند. این عمل با استفاده از الگوریتم‌های ثبت تصویر انجام می‌شود. در ادامه مدل‌های استفاده شده برای اعمال تغییرات هندسی و همینطور الگوریتم‌های ثبت تصویر مورد استفاده مرور می‌گردد.

ساده‌ترین مدل تغییرات هندسی، مدل حرکت انتقالی<sup>۱</sup> است. در کارهای انجام شده چندین روش برای تخمین حرکت انتقالی بیان گردیده است که از آن بین می‌توان به تطبیق بلاک سلسله‌مراتبی<sup>۲</sup> [۸۱] و روش‌های همبستگی زاویه<sup>۳</sup> [۸۲] اشاره کرد.

سطح بعدی از نظر پیچیدگی در مدل‌سازی تغییرات هندسی، جابجایی و چرخش حول محور عمود بر صحنه است. تخمین زاویه‌ی چرخش و جابجایی در [۳۲، ۸۳] با استفاده از اولین جمله از بسط سری تیلور انجام شده است.

با پیچیده‌تر کردن مدل به تبدیل همگر<sup>۴</sup> می‌رسیم که انتقال، چرخش و تغییر مقیاس از حالات خاص آن می‌باشد. این مدل در مراجع [۳۱، ۳۲] استفاده شده است. مدل دیگر تبدیل دو خطی<sup>۵</sup> است که در [۸۴] از آن استفاده شده است. برای تخمین تغییرات هندسی در این مدل‌ها، علاوه بر تکنیک‌های مذکور از روش‌های مرتبط به الگوریتم Lucas-Kanade نیز استفاده شده است [۸۵].

تطبیق ویژگی<sup>۶</sup> نیز در تخمین تغییرات هندسی در SR استفاده شده است که می‌توان به الگوریتم تشخیص ویژگی Harris [۸۶، ۸۷] و SIFT [۸۸] اشاره کرد. همچنین [۸۹] مقایسه‌ای بین الگوریتم‌های مبتنی بر Lucas-kanade و الگوریتم‌های تطبیق ویژگی در SR انجام داده است.

<sup>1</sup> Translational Motion

<sup>2</sup> Hierarchical Block Matching

<sup>3</sup> Phase Correlation

<sup>4</sup> Affine Transformation

<sup>5</sup> Bilinear Transformation

<sup>6</sup> Feature Matching

## ۵-۲ جمع‌بندی

در این فصل، کارهای پیشین و تحقیقات انجام شده در حوزه ابرتفکیک‌پذیری دسته‌بندی شده و مورد بررسی قرار گرفتند. سپس برخی از روش‌های تخمین تاری بیان شد و در انتها مدل‌های تغییرات هندسی استفاده شده در ابرتفکیک‌پذیری و الگوریتم‌های ثبت تصویر مرتبط با آن‌ها مرور گردید.



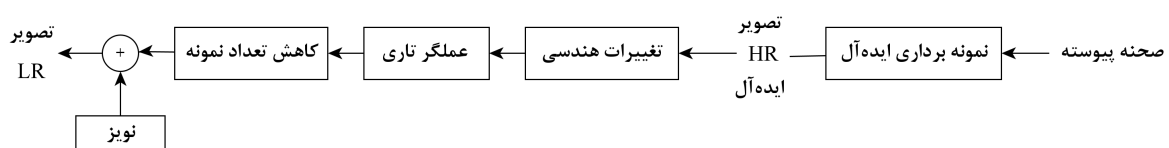
## فصل ۳

# تعیین تاری اعمال شده بر تصویر پر دقت با شبکه عصبی

### ۱-۳ مقدمه


همان گونه که در فصل ۱ ذکر شد، هدف ابرتفکیک‌پذیری معکوس کردن مدل مشاهده است. مدل مشاهده، فرآیند تولید تصویر کم دقت را از روی تصویر ایده‌آل صحنه فرمول‌بندی می‌کند. در تحقیقات انجام شده معمولاً از یکی از دو مدل مشاهده‌ی blur-warp یا warp-blur استفاده شده است. شکل ۱-۳ مدل warp-blur را نمایش می‌دهد.

طبق این شکل تصویر ایده‌آل صحنه ابتدا تحت تاثیر تغییرات هندسی قرار گرفته، سپس تار شده،



شکل ۱-۳: مدل warp-blur





شکل ۲-۳: خروجی الگوریتم تخمین هسته بر روی چهار تصویر LR. تصاویر LR با استفاده از مدل مشاهده، از روی یک تصویر HR و با اعمال تاری یکسان و تغییرات هندسی متفاوت ایجاد شده‌اند.


بعد از آن به خاطر اعمال کاهش تعداد نمونه قسمتی از اطلاعات آن از بین می‌رود و در نهایت به آن نویز اضافه می‌گردد. در این فصل هدف ما تعیین تاری اعمال شده به تصویر ایده‌آل صحنه از روی تصاویر کم دقت و استفاده از آن در الگوریتم ابرتفکیک‌پذیری است.

با توجه به شکل ۱-۳ بعد از اعمال تاری، تصویر تار شده تحت تاثیر عملگر کاهش تعداد نمونه قرار می‌گیرد و همانطور که در زیربخش ۱-۲-۱ دیدیم، تاری تصاویر کم دقت با تاری تصویر ایده‌آل صحنه متفاوت است. به همین دلیل در روش پیشنهادی برای تعیین تاری تصویر از شبکه عصبی استفاده می‌شود. در این فصل شبکه‌ی عصبی در چارچوب دسته‌بندی<sup>۱</sup> استفاده شده است. بدین معنی که شبکه عصبی هسته‌ی تاری مطلوب را از میان هسته‌های تاری مفروض انتخاب می‌کند. در ادامه بعد از بررسی چالش مسئله، روش پیشنهادی تشریح می‌گردد.

## ۲-۳ چالش مسئله

از آنجا که الگوریتم تخمین هسته‌ی تاری ایده‌آل نیست، خطاهایی در تخمین هسته‌ی تاری وجود دارد. برای مثال در شکل ۲-۳ هسته‌های تاری مربوط به تعدادی تصویر LR که طبق مدل مشاهده از روی یک تصویر HR با اعمال هسته‌ی تاری یکسان، اما تغییرات هندسی متفاوت ایجاد شده‌اند نشان داده شده است. همانطور که مشاهده می‌شود، هسته‌ی تاری برآورد شده برای هر یک از تصاویر با هسته‌های دیگر متفاوت است. حال آنکه در حالت ایده‌آل همه‌ی هسته‌های تاری باید یکسان می‌بودند. این خطاها آموزش شبکه عصبی را سخت می‌کند.

<sup>۱</sup>Classification



شکل ۳-۳: نمودار روش پیشنهادی

### ۳-۳ تعیین تاری با شبکه عصبی

با توجه به مدل مشاهده (۱-۸)، برای بازسازی تصویر HR، نیاز است تاری اعمال شده در فرآیند اخذ تصویر معلوم باشد. اما در عمل معمولاً این اطلاعات در دسترس نیست و تنها اطلاعات موجود تصاویر کم دقت می‌باشد. از این رو در این فصل فرض می‌کنیم تعداد مشخصی هسته تاری وجود دارد که یکی از آن‌ها در فرآیند اخذ بر تصویر ایده‌آل اعمال شده است. در ادامه به این هسته‌های تاری، هسته‌های تاری آموزشی گفته می‌شود. هدف روش پیشنهادی که جزئیات آن در ادامه تشریح می‌شود، تعیین هسته‌ی تاری اعمال شده بر تصویر HR از روی تصاویر LR و استفاده از آن در فرآیند SR است.

ایده‌ی کلی روش پیشنهاد شده در این فصل در شکل ۳-۳ نشان داده شده است. طبق این شکل ابتدا هسته‌ی تاری تصاویر کم دقت توسط الگوریتم ارائه شده در [۹۰] برآورد می‌شود. سپس هسته‌های تاری برآورد شده به شبکه‌ی عصبی آموزش یافته داده می‌شود. شبکه عصبی دسته‌ی<sup>۱</sup> هسته‌ی تاری را تعیین می‌کند. از هسته‌ی تاری تعیین شده در الگوریتم SR استفاده می‌گردد. در آزمایش‌های انجام شده برای انجام عمل ابرتفکیک‌پذیری از روش ارائه شده در [۵۲] استفاده می‌شود. در روش مذکور از مدل مشاهده‌ی warp-blur استفاده شده است. از این رو در آزمایش‌های انجام شده تصاویر کم دقت بر طبق این مدل تولید می‌شوند.

هسته‌های تاری آموزشی در این تحقیق از سه نوع تاری میانگین، تاری گوسی و تاری عدم تمرکز می‌باشند. از هر نوع هسته دو عدد و در مجموع شش هسته تاری آموزشی انتخاب شده است.

<sup>1</sup>Class

جدول ۳-۱: مشخصات هسته‌های تاری آموزشی

شماره دسته	پارامتر تاری	اندازه	نوع تاری
۱	-	۵×۵	میانگین
۲	-	۱۱×۱۱	میانگین
۳	۳	۵×۵	گوسی
۴	۵	۱۱×۱۱	گوسی
۵	-	۵×۵	دیسک
۶	-	۱۱×۱۱	دیسک

مشخصات هسته‌های تاری آموزشی در جدول ۳-۱ آورده شده است.


### ۴-۳ ساختار و آموزش شبکه عصبی

شبکه عصبی مورد استفاده دارای یک لایه مخفی با ۶۰ نرون است. با توجه به کارایی بالای تابع فعالیت خطی یکسو شده<sup>۱</sup> در تحقیقات اخیر [۹۱]، از این تابع در شبکه عصبی استفاده گردید. در آزمایش‌های انجام شده در این تحقیق نیز کارایی بالاتر این تابع در مقایسه با تابع فعالیت متداول Sigmoid تایید گردید.

همانطور که بیان شد، برای تخمین هسته‌ی تاری تصاویر کم دقت از روش ارائه شده در [۹۰] استفاده گردید. در اجرای این الگوریتم اندازه‌ی هسته‌های خروجی  $11 \times 11$  تعیین گردید. از این رو در طراحی شبکه عصبی تعداد ۱۲۱ گره‌ی ورودی در نظر گرفته شده است که برای اعمال هسته‌های تاری به شبکه عصبی استفاده می‌شود. بدین منظور هسته‌ی تاری تصویر کم دقت برآورد شده با اندازه  $11 \times 11$  به صورت برداری  $121 \times 1$  به شبکه عصبی داده می‌شود. شبکه عصبی همچنین دارای ۶ گره خروجی متناظر با ۶ دسته‌ی هسته‌ی تاری آموزشی است.

برای آموزش شبکه عصبی ابتدا از روی تعدادی تصویر HR، بر طبق مدل مشاهده و با استفاده از هسته‌های تاری آموزشی تعدادی تصویر کم دقت با ضریب کاهش دقت برابر با ۲ تولید می‌شود. در

<sup>1</sup>Rectified Linear Unit (ReLU) Activation Function



شکل ۳-۴: فرآیند آموزش شبکه عصبی

مرحله‌ی بعد هسته‌ی تاری تصاویر کم دقت برآورد می‌گردد. این هسته‌های تاری به عنوان ورودی شبکه عصبی و دسته‌ی آن به عنوان دسته‌ی هدف به منظور آموزش شبکه عصبی مورد استفاده قرار می‌گیرد. این فرآیند در شکل ۳-۴ نشان داده شده است.

برای تولید داده‌های آموزشی، در حدود هفتصد تصویر طبیعی از مجموعه داده‌ی ImageNet [۹۲] انتخاب گردید. در انتخاب این تصاویر سعی شد تصاویر انتخاب شده بدون تاری و یا با تاری اندک باشند. برخی از این تصاویر در شکل ۳-۵ نمایش داده شده‌اند.

### ۳-۵ ارزیابی روش پیشنهادی و نتایج آزمایش‌ها

برای ارزیابی سیستم پیشنهادی، روال تولید تصاویر LR بیان شده در بخش قبل بر ۶۰ تصویر آزمون متفاوت از تصاویر آموزشی اعمال شد. برخی از این تصاویر آزمون در شکل ۳-۶ نشان داده شده است. جزئیات کار به این صورت است که از هر تصویر آزمون طبق مدل مشاهده با استفاده از هسته‌های آموزشی و با اعمال تغییرات هندسی تصادفی، ۱۰ تصویر کم دقت با ضریب کاهش دقت برابر با ۲ تولید شد. سپس هسته‌ی تاری هر یک از این تصاویر برآورد گردید. در آخر هر یک از هسته‌های تاری برآورد شده به شبکه عصبی آموزش یافته برای پیش‌بینی هسته‌ی تاری اعمال شده بر



جدول ۳-۲: ماتریس در هم ریختگی قبل از اعمال رای‌گیری

کلاس واقعی						
۶	۵	۴	۳	۲	۱	
۰	۱/۵	۰	۲۰/۱۷	۰	۹۰/۸۳	۱
۱/۶۷	۰/۳۳	۶	۰/۱۷	۹۸/۱۷	۰/۱۷	۲
۰	۹	۰	۷۸/۱۷	۰	۸	۳
۳/۸۳	۰	۹۲/۱۷	۰/۵	۱/۸۸	۰/۵	۴
۰	۸۹/۱۷	۰	۱	۰	۰/۵	۵
۹۴/۵	۰	۱/۸۳	۰	۰	۰	۶

کلاس پیش‌بینی شده

جدول ۳-۳: ماتریس در هم ریختگی بعد از اعمال رای‌گیری

کلاس واقعی						
۶	۵	۴	۳	۲	۱	
۰	۰	۰	۱۸/۳۳	۰	۹۳/۳۳	۱
۱/۶۷	۰	۳/۳۳	۰	۱۰۰	۰	۲
۰	۸/۳۳	۰	۸۰	۰	۶/۶۶	۳
۳/۳۳	۰	۹۶/۶۷	۰	۰	۰	۴
۰	۹۱/۶۷	۰	۱/۶۷	۰	۰	۵
۹۵	۰	۰	۰	۰	۰	۶

کلاس پیش‌بینی شده

جدول ۳-۴: میانگین معیارهای شباهت ساختاری و میانگین مربع خطا

تصاویری که هسته‌ی تاری درست پیش‌بینی شده		همه تصاویر		شماره هسته
MSE	SSIM	MSE	SSIM	
$1.17 \times 10^{-4}$	۰.۹۴	$1.18 \times 10^{-4}$	۰.۹۳	۱
$1.65 \times 10^{-4}$	۰.۸۹	$1.65 \times 10^{-4}$	۰.۸۹	۲
$1.06 \times 10^{-4}$	۰.۹۴	$1.20 \times 10^{-4}$	۰.۹۲	۳
$1.72 \times 10^{-4}$	۰.۸۷	$1.71 \times 10^{-4}$	۰.۸۶	۴
$1.01 \times 10^{-4}$	۰.۹۴	$1.26 \times 10^{-4}$	۰.۹۰	۵
$1.47 \times 10^{-4}$	۰.۹۱	$1.56 \times 10^{-4}$	۰.۸۸	۶

دسته‌ها شده است. علاوه بر این بعد از رای‌گیری خطای دسته‌بندی فقط در دسته‌های مربوط به هسته‌های تاری با اندازه یکسان رخ داده است.

بعد از تعیین هسته تاری توسط شبکه عصبی و اعمال رای‌گیری، هسته‌ی مذکور همراه با تصاویر کم دقت مطابق شکل ۳-۳ به الگوریتم ابرتفکیک‌پذیری جهت بازسازی تصویر پر دقت داده می‌شود. برای ارزیابی کارایی روش پیشنهادی، از معیار شباهت ساختاری<sup>۱</sup> [۹۳] و میانگین مربع خطا<sup>۲</sup> بین تصویر HR بازسازی شده و تصویر اصلی استفاده گردید. میانگین نتایج در جدول ۳-۴ هم به ازای هر ۶۰ تصویر و ۶ هسته تاری و هم برای تصاویری که هسته‌ی تاری آن‌ها درست پیش‌بینی شده است به طور جداگانه گزارش شده است. مقایسه‌ی ستون‌های جدول نشان می‌دهد پیش‌بینی درست هسته‌ی تاری منجر به بازسازی دقیق‌تر تصویر HR گردیده است.

در شکل ۳-۷ دو نمونه از تصاویر آزمون بازیافت شده به ازای هر یک از هسته‌های تاری به همراه یکی از تصاویر کم دقت متناظر نشان داده شده است. هسته‌ی تاری مربوط به تصاویر نشان داده شده در این شکل به درستی تشخیص داده شده‌اند؛ از این رو کیفیت تصویر پر دقت بازسازی شده قابل قبول است.

در مقابل اگر هسته‌ی تاری به طور نادرست تعیین شود، حاصل الگوریتم ابرتفکیک‌پذیری دارای

<sup>1</sup>Structural Similarity (SSIM) Index

<sup>2</sup>Mean Square Error (MSE)



(الف) معیار شباهت ساختاری تصاویر بازیافت شده از چپ به راست: ۰٫۸۸، ۰٫۹۲، ۰٫۸۵، ۰٫۹۳، ۰٫۸۵، ۰٫۹۳



(ب) معیار شباهت ساختاری تصاویر بازیافت شده از چپ به راست: ۰٫۸۷، ۰٫۹۳، ۰٫۹۶، ۰٫۹۲، ۰٫۹۵، ۰٫۹۴


شکل ۳-۷: نتیجه روش پیشنهادی در بازسازی تصاویر کم دقت تاری. در هر مجموعه از تصاویر، ردیف بالا یکی از تصاویر کم دقت و ردیف پایین تصویر پر دقت بازسازی شده را نشان می‌دهد. ستون‌ها به ترتیب از چپ به راست معادلند با هسته‌های تاری ۱ تا ۶. معیار SSIM تصاویر بازیافت شده در زیر شکل‌ها نشان داده شده است.

اثرات تصنعی<sup>۱</sup> خواهد بود. این مطلب در شکل ۳-۸ نشان داده شده است. در شکل ۳-۸ الف هسته‌های تاری ۳، ۴ و ۶ به طور اشتباه پیش‌بینی شده‌اند. هسته‌ی ۳ بطور اشتباه ۵ و دو هسته‌ی ۴ و ۶ بطور اشتباه ۲ تشخیص داده شده‌اند. هر چند که اثرات تصنعی مربوط به تشخیص هسته ۳ اندک است اما این اثرات برای دو هسته‌ی دیگر به وضوح قابل مشاهده است. در تصویر ۳-۸ ب دو هسته‌ی ۵ و ۶ که هر دو از نوع دیسک هستند به ترتیب به طور اشتباه ۳ و ۴ یعنی از نوع گوسی تشخیص داده شده‌اند. در اینجا اثرات تصنعی هر دو تصویر به راحتی قابل مشاهده است هر چند این اثرات در تشخیص اشتباه هسته‌ی ۶ خیلی شدیدتر می‌باشد.


در شکل ۳-۹ حاصل ابرتفکیک‌پذیری دو تصویری که بیشترین اثرات تصنعی را به خاطر تشخیص اشتباه هسته‌ی تاری متحمل شده‌اند، هم با هسته‌ی اشتباه و هم با هسته‌ی صحیح نمایش داده شده است. مقایسه‌ی این تصاویر در واقع بیانگر اهمیت یافتن هسته‌ی تاری صحیح در ابرتفکیک‌پذیری است.

<sup>۱</sup>Artifact






(الف) هسته‌های ۳، ۴ و ۶ اشتباه پیش‌بینی شده‌اند.



(ب) هسته‌های ۵ و ۶ اشتباه پیش‌بینی شده‌اند.

شکل ۳-۸: نتیجه روش پیشنهادی در بازسازی تصاویر کم دقت تار. در هر مجموعه از تصاویر، ردیف بالا یکی از تصاویر کم دقت و ردیف پایین تصویر پر دقت بازسازی شده را نشان می‌دهد. ستون‌ها به ترتیب از چپ به راست معادلند با هسته‌های تاری ۱ تا ۶.



(الف) از چپ به راست: تصویر HR اصلی، تصویر HR بازسازی شده با هسته اشتباه (SSIM: ۰.۲۵)، تصویر HR بازسازی شده با هسته صحیح (SSIM: ۰.۸۶).



(ب) از چپ به راست: تصویر HR اصلی، تصویر HR بازسازی شده با هسته اشتباه (SSIM: ۰.۴۲)، تصویر HR بازسازی شده با هسته صحیح (SSIM: ۰.۸۵).

شکل ۳-۹: تاثیر انتخاب درست هسته‌ی تاری در حاصل الگوریتم ابرتفکیک‌پذیری.

### ۶-۳ جمع‌بندی

برای تولید تصویر HR با استفاده از ابرتفکیک‌پذیری، جزئیات اطلاعات مربوط به فرآیند اخذ تصویر مورد نیاز است. در ابرتفکیک‌پذیری این اطلاعات به صورت مدل مشاهده یا مدل تخریب مدل می‌شوند. مدل مشاهده شامل اطلاعاتی در خصوص تغییرات هندسی، تاری اعمال شده به تصویر، کاهش تعداد نمونه و نویز فرآیند اخذ تصویر است.

در این فصل روشی برای پیش‌بینی هسته‌ی تاری در چارچوبی شبیه‌سازی شده پیشنهاد گردید. بدین منظور ابتدا تاری تصاویر کم دقت برآورد شده و به شبکه عصبی آموزش یافته اعمال می‌گردد. شبکه عصبی دسته‌ی هسته‌ی تاری را تعیین می‌کند. در آخر از هسته تاری تعیین شده توسط شبکه عصبی در الگوریتم ابرتفکیک‌پذیری استفاده می‌گردد.

نتایج آزمایش‌ها نشان می‌دهد شبکه عصبی مورد استفاده در بیش از ۹۰ درصد حالات، هسته‌ی تاری اعمال شده را درست تشخیص داده است. علاوه بر این، از آنجا که طبق مدل مشاهده‌ی مورد استفاده، تاری اعمال شده به تصویر ایده‌آل حین اخذ همه‌ی تصاویر کم دقت، یکسان فرض شده است، توانستیم با استفاده از رای‌گیری دقت روش پیشنهادی را تا بیش از ۹۲٪ درصد افزایش دهیم.

نتایج آزمایش‌ها همچنین نشان دهنده‌ی اهمیت تعیین درست هسته تاری در کارایی الگوریتم‌های ابرتفکیک‌پذیری است.



## فصل ۴

# تعیین تاری اعمال شده بر تصویر پر دقت با یادگیری عمیق

### ۱-۴ مقدمه

روش پیشنهاد شده در فصل قبل، با استفاده از شبکه عصبی، دسته‌ی هسته‌ی تاری را تعیین می‌کند. در این فصل اما هدف، تولید هسته‌ی تاری با استفاده از شبکه عصبی عمیق<sup>۱</sup> است. به بیان دقیقتر شبکه عصبی عمیق در روش پیشنهاد شده در این فصل عمل رگرسیون را انجام می‌دهد. از این رو همانند فصل قبل در چارچوبی شبیه‌سازی شده تعدادی هسته‌ی تاری انتخاب می‌شود. هسته‌های تاری مورد استفاده در این فصل از دو نوع تاری گوسی و تاری عدم تمرکز هستند. سپس با استفاده از این هسته‌ها و با اعمال مدل مشاهده بر روی تعدادی تصویر آموزشی HR تصاویر کم دقت تولید می‌شوند. در ادامه هسته‌ی تاری تصاویر کم دقت برآورد شده و به شبکه عصبی آموزش یافته اعمال می‌گردد. شبکه عصبی اعمال شده بر تصویر HR را بازسازی می‌کند. از این هسته در الگوریتم

---

<sup>1</sup>Deep Neural Network (DNN)

الگوریتم ۴-۱: الگوریتم پیشنهادی برای تخمین هسته‌ی تاری

- ۱ ورودی: هسته‌های تاری  $\{g_k\}$
- ۲ شروع
- ۳ برای  $k$  از ۱ تا  $L$
- ۴ نوع هسته‌ی تاری را با شبکه‌ی عصبی پیچشی تعیین کن.
- ۵ اگر هسته‌ی تاری از نوع گوسی بود آنگاه
- ۶  $\hat{h}_k$  را با اعمال  $g_k$  با شبکه عصبی  $DNN_G$  تعیین کن.
- ۷ در غیر این صورت
- ۸  $\hat{h}_k$  را با اعمال  $g_k$  با شبکه عصبی  $DNN_D$  تعیین کن.
- ۹ هسته‌های پرت را حذف کن.
- ۱۰ با میانگین‌گیری از هسته‌های موجود در مجموعه هسته‌ی  $\{\hat{h}_k\}$  هسته‌ی  $\hat{h}$  را تولید کن.
- ۱۱ هسته‌ی  $\hat{h}$  را برگردان.
- ۱۲ پایان


ابرتفکیک‌پذیری استفاده می‌شود. در ادامه روش پیشنهادی تشریح می‌گردد.

## ۴-۲ تخمین هسته‌ی تاری تصویر پر دقت

به منظور بیان بهتر روش پیشنهادی، هسته‌ی تاری تصویر کم دقت  $y_k$  به ازای  $k = 1, \dots, L$  را با  $g_k$  نشان می‌دهیم. هدف، تخمین هسته‌ی تاری اعمال شده بر تصویر پر دقت  $x$  یعنی  $h$  از روی  $g_k$ ها است. این کار توسط شبکه عصبی عمیق در چارچوب رگرسیون انجام می‌شود. الگوریتم روش پیشنهادی در الگوریتم ۴-۱ آمده است.

در روش پیشنهادی از دو نوع شبکه عصبی استفاده شده است. در ابتدا نوع هسته‌ی تاری توسط شبکه‌ی عصبی پیچشی<sup>۱</sup> تعیین می‌شود و سپس بسته به نوع هسته، از یکی از دو شبکه عصبی عمیق برای تعیین هسته‌ی تاری استفاده می‌گردد. این عمل بر روی همه‌ی هسته‌های تاری مربوط به تصاویر کم دقت اعمال می‌شود. به دلیل وجود نویز و خطا در تخمین هسته‌های تاری تصاویر کم

<sup>۱</sup>Convolutional Neural Network



شکل ۴-۱: ساختار شبکه عصبی عمیق

دقت، هسته‌های تاری تولید شده توسط شبکه عصبی یکسان نیستند. از این رو هسته‌های تاری پرت<sup>۱</sup> با روشی که جلوتر بیان می‌شود حذف می‌گردند. در نهایت هسته‌ی تاری اعمال شده بر تصویر HR با میانگین‌گیری از هسته‌های تاری باقیمانده به دست می‌آید.

### ۳-۴ ساختار شبکه‌های عصبی

همانطور که در بخش قبل بیان شد، در روش پیشنهادی از دو نوع شبکه عصبی استفاده شده است: یک عدد شبکه عصبی پیچشی (CNN) برای تعیین نوع هسته‌ی  $g_k$  (دیسک یا گوسی بودن)؛ و دو عدد شبکه عصبی عمیق برای تولید هسته‌ی  $\hat{h}_k$  که یکی از آن‌ها برای تولید هسته‌های از نوع گوسی مورد استفاده قرار می‌گیرد ( $DNN_G$ ) و دیگری برای تولید هسته‌های از نوع دیسک ( $DNN_D$ ) استفاده می‌شود.

ساختار شبکه‌های عصبی عمیق مورد استفاده با الهام از شبکه Inception-ResNet [۹۴] و با بررسی کارایی انتخاب‌های مختلف در ترتیب، تعداد و نوع لایه‌ها به طور تجربی طراحی شد. در این شبکه از دو بلوک Inception-ResNet پشت سر هم در ورودی و پس از آن‌ها از یک لایه تخت‌کننده<sup>۲</sup> و دو لایه‌ی کاملاً متصل<sup>۳</sup> استفاده گردید. بعد از این دو لایه از فن حذف تصادفی<sup>۴</sup> [۹۵] استفاده شد تا جلوی آموزش بیش از حد<sup>۵</sup> را بگیرد. ساختار شبکه در شکل ۴-۱ و بلوک Inception-ResNet مورد استفاده در شکل ۴-۲ نمایش داده شده است.

در ساختار شبکه عصبی پیچشی از لایه‌های پیچشی<sup>۶</sup> استفاده می‌شود. این لایه‌ها شامل فیلترهایی

<sup>1</sup>Outlier


<sup>2</sup>Flatten

<sup>3</sup>Fully Connected

<sup>4</sup>Dropout

<sup>5</sup>Overfitting

<sup>6</sup>Convolutional Layer




شکل ۴-۲: بلوک Inception-ResNet مورد استفاده در شبکه عصبی عمیق

است که وظیفه‌ی استخراج ویژگی از ورودی را بر عهده دارند. ورودی  $g_k$  به صورت دو بعدی به این شبکه اعمال می‌شود. به دلیل اینکه قسمت‌های مختلف هسته تاری ورودی با هم متفاوت است، در اولین لایه‌ی شبکه از لایه پیچشی متصل شده‌ی محلی<sup>۱</sup> [۹۶] استفاده شده است. ویژگی این لایه این است که به ازای هر قسمت از ورودی، فیلتر پیچش مجزایی در این لایه به طور تخصصی ویژگی‌های آن ناحیه را استخراج می‌کند. بعد از لایه اول از سه لایه پیچشی معمولی (غیر محلی) استفاده شده است. در ادامه ویژگی‌های استخراج شده به صورت تخت<sup>۲</sup> در آورده شده و به لایه‌های کاملاً متصل داده می‌شود. در شبکه مورد استفاده از دو لایه کاملاً متصل استفاده شده است. در این شبکه نیز برای جلوگیری از آموزش بیش از حد بعد از دو لایه کاملاً متصل از حذف تصادفی استفاده شده است. همچنین به همین منظور در لایه‌های کاملاً متصل از منظم‌سازی نرْم  $l_2$ <sup>۳</sup> استفاده می‌شود. آخرین لایه هم دو گره (برابر با تعداد انواع هسته‌ی تاری) دارد که عمل دسته‌بندی را انجام می‌دهد. معماری این شبکه در شکل ۴-۳ نمایش داده شده است.


<sup>1</sup>Locally Connected Convolutional Layer

<sup>2</sup>Flat

<sup>3</sup> $l_2$ -norm Regularization



شکل ۳-۴: ساختار شبکه عصبی پیچشی



شکل ۴-۴: روال آموزش دو شبکه عصبی عمیق



## ۴-۴ آموزش شبکه‌های عصبی

### ۱-۴-۴ تولید داده‌های آموزشی

روند آموزش دو شبکه DNN در شکل ۴-۴ نشان داده شده است. طبق شکل مذکور ابتدا هر یک از هسته‌های آموزشی برای تولید تصویر کم دقت مورد استفاده قرار می‌گیرد. سپس تصویر کم دقت ایجاد شده به الگوریتم تخمین هسته داده شده و هسته‌ی آن یعنی  $g_k$  برآورد می‌شود. این هسته به شبکه عصبی عمیق داده شده و خروجی آن یعنی  $\hat{h}_k$  به همراه هسته آموزشی  $h$  به الگوریتم یادگیری شبکه داده می‌شود. الگوریتم یادگیری از خطای بین هسته‌ی  $h$  و هسته برآورد شده برای آموزش شبکه استفاده می‌کند. شبکه‌ی ( $DNN_G$ ) تنها با هسته‌های گوسی و شبکه‌ی ( $DNN_D$ ) تنها با هسته‌های از نوع دیسک آموزش می‌بیند. هسته‌های ورودی به صورت دو بعدی به شبکه اعمال می‌شود و خروجی به صورت یک بعدی (بردار) تولید می‌گردد.

از آنجا که شبکه عصبی پیچشی مورد استفاده در این رساله به عنوان یک دسته‌بند دو کلاسی ایفای نقش می‌کند، فرایند آموزش آن با شبکه‌های عمیق مذکور متفاوت است. کلیت کار شبیه به شکل ۴-۴ است با این تفاوت که در حین آموزش، هر دو نوع هسته‌های تاری به آن داده می‌شود. برخلاف دو شبکه‌ی عصبی عمیق که مقادیر هسته  $h$  به الگوریتم آموزش شبکه عصبی داده می‌شود، برای آموزش شبکه عصبی پیچشی، یکی از دو بردار  $[0, 1]$  یا  $[1, 0]$  بسته به نوع هسته (دیسک یا گوسی بودن) به الگوریتم آموزش شبکه عصبی داده می‌شود.<sup>۱</sup> در زمان استفاده از این شبکه، در خروجی دو مقدار تولید می‌شود که هر یک بیانگر احتمال گوسی بودن و دیسک بودن نوع هسته هستند. نوع هسته با توجه به بیشینه دو مقدار تعیین می‌گردد. برای آموزش این شبکه از معیار خطای آنتروپی متقاطع<sup>۲</sup> [۹۷] استفاده شده است و بهینه‌یاب مورد استفاده برای آموزش هر دو نوع شبکه بهینه‌یاب Adam<sup>۳</sup> [۹۸] می‌باشد.

<sup>۱</sup>One-hot Encoding

<sup>۲</sup>Cross-Entropy

<sup>۳</sup>Adaptive Moment Estimation (Adam) Optimizer

برای آموزش شبکه‌های عصبی، ۷۰۷ تصویر طبیعی و تعداد ۴۰ هسته تاری انتخاب شد. در ادامه تعداد تصاویر و هسته‌ها را به ترتیب با  $N_{im}$  و  $N_k$  نمایش می‌دهیم. تصاویر از پایگاه داده imageNet [۹۲] انتخاب شدند و سعی شد که بدون تاری بوده یا تاری اندکی داشته باشند. اندازه کوچکترین تصویر و بزرگترین تصویر در مجموعه تصاویر آموزشی به ترتیب  $۳۷۵ \times ۲۶۴$  و  $۲۰۴۸ \times ۱۵۳۶$  است. برخی از این تصاویر در فصل قبل در شکل ۳-۵ نشان داده شده است.

هسته‌های تاری انتخاب شده میزان تاری کنندگی متفاوت داشته و برای شبیه‌سازی تاری ناشی از اغتشاش‌های جوی و تاری ناشی از عدم تمرکز عدسی، به ترتیب نیمی از آن‌ها از نوع گوسی و نیم دیگر از نوع دیسک انتخاب شد. جهت یکسان‌سازی اندازه داده‌ها برای آموزش شبکه عصبی، اندازه همه‌ی هسته‌ها  $۱۱ \times ۱۱$  گردید. برای این منظور به اطراف هسته‌های کوچک صفر اضافه شد.<sup>۱</sup> این هسته‌ها را مجموعه هسته‌های آموزشی می‌نامیم.

در مرحله بعد بر طبق مدل مشاهده (۱-۸) با استفاده از هسته‌ها و تصاویر آموزشی، تصاویر LR تولید می‌شوند. در تولید تصاویر LR ضریب افزایش دقت دو انتخاب شد ( $P = ۲$ ) و تغییرات هندسی به صورت تصادفی و به تعداد  $L = ۶۹$  انتخاب گردید. بدین ترتیب تعداد  $N_{im} \times N_k \times L = ۱۹۵۱۳۲۰$  تصویر LR برای آموزش شبکه عصبی تولید می‌گردد. هر یک از تصاویر LR تولید شده را به صورت  $y_{ijk}$  نمایش می‌دهیم که در آن اندیس‌های  $i$ ،  $j$  و  $k$  به ترتیب نشان دهنده‌ی تصویر آموزشی، تغییرات هندسی و هسته آموزشی مورد استفاده است.

بعد از تولید تصاویر LR، الگوریتم تخمین هسته‌ی تاری ارائه شده در [۹۰] بر روی هر یک از آن‌ها اعمال می‌گردد تا هسته‌ی تاری  $g_{ijk}$  متناظر با تصویر  $y_{ijk}$  تولید شود. در اجرای الگوریتم تخمین تاری، با توجه به اندازه هسته‌های آموزشی و ضریب افزایش دقت، اندازه هسته‌های  $g_{ijk}$  برابر با  $۷ \times ۷$  تعیین شد.

<sup>۱</sup>Zero Padding

الگوریتم ۲-۴: الگوریتم حذف هسته‌های پرت

۱ ورودی: هسته‌های تاری  $\{g_{ijk}\}$

۲ شروع

۳ برای  $k$  از ۱ تا  $N_k$

$$\mu_k \leftarrow \frac{1}{N_{im}L} \sum_{i=1}^{N_{im}} \sum_{j=1}^L g_{ijk} \quad 4$$

۵  $D_M(g_{ijk})$  را طبق رابطه‌ی (۱-۴) محاسبه کن.

۶ مقادیر  $D_M(g_{ijk})$  را به طور صعودی مرتب کن.

۷  $N_{out}$  هسته با بیشترین فاصله را حذف کن.

۸ هسته‌های باقیمانده را برگردان.

۹ پایان

۲-۴-۴ حذف هسته‌های پرت

همانگونه که قبلاً بیان شد، به علت وجود نویز و خطا در تخمین هسته‌ی تاری تصاویر کم دقت، برخی از هسته‌های برآورد شده توسط شبکه عصبی عمیق پرت بوده و باید حذف شوند. بدین منظور بر طبق الگوریتم ۲-۴ با استفاده از فاصله‌ی ماهالانوبیس<sup>۱</sup> [۹۹] که بر طبق رابطه‌ی (۱-۴) محاسبه می‌شود، هسته‌های پرت حذف می‌گردد.

$$D_M(g_k) = \sqrt{(g_k - \mu)^T S^{-1} (g_k - \mu)} \quad (1-4)$$


در رابطه (۱-۴)  $\mu$  میانگین هسته‌ها است و ماتریس پراکندگی<sup>۲</sup>  $S$  تخمینی از ماتریس کوواریانس بوده که از رابطه‌ی (۲-۴) به دست می‌آید.

$$S = \sum_{k=1}^L (g_k - \mu)(g_k - \mu)^T \quad (2-4)$$

در آزمایش‌های انجام شده مقدار  $N_{out}$  در الگوریتم ۲-۴ یعنی تعداد هسته‌های پرت به طور تجربی برابر با  $\frac{1}{4} N_{im}L$  انتخاب شد.

<sup>1</sup>Mahalanobis Distance

<sup>2</sup>Scatter Matrix



شکل ۴-۵: نمودار بلوکی استفاده از روش پیشنهادی




شکل ۴-۶: تصویر اصلی مورد استفاده در نتایج نشان داده شده در شکل ۴-۷.

## ۵-۴ استفاده از روش پیشنهادی

نمودار شکل ۴-۵ چگونگی استفاده از روش پیشنهادی را نشان می‌دهد. بر طبق این شکل، ابتدا هسته‌های تصاویر LR برآورد شده سپس با استفاده از الگوریتم ۱-۴ هسته  $\hat{h}$  تولید می‌شود. همانگونه که در الگوریتم ۱-۴ بیان شده است، هسته‌های تولید شده توسط شبکه عصبی همانند هسته‌های تصاویر کم‌دقت بررسی شده و هسته‌های پرت حذف می‌گردند. سپس از میانگین هسته‌های باقی‌مانده در الگوریتم SR برای تولید تصویر HR استفاده می‌گردد. برای انجام عمل SR در آزمایش‌ها از روش بیان شده در [۵۲] استفاده شد.

## ۶-۴ نتایج آزمایش‌ها

برای ارزیابی روش پیشنهادی، با استفاده از مدل مشاهده، از تعدادی تصویر HR آزمون، ۳۵ تصویر LR ایجاد گردید. تصاویر HR مذکور در مجموعه تصاویر آموزشی نبودند. سپس طبق نمودار شکل ۴-۵ نسخه‌ی ابرتفکیک‌پذیر شده این تصاویر به دست آمد. ما از تصویر نشان داده شده در شکل ۴-۶ برای ارزیابی روش پیشنهادی استفاده کردیم.




(ج) هسته‌های تاری اصلی و برآورد شده. ( $MSE = 5.86 \times 10^{-9}$ )



(ب) تصویر HR بازیافت شده. ( $SSIM = 0.82$ )



(الف) یک نمونه از تصاویر LR



(و) هسته‌های تاری اصلی و برآورد شده. ( $MSE = 5.87 \times 10^{-8}$ )



(ه) تصویر HR بازیافت شده. ( $SSIM = 0.84$ )




(د) یک نمونه از تصاویر LR


شکل ۴-۷: نتیجه اعمال روش پیشنهادی. ردیف بالا: ابرتفکیک‌پذیری تصاویر تار شده با هسته‌ی گوسی، ردیف پایین: ابرتفکیک‌پذیری تصاویر تار شده با هسته‌ی دیسک. هر یک از شکل‌های (ج) و (و) شامل دو هسته‌ی تاری اصلی و برآورد شده می‌باشند که برای مقایسه به صورت یک بعدی نمایش داده شده‌اند.

در شکل ۴-۷ دو نمونه از نتیجه آزمایش نشان داده شده است. مقایسه‌ی تصاویر بازسازی شده با تصویر اصلی و توجه به میزان تاری تصاویر LR نشان می‌دهد روش پیشنهادی علاوه بر افزایش تفکیک‌پذیری توانسته تاری را به خوبی کاهش دهد. مقادیر معیار SSIM تصاویر بازسازی شده نیز این ادعا را تایید می‌کند. همچنین در این شکل هسته تاری اعمال شده و هسته تاری برآورد شده نشان داده شده است. هر کدام از نمودارهای (ج) و (و) از شکل ۴-۷ شامل دو نمودار هسته تاری است که برای مقایسه‌ی بهتر، به صورت یک بعدی نمایش داده شده است. همان گونه مشاهده می‌شود اختلاف دو هسته بسیار ناچیز است به گونه‌ای که دو هسته تقریباً بر روی هم منطبق شده‌اند. میزان MSE در زیر نمودارها نیز این مطلب را نشان می‌دهد.

از مشکلات روش پیشنهادی حساسیت آن به خطای تخمین هسته‌ی تاری است. این مشکل در شکل ۴-۸ قابل مشاهده است. همانطور که مشاهده می‌شود اختلاف دو هسته نسبت به مثال‌های نشان داده شده در شکل ۴-۷ زیاد است و این اختلاف منجر به ایجاد اثرات تصنعی در خروجی الگوریتم



(ج) هسته‌های تاری اصلی و بازسازی شده. ( $MSE = 1.05 \times 10^{-6}$ )



(ب) تصویر HR بازیافت شده. (SSIM = 0.52)



(الف) یک نمونه از تصاویر LR

شکل ۴-۸: نمونه‌ای از خطای ایجاد شده در بازسازی تصویر HR.

SR شده است. ایجاد این اثرات تصنعی شدید در تصویر بازسازی شده را شاید بتوان با بدمطرح بودن مسئله SR توجیه کرد. وجود خطا در تخمین هسته‌ی تاری معادل است با مدل مشاهده نادرست و این عدم سازگاری در مدل مستقیم و مدل معکوس خود را در پاسخ مسئله معکوس نشان داده است.

## ۷-۴ جمع‌بندی

در این فصل روشی برای بازسازی هسته تاری اعمال شده بر تصویر پر دقت از روی هسته‌ی تاری تصاویر کم دقت با استفاده از شبکه عصبی عمیق ارائه گردید. در این روش هسته‌ی تاری اعمال شده بر تصویر پر دقت توسط شبکه‌ی عصبی عمیق بازسازی می‌گردد. بدین منظور ابتدا نوع هسته‌ی تاری توسط شبکه عصبی پیچشی تعیین شده و سپس بسته به نوع هسته تاری به یکی از شبکه‌های عصبی عمیق اعمال می‌گردد.

نتایج آزمایش‌ها نشان می‌دهد روش پیشنهادی توانایی تولید هسته‌ی تاری اعمال شده بر تصویر پر دقت را دارد. با این حال خطا در تخمین هسته‌ی تاری اثرات مخربی بر تصویر بازسازی شده می‌گذارد.



## فصل ۵

# ابرتفکیک‌پذیری تصاویر با تاری ناشی از عدم تمرکز عدسی

### ۱-۵ مقدمه

در این فصل روشی برای ابرتفکیک‌پذیری تصاویر تاری ناشی از عدم تمرکز عدسی دوربین پیشنهاد می‌گردد. اما قبل از آن الگوریتم بهینه‌یابی ADMM<sup>۱</sup> که از آن برای حل تابع هزینه پیشنهادی استفاده شده است معرفی می‌گردد.

### ۲-۵ الگوریتم بهینه‌یابی ADMM

الگوریتم ADMM [۱۰۰] برای حل مسئله کمینه‌یابی نامقید زیر مناسب است.

$$\min_{\mathbf{z} \in \mathbb{R}^d} \sum_{j=1}^J g^{(j)}(\mathbf{G}^{(j)} \mathbf{z}) \quad (1-5)$$

---

<sup>1</sup>Alternating Direction Method of Multipliers  
(ADMM)



الگوریتم ۵-۱: الگوریتم ADMM

۱ شروع

۲  $k = 0$ ، مقادیر  $\mu^j > 0$  و  $\mathbf{u}^{(j)}$  و  $\mathbf{d}^{(j)}$  را به ازای  $j = 1, \dots, J$  انتخاب کن

۳ تکرار کن

$$\mathbf{r}_{k+1} \leftarrow \sum_{j=1}^J \mu^{(j)} (\mathbf{G}^{(j)})^T (\mathbf{u}_k^{(j)} + \mathbf{d}_k^{(j)}) \quad 4$$

$$\mathbf{z}_{k+1} \leftarrow \left[ \sum_{j=1}^J \mu^{(j)} (\mathbf{G}^{(j)})^T (\mathbf{G}^{(j)}) \right]^{-1} \mathbf{r}_{k+1} \quad 5$$

۶ برای  $j$  از ۱ تا  $J$

$$\mathbf{u}_{k+1}^{(j)} \leftarrow \text{prox}_{g^{(j)}/\mu^{(j)}} \left( \mathbf{G}^{(j)} \mathbf{z}_{k+1} - \mathbf{d}_k^{(j)} \right) \quad 7$$

$$\mathbf{d}_{k+1}^{(j)} \leftarrow \mathbf{d}_k^{(j)} - \left( \mathbf{G}^{(j)} \mathbf{z}_{k+1} - \mathbf{u}_{k+1}^{(j)} \right) \quad 8$$

$$k \leftarrow k + 1 \quad 9$$

۱۰ تا وقتی که شرط توقف برقرار شود

۱۱ پایان

که در آن  $\mathbf{z}$  متغیر مستقل،  $\mathbf{G}^{(j)} \in \mathbb{R}^{p_j \times d}$  ماتریسی دلخواه و  $g^{(j)}: \mathbb{R}^{p_j} \mapsto \mathbb{R}$  تابع هستند. معادله (۵-۱) را می‌توان به صورت کمینه‌یابی مقید (۵-۲) بازنویسی کرد که در آن  $\mathbf{u}^{(j)}$  متغیر جدا کننده<sup>۱</sup> است.

$$\min_{\mathbf{z} \in \mathbb{R}^d, \mathbf{u}^{(1)} \in \mathbb{R}^{p_1}, \dots, \mathbf{u}^{(J)} \in \mathbb{R}^{p_J}} \sum_{j=1}^J g^{(j)}(\mathbf{G}^{(j)} \mathbf{z}) \quad (2-5)$$

subject to  $\mathbf{u}^{(j)} = \mathbf{G}^{(j)} \mathbf{z}$ , for  $j = 1, \dots, J$ .

الگوریتم ADMM برای حل رابطه (۵-۲) در الگوریتم ۵-۱ آمده است. در این الگوریتم  $\mathbf{d}^{(j)}$  متغیر دوگان<sup>۲</sup> و  $\mu^{(j)}$  پارامتر جریمه است. در سطر ۷ الگوریتم، عبارت  $\text{prox}_{g^{(j)}/\mu^{(j)}}$  عملگر مجاورت<sup>۳</sup>  $g^{(j)}/\mu^{(j)}$  است. عملگر مجاورت برای تابع  $f$  طبق رابطه زیر تعریف می‌شود.

$$\text{prox}_f(\mathbf{v}) = \arg \min_{\mathbf{x}} \frac{1}{\mu} \|\mathbf{v} - \mathbf{x}\|_{\mu}^2 + f(\mathbf{x}) \quad (3-5)$$

<sup>1</sup> Splitting Variable

<sup>2</sup> Dual Variable

<sup>3</sup> Proximity Operator

## ۳-۵ روش پیشنهادی

همانگونه که در فصل ۱ بیان شد، اولین قدم در حل مسئله‌ی SR انتخاب مدل مشاهده است. در روش پیشنهادی از مدل مشاهده‌ی blur-warp استفاده شده است. این مدل این امکان را فراهم می‌کند که مسئله‌ی ابرتفکیک‌پذیری در دو مرحله حل شود: در مرحله‌ی اول تصویر پر دقت‌تر باز یافت می‌شود و در مرحله‌ی بعد تصویر مذکور تار زدایی می‌گردد. جزئیات کار در زیر بخش‌های آتی بیان می‌گردد. یکی از مشکلات مسئله‌ی تار زدایی، پیکسل‌های واقع و یا نزدیک در مرزهای تصویر است. مقادیر این پیکسل‌ها در اثر تار شدن تصویر وابسته به نقاطی از صحنه است که در تصویر وجود ندارند. از این رو در الگوریتم‌های تار زدایی معمولاً فرض‌هایی درباره‌ی آن نقاط می‌شود که اصطلاحاً به آن شرایط مرزی<sup>۱</sup> گفته می‌شود. برای مثال فرض متناوب بودن تصویر و یا فرض صفر بودن نقاط خارج از تصویر که به کرات در تحقیقات استفاده شده‌اند. با این وجود هیچ یک از این فرض‌ها در عمل درست نیست و اعمال آن‌ها باعث ایجاد اثرات تصنعی حلقوی<sup>۲</sup> در تصویر بازسازی شده می‌گردد. یکی از راه‌حل‌های متداول که به طور مصنوعی این مشکل را حل می‌کند، کاهش تدریجی ناپیوستگی در مرزهای تصویر است.<sup>۳</sup>

در [۱۰۱] راه‌حل بهتری برای این مسئله ارائه شده است که در آن هیچگونه فرضی درباره‌ی نقاط مرزی نمی‌شود. در این روش پیکسل‌های مرزی خارج از تصویر به مجهولات مسئله اضافه می‌شوند و با حل مسئله مقادیر آن‌ها به طور سازگار با بقیه پیکسل‌ها برآورد می‌گردد. با اعمال این روش، مدل مشاهده در الگوریتم پیشنهادی به صورت رابطه‌ی (۴-۵) خواهد شد. بدین ترتیب می‌توان گفت مسئله حاضر ترکیبی از دو مسئله‌ی SR و inpainting [۱۰۲] است.

$$\mathbf{y}_k = \mathbf{D} \times \mathbf{W}_k \times \mathbf{M} \times \mathbf{H} \times \mathbf{x} + \mathbf{n}_k \quad (4-5)$$

در رابطه‌ی (۴-۵)، ماتریس  $\mathbf{M}$  شامل عناصر  $\circ$  و  $\mathbf{1}$  است و به عنوان عملگر نقاب<sup>۴</sup> پیکسل‌های مرزی را

<sup>1</sup>Boundary Condition

<sup>2</sup>Ringing Artifact

<sup>۳</sup> یکی از پیاده‌سازی‌های این روش تابع edgetaper

<sup>4</sup>Masking Operator

در نرم‌افزار متلب است.

الگوریتم ۵-۲: الگوریتم کاهش گرادیان برای حل رابطه‌ی (۵-۵)

۱ شروع

۲  $\mathbf{b}$  را مقداردهی اولیه کن، مقادیر  $\gamma$  و  $\epsilon$  را انتخاب کن.

۳ تکرار کن

۴  $\mathbf{b}_{\text{old}} \leftarrow \mathbf{b}$

۵  $\nabla_{\mathbf{b}} \leftarrow \sum_{k=1}^L -2 (\mathbf{D}\mathbf{W}_k)^T (\mathbf{y}_k - \mathbf{D}\mathbf{W}_k\mathbf{b})$

۶  $\mathbf{b} \leftarrow \mathbf{b} - \gamma \nabla_{\mathbf{b}}$

۷ تا وقتی که  $\|\mathbf{b} - \mathbf{b}_{\text{old}}\| < \epsilon$

۸ پایان

حذف می‌کند. در این رابطه  $\mathbf{H} \times \mathbf{x}$  متناظر است با پیچش هم اندازه<sup>۱</sup> (یعنی اندازه‌ی تصویر  $\mathbf{H} \times \mathbf{x}$  با اندازه تصویر  $\mathbf{x}$  یکسان است)، در حالی که  $\mathbf{M} \times \mathbf{H} \times \mathbf{x}$  متناظر است با پیچش با اندازه مجاز<sup>۲</sup>. به بیان دیگر نقش  $\mathbf{M}$  در مدل مشاهده‌ی (۴-۵) حذف پیکسل‌های ایجاد شده در اطراف تصویر تاری به خاطر عمل پیچش است. بدین ترتیب در مسئله‌ی معکوس، حضور  $\mathbf{M}$  موجب تولید پیکسل‌های مذکور از روی تصاویر کم دقت می‌گردد.

۵-۳-۱ تخمین تصویر پر دقت تاری

با توجه به مدل مشاهده‌ی (۴-۵) تصویر پر دقت تاری  $\mathbf{b} = \mathbf{M} \times \mathbf{H} \times \mathbf{x}$  جواب رابطه‌ی بهینه‌یابی (۵-۵) است.

$$\hat{\mathbf{b}} = \arg \min_{\mathbf{b}} \sum_{k=1}^L \|\mathbf{y}_k - \mathbf{D} \times \mathbf{W}_k \times \mathbf{b}\|_2^2 \quad (5-5)$$

از آنجا که رابطه‌ی (۵-۵) از درجه دوم<sup>۳</sup> است، برای حل آن می‌توان از الگوریتم ساده‌ی کاهش گرادیان [۱۰۳] و یا از الگوریتم‌های پیشرفته‌تر مانند primal-dual [۱۰۴] استفاده کرد. در الگوریتم ۲-۵ روش حل رابطه‌ی (۵-۵) با استفاده از کاهش گرادیان بیان شده است.

<sup>1</sup> Same Shape Convolution

<sup>2</sup> Valid Shape Convolution

<sup>3</sup> Quadratic

## الگوریتم ۳-۵: الگوریتم واپیچش کور مورد استفاده

۱ شروع

۲  $\hat{\mathbf{h}}$  را با فیلتر همانی مقداردهی اولیه کن و مقدار  $\lambda$  را انتخاب کن.

۳ تکرار کن

$$\hat{\mathbf{x}} \leftarrow \arg \min_{\mathbf{x}} J_{\lambda}(\mathbf{x}, \hat{\mathbf{h}}) \quad 4$$

$$\hat{\mathbf{h}} \leftarrow \arg \min_{\mathbf{h}} J_{\lambda}(\hat{\mathbf{x}}, \mathbf{h}) \quad 5$$

۶  $\lambda$  را به روزرسانی کن

۷ تا وقتی که شرط توقف برقرار شود

۸ پایان

## ۲-۳-۵ تازی زدایی تصویر پر دقت تار

بعد از تخمین  $\mathbf{b}$ ، مسئله ابرتفکیک پذیری به مسئله واپیچش کور<sup>۱</sup> یعنی تخمین تصویر پر دقت  $\mathbf{x}$  و هسته‌ی تازی  $\mathbf{h}$  تبدیل می‌شود. این مجهولات را می‌توان یک‌درمیان تخمین زد: ابتدا هسته‌ی تازی با فیلتر همانی مقداردهی شده، تصویر پر دقت برآورد می‌گردد؛ سپس با مقدار برآورد شده برای تصویر، هسته‌ی تازی برآورد می‌گردد. این فرآیند تا رسیدن به شرطی خاص تکرار می‌شود. جزئیات کار در الگوریتم ۳-۵ بیان شده است. در این الگوریتم  $J_{\lambda}(\mathbf{x}, \mathbf{h})$  تابع هزینه بوده که بعداً معرفی می‌گردد و  $\lambda$  بردار پارامترهای منظم‌سازی است.

همان‌طور که پیشتر بیان شد، مسئله‌ی واپیچش کور مسئله‌ای معکوس و بد مطرح است. از این رو برای همگرا شدن تابع هزینه به جوابی مفید، باید از منظم‌ساز مناسب استفاده شود. بنابراین در الگوریتم پیشنهادی تابع هزینه به صورت زیر تعریف می‌گردد.

$$J_{\lambda}(\mathbf{x}, \mathbf{h}) = \|\hat{\mathbf{b}} - \mathbf{M}\mathbf{H}\mathbf{x}\|_2^2 + \lambda_1 R_1(\mathbf{x}) + \lambda_2 R_2(\mathbf{x}) + \lambda_h R_h(\mathbf{h}) \quad (6-5)$$

در (۶-۵) اولین عبارت در سمت راست، عبارت سازگاری داده است که هدف از آن کمینه کردن ناسازگاری بین تصویر  $\mathbf{x}$  و تصویر تار  $\hat{\mathbf{b}}$  است.  $R_1(\mathbf{x})$ ،  $R_2(\mathbf{x})$  و  $R_h(\mathbf{h})$  توابع منظم‌سازی هستند که در ادامه معرفی می‌شوند و  $\lambda_1$ ،  $\lambda_2$  و  $\lambda_h$  پارامترهای منظم‌سازی متناظر می‌باشند.  $\lambda$  در الگوریتم ۳-۵

<sup>1</sup>Blind Image Deconvolution

برابر است با  $\lambda = [\lambda_1, \lambda_2, \lambda_h]$ .

در الگوریتم پیشنهادی،  $R_1(\mathbf{x})$  طبق (۷-۵) برابر با مجموع تغییرات تعمیم‌یافته<sup>۱</sup> [۳] تعریف می‌شود.

$$R_1(\mathbf{x}) = \|\mathbf{D}_\circ \mathbf{x}\|_q^q + \|\mathbf{D}_{\circ\delta} \mathbf{x}\|_q^q + \|\mathbf{D}_{\circ\theta} \mathbf{x}\|_q^q + \|\mathbf{D}_{\circ\delta\theta} \mathbf{x}\|_q^q \quad (7-5)$$

که در آن  $\mathbf{D}_\theta$  به ازای  $\theta \in \{0, 45, 90, 135\}$ ، عملگر مشتق در جهتی است که با جهت مثبت محور  $x$  زاویه  $\theta$  می‌سازد. همانگونه که قبلاً بیان شد گرادیان تصاویر طبیعی توزیعی با دنباله‌ای طولانی دارد که می‌توان آن را با توزیع فوق‌لاپلاس مدل کرد [۶۹]. برای این منظور کافی است پارامتر  $q$  در رابطه‌ی ۷-۵ در محدوده‌ی  $(0, 1)$  مقداردهی شود.

آزمایش‌های انجام شده در مرجع [۹۰] نشان داده است که توزیع گرادیان مرتبه دوم تصاویر طبیعی نیز دنباله‌ای طولانی دارد. از این رو در الگوریتم پیشنهادی منظم‌ساز  $R_2(\mathbf{x})$  به صورت زیر تعریف می‌گردد.

$$R_2(\mathbf{x}) = \|\mathbf{D}_{xx} \mathbf{x}\|_q^q + \|\mathbf{D}_{xy} \mathbf{x}\|_q^q + \|\mathbf{D}_{yy} \mathbf{x}\|_q^q \quad (8-5)$$

که در آن  $\mathbf{D}_{xx}$ ،  $\mathbf{D}_{xy}$  و  $\mathbf{D}_{yy}$  به ترتیب عملگرهای مشتق درجه دوم در جهت افقی، قطری و عمودی هستند.

همانطور که پیشتر بیان شد، هدف این فصل ابرتفکیک‌پذیری تصاویر تار شده در اثر عدم تمرکز عدسی است. بر اساس رابطه‌ی (۶-۱) هسته‌ی تاری عدم تمرکز، پیوسته بوده و دارای مقادیری یکسان است. از این رو برای اعمال این قید بر هسته‌ی تاری، منظم‌ساز  $R_h(\mathbf{h})$  به صورت (۹-۵) تعریف می‌گردد.

$$R_h(\mathbf{h}) = \|\mathbf{D}_{\circ\delta} \mathbf{h}\|_1 + \|\mathbf{D}_{\circ\delta\theta} \mathbf{h}\|_1 \quad (9-5)$$

منظم‌ساز (۹-۵) گرادیان هسته‌ی تاری را در دو جهت متعامد محدود می‌کند. این جهت‌ها به طور تجربی انتخاب گردیده است.

<sup>1</sup>Generalized Total Variation (GTV)

## ۴-۵ تخمین تصویر پر دقت

برای تخمین تصویر پر دقت یعنی دستور ۴ در الگوریتم ۳-۵ باید مسئله‌ی کمینه‌یابی زیر حل شود.

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \|\hat{\mathbf{b}} - \mathbf{M}\mathbf{H}\mathbf{x}\|_2^2 + \lambda_1 R_1(\mathbf{x}) + \lambda_2 R_2(\mathbf{x}) \quad (10-5)$$

با توجه به مقدار  $q$  در روابط (۷-۵) و (۸-۵)، سمت راست عبارت (۱۰-۵) معادله‌ای از درجه دوم نیست و در نتیجه حل آن نیاز به الگوریتم‌های پیشرفته‌تری دارد. دو الگوریتم متداول برای حل چنین مسائلی عبارت است از «روش کمینه‌یابی نیمه درجه دوم»<sup>۱</sup> [۱۰۵] و «روش جهت یک‌درمیان ضرایب»<sup>۲</sup>. در الگوریتم پیشنهادی از ADMM به دلیل سادگی در پیاده‌سازی، کارایی بالا و توانایی در حل توابع هزینه با چندین جمله و قید استفاده شده است. هر چند روش اول نیز قابل استفاده است.

در ادامه جزئیات فرمول‌بندی روش ADMM برای حل (۱۰-۵) بیان شده است. با قرار دادن روابط

(۷-۵) و (۸-۵) در (۱۰-۵) هشت جمله خواهیم داشت. از این رو  $J = 8$ .

$$\mathbf{G}^{(1)} = \mathbf{H} \quad (11-5)$$

$$\mathbf{G}^{(2)} = \mathbf{D}_0, \quad \mathbf{G}^{(3)} = \mathbf{D}_{\varphi_0} \quad (12-5)$$

$$\mathbf{G}^{(4)} = \mathbf{D}_{\varphi_1}, \quad \mathbf{G}^{(5)} = \mathbf{D}_{\varphi_2} \quad (13-5)$$

$$\mathbf{G}^{(6)} = \mathbf{D}_{xx}, \quad \mathbf{G}^{(7)} = \mathbf{D}_{xy}, \quad \mathbf{G}^{(8)} = \mathbf{D}_{yy} \quad (14-5)$$

$$g^{(1)}(\mathbf{u}^{(1)}) = \frac{1}{2} \|\mathbf{y} - \mathbf{M}\mathbf{u}^{(1)}\|_2^2 \quad (15-5)$$

$$g^{(j)}(\mathbf{u}^{(j)}) = \lambda_j \|\mathbf{u}^{(j)}\|_q^q, \quad j = 2, \dots, 8 \quad (16-5)$$

که در آن

$$\lambda_j = \begin{cases} \lambda_1 & j = 2, \dots, 5 \\ \lambda_2 & j = 6, 7, 8 \end{cases} \quad (17-5)$$

<sup>1</sup>Half-Quadratic Minimization Method

<sup>2</sup>Alternating Direction Method of Multipliers (ADMM)

در اجرای الگوریتم ADMM، یعنی الگوریتم ۵-۱، مهمترین مراحل، دستورات ۵ و ۷ هستند. با

قرار دادن روابط (۵-۱۱) تا (۵-۱۶) در سطر ۵ الگوریتم به رابطه‌ی زیر می‌رسیم.

$$\mathbf{z}_{k+1} \leftarrow \mathbf{A} \left( \mu^{(1)} \mathbf{H}^T \left( \mathbf{u}_k^{(1)} + \mathbf{d}_k^{(1)} \right) + \sum_{j=2}^{\wedge} \mu^{(j)} \mathbf{G}_j^T \left( \mathbf{u}_k^{(j)} + \mathbf{d}_k^{(j)} \right) \right) \quad (5-18)$$

که در آن

$$\mathbf{A} = \left( \mu^{(1)} \mathbf{H}^T \mathbf{H} + \sum_{j=2}^{\wedge} \mu^{(j)} \mathbf{G}_j^T \mathbf{G}_j \right)^{-1} \quad (5-19)$$

و

$$\mu^{(j)} = \begin{cases} \mu_1 & j = 1 \\ \mu_2 & j = 2, \dots, 5 \\ \mu_3 & j = 6, 7, 8 \end{cases} \quad (5-20)$$

در رابطه‌ی (۵-۱۸) تصویر HR بازسازی شده در تکرار  $k + 1$  است. حل سطر ۷ از الگوریتم

۵-۱ منجر به عملگرهای مجاورت (۵-۲۱) و (۵-۲۲) می‌گردد.

$$\begin{aligned} \text{prox}_{g^{(1)}/\mu_1}(\mathbf{v}) &= \arg \min_{\mathbf{x}} \frac{1}{\mu_1} \|\mathbf{y} - \mathbf{M}\mathbf{x}\|_2^2 + \frac{1}{\mu_1} \|\mathbf{v} - \mathbf{x}\|_2^2 \\ &= (\mu_1 \mathbf{I} + \mathbf{M}^T \mathbf{M})^{-1} (\mathbf{M}^T \mathbf{y} + \mu_1 \mathbf{v}) \end{aligned} \quad (5-21)$$

در (۵-۲۱) ماتریس همانی است و  $\mu^{(j)}$  در (۵-۲۰) تعریف شده است. این رابطه به راحتی قابل حل

است و جزئیات حل در [۱۰۶] آمده است.

$$\text{prox}_{g^{(j)}/\mu^{(j)}}(\mathbf{v}) = \arg \min_{\mathbf{x}} \frac{\lambda_j}{\mu^{(j)}} \|\mathbf{x}\|_q^q + \frac{1}{\mu^{(j)}} \|\mathbf{v} - \mathbf{x}\|_2^2, \quad j = 2, \dots, 8 \quad (5-22)$$

رابطه‌ی (۵-۲۲) فقط به ازای  $q \in \{0, \frac{1}{2}, \frac{2}{3}, 1, \frac{4}{3}, \frac{3}{2}, 2\}$  جواب بسته<sup>۱</sup> دارد [۱۰۷]. به ازای بقیه مقادیر

$q$  می‌توان رابطه را به طور عددی حل کرد و برای تکرارهای بعدی در جدول جست‌وجو<sup>۲</sup> ذخیره کرد

[۶۹]. در الگوریتم پیشنهادی از همین رهیافت استفاده شده است.

<sup>1</sup>Closed Form Solution

<sup>2</sup>Lookup Table

## ۵-۵ تخمین هسته‌ی تاری

برای تخمین هسته‌ی تاری  $\mathbf{h}$  یعنی دستور ۵ در الگوریتم ۳-۵ مسئله‌ی کمینه‌یابی زیر باید با استفاده از اجرای دیگری از الگوریتم ADMM حل شود.

$$\hat{\mathbf{h}} = \arg \min_{\mathbf{h}} \|\hat{\mathbf{b}} - \mathbf{M}\mathbf{X}\mathbf{h}\|_2^2 + \lambda_h R_h(\mathbf{h}) \quad (23-5)$$

که در آن  $\mathbf{X}$  ماتریس پیچش<sup>۱</sup> متناظر با تصویر پر دقت  $\mathbf{x}$  است به طوری که  $\mathbf{X}\mathbf{h} = \mathbf{H}\mathbf{x}$ .

جزئیات الگوریتم ADMM برای حل (۲۳-۵) بدین قرار است:  $J = 3$

$$\mathbf{G}^{(1)} = \mathbf{X} \quad (24-5)$$

$$\mathbf{G}^{(2)} = \mathbf{D}_{\rho_2} \quad (25-5)$$

$$\mathbf{G}^{(3)} = \mathbf{D}_{\rho_3} \quad (26-5)$$

$$g^{(j)}(\mathbf{u}^{(j)}) = \lambda_j \|\mathbf{u}^{(j)}\|_q, \quad j = 2, 3 \quad (27-5)$$

جایگذاری روابط (۲۴-۵) تا (۲۷-۵) در الگوریتم ADMM منجر به روابط زیر می‌شود:

$$\mathbf{z}_{k+1} \leftarrow \mathbf{B} \left( \mu^{(1)} \mathbf{X}^T (\mathbf{u}_k^{(1)} + \mathbf{d}_k^{(1)}) + \mu^{(2)} \sum_{j=2}^3 \mu^{(j)} \mathbf{G}_j^T (\mathbf{u}_k^{(j)} + \mathbf{d}_k^{(j)}) \right) \quad (28-5)$$

که در آن

$$\mathbf{B} = \left( \mu^{(1)} \mathbf{X}^T \mathbf{X} + \mu^{(2)} \sum_{j=2}^3 \mathbf{G}_j^T \mathbf{G}_j \right)^{-1} \quad (29-5)$$

و

$$\mu_j = \begin{cases} \rho_1 & j = 1 \\ \rho_2 & j = 2, 3 \end{cases} \quad (30-5)$$

<sup>1</sup>Convolution Matrix





شکل ۵-۱: تعدادی از تصاویر استفاده شده در آزمایش اول

عبارت  $\text{prox}_{g^{(j)}}/\mu^{(j)}$  مشابه (۲۱-۵) است و عبارت  $\text{prox}_{g^{(j)}}/\mu^{(j)}$  به ازای  $j = 2, 3$  نیز مشابه (۲۲-۵) است. در رابطه‌ی (۲۸-۵)  $\mathbf{z}_{k+1}$  هسته‌ی تاری بازسازی شده در تکرار  $k + 1$  است. در هر تکرار بعد از تخمین هسته‌ی تاری مقادیر منفی آن صفر می‌گردد.

## ۵-۶ نتایج آزمایش‌ها

برای ارزیابی روش پیشنهادی، دو آزمایش انجام شد. در آزمایش اول روش پیشنهادی روی تصاویر کم دقت تولید شده از تعداد ده تصویر HR اعمال شد. اندازه بزرگترین و کوچکترین تصویر در این تصاویر به ترتیب  $198 \times 134$  و  $512 \times 512$  است. تعدادی از این تصاویر در شکل ۵-۱ نشان داده شده است.

تصاویر کم دقت طبق مدل مشاهده‌ی (۹-۱) با اعمال سه هسته‌ی تاری با اندازه‌های  $7 \times 7$ ،  $11 \times 11$  و  $15 \times 15$  ایجاد شد و ضریب کاهش دقت در ساخت تصاویر کم دقت ۲ انتخاب گردید ( $P = 2$ ). در آزمایش‌های انجام شده پارامترهای الگوریتم به طور تجربی به صورت زیر تنظیم شد:  $\lambda_1 = 1$ ،  $\lambda_2 = 0.16$ ،  $\lambda_h = 0.1$ ،  $q = 0.8$ ،  $\mu_1 = 1$ ،  $\mu_2 = \lambda_1/2$ ،  $\mu_3 = \lambda_2/2$ ،  $\rho_1 = 1$ ،  $\rho_2 = \lambda_h/2$ . همچنین

به‌روزرسانی  $\lambda$  (سطر ۶ از الگوریتم ۳-۵) به صورت زیر انجام می‌شود.

$$\lambda_j = \max(\alpha\lambda_j, \epsilon_j), j = 1, 2 \quad (31-5)$$

که در آن  $\alpha = 0.7$  و  $\epsilon_1 = \epsilon_2 = 10^{-6}$ . مقدار  $\lambda_h$  در همه‌ی تکرارها ثابت می‌باشد.

در پیاده‌سازی انجام شده از پارامترهای با جریمه‌ی متغیر<sup>۱</sup> [۱۰۰] برای تغییر تطبیقی همه‌ی  $\mu^{(j)}$ ها در هر دو اجرای الگوریتم ADMM استفاده شد. همانند [۱۰۱] برای تخمین تصویر (دستور ۴ از الگوریتم ۳-۵)، الگوریتم ADMM ۲۰ بار تکرار شد که مقداردهی اولیه متغیرهای این الگوریتم اینگونه بود:  $\mathbf{u}^{(j)} = \mathbf{u}^{(j)}\hat{\mathbf{x}}, \mathbf{d}^{(j)} = \mathbf{0}$  که در آن  $\hat{\mathbf{x}}$  تخمین تصویر در اجرای قبلی الگوریتم ۳-۵ است. همچنین تخمین هسته تاری (دستور ۵ از الگوریتم ۳-۵)، با ۱۰ بار تکرار الگوریتم ADMM انجام شد که مقداردهی اولیه متغیرها اینگونه بود:  $\mathbf{u}^{(j)} = \mathbf{u}^{(j)}\hat{\mathbf{h}}, \mathbf{d}^{(j)} = \mathbf{0}$  که در آن  $\hat{\mathbf{h}}$  تخمین هسته تاری در اجرای قبلی الگوریتم ۳-۵ است. در آزمایش‌های انجام شده پارامترهای تغییرات هندسی معلوم فرض شد.

در شکل‌های ۲-۵، ۳-۵ و ۴-۵ نتیجه اعمال روش پیشنهادی بر روی تصاویر تار شده به ترتیب با هسته‌ی تاری  $7 \times 7$ ،  $11 \times 11$  و  $15 \times 15$  برای چند نمونه تصویر نشان داده شده است. همچنین در این شکل‌ها یکی از تصاویر کم‌دقت، تصویر HR تار و خروجی روش ارائه شده در [۹۰] برای مقایسه نشان داده شده است. علاوه بر این در جدول ۱-۵ معیار SSIM مربوط به نتایج دو روش برای هر ده تصویر و به ازای همه هسته‌های تاری نشان داده شده است. مقایسه‌ی کیفی تصاویر در شکل‌های مذکور و معیارهای ارزیابی در جدول ۱-۵ نشان دهنده‌ی برتری الگوریتم پیشنهادی بر روش ارائه شده در [۹۰] است.

در آزمایش دوم روش پیشنهادی بر روی  $5^\circ$  تصویر طبیعی دیگر اعمال شد. جدول ۲-۵ نشان دهنده‌ی میانگین دو معیار SSIM و PSNR بر روی نتایج روش پیشنهادی و روش ارائه شده در [۹۰] است.

<sup>1</sup>Varying Penalty Parameters

جدول ۵-۱: معیار SSIM مربوط به نتایج روش پیشنهادی بر روی ۱۰ تصویر آزمون و مقایسه‌ی آن با [۹۰]

اندازه هسته						نام تصویر
۱۵×۱۵		۱۱×۱۱		۷×۷		
روش پیشنهادی [۹۰]		روش پیشنهادی [۹۰]		روش پیشنهادی [۹۰]		
۰٫۳۹۱۸	۰٫۴۱۷۹	۰٫۴۵۳۴	۰٫۵۵۸۵	۰٫۶۱۵۸	۰٫۷۰۹۳	Baboon
۰٫۶۵۰۵	۰٫۷۳۰۹	۰٫۷۱۱۰	۰٫۷۹۹۳	۰٫۸۰۲۳	۰٫۸۸۱۴	Boat
۰٫۷۲۰۲	۰٫۷۵۶۱	۰٫۷۶۳۰	۰٫۸۳۸۱	۰٫۸۱۹۰	۰٫۸۹۰۷	Cameraman
۰٫۸۰۰۴	۰٫۷۷۹۳	۰٫۸۱۱۴	۰٫۸۳۵۹	۰٫۸۴۸۱	۰٫۸۹۱۳	Girl
۰٫۷۵۴۷	۰٫۷۷۱۴	۰٫۸۱۱۴	۰٫۸۳۰۵	۰٫۸۲۷۲	۰٫۸۷۰۷	House
۰٫۶۴۹۳	۰٫۷۴۱۴	۰٫۷۱۵۳	۰٫۸۴۳۳	۰٫۸۱۷۸	۰٫۹۱۷۱	Man
۰٫۶۶۹۴	۰٫۷۷۱۹	۰٫۷۸۷۵	۰٫۸۷۲۵	۰٫۸۵۱۷	۰٫۹۲۲۹	Onion
۰٫۷۷۷۶	۰٫۸۳۶۸	۰٫۸۱۲۷	۰٫۸۸۷۷	۰٫۸۴۴۸	۰٫۹۲۷۲	Parrot
۰٫۷۹۱۲	۰٫۸۰۱۲	۰٫۸۰۹۴	۰٫۸۴۷۸	۰٫۸۳۵۱	۰٫۸۷۰۸	Pepper
۰٫۶۲۹۵	۰٫۷۱۰۴	۰٫۷۶۷۴	۰٫۷۹۰۸	۰٫۸۲۲۱	۰٫۹۲۴۸	Tire

معیارهای گزارش شده برای روش پیشنهادی مربوط به بهترین تصویر پر دقت بازسازی شده است.

با بزرگتر شدن هسته‌ی تاری، میزان تاری اعمال شده به تصویر ورودی بیشتر شده و تخریب بیشتری در آن ایجاد می‌شود. این موضوع باعث می‌شود بازیافت تصویر دشوارتر شود. بررسی تصاویر نشان داده شده در شکل‌های ۲-۵ تا ۴-۵ و همچنین مقدار معیارهای گزارش شده در جداول ۱-۵ و ۲-۵ این موضوع را تایید می‌کند.

یکی از نقاط ضعف روش پیشنهادی، شرط توقف الگوریتم ۳-۵ است. در آزمایش‌های انجام شده، این الگوریتم ۵۰ بار تکرار شده است و تصویر دارای بیشترین معیار SSIM به عنوان خروجی الگوریتم انتخاب شده است. در شکل ۵-۵ معیار SSIM یکی از تصاویر بازسازی شده در هر تکرار به همراه تصویر بازسازی شده در چند مرحله مختلف نشان داده شده است. عیب دیگر روش پیشنهادی این است که اندازه هسته‌ی تاری باید از قبل مشخص شود. در آزمایش‌های انجام شده اندازه‌ی هسته‌های تاری برابر با اندازه هسته‌ی اصلی به اضافه دو انتخاب شده است.



شکل ۵-۲: مقایسه نتایج روش پیشنهادی با [۹۰] بر روی داده‌های تار شده با هسته‌ی تار  $7 \times 7$ . ستون‌ها به ترتیب از راست به چپ عبارتند از نمونه‌ای از تصویر LR، تصویر HR تار، خروجی روش پیشنهادی، خروجی روش [۹۰]. تصاویر اصلی در شکل ۱-۵ نمایش داده شده است.



شکل ۳-۵: مقایسه نتایج روش پیشنهادی با [۹۰] بر روی داده‌های تار شده با هسته‌ی تاری  $11 \times 11$ . ستون‌ها به ترتیب از راست به چپ عبارتند از نمونه‌ای از تصویر LR، تصویر HR تار، خروجی روش پیشنهادی، خروجی روش [۹۰]. تصاویر اصلی در شکل ۱-۵ نمایش داده شده است.

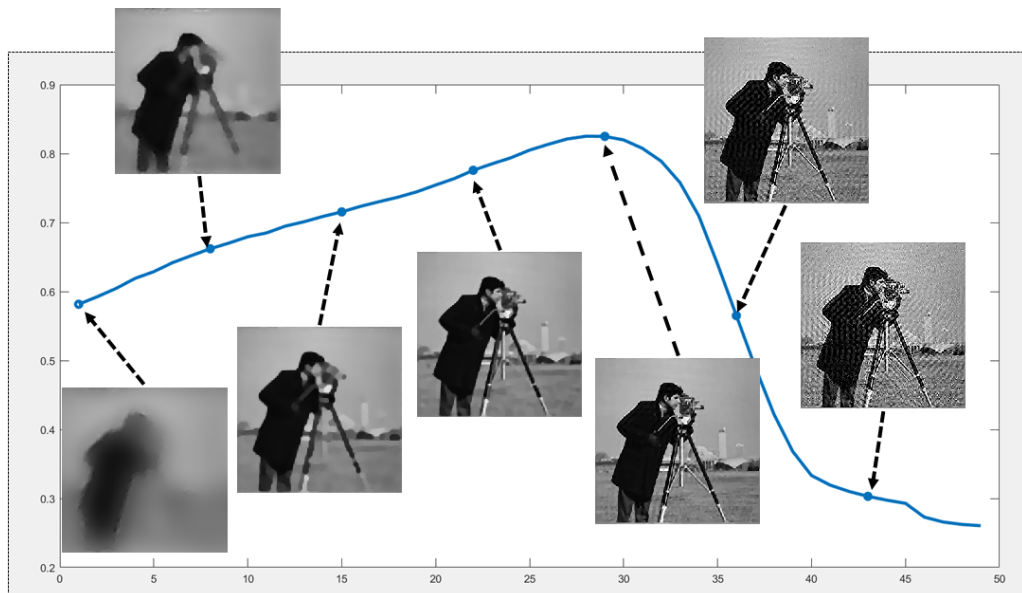


شکل ۴-۵: مقایسه نتایج روش پیشنهادی با  $[90^\circ]$  بر روی داده‌های تار شده با هسته‌ی تار  $15 \times 15$ . ستون‌ها به ترتیب از راست به چپ عبارتند از نمونه‌ای از تصویر LR، تصویر HR، خروجی روش پیشنهادی، خروجی روش  $[90^\circ]$ . تصاویر اصلی در شکل ۱-۵ نمایش داده شده است.

جدول ۵-۲: مقایسه‌ی نتایج الگوریتم پیشنهادی و روش [۹۰] بر روی ۶۰ تصویر آزمون

اندازه هسته			روش	معیار ارزیابی
۱۵×۱۵	۱۱×۱۱	۷×۷		
۰/۷۲۹۶	۰/۸۲۵۳	۰/۹۰۲۵	روش پیشنهادی	SSIM
۰/۶۶۹۰	۰/۷۳۸۳	۰/۸۱۶۵	[۹۰]	
۳۲/۹۷۳۸	۳۴/۵۳۲۸	۳۶/۶۱۶۴	روش پیشنهادی	PSNR
۳۱/۴۳۷۳	۳۲/۲۰۳۲	۳۲/۷۹۷۳	[۹۰]	

معیارهای گزارش شده برای روش پیشنهادی مربوط به بهترین تصویر پر دقت بازسازی شده است.



شکل ۵-۵: نمودار معیار SSIM تصویر بازسازی شده در تکرارهای مختلف الگوریتم ۳-۵

## ۷-۵ جمع‌بندی

در این فصل روشی برای ابرتفکیک‌پذیری تصاویر با تاری ناشی از عدم تمرکز عدسی پیشنهاد گردید. در این روش منظم‌ساز جدیدی برای اعمال بر هسته‌ی تاری پیشنهاد شد. ایده‌ی استفاده از این منظم‌ساز، پیوستگی و یکنواختی هسته تاری ناشی از عدم تمرکز عدسی است. نتایج آزمایش‌ها نشان می‌دهد منظم‌ساز پیشنهادی تاثیر قابل ملاحظه‌ای در کیفیت تصویر بازسازی شده دارد.





## فصل ۶

# جمع‌بندی و کارهای آینده

### ۱-۶ مقدمه

در این فصل، ضمن جمع‌بندی کارهای انجام شده، به پیشنهادهای برای انجام پژوهش‌های بعدی خواهیم پرداخت.

### ۲-۶ جمع‌بندی روش‌های پیشنهادی در رساله

هدف اصلی این رساله ابرتفکیک‌پذیری تصاویر تار است. در راستای این هدف دو رهیافت پیشنهاد شده است که در ادامه تشریح می‌گردد.

ایده رهیافت اول، تعیین تاری اعمال شده بر تصویر ایده‌آل صحنه از روی تاری تصاویر کم‌دقت است. از آنجا که حسگر تصویر دوربین عکاسی همانند عملگر غیر خطی کاهش تعداد نمونه عمل می‌کند، تاری تصاویر کم‌دقت با تاری تصویر ایده‌آل صحنه یکسان نیست. از این رو تعیین تاری تصویر ایده‌آل توسط شبکه عصبی و یادگیری عمیق انجام می‌شود. شبکه عصبی هسته‌ی تاری تصاویر کم

دقت را به عنوان ورودی دریافت کرده، هسته‌ی تاری تصویر ایده‌آل را تعیین می‌کند. سپس هسته تاری تعیین شده توسط شبکه عصبی، در الگوریتم SR مورد استفاده قرار می‌گیرد.

در این رساله ایده‌ی فوق به دو صورت پیاده‌سازی گردید. در روش اول از شبکه عصبی به عنوان دسته‌بند<sup>۱</sup> استفاده شده است. بدین منظور تعداد شش هسته تاری از سه نوع مختلف شامل تاری میانگین، تاری گوسی و تاری عدم تمرکز عدسی انتخاب شد. این شش هسته‌ی تاری، در واقع تشکیل دهنده‌ی شش دسته‌ی مسئله‌ی دسته‌بندی هستند. سپس برای تولید داده‌های آموزشی بیش از ۷۰۰ تصویر بدون تاری یا با تاری اندک به عنوان تصویر HR انتخاب گردید. در ادامه بر طبق مدل مشاهده با ضریب کاهش دقت برابر با دو و با استفاده از شش هسته تاری مذکور، تصاویر LR متناظر با هر تصویر HR به دست آمد. در مرحله‌ی بعد، هسته‌ی تاری تصاویر LR با استفاده از یکی از روش‌های تخمین هسته‌ی تاری برآورد گردید. برای آموزش شبکه عصبی، هر یک از این هسته‌ها به عنوان ورودی شبکه عصبی و دسته‌ی تاری اعمال شده بر تصویر LR به عنوان خروجی یا دسته‌ی هدف شبکه عصبی مورد استفاده قرار گرفت.

در مرحله‌ی آزمون شبکه عصبی، از ۶۰ تصویر دیگر به عنوان تصاویر HR استفاده گردید. این بار نیز طبق مدل مشاهده با ضریب کاهش دقت برابر با دو و با اعمال شش هسته‌ی تاری مذکور، از هر تصویر HR با اعمال تغییرات هندسی متفاوت ده تصویر LR تولید شد. سپس با استفاده از شبکه عصبی آموزش دیده، دسته‌ی تاری هر یک از ده تصویر LR به دست آمد. در انتها برای تعیین نهایی دسته‌ی تاری مرتبط با تصاویر LR، از رای‌گیری بین دسته‌های پیش‌بینی شده برای ده تصویر LR استفاده شد.

در ادامه، بعد از تعیین هسته‌ی تاری توسط شبکه‌ی عصبی، از این هسته برای بازسازی تصویر HR با اعمال الگوریتم SR بر روی تصاویر LR استفاده شد. مقایسه‌ی تصاویر HR بازسازی شده با تصاویر HR اصلی نشان دهنده‌ی آن است که استفاده از هسته‌ی تاری پیش‌بینی شده توسط شبکه عصبی در کل باعث افزایش کیفیت تصویر بازسازی شده می‌شود.

<sup>۱</sup>Classifier

در روش دوم از رهیافت اول از دو نوع شبکه عصبی استفاده می‌شود. در مرحله‌ی اول از شبکه عصبی پیچشی برای تعیین نوع هسته تاری (دیسک یا گوسی بودن) استفاده می‌شود و در مرحله‌ی دوم بسته به نوع هسته تاری ورودی از یکی از دو شبکه عصبی عمیق برای تولید هسته تاری اعمال شده بر تصویر ایده‌آل استفاده می‌گردد. این دو شبکه عصبی عمیق عمل رگرسیون را انجام می‌دهند بدین معنی که هسته‌ی تصویر LR را به عنوان ورودی دریافت کرده و هسته اعمال شده بر تصویر HR را تولید می‌کنند. در این روش چهار هسته‌ی تاری با میزان تاری متفاوت انتخاب شد که نیمی از آن‌ها از نوع گوسی و نیم دیگر از نوع عدم تمرکز عدسی بودند. برای تولید داده‌های آموزشی، در این آزمایش همانند آزمایش قبل از حدود ۷۰۰ تصویر طبیعی استفاده گردید. در مرحله‌ی بعد بر طبق مدل مشاهده با استفاده از تصاویر آموزشی و چهار هسته‌ی تاری مذکور تصاویر LR تولید شدند. ضریب کاهش دقت در این آزمایش نیز دو انتخاب شد. بعد از تولید تصاویر LR، هسته‌ی تاری هر یک از آن‌ها با اعمال الگوریتم تخمین تاری به دست آمد. سپس با استفاده از فاصله‌ی ماهالانویس هسته‌های پرت حذف گردید و از هسته‌های باقیمانده برای آموزش شبکه عصبی استفاده شد.

برای ارزیابی روش فوق، تعدادی تصویر HR انتخاب گردید و طبق مدل مشاهده تصاویر LR متناظر با آن‌ها به تعداد ۳۵ عدد ایجاد شد. سپس با استفاده از الگوریتم تخمین تاری، هسته‌ی تاری هر یک به دست آمد. این هسته‌ها به شبکه عصبی پیچشی داده شد تا نوع هسته‌ی آن‌ها تعیین گردد و سپس بسته به نوع هسته، به شبکه عصبی عمیق مربوطه داده شد تا هسته‌ی تاری اعمال شده بر تصویر ایده‌آل صحنه برآورد گردد. در ادامه هسته‌های تاری پرت در بین ۳۵ هسته‌ی برآورد شده حذف شد و میانگین هسته‌های تاری باقیمانده به عنوان تقریبی از هسته‌ی تاری اعمال شده بر تصویر HR به دست آید. از این هسته تاری در ابرتفکیک‌پذیری تصاویر LR برای بازسازی تصویر HR استفاده گردید. نتایج آزمایش‌ها نشان می‌دهد اگر هسته‌ی برآورد شده نزدیک به هسته‌ی اصلی باشد، تصویر بازسازی شده از کیفیت بالایی برخوردار خواهد بود. همچنین نتایج آزمایش‌ها بیانگر حساسیت کیفیت تصویر بازسازی شده به خطای تخمین هسته است. به عبارت دیگر وجود اختلاف قابل ملاحظه بین هسته‌ی

برآورد شده و هسته اصلی منجر به ایجاد اثرات تصنعی در تصویر بازسازی شده می‌گردد. در رهیافت دوم این رساله، روشی برای ابرتفکیک‌پذیری تصاویر تاری ناشی از عدم تمرکز عدسی با پارامتر تاری نامعلوم پیشنهاد شده است. ایده رهیافت دوم، فرمول‌بندی مسئله‌ی یافتن تصویر ایده‌آل صحنه و هسته‌ی تاری اعمال شده بر آن در قالب یک مسئله بهینه‌یابی است. از این رو بر طبق مدل مشاهده‌ی blur-warp، ابتدا تصویر پر دقت تاری به دست آمده و سپس تصویر مذکور با بهینه‌یابی تابع هزینه پیشنهاد شده تاری‌زدایی می‌گردد. از آنجا که تاری‌زدایی مسئله‌ای معکوس و بدمطرح است، برای حل آن نیاز به اعمال منظم‌سازی است. در این راستا همانند بسیاری از تحقیقات انجام شده، از توزیع فوق لاپلاس برای منظم‌سازی تصویر استفاده شد. همچنین برای تخمین هسته‌ی تاری، منظم‌ساز جدیدی پیشنهاد گردید. برای این منظور به این نکته توجه کردیم که ساختار هسته‌ی تاری عدم تمرکز، پیوسته و یکنواخت است. از این رو محدودیت‌هایی بر روی گرادیان هسته‌ی تاری اعمال گردید. نتایج آزمایش‌ها نشان می‌دهد استفاده از تابع هزینه و منظم‌ساز پیشنهاد شده منجر به افزایش کیفیت تصویر پر دقت نهایی می‌گردد.

برای حل مسئله بهینه‌یابی در رهیافت دوم از الگوریتم بهینه‌یابی ADMM که الگوریتمی تکراری است استفاده شد. از ویژگی‌های الگوریتم ADMM سادگی در پیاده‌سازی، کارایی بالا و توانایی در حل توابع هزینه با چندین جمله و قید است.

## ۳-۶ کارهای آینده

همانطور که در بخش قبل بیان شد، در رهیافت اول این رساله تاری اعمال شده بر تصویر ایده‌آل صحنه از روی تصاویر کم دقت به دست می‌آید و سپس در الگوریتم SR مورد استفاده قرار می‌گیرد. در ادامه موارد زیر برای تحقیقات آتی در این خصوص پیشنهاد می‌گردد:

- از آنجا که خطا در تخمین تاری تصاویر کم دقت به شدت در تعیین تاری اعمال شده بر تصویر ایده‌آل صحنه تاثیر منفی می‌گذارد، یافتن الگوریتمی بهتر در زمینه تخمین تاری می‌تواند

کارایی روش پیشنهادی را ارتقاء دهد.

- با توجه به پیشرفت چشم‌گیر یادگیری عمیق در سال‌های اخیر، پیشنهاد می‌شود تحقیقاتی در خصوص تخمین هسته‌ی تاری تصویر به طور مستقیم از روی تصویر تار توسط شبکه عصبی پیچشی عمیق انجام گیرد.

- همانطور که بیان شد، الگوریتم SR مورد استفاده در رهیافت دوم حساسیت نسبتاً زیادی به خطا در هسته تاری از خود نشان می‌دهد. به عبارت دیگر خطای کوچکی در مدل کردن فرآیند مسئله باعث خطای بزرگی در خروجی می‌شود. به عنوان تحقیقی دیگر می‌توان رابطه‌ای برای منظم‌سازی تصویر خروجی جستجو کرد که باعث کاهش این حساسیت شود.

در مورد رهیافت دوم موارد زیر به عنوان تحقیقات آتی پیشنهاد می‌گردد:

- همانطور که در فصل ۵ بیان شده است، در روش پیشنهاد شده، الگوریتم بهینه‌یابی به تعداد مشخص تکرار گردیده و بهترین جواب به دست آمده گزارش شده است. یافتن معیاری مناسب جهت توقف تکرار در این الگوریتم به عنوان یکی از موارد تحقیقات آتی پیشنهاد می‌شود.

- در روش پیشنهاد شده، اندازه هسته‌ی تاری باید از قبل تعیین شود. به عنوان تحقیقی دیگر، ارتقاء الگوریتم به طوری که الگوریتم خود اندازه هسته‌ها را تعیین کند پیشنهاد می‌گردد.

- یافتن منظم‌ساز مناسب برای انواع دیگر تاری می‌تواند به عنوان تحقیقی دیگر مطرح شود.

در انتها می‌توان پیشنهادهای دیگری برای ادغام دو رهیافت در قالب یک روش جامع ابرتفکیک‌پذیری داشت:

- پیشنهاد می‌شود ابتدا نوع هسته‌ی تاری توسط یادگیری عمیق تعیین شود و سپس متناسب با نوع تاری تعیین شده، در ابرتفکیک‌پذیری از منظم‌ساز مناسب با آن نوع تاری استفاده گردد.

- اخیراً از شبکه عصبی و یادگیری عمیق برای منظم‌سازی استفاده شده است. امکان انجام این روش در مسئله حاضر می‌تواند مورد تحقیق قرار گیرد.







# واژه‌نامه انگلیسی به فارسی

## default

$\ell_1$ Norm	نرم $\ell_1$
$\ell_2$ Norm	نرم $\ell_2$
$\ell_2$ -norm Regularization	منظم‌سازی نرم $\ell_2$

## A

Affine Transformation	تبدیل همگر
Aliasing	بدنمایی
Alignment	تراز
Alternating Direction Method of Multipliers	روش جهت یک‌درمیان ضرائب
Anisotropic Diffusion	نفوذ ناهمسان‌گرد
Anisotropic Total Variation	تغییرات کلی ناهمسان‌گرد
Aperture	قطر روزنه
Artifact	اثرات تصنعی
Atmospheric Turbulence Blur	تاری ناشی از اغتشاشات جوی

## B

Bandlimited	محدود باند
Bayesian Approach	رویکرد بیزی
Bilateral Total Variation	تغییرات کلی دو جهته
Bilinear Transformation	تبدیل دو خطی
Blind Deconvolution	وابیچش کور
Boundary Condition	شرایط مرزی

## C

Class	دسته
Classification	دسته‌بندی
Classifier	دسته‌بند
Closed Form Solution	جواب بسته
Confusion Matrix	ماتریس در هم ریختگی
Convex Constraint Sets	مجموعه‌های محدب قید
Convolutional Layer	لایه‌ی پیچشی
Convolutional Neural Network	شبکه عصبی پیچشی
Cross-entropy Loss	اتلاف آنتروپی متقاطع

## D

Data Consistency Term	عبارت سازگاری داده
Data Fidelity Term	عبارت صحت داده
Deep Neural Network	شبکه عصبی عمیق
Degradation	تخریب
Degradation Model	مدل تخریب

Depth of Field ..... عمق میدان  
Downsampling Operator ..... عملگر کاهش تعداد نمونه  
Dual Variable ..... متغیر دوگان

**E**

Exposure ..... پرتوگیری

**F**

Feature Matching ..... تطبیق ویژگی  
Flat ..... تخت  
Flatten Layer ..... لایه تخت‌کننده  
Forward Problem ..... مسئله‌ی مستقیم  
Fully Connected Layer ..... لایه‌ی کاملاً متصل

**G**

Generalized Multichannel Sampling Theorem ..... قضیه‌ی نمونه‌برداری چندکاناله تعمیم‌یافته  
Generalized Total Variation ..... تغییرات کلی تعمیم‌یافته  
Global Transformation ..... انتقال کلی

**H**

Half-Quadratic Minimization Method ..... روش کمینه‌یابی نیمه درجه دوم  
Heavy-tailed Distribution ..... توزیع با دنباله طولانی  
Hierarchical Block Matching ..... تطبیق بلاک سلسله‌مراتبی  
Huber Markov Random Field ..... میدان تصادفی مارکوفی هوبر  
Hyper Laplacian Distribution ..... توزیع فوق لاپلاس

**I**

Ill-conditioned Problem ..... مسئله‌ی بد وضعیت  
Ill-posed Problem ..... مسئله‌ی بدمطرح  
Image Patch ..... وصله‌ی تصویر  
Image Registration ..... ثبت تصویر  
Image Zooming ..... بزرگ‌نمایی تصویر  
Inverse Problem ..... مسئله‌ی معکوس  
Isotropic Total Variation ..... تغییرات کلی همسانگرد  
Iterative Adaptive Filtering ..... پالایش تطبیقی تکراری  
Iterative Back Projection ..... پس افکنش تکراری

**K**

Kalman Filter ..... فیلتر کالمن

**L**

Least Mean Square Adaptive Filter ..... فیلتر تطبیقی کمترین میانگین مربعات  
Linear Space Invariant ..... خطی نامتغیر با مکان  
Locally Connected Convolutional Layer ..... لایه‌ی پیچشی متصل شده‌ی محلی  
Lookup Table ..... جدول جست‌وجو

**M**

Mahalanobis Distance ..... فاصله‌ی ماهالانوبیس  
Masking Operator ..... عملگر نقاب

Maximum a Posteriori	بیشینه احتمال پسین
Maximum Likelihood	بیشینه درست‌نمایی
Mean Square Error	خطای میانگین مربعات
Motion Blur	تاری حرکتی
Moving Least Square	کمترین مربعات متحرک

## N

Nearest Neighbor Interpolation	درون‌یابی نزدیکترین همسایه
Nonuniform Interpolation	درون‌یابی غیر یکنواخت

## O

Observation Model	مدل مشاهده
Off-line	برون خط
One-hot Encoding	رمزگذاری یکی فعال
Outlier	پرت
Out-of-Focus Blur	تاری عدم تمرکز
Over-Complete Dictionary	دیکشنری فوق کامل
Overfitting	آموزش بیش از حد

## P

Phase Correlation	همبستگی زاویه
Photoelectric Cell	سلول فتوالکترونیک
Piecewise-smooth	هموار تکه‌ای
Point Spread Function	تابع نقطه گستر
Posterior Probability	توزیع احتمال پسین
Posterior Probability Distribution	توزیع احتمال پسین
Prior Knowledge	دانش پیشین
Projection onto Convex Sets	افکنش بر مجموعه‌های محدب
Proximity Operator	عملگر مجاورت

## Q

Quadratic Equation	معادله درجه دوم
--------------------	-----------------

## R

Real-time	بلادرنگ
Rectified Linear Unit (ReLU) Activation Function	تابع فعالیت خطی یکسو شده
Regression	رگرسیون
Regularization	منظم‌سازی
Remote Sensing	سنجش از راه دور
Residual Term	عبارت باقیمانده
Resolution	تفکیک‌پذیری
Resolution Enhancement	افزایش تفکیک‌پذیری
Ringling Artifact	اثرات تصنعی حلقوی

## S

Same Shape Convolution	کانولوشن هم اندازه
Sampling Method	روش نمونه‌برداری
Scatter Matrix	ماتریس پراکندگی
Second Generation Wavelet	موجک نسل دوم
Sensor	حسگر
Shifting Property	خاصیت انتقال

Signal to Noise Ratio	نسبت سیگنال به نویز
Simultaneous Autoregressive	خودهمبسته‌ی همزمان
Singular Value Decomposition Based Filtering	فیلتر مبتنی بر تجزیه مقادیر تکین
Sparse Linear Combination	ترکیب خطی خلوت
Staircasing Effect	اثر پلکانی
State Estimation Problem	مسئله تخمین حالت
Structural Similarity Index	معیار شباهت ساختاری
Subpixel Displacement	جابجایی زیرپیکسل
Superresolution	ابر تفکیک پذیری

## T

Total Variation	تغییرات کلی
Transitional Motion	حرکت انتقالی

## V

Valid Shape Convolution	کانولوشن با اندازه مجاز
Variational Bayesian Analysis	تحلیل بیزی تغییراتی
Varying Penalty Parameters	پارامترهای با جریمه متغیر
Video to Video SR	ابر تفکیک پذیری ویدیو

## W

Warping	تغییرات هندسی
Wavelet Thresholding	آستانه‌گذاری موجک
Wavelet Transform	تبدیل موجک
Well-posed Problem	مسئله‌ی خوش مطرح
Wide Lens	عدسی عریض

## Z

Zero Padding	الحاق صفر
--------------	-----------

# واژه‌نامه فارسی به انگلیسی

ا

Wavelet Thresholding	آستانه‌گذاری موجک
Overfitting	آموزش بیش از حد
Superresolution	ابر تفکیک پذیری
Video to Video SR	ابر تفکیک پذیری ویدیو
Cross-entropy Loss	اتلاف آنتروپی متقاطع
Staircasing Effect	اثر پلکانی
Artifact	اثرات تصنعی
Ringing Artifact	اثرات تصنعی حلقوی
Resolution Enhancement	افزایش تفکیک پذیری
Projection onto Convex Sets	افکنش بر مجموعه‌های محدب
Zero Padding	الحاق صفر
Global Transformation	انتقال کلی

ب

Aliasing	بدنمایی
Off-line	برون خط
Image Zooming	بزرگ‌نمایی تصویر
Real-time	بلادرنگ
Maximum a Posteriori	بیشینه احتمال پسین
Maximum Likelihood	بیشینه درست‌نمایی

پ

Varying Penalty Parameters	پارامترهای با جریمه متغیر
Iterative Adaptive Filtering	پالایش تطبیقی تکراری
Outlier	پرت
Exposure	پرتوگیری
Iterative Back Projection	پس افکنش تکراری

ت

Rectified Linear Unit (ReLU) Activation Function	تابع فعالیت خطی یکسو شده
Point Spread Function	تابع نقطه گستر
Motion Blur	تاری حرکتی
Out-of-Focus Blur	تاری عدم تمرکز
Atmospheric Turbulence Blur	تاری ناشی از اغتشاشات جوی
Bilinear Transformation	تبدیل دو خطی
Wavelet Transform	تبدیل موجک
Affine Transformation	تبدیل همگر
Variational Bayesian Analysis	تحلیل بیزی تغییراتی
Flat	تخت
Degradation	تخریب
Alignment	تراز

Sparse Linear Combination	ترکیب خطی خلوت
Hierarchical Block Matching	تطبیق بلاک سلسله‌مراتبی
Feature Matching	تطبیق ویژگی
Total Variation	تغییرات کلی
Generalized Total Variation	تغییرات کلی تعمیم‌یافته
Bilateral Total Variation	تغییرات کلی دو جهته
Anisotropic Total Variation	تغییرات کلی ناهمسانگرد
Isotropic Total Variation	تغییرات کلی همسانگرد
Warping	تغییرات هندسی
Resolution	تفکیک‌پذیری
Posterior Probability	توزیع احتمال پسین
Heavy-tailed Distribution	توزیع با دنباله طولانی
Hyper Laplacian Distribution	توزیع فوق لاپلاس

## ث

Image Registration	ثبت تصویر
--------------------	-----------

## ج

Subpixel Displacement	جابجایی زیرپیکسل
Lookup Table	جدول جست‌وجو
Closed Form Solution	جواب بسته

## ح

Transitional Motion	حرکت انتقالی
Sensor	حسگر

## خ

Shifting Property	خاصیت انتقال
Mean Square Error	خطای میانگین مربعات
Linear Space Invariant	خطی نامتغیر با مکان
Simultaneous Autoregressive	خودهمبسته‌ی همزمان

## د

Prior Knowledge	دانش پیشین
Nonuniform Interpolation	درون‌یابی غیر یکنواخت
Nearest Neighbor Interpolation	درون‌یابی نزدیکترین همسایه
Class	دسته
Classifier	دسته‌بند
Classification	دسته‌بندی
Over-Complete Dictionary	دیکشنری فوق کامل

## ر

Regression	رگرسیون
One-hot Encoding	رمزگذاری یکی فعال
Alternating Direction Method of Multipliers	روش جهت یک‌درمیان ضرائب
Half-Quadratic Minimization Method	روش کمینه‌یابی نیمه درجه دوم
Sampling Method	روش نمونه‌برداری
Bayesian Approach	رویکرد بیزی

## س

Photoelectric Cell ..... سلول فتوالکتریک  
Remote Sensing ..... سنجش از راه دور

## ش

Convolutional Neural Network ..... شبکه عصبی پیچشی  
Boundary Condition ..... شرایط مرزی  
Deep Neural Network ..... شبکه عصبی عمیق

## ع

Residual Term ..... عبارت باقیمانده  
Data Consistency Term ..... عبارت سازگاری داده  
Data Fidelity Term ..... عبارت صحت داده  
Wide Lens ..... عدسی عریض  
Depth of Field ..... عمق میدان  
Downsampling Operator ..... عملگر کاهش تعداد نمونه  
Proximity Operator ..... عملگر مجاورت  
Masking Operator ..... عملگر نقاب

## ف

Mahalanobis Distance ..... فاصله‌ی ماهالانوبیس  
Least Mean Square Adaptive Filter ..... فیلتر تطبیقی کمترین میانگین مربعات  
Kalman Filter ..... فیلتر کالمن  
Singular Value Decomposition Based Filtering ..... فیلتر مبتنی بر تجزیه مقادیر تکین

## ق

Generalized Multichannel Sampling Theorem ..... قضیه‌ی نمونه‌برداری چندکاناله تعمیم‌یافته  
Aperture ..... قطر روزنه

## ک

Valid Shape Convolution ..... کانولوشن با اندازه مجاز  
Same Shape Convolution ..... کانولوشن هم اندازه  
Moving Least Square ..... کمترین مربعات متحرک

## ل

Flatten Layer ..... لایه تخت‌کننده  
Convolutional Layer ..... لایه‌ی پیچشی  
Locally Connected Convolutional Layer ..... لایه‌ی پیچشی متصل شده‌ی محلی  
Fully Connected Layer ..... لایه‌ی کاملاً متصل

## م

Scatter Matrix ..... ماتریس پراکندگی  
Confusion Matrix ..... ماتریس در هم ریختگی  
Dual Variable ..... متغیر دوگان  
Convex Constraint Sets ..... مجموعه‌های محدب قید  
Bandlimited ..... محدود باند  
Degradation Model ..... مدل تخریب



Observation Model	مدل مشاهده
State Estimation Problem	مسئله تخمین حالت
Ill-conditioned Problem	مسئله‌ی بد وضعیت
Ill-posed Problem	مسئله‌ی بدمطرح
Well-posed Problem	مسئله‌ی خوش‌مطرح
Forward Problem	مسئله‌ی مستقیم
Inverse Problem	مسئله‌ی معکوس
Quadratic Equation	معادله درجه دوم
Structural Similarity Index	معیار شباهت ساختاری
Regularization	منظم‌سازی
$\ell_2$ -norm Regularization	منظم‌سازی نُرم $\ell_2$
Second Generation Wavelet	موجک نسل دوم
Huber Markov Random Field	میدان تصادفی مارکوفی هوبر

## ن

$\ell_1$ Norm	نُرم $\ell_1$
$\ell_2$ Norm	نُرم $\ell_2$
Signal to Noise Ratio	نسبت سیگنال به نویز
Anisotropic Diffusion	نفوذ ناهمسان‌گرد

## و

Blind Deconvolution	واپیچش کور
Image Patch	وصله‌ی تصویر

## ه

Phase Correlation	همبستگی زاویه
Piecewise-smooth	هموار تکه‌ای





## مراجع

- [1] Komatsu, T., Aizawa, K., Igarashi, T., and Saito, T. Signal-processing based method for acquiring very high resolution images with multiple cameras and its theoretical analysis. *IEE Proceedings I - Communications, Speech and Vision*, 140(1):19–24, Feb 1993.
- [2] Duponchel, Ludovic, Milanfar, Peyman, Ruckebusch, Cyril, and Huvenne, Jean-Pierre. Super-resolution and raman chemical imaging: From multiple low resolution images to a high resolution image. *Analytica Chimica Acta*, 607(2):168 – 175, 2008.
- [3] Fan, Jun, Wu, Yue, Zeng, Xiangrong, Huangpeng, Qizi, Liu, Yan, Long, Xin, and Zhou, Jinglun. A multi-view super-resolution method with joint-optimization of image fusion and blind deblurring. *TIIS*, 12(5):2366–2395, 2018.
- [4] Katsaggelos, Aggelos K., Molina, Rafael, and Mateos, Javier. Super resolution of images and video. *Synthesis Lectures on Image, Video, and Multimedia Processing*, 3(1):1–134, 2007.
- [۵] حسن پور، حمید و اسدی امیری، سکینه. مفاهیم جامع پردازش تصویر دیجیتال به همراه پیاده سازی الگوریتمها با متلب. انتشارات دانشگاه صنعتی شاهرود، ۱۳۹۵.
- [6] Gonzalez, R.C. and Woods, R.E. *Digital Image Processing*. Pearson/Prentice Hall, 3 ed. , 2008.
- [7] Hsieh Hou and Andrews, H. Cubic splines for image interpolation and digital filtering. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 26(6):508–517, December 1978.
- [8] Gotoh, T. and Okutomi, M. Direct super-resolution and registration using raw CFA images. in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR*, vol. 2, pp. II–II, June 2004.
- [9] Wang, Zhaozhong and Qi, Feihu. On ambiguities in super-resolution modeling. *IEEE signal processing letters*, 11(8):678–681, 2004.
- [10] Bishop, Tom E, Babacan, S Derin, Amizic, Bruno, Katsaggelos, Aggelos K, Chan, Tony, and Molina, Rafael. Blind image deconvolution: problem formulation and existing approaches. in Campisi, Patrizio and Egiazarian, Karen, eds. , *Blind Image Deconvolution, Theory and Applications*, pp. 1–41. CRC press, 2007.
- [11] Fox, Colin, Nicholls, Geoff K, and Tan, Sze M. An introduction to inverse problems. tech. rep., Electronics Research Group, Otago University, New Zealand, 2010.
- [12] Bertero, M., Poggio, T. A., and Torre, V. Ill-posed problems in early vision. *Proceedings of the IEEE*, 76(8):869–889, Aug 1988.
- [13] Vogel, C.R. *Computational Methods for Inverse Problems*. Frontiers in Applied Mathematics. Society for Industrial and Applied Mathematics, 2002.
- [14] Lindley, D.V. *Bayesian Statistics, A Review*. CBMS-NSF Regional Conference Series in Applied Mathematics. Society for Industrial and Applied Mathematics, 1972.
- [15] Giovannelli, J.F. and Idier, J., eds. . *Regularization and Bayesian Methods for Inverse Problems in Signal and Image Processing*. Digital signal and image processing series. Wiley, 2015.
- [۱۶] سیدیزدی، سید جلال و حسن پور، حمید. ابر تفکیک پذیری: مروری بر روشها. نشریه علمی ترویجی محاسبات نرم، ۲(۲):۵۱، ۳۶:۱۳۹۲.

[17] Seyyed Yazdi, S J and Hassanpour, H. Improving superresolution techniques via employing blurriness information of the image. *International Journal of Engineering, Transaction B: Application*, 31(2):241–249, 2018.

[۱۸] سید یزدی، سید جلال، حسن پور، حمید، و احمدی فرد، علیرضا. روشی برای تخمین هسته تاری جهت بهبود کارایی الگوریتم‌های ابرتفکیک‌پذیری. در اولین کنفرانس علوم و تکنولوژی های نوین، بابل، ۱۳۹۷.

[19] Seyyed Yazdi, S J and Hassanpour, H. Superresolution of defocus blurred images. *International Journal of Engineering, Transaction A: Basics*, 33(4):539–545, 2020.

[20] Park, Sung Cheol, Park, Min Kyu, and Kang, Moon Gi. Super-resolution image reconstruction: a technical overview. *IEEE signal processing magazine*, 20(3):21–36, 2003.

[21] Gerchberg, R.W. Super-resolution through error energy reduction. *Optica Acta: International Journal of Optics*, 21(9):709–720, 1974.

[22] Santis, P. De and Gori, F. On an iterative method for super-resolution. *Optica Acta: International Journal of Optics*, 22(8):691–695, 1975.

[23] Milanfar, P. *Super-Resolution Imaging*. Digital Imaging and Computer Vision. Taylor & Francis, 2010.

[24] Tian, Jing and Ma, Kai-Kuang. A survey on super-resolution imaging. *Signal, Image and Video Processing*, 5(3):329–342, 2011.

[25] Nasrollahi, Kamal and Moeslund, Thomas B. Super-resolution: a comprehensive survey. *Machine vision and applications*, 25(6):1423–1468, 2014.

[26] Rhee, Seunghyeon and Kang, Moon Gi. Discrete cosine transform based regularized high-resolution image reconstruction algorithm. *Optical Engineering*, 38(8):1348–1356, 8 1999.

[27] Ji, H. and Fermüller, C. Robust wavelet-based super-resolution reconstruction: Theory and algorithm. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(4):649–660, April 2009.

[28] Bose, N.K., Lertrattanapanich, S., and Chappalli, M.B. Superresolution with second generation wavelets. *Signal Processing: Image Communication*, 19(5):387 – 391, 2004.

[29] Robinson, M. D., Toth, C. A., Lo, J. Y., and Farsiu, S. Efficient fourier-wavelet super-resolution. *IEEE Transactions on Image Processing*, 19(10):2669–2681, Oct 2010.

[30] Irani, M. and Peleg, S. Super resolution from image sequences. in *Proceedings. 10th International Conference on Pattern Recognition*, vol. ii, pp. 115–120 vol.2, June 1990.

[31] Irani, Michal and Peleg, Shmuel. Motion analysis for image enhancement: Resolution, occlusion, and transparency. *Journal of Visual Communication and Image Representation*, 4(4):324 – 335, 1993.

[32] Irani, Michal and Peleg, Shmuel. Improving resolution by image registration. *CVGIP: Graphical Models and Image Processing*, 53(3):231 – 239, 1991.

[33] Farsiu, Sina, Robinson, Dirk, Elad, Michael, and Milanfar, Peyman. Robust shift and add approach to superresolution. in Tescher, Andrew G., ed., *Applications of Digital Image Processing XXVI*, vol. 5203, pp. 121 – 130. International Society for Optics and Photonics, SPIE, 2003.

[34] Farsiu, Sina, Robinson, Dirk, Elad, Michael, and Milanfar, Peyman. Advances and challenges in super-resolution. *International Journal of Imaging Systems and Technology*, 14(2):47–57, 2004.

[35] Elad, M. and Feuer, A. Superresolution restoration of an image sequence: adaptive filtering approach. *IEEE Transactions on Image Processing*, 8(3):387–395, March 1999.

[36] Welch, Greg and Bishop, Gary. An introduction to the kalman filter. Tech. Rep. TR95-041, University of North Carolina, Chapel Hill, NC, 2006.

[37] Brown, Robert Grover and Hwang, Patrick YC. *Introduction to random signals and applied Kalman filtering*. Wiley New York, 4 ed., 2012.

[38] Mandic, D. P., Kanna, S., and Constantinides, A. G. On the intrinsic relationship between the least mean square and kalman filters [lecture notes]. *IEEE Signal Processing Magazine*, 32(6):117–122, Nov 2015.

- [39] Tian, Jing and Ma, Kai-Kuang. A state-space super-resolution approach for video reconstruction. *Signal, image and video processing*, 3(3):217–240, 2009.
- [40] Nasonov, A. V. and Krylov, A. S. Fast super-resolution using weighted median filtering. in *20th International Conference on Pattern Recognition*, pp. 2230–2233, Aug 2010.
- [41] Nasir, H., Stankovic, V., and Marshall, S. Singular value decomposition based fusion for super-resolution image reconstruction. in *IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*, pp. 393–398, Nov 2011.
- [42] Ur, Hanoach and Gross, Daniel. Improved resolution from subpixel shifted pictures. *CVGIP: Graphical Models and Image Processing*, 54(2):181 – 186, 1992.
- [43] Brown, J. Multi-channel sampling of low-pass signals. *IEEE Transactions on Circuits and Systems*, 28(2):101–106, February 1981.
- [44] Bose, N. K. and Ahuja, N. A. Superresolution and noise filtering using moving least squares. *IEEE Transactions on Image Processing*, 15(8):2239–2248, Aug 2006.
- [45] Stark, Henry and Oskoui, Peyma. High-resolution image recovery from image-plane arrays, using convex projections. *J. Opt. Soc. Am. A*, 6(11):1715–1726, Nov 1989.
- [46] Tekalp, A. M., Ozkan, M. K., and Sezan, M. I. High-resolution image reconstruction from lower-resolution image sequences and space-varying image restoration. in *[Proceedings] ICASSP-92: IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 3, pp. 169–172, March 1992.
- [47] Bertero, M. and Boccacci, P. *Introduction to Inverse Problems in Imaging*. CRC Press, 1998.
- [48] Schultz, R. R. and Stevenson, R. L. Extraction of high-resolution frames from video sequences. *IEEE Transactions on Image Processing*, 5(6):996–1011, June 1996.
- [49] Rezayi, H. and Seyedin, S. A. Huber markov random field for joint super resolution. in *10th Iranian Conference on Machine Vision and Image Processing (MVIP)*, pp. 93–98, Nov 2017.
- [50] Rudin, Leonid I., Osher, Stanley, and Fatemi, Emad. Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, 60(1):259 – 268, 1992.
- [51] Chambolle, Antonin, Caselles, Vicent, Cremers, Daniel, Novaga, Matteo, and Pock, Thomas. An introduction to total variation for image analysis. *Theoretical foundations and numerical methods for sparse recovery*, 9(263-340):227, 2010.
- [52] Babacan, S. D., Molina, R., and Katsaggelos, A. K. Variational bayesian super resolution. *IEEE Transactions on Image Processing*, 20(4):984–999, April 2011.
- [53] Villena, S., Vega, M., Babacan, S.D., Molina, R., and Katsaggelos, A.K. Bayesian combination of sparse and non-sparse priors in image super resolution. *Digital Signal Processing*, 23(2):530 – 541, 2013.
- [54] Huangpeng, Qizi, Zeng, Xiangrong, Sun, Quan, Fan, Jun, Feng, Jing, and Pan, Zhengqiang. Super-resolving blurry multiframe images through multiframe blind deblurring using admm. *Multimedia Tools and Applications*, 76(11):13563–13579, 2017.
- [55] Chan, T., Esedoglu, S., Park, F., and Yip, A. Total variation image restoration: Overview and recent developments. in Paragios, N., Chen, Y., and Faugeras, O., eds. , *Handbook of Mathematical Models in Computer Vision*, chap. 2, pp. 17–31. Springer, Boston, MA, 2006.
- [56] Farsiu, S., Robinson, M. D., Elad, M., and Milanfar, P. Fast and robust multiframe super resolution. *IEEE Transactions on Image Processing*, 13(10):1327–1344, Oct 2004.
- [57] Laghrib, Amine, Ezzaki, Mahmoud, Rhabi, Mohammed El, Hakim, Abdelilah, Monasse, Pascal, and Raghay, Said. Simultaneous deconvolution and denoising using a second order variational approach applied to image super resolution. *Computer Vision and Image Understanding*, 168:50 – 63, 2018. Special Issue on Vision and Computational Photography and Graphics.
- [58] Li, Xuelong, Hu, Yanting, Gao, Xinbo, Tao, Dacheng, and Ning, Beijia. A multi-frame image super-resolution method. *Signal Processing*, 90(2):405 – 414, 2010.
- [59] Bishop, C.M. *Pattern Recognition and Machine Learning*. Information Science and Statistics. Springer-Verlag New York, 2006.

- [60] Zhang, Hongyan, Zhang, Liangpei, and Shen, Huanfeng. A super-resolution reconstruction algorithm for hyperspectral images. *Signal Processing*, 92(9):2082 – 2096, 2012.
- [61] Chen, Chuanbo, Liang, Hu, Zhao, Shengrong, Lyu, Zehua, Fang, Shaohong, and Pei, Xiaobing. Integrating the missing information estimation into multi-frame super-resolution. *Circuits, Systems, and Signal Processing*, 35(4):1213–1238, Apr 2016.
- [62] Hardie, Russell C., Barnard, Kenneth J., Bognar, John G., Armstrong, Ernest E., and Watson, Edward A. High-resolution image reconstruction from a sequence of rotated and translated frames and its application to an infrared imaging system. *Optical Engineering*, 37(1):247 – 260, 1998.
- [63] Kim, Hyunwoo, Jang, Jeong-Hun, and Hong, Ki-Sang. Edge-enhancing super-resolution using anisotropic diffusion. in *Proceedings 2001 International Conference on Image Processing (Cat. No.01CH37205)*, vol. 3, pp. 130–133, Oct 2001.
- [64] Rajan, Deepu and Chaudhuri, Subhasis. An MRF-based approach to generation of super-resolution images from blurred observations. *Journal of Mathematical Imaging and Vision*, 16(1):5–15, Jan 2002.
- [65] Capel, D. and Zisserman, A. Super-resolution from multiple views using learnt image models. in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR*, vol. 2, pp. II–II, Dec 2001.
- [66] Willett, Rebecca, Jermyn, IH, Nowak, Robert, and Zerubia, Josiane. Wavelet-based superresolution in astronomy. in *Astronomical data analysis software and systems XIII. California: Astronomical Society of the Pacific*, pp. 107–116. Astronomical Society of the Pacific, 2003.
- [67] Olshausen, Bruno A and Field, David J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images. *Nature*, 381(6583):607–609, 1996.
- [68] Levin, Anat, Fergus, Rob, Durand, Frédo, and Freeman, William T. Image and depth from a conventional camera with a coded aperture. *ACM Trans. Graph.*, 26(3):70–es, July 2007.
- [69] Krishnan, Dilip and Fergus, Rob. Fast image deconvolution using hyper-Laplacian priors. in Bengio, Y., Schuurmans, D., Lafferty, J. D., Williams, C. K. I., and Culotta, A., eds. , *Advances in Neural Information Processing Systems 22*, pp. 1033–1041. Curran Associates, Inc., 2009.
- [70] Hertzmann, Aaron, Jacobs, Charles E., Oliver, Nuria, Curless, Brian, and Salesin, David H. Image analogies. in *Proceedings of the 28th Annual Conference on Computer Graphics and Interactive Techniques, SIGGRAPH '01*, p. 327–340, New York, NY, USA, 2001. Association for Computing Machinery.
- [71] Wang, Jinjun, Zhu, Shenghuo, and Gong, Yihong. Resolution enhancement based on learning the sparse association of image patches. *Pattern Recognition Letters*, 31(1):1 – 10, 2010.
- [72] Kim, K. I. and Kwon, Y. Single-image super-resolution using sparse regression and natural image prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(6):1127–1133, June 2010.
- [73] Yang, J., Wright, J., Huang, T. S., and Ma, Y. Image super-resolution via sparse representation. *IEEE Transactions on Image Processing*, 19(11):2861–2873, Nov 2010.
- [74] Tang, Yi, Yuan, Yuan, Yan, Pingkun, and Li, Xuelong. Greedy regression in sparse coding space for single-image super-resolution. *J. Vis. Comun. Image Represent.*, 24(2):148–159, February 2013.
- [75] Gunturk, B. K. and Gevrekci, M. High-resolution image reconstruction from multiple differently exposed images. *IEEE Signal Processing Letters*, 13(4):197–200, April 2006.
- [76] Begin, I. and Ferrie, F. P. Psf recovery from examples for blind super-resolution. in *IEEE International Conference on Image Processing*, vol. 5, pp. V – 421–V – 424, Sep. 2007.
- [77] Park, Haesol and Lee, Kyoung Mu. Joint estimation of camera pose, depth, deblurring, and super-resolution from a blurred image sequence. *CoRR*, abs/1709.05745, 2017.
- [78] Zhang, Xinyi, Dong, Hang, Hu, Zhe, Lai, Wei-Sheng, Wang, Fei, and Yang, Ming-Hsuan. Gated fusion network for joint image deblurring and super-resolution. *CoRR*, abs/1807.10806, 2018.
- [79] Zhang, Kai, Zuo, Wangmeng, and Zhang, Lei. Deep plug-and-play super-resolution for arbitrary blur kernels. *CoRR*, abs/1903.12529, 2019.

- [80] Wang, Yifan, Wang, Lijun, Wang, Hongyu, Li, Peihua, and Lu, Huchuan. Blind single image super-resolution with a mixture of deep networks. *Pattern Recognition*, 102:107169, 2020.
- [81] Borman, Sean, Robertson, Mark A., and Stevenson, Robert L. Block-matching subpixel motion estimation from noisy undersampled frames: an empirical performance evaluation. in Aizawa, Kiyoharu, Stevenson, Robert L., and Zhang, Ya-Qin, eds., *Visual Communications and Image Processing '99*, vol. 3653, pp. 1442 – 1451. International Society for Optics and Photonics, SPIE, 1998.
- [82] Tekalp, A.M. *Digital Video Processing*. Prentice-Hall signal processing series. Prentice Hall, 2 ed., 2015.
- [83] Keren, D., Peleg, S., and Brada, R. Image sequence enhancement using sub-pixel displacements. in *Proceedings CVPR '88: The Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 742–746, June 1988.
- [84] Cheeseman, Peter, Kanefsky, Bob, Kraft, Richard, Stutz, John, and Hanson, Robin. Super-resolved surface reconstruction from multiple images. in Heidbreder, Glenn R., ed., *Maximum Entropy and Bayesian Methods: Santa Barbara, California, U.S.A., 1993*, pp. 293–308. Springer Netherlands, Dordrecht, 1996.
- [85] Baker, Simon and Matthews, Iain. Lucas-kanade 20 years on: A unifying framework. *International journal of computer vision*, 56(3):221–255, 2004.
- [86] Capel, David. Image mosaicing. in *Image Mosaicing and super-resolution*, pp. 47–79. Springer, 2004.
- [87] Capel, D. and Zisserman, A. Computer vision applied to super resolution. *IEEE Signal Processing Magazine*, 20(3):75–86, May 2003.
- [88] Amintoosi, M, Fathy, M, and Mozayani, N. A fast image registration approach based on SIFT keypoints applied to super-resolution. *The Imaging Science Journal*, 60(4):185–201, 2012.
- [89] Lim, Douglas. Achieving accurate image registration as the basis for super-resolution. Master’s thesis, The School of Computer Science and Software Engineering, The University of Western Australia, 2003.
- [90] Javaran, Taiebeh Askari, Hassanpour, Hamid, and Abolghasemi, Vahid. Local motion deblurring using an effective image prior based on both the first-and second-order gradients. *Machine Vision and Applications*, 28(3-4):431–444, 2017.
- [91] Dahl, G. E., Sainath, T. N., and Hinton, G. E. Improving deep neural networks for LVCSR using rectified linear units and dropout. in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 8609–8613, May 2013.
- [92] Russakovsky, Olga, Deng, Jia, Su, Hao, Krause, Jonathan, Satheesh, Sanjeev, Ma, Sean, Huang, Zhiheng, Karpathy, Andrej, Khosla, Aditya, Bernstein, Michael, and Fei-Fei, Li. Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3):211–252, 2015.
- [93] Zhou Wang, Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4):600–612, April 2004.
- [94] Szegedy, Christian, Ioffe, Sergey, Vanhoucke, Vincent, and Alemi, Alexander A. Inception-v4, inception-resnet and the impact of residual connections on learning. in *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, AAAI'17*, p. 4278–4284. AAAI Press, 2017.
- [95] Srivastava, Nitish, Hinton, Geoffrey, Krizhevsky, Alex, Sutskever, Ilya, and Salakhutdinov, Ruslan. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1):1929–1958, 2014.
- [96] Taigman, Y., Yang, M., Ranzato, M., and Wolf, L. Deepface: Closing the gap to human-level performance in face verification. in *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1701–1708, June 2014.
- [97] Kline, Douglas M and Berardi, Victor L. Revisiting squared-error and cross-entropy functions for training neural network classifiers. *Neural Computing & Applications*, 14(4):310–318, 2005.
- [98] Kingma, Diederik P and Ba, Jimmy. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [99] Mahalanobis, Prasanta Chandra. On the generalized distance in statistics. *Proceedings of the National Institute of Sciences (Calcutta)*, 2:49–55, 1936.



- [100] Boyd, Stephen, Parikh, Neal, Chu, Eric, Peleato, Borja, and Eckstein, Jonathan. Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations and Trends® in Machine Learning*, 3(1):1–122, 2011.
- [101] Almeida, M. S. C. and Figueiredo, M. Deconvolving images with unknown boundaries using the alternating direction method of multipliers. *IEEE Transactions on Image Processing*, 22(8):3074–3086, Aug 2013.
- [102] Bertalmio, Marcelo, Sapiro, Guillermo, Caselles, Vincent, and Ballester, Coloma. Image inpainting. in *Proceedings of the 27th Annual Conference on Computer Graphics and Interactive Techniques, SIGGRAPH '00*, p. 417–424, USA, 2000. ACM Press/Addison-Wesley Publishing Co.
- [103] Boyd, Stephen and Vandenberghe, Lieven. *Convex Optimization*. Cambridge University Press, 2004.
- [104] Chambolle, Antonin and Pock, Thomas. A first-order primal-dual algorithm for convex problems with applications to imaging. *Journal of Mathematical Imaging and Vision*, 40(1):120–145, May 2011.
- [105] Geman, D. and Chengda Yang. Nonlinear image recovery with half-quadratic regularization. *IEEE Transactions on Image Processing*, 4(7):932–946, July 1995.
- [106] Almeida, M. S. C. and Figueiredo, M. A. T. Blind image deblurring with unknown boundaries using the alternating direction method of multipliers. in *2013 IEEE International Conference on Image Processing*, pp. 586–590, Sep. 2013.
- [107] Combettes, Patrick L. and Wajs, Valérie R. Signal recovery by proximal forward-backward splitting. *Multiscale Modeling & Simulation*, 4(4):1168–1200, 2005.

## **Abstract**

Superresolution is a technique that combines information of some low resolution images of a scene to make an image with higher resolution. In most of the previous related works, the blurriness that is applied to low resolution images is assumed to be due to the integral effect of the image sensor of the digital camera. But in practice, there are other sources of blurriness as well, such as, defocus, atmospheric and motion blur that may be applied to low resolution images. In this dissertation, we assume that the integral effect of the sensor is not the only factor of blurriness of the low resolution images and propose the following two approaches to consider the low resolution image blurriness.

In the first approach, we use a neural network to determine the desired blur kernel. To this end, first, the blur kernel of the low resolution images are estimated. These blur kernels are fed to the neural network to determine the desired blur kernel that is applied to the high resolution image in the acquisition process. Based on this idea, we propose two distinct methods. In the first method, the neural network is used as a classifier that predicts the desired blur kernel. In the second method, the neural network is used in a regression framework that produces the desired blur kernel. The experimental results show using the determined blur kernel increases the quality of the reconstructed high resolution image.

In the second approach, we propose a method for superresolution of defocus blurred images with unknown blurriness. In this method, the high resolution blurred image is estimated and then deblurred. Since the blurriness is unknown, the deblurring process is a blind image deconvolution. Deblurring is an inverse and ill-posed problem and solving such problems needs regularization. Hence, a proper regularizer and cost function is proposed. The experimental results show using the proposed cost function increases the quality of the reconstructed high resolution image.

**Keywords:** Superresolution, Inverse Problem, Regularization, Blur Kernel, Deep Learning, Blind Image Deconvolution.



**Faculty of Computer Engineering**

**PhD Thesis in Artificial Intelligence Engineering**

# **Employing Blurring Information of Images for Generating High Resolution Images**

**By: Seyyed Jalal Seyyed Yazdi**

**Supervisor:**

**Prof. Hamid Hassanpour**

**Advisor:**

**Dr. Alireza Ahmadifard**

**February 2020**