

تاریخ دریافت: ۹۲/۱۰/۲۴

تاریخ پذیرش: ۹۳/۴/۶

ابر تفکیک پذیری: مروری بر روش‌های موجود

سید جلال سیدیزدی^{۱*}، حمید حسن پور^۲

^۱ دانشجوی دکتری مهندسی کامپیوتر، دانشکده مهندسی کامپیوتر، دانشگاه شاهروд، شاهرود، ایران

seyyedyazdi@shahroodut.ac.ir

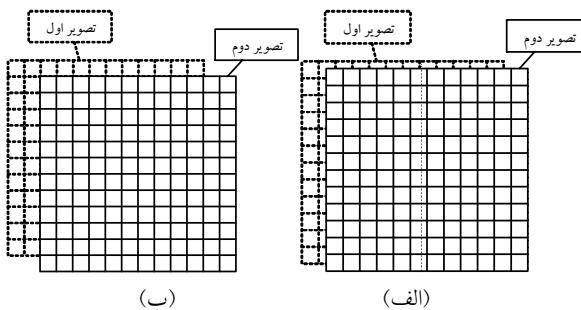
^۲ استاد دانشکده مهندسی کامپیوتر، دانشگاه شاهرود، شاهرود، ایران

h.hassanpour@shahroodut.ac.ir

چکیده: استفاده روزافزون از تصاویر دیجیتال در کاربردهای مختلف بر کسی پوشیده نیست. تقریباً در همگی کاربردها تصاویر با تفکیک پذیری زیاد، کارایی و کیفیت بالاتری دارند. یک راه برای دستیابی به تصاویری با تفکیک پذیری زیاد، افزایش سخت افزاری سخت افزار سیستم تصویربرداری است که منجر به افزایش هزینه می‌شود. همچنین محدودیت‌های فیزیکی سیستم سخت افزاری افزایش تفکیک پذیری تصویر را محدود می‌کند. در مقابل، ابر تفکیک پذیری روشی نرم افزاری است که هدف آن ایجاد تصاویری با درجه تفکیک پذیری زیاد با استفاده از تصاویر کم‌دقیق از صحنه می‌باشد. از آنجاکه مسئله ابر تفکیک پذیری یک مسئله معکوس است، روش‌های منظم سازی که هدف آن‌ها وارد کردن اطلاعات پیشین از تصاویر در الگوریتم ابر تفکیک پذیری است، از جایگاه ویژه‌ای برخوردار هستند. در روش منظم سازی تصادفی، همه متغیرها و پارامترهای مسئله به صورت متغیری تصادفی در نظر گرفته شده و اطلاعات پیشین در مورد آن‌ها به صورت توابع توزیع احتمال لحاظ می‌گردد. همچنین در روش‌های مبتنی بر یادگیری اطلاعات پیشین به طرق دیگر، از جمله استفاده از دیکشنری برای اجرای تصویر به الگوریتم اعمال می‌شود. در این مقاله، بعد از تعریف مسئله ابر تفکیک پذیری، به بررسی چالش‌های آن و کارهای انجام شده با تأکید بر روش منظم سازی تصادفی می‌پردازیم.

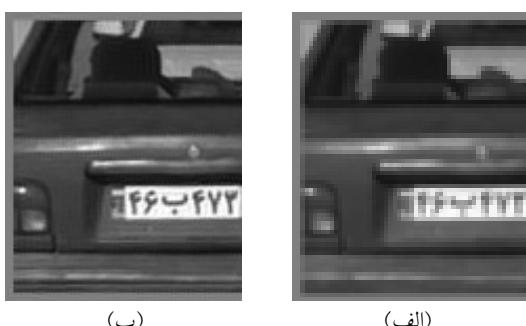
واژه‌های کلیدی: ابر تفکیک پذیری، مسائل معکوس بدمطرح، منظم سازی، ثبت تصویر، چهارچوب بیز.

هم‌پوشانی شده) اطلاعات یکسانی خواهد داشت و درنتیجه، با استفاده از تصاویری که به این‌گونه به‌دست می‌آید، نمی‌توان تصویر HR را بازسازی کرد. در مقابل، اگر مانند شکل (ب) جابجایی دو تصویر ضربی نادرست از اندازه پیکسل باشد یا به‌عبارت دیگر، جابجایی مؤلفه زیرپیکسل^۵ داشته باشد، هر یک از این تصاویر، اطلاعاتی متفاوت از صحنه در خود دارند که می‌توان از آن‌ها جهت بازسازی تصویر HR استفاده کرد. هدف SR این است که با ترکیب‌کردن این اطلاعات مکمل، تصویری با جزئیات زیاد ایجاد شود.



شکل (۱): الف) جابجایی دو تصویر نسبت به هم ضربی از اندازه پیکسل است؛ در این حالت، اطلاعات جدیدی به‌دست نمی‌آید. ب) جابجایی دو تصویر به‌گونه‌ای است که اطلاعات جدیدی حاصل می‌شود.

مثالی از ابرتفکیک‌پذیری در شکل (۲) نشان داده شده است. شکل (الف) یکی از چهار تصویر LR و شکل (ب) خروجی الگوریتم ابرتفکیک‌پذیری است. تفاوت تفکیک‌پذیری در این دو تصویر، کاملاً مشخص است؛ برای مثال، قسمت‌هایی از پلاک ماشین در تصویر (الف) تشخیص داده نمی‌شود؛ اما در تصویر (ب) پلاک ماشین کاملاً خواناست.



شکل (۲): مثالی از ابرتفکیک‌پذیری؛ الف) تصویر LR. ب) تصویر LR ایجاد شده توسط ابرتفکیک‌پذیری با استفاده از چهار تصویر LR

۱. مقدمه

کیفیت تصاویر تولید شده توسط سیستم‌های تصویربرداری رقمی هر قدر هم که مطلوب باشد، به‌دلیل ایدئال‌بودن ساخت افزار سیستم تصویربرداری، تصویر ایجاد شده نسبت به صحنه واقعی، همواره حاوی اطلاعات کمتری است. دلیل این امر وجود محدودیت‌هایی از قبیل محدودیت دقیق در حسگر تصویربرداری، نرخ انتقال اطلاعات محدود و وجود نویز در فرایند تصویربرداری است [۱]. برخی از این محدودیت‌ها ذاتی است و برخی دیگر برای معادل نگهداشتن قیمت محصول لحاظ می‌شود. با وجود این، در بسیاری از کاربردهای تصاویر رقمی از جمله نظامی، پزشکی، صنعتی و نظارت، تصاویری با تفکیک‌پذیری^۱ زیاد لازم است. برای غلبه بر این مشکل، روش‌های نرم‌افزاری تحت عنوان ابرتفکیک‌پذیری^۲ یا «وضوح برتر» ایجاد شده است که به‌کمک آن‌ها می‌توان بر محدودیت‌های ساخت افزاری غلبه کرد و تصاویری فراتر از تفکیک‌پذیری سیستم تصویربرداری ایجاد کرد. در این الگوریتم‌ها با استفاده از یک یا چند تصویر از صحنه با تفکیک‌پذیری کم (LR)، تصویری با تفکیک‌پذیری زیاد (HR)^۴ به‌وجود می‌آید.

به‌طور دقیق، می‌توان گفت مسئله SR یک مسئله معکوس است که هدف آن ایجاد تصویر \mathbf{x} با اندازه $P_1 L_1 \times P_2 L_2$ از یک صحنه با استفاده از مجموعه تصاویر \mathbf{y}_k با اندازه $L_1 \times L_2$ است. همان‌سانه به‌ازای $k = 1, 2, \dots, K$ و P_1, P_2 ضرایب افزایش تفکیک‌پذیری هستند. در ابرتفکیک‌پذیری با استفاده از اطلاعاتی که در چندین تصویر LR وجود دارد، تصویر HR بازسازی می‌شود؛ از این‌رو، شرط عملی بودن SR وجود اطلاعات متفاوت از صحنه در تصاویر LR است. این موضوع در شکل (۱) نمایش داده شده است. همان‌گونه که در شکل (الف) دیده می‌شود، زمانی که جابجایی دو تصویر ضربی از اندازه پیکسل باشد، دو تصویر (در قسمت‌های

1. Resolution
2. Super Resolution (SR)
3. Low Resolution
4. High Resolution

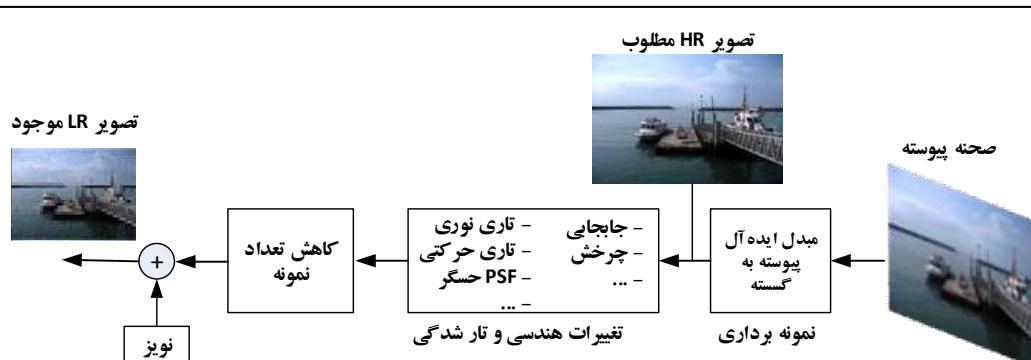
اعمال شده بر روی تصویر HR، تنها از روی تصاویر LR تخمین زده شوند [۲]. در بیشتر اوقات، به سختی می‌توان این پارامترها را تنها از روی تصاویر LR تخمین زد؛ ازین‌رو، خطای تخمین در بسیاری از سیستم‌های عملی اجتناب‌ناپذیر است. خطأ در تخمین پارامترهای تاری و جابجایی بین تصاویر، موجب اشکال‌های زیادی در SR شده که منجر به عدم کیفیت در بازیابی تصویر HR می‌شود.

با توجه به وجود مشکلات مذکور در مسئله SR، رهیافت‌هایی که بتوانند به گونه‌ای خطاهای موجود را مدل کنند و عدم قطعیت را در فرمول‌های حل SR پوشش دهن، از موفقیت بیشتری برخوردارند. از بین روش‌های مختلف، رهیافت‌های آماری و به‌ویژه چهارچوب بیز، این ویژگی را ارائه می‌کند [۲]؛ زیرا به هر کمیت یکتابع توزیع احتمال نسبت می‌دهد. همچنین با استفاده از چهارچوب بیز سلسله‌مراتبی می‌توان پارامترهای توابع توزیع مذکور را به‌طور خودکار به دست آورد.

ساختار مقاله بدین قرار است که در بخش دوم، مدل سیستم تصویربرداری بیان می‌شود. در بخش سوم، مسائل معکوس و مفهوم بدمطرح بودن تشریح می‌شود. در بخش چهارم، رهیافت‌های موجود در حل مسئله SR به اختصار ارائه می‌شود. در بخش پنجم، روش منظم‌سازی تصادفی در چهارچوب بیز بیان می‌شود و بخش ششم نیز مقاله را جمع‌بندی می‌کند.

هرچند در زمینه SR کارهای زیادی انجام شده، این مسئله هنوز یک موضوع باز است که توسط محققان در حال بررسی است [۲]. اولین چالش در حل مسئله SR مدل‌سازی دقیق فرایند تصویربرداری است. گفتیم SR یک مسئله معکوس است؛ بدین معنی که خروجی سیستم تصویربرداری ورودی الگوریتم SR است و این الگوریتم باید ورودی سیستم تصویربرداری را بازتولید کند. برای دست‌یابی به این هدف، در اولین قدم، باید سیستم تصویربرداری به‌طور دقیق مدل شود. مشکل دیگر در مسئله SR این است که تنها با استفاده از تصاویر LR نمی‌توان تصویر HR را ایجاد کرد و نیاز به دانش پیشین^۱ درباره تصویر HR است. دلیل این امر از بدمطرح بودن مسئله SR ناشی می‌شود؛ بنابراین، چالش دیگر در مسئله SR توصیف، ترکیب و به کارگیری دانش پیشین درباره تصویر HR در فرایند بازسازی است.

همان‌طور که بیان شد، برای ایجاد تصویر HR نیاز است اطلاعات موجود در تصاویر LR با هم ترکیب شود. برای این کار، یکی از تصاویر LR به عنوان مرجع انتخاب و جابجایی بقیه تصاویر LR با تصویر مرجع تعیین می‌شود. به این عمل، تخمین حرکت^۲ یا ثبت تصویر^۳ می‌گویند. همچنین تصاویر LR معمولاً توسط سیستم تصویربرداری، تار می‌شوند که الگوریتم SR باید آن را رفع کند. مسئله SR یک مسئله بسیار بدمطرح است، به‌ویژه زمانی که قرار باشد پارامترهای تاری و جابجایی



شکل (۳): مدل سیستم تصویربرداری رقمنی

1. Prior Knowledge
2. Ill-posed
3. Motion Estimation
4. Image Registration

در کارهای انجام شده، معمولاً از مدل Warp-Blur استفاده می‌شود. همچنین اگر تاری تصویر به‌طور مکانی-زمانی تغییرناپذیر با جابجایی^۳ باشد و حرکت فقط شامل مؤلفه جابجایی کلی^۴ باشد، دو مدل یکسان خواهد بود. ذکر شدنی است در این حالت، ماتریس‌های حرکت و تاری با ماتریس‌های کانولوشن متناظرخواهند شد و در نتیجه، دارای خاصیت جابجایی هستند. جزئیات بیشتر در [۴] آمده است.

برای مقایسه با روابط بخش بعد، رابطه (۱) را می‌توان به صورت کلی زیر در نظر گرفت:

$$\mathbf{y}_k = \mathbf{W}_k \mathbf{x} + \mathbf{n}_k \quad (3)$$

که در آن، $\mathbf{W}_k = \mathbf{A} \mathbf{H}_k \mathbf{C}(\mathbf{d}_k)$ است.

۳. بررسی مسائل معکوس

همان‌گونه که در بخش ۱ بیان شد، مسئله ابرتفکیک‌پذیری یک مسئله معکوس است؛ ازین‌رو در این قسمت، به‌طور اجمالی، مسائل معکوس و روش حل آن‌ها بررسی می‌شود. تمرکز ما بر روی مسائل خطی معکوسی است که بتوان آن‌ها را به فرم کلی زیر بیان کرد:

$$\int_{\Omega} \text{system} \times \text{input} d\Omega = \text{output} \quad (4)$$

یک مثال کلاسیک از این دست، معادله انتگرال فردھلم نوع اول است [۵] که می‌توان آن را به صورت زیر نوشت:

$$\int_0^1 K(s, t) f(t) dt = g(s), \quad 0 \leq s \leq 1 \quad (5)$$

که در آن، قسمت سمت راست یعنی (s) $g(s)$ و هسته $K(s, t)$ معلوم و $f(t)$ نامعلوم بوده و هدف یافتن آن است. در اصطلاحات مربوط به مسائل معکوس، اغلب (s) یعنی ورودی سیستم معکوس را «داده» و $(t)f$ را که خروجی آن است، «تصویر»^۶ گویند. همچنین به مجموعه همه تصویرهای ممکن، فضای تصویر^۷ گفته می‌شود. یک حالت خاص از رابطه

۲. مدل سیستم تصویربرداری

در مباحث پردازش تصویر، اغلب تصاویر به صورت ماتریسی نمایش داده می‌شوند؛ اما در حوزه ابرتفکیک‌پذیری معمول است که اطلاعات تصاویر به صورتی که lexicographical نامیده می‌شود، نمایش داده شوند. در این روش، اطلاعات تصویر به ترتیب (مثلاً سطر به سطر) در یک بردار ستونی قرار داده می‌شود و تمامی پردازش‌ها بر روی بردارها انجام می‌گیرد؛ برای مثال، یک تصویر $n \times m$ به برداری با اندازه $1 \times mn$ تبدیل می‌شود.

در ادامه، تصویر HR را با بردار \mathbf{x} با اندازه $1 \times NP$ و تصویر LR را با بردارهای \mathbf{y}_k با اندازه $1 \times N$ به‌ازای $k = 1, 2, \dots, K$ نمایش می‌دهیم. ضریب افزایش دقت تصویر است.

شکل (۳) مدل سیستم تصویربرداری رقمی و چگونگی ایجاد تصویر LR را نمایش می‌دهد. در این مدل تقریبی، تغییرات هندسی^۸ و تارشده‌گی^۹ تصویر در کنار هم، در یک کادر مدل شده است. ترتیب اعمال این دو عمل نسبت به هم، موجب ایجاد دو مدل Blur-Warp و Warp-Blur می‌شود. در مدل Warp-Blur ابتدا تغییرات هندسی و سپس تارشده‌گی بر روی تصاویر اعمال می‌شود؛ ازین‌رو، رابطه بین تصویر LR و تصویر HR به صورت زیر تعریف می‌شود [۳].

$$\mathbf{y}_k = \mathbf{A} \mathbf{H}_k \mathbf{C}(\mathbf{d}_k) \mathbf{x} + \mathbf{n}_k \quad (1)$$

در این رابطه، \mathbf{x} بردار تصویر HR با اندازه $1 \times NP$ ، \mathbf{y}_k بردار تصویر LR با اندازه $1 \times N$ ، ماتریس کاهش نمونه با اندازه $N \times NP$ ، \mathbf{H}_k ماتریس تاری با اندازه $NP \times N$ ، $\mathbf{C}(\mathbf{d}_k)$ ماتریس تغییرات هندسی با اندازه $NP \times NP$ است که توسط بردار جابجایی یا حرکت \mathbf{d}_k تولید می‌شود و \mathbf{n}_k بردار نویز فرایند تصویربرداری با اندازه $1 \times N$ است.

در مدل Blur-Warp ترتیب تارشده‌گی و تغییرات هندسی جابه‌جا می‌شود و در نتیجه، این مدل منجر به رابطه زیر می‌شود:

$$\mathbf{y}_k = \mathbf{A} \mathbf{C}(\mathbf{d}_k) \mathbf{H}_k \mathbf{x} + \mathbf{n}_k \quad (2)$$

1. Warping

2. Blurring

3. Spatiotemporal Shift Invariant

4. Global Translational

۵. «تصویر» در اینجا یک مفهوم کلی است و نباید آن را با تصویر دیجیتال که توسط سیستم تصویربرداری ایجاد می‌شود، اشتباہ گرفت.

6. Image Space

گسته‌سازی معادله دو بعدی فردholm نیز مانند حالت یک بعدی با روش‌هایی همچون روش تربیع انجام می‌گیرد و نتیجه باز به فرم کلی (۶) خواهد بود.

۱.۳. مسائل بدمعطّر و بدحالتی^۳

با فرض معلوم بودن \mathbf{y} و \mathbf{A} ، مسئله معکوسِ یافتن \mathbf{x} با توجه به رابطه $\mathbf{y} = \mathbf{Ax}$ خوش‌تعریف^۴ گفته می‌شود اگر شرایط خوش‌تعریفی را داشته باشد [۱۰]. این شرایط عبارت‌اند از: ۱. برای هر داده \mathbf{y} در فضای داده، تصویری مانند \mathbf{x} وجود داشته باشد؛ ۲. جواب در فضای تصویر یکتا باشد؛ ۳. نگاشت معکوس $\mathbf{x} \rightarrow \mathbf{y}$ پیوسته باشد؛ یعنی تغییرات اندک \mathbf{y} منجر به تغییرات اندک \mathbf{x} گردد.

شرط ۱ و ۲ بیان می‌دارند که \mathbf{A} دارای معکوسی مانند \mathbf{A}^{-1} است. شرط پیوستگی^۵ شرطی لازم، ولی ناکافی برای پایداری جواب است. در مسائل خوش‌تعریف، خطای نسبی که از داده (\mathbf{y}) به جواب (\mathbf{x}) منتقل می‌شود، با عدد وضعیت^۶ کترول می‌شود؛ اگر $\Delta\mathbf{y}$ میزان تغییر \mathbf{y} و $\Delta\mathbf{x}$ میزان تغییر متناظر در \mathbf{x} باشد، آنگاه [۱۱]:

$$\frac{\|\Delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \text{cond}(\mathbf{A}) \frac{\|\Delta\mathbf{y}\|}{\|\mathbf{y}\|} \quad (8)$$

با توجه به اینکه طبق (۸) خطای نسبی در \mathbf{x} برابر است با حاصل ضرب عدد وضعیت \mathbf{A} در خطای نسبی \mathbf{y} ، مقادیر کم مطلوب است. اگر $\text{cond}(\mathbf{A})$ خیلی بزرگ نباشد، مسئله معکوس $\mathbf{y} = \mathbf{A}(\mathbf{x})$ خوش‌حالت^۷ خوانده می‌شود و جواب نسبت به تغییرات اندک داده‌ها پایدار است؛ یعنی تغییر اندک \mathbf{y} موجب تغییر اندک \mathbf{x} خواهد شد. زمانی که $\text{cond}(\mathbf{A})$ بزرگ باشد، مسئله بدحالت^۸ نامیده می‌شود.

بدمعطّر بودن یک مسئله به این صورت تعریف شده است که مسئله شرایط خوش‌تعریفی را نداشته باشد؛ بنابراین، مسئله بدمعطّر مسئله‌ای است که در آن، معکوس وجود ندارد؛ زیرا

(۵) زمانی است که $K(s, t)$ تنها تابعی از $t - s$ باشد که در این صورت، رابطه (۵) عملگر آشنا کانولوشن خواهد شد.

با توجه به رابطه (۵)، مشکل در مسائل معکوس از این دست این است که ورودی $f(t)$ در اثر ضرب شدن در هسته $K(s, t)$ و انتگرال‌گیری هموار می‌شود و فرکانس‌های بالای آن از بین می‌رود. این عمل شبیه کانوالو کردن یک تصویر با یک فیلتر پایین گذرا است که سبب هموارشدن لبه‌های تصویر می‌شود. همچنین وجود خطای نویز در (s) سبب ایجاد مشکلاتی در بازیابی $f(t)$ می‌شود.

رابطه (۵) ارتباط بین داده‌های واقعی و تصویر را بیان می‌کند. از آنجاکه معمولاً این معادله با روش‌های عددی حل می‌شود، باید گسته شود. دو روش اصلی برای این کار عبارت‌اند از: روش تربیع^۹ و روش بسط^{۱۰} یا Galerkin. برای اطلاعات بیشتر درخصوص این روش‌ها به [۸-۶] مراجعه شود. حاصل گسته‌سازی رابطه (۵) به صورت زیر است:

$$\mathbf{y} = \mathbf{Ax} \quad (6)$$

که در آن، $(\tilde{f}(t_j) = x_j)$ عناصر بردار \mathbf{x} و $y_i = g(s_i)$ عناصر بردار \mathbf{y} و $a_{ij} = w_j K(s_i, t_j)$ عناصر ماتریس \mathbf{A} بوده و w_j هاوزن‌های استفاده شده در روش تربیع هستند. نکته جالب توجه این است که اگر معادله (۵) به فرم کانولوشن باشد، ماتریس \mathbf{A} Toeplitz ماتریس عبارت از یافتن تصویر \mathbf{x} با فرض معلوم بودن داده \mathbf{y} و مدل مستقیم \mathbf{A} است.

از آنجاکه داده‌های اندازه‌گیری شده همواره با مقداری نویز همراه هستند، رابطه (۶) را می‌توان به صورت $\mathbf{y}_{exact} = \mathbf{Ax} + \mathbf{n}$ نوشت که در آن، \mathbf{y}_{exact} داده بدون نویز است. مقایسه (۳) با این رابطه، ارتباط مسئله ابرتفکیک‌پذیری را با مسائل معکوس، به خوبی نشان می‌دهد.

در حالت دو بعدی، معادله فردholm به شکل زیر است:

$$\int_0^1 \int_0^1 K(s, t, s', t') f(s, t) ds dt = g(s', t'), \quad 0 \leq s \leq 1 \quad (7)$$

3. Ill-conditioning

4. Well-posed

5. Condition Number

6. Well-Condition

7. Ill-Condition

1. Quadrature Method

2. Expansion Method

نشان می‌دهد که هیچ مسئله نزدیکی که دارای ماتریس ضرایب خوش‌حالت و رتبه عددی خوبی باشد، وجود ندارد که بتوان این مسئله را به آن تقریب زد.

نکته جالب و مهم درباره مسائل بدمطرح گسته این است که بحالات بودن مسئله به این معنی نیست که یک جواب با تقریب خوب محاسبه‌پذیر نیست؛ بلکه بحالات بودن بیان می‌دارد که روش‌های استاندارد در جبر خطی عددی برای حل معادلات بالا به طور مستقیم، استفاده شدنی نیست و باید از روش‌های پیشرفته‌تری برای تعیین جواب استفاده شود. این مطلب هدف اساسی روش‌های منظم‌سازی است که جلوتر بررسی خواهد شد.

در ادامه، یکی از ابزارهای مهم برای تحلیل مسائل بدمطرح گسته بررسی می‌شود.

۲.۳. تحلیل SVD

یکی از ابزارهای عددی مناسب برای تحلیل مسائل بدمطرح گسته، تجزیه مقادیر تکین^۳ ماتریس \mathbf{A} است [۴۱]. این تحلیل مشکلات مربوط به بحالات بودن ماتریس \mathbf{A} را آشکار می‌کند. فرض کنیم $\mathbf{A} \in \mathbb{R}^{m \times n}$ یک ماتریس مستطیلی است که $m \geq n$ ، آنگاه SVD ماتریس \mathbf{A} تجزیه‌ای به شکل زیر است:

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^T = \sum_{i=1}^n \mathbf{u}_i \sigma_i \mathbf{v}_i^T \quad (11)$$

که $(\mathbf{u}_1, \dots, \mathbf{u}_m) = \mathbf{U}$ و $(\mathbf{v}_1, \dots, \mathbf{v}_n) = \mathbf{V}$ ماتریس‌هایی با ستون‌های متعامد هستند؛ یعنی $\mathbf{U}^T \mathbf{U} = \mathbf{I}_m$ و $\mathbf{V}^T \mathbf{V} = \mathbf{I}_n$ و ماتریس قطعی Σ دارای عناصر نامنفی σ_i است که به صورت غیر افزایشی بر روی قطر اصلی قرار گرفته‌اند:

$$\sigma_1 \geq \dots \geq \sigma_n \geq 0. \quad (12)$$

اعداد σ_i مقادیر تکین ماتریس \mathbf{A} بوده که معادل جذر مقادیر ویژه ماتریس \mathbf{A} است. $\mathbf{A}^T \mathbf{A}$ می‌باشد و بردارهای \mathbf{u}_i و \mathbf{v}_i به ترتیب، بردارهای تکین چپ و راست ماتریس \mathbf{A} هستند. فرض می‌کنیم اولین r مقدار تکین \mathbf{A} غیر صفر باشند، در این صورت، عدد وضعیت ماتریس \mathbf{A} برابر است با نسبت σ_1/σ_r .

داده‌ها در بُرد^۱ عملگر \mathbf{A} نیستند، یا اینکه معکوس به دست آمده یکتا نیست (یعنی دو یا چند تصویر به داده‌های یکسانی نگاشت می‌شوند) یا اینکه یک تغییر کوچک در داده‌ها می‌تواند موجب تغییر بزرگی در تصویر شود؛ برای مثال، نشان می‌دهیم معادله (۵) یک مسئله بدمطرح است. با فرض اینکه تغییرات ورودی برابر $\Delta f(t) = \sin(2\pi pt)$ به ازای $p = 1, 2, \dots$ باشد، تغییرات خروجی برابر است با:

$$\Delta g(s) = \int_0^1 K(s, t) \sin(2\pi pt) dt \quad (9)$$

طبق قضیه Riemann-Lebesgue با میل کردن p به سمت بی‌نهایت، مقدار Δg به سمت صفر می‌کند. پس با انتخاب مقدار p به اندازه کافی بزرگ، نسبت $\|\Delta f\|/\|\Delta g\|$ به طور دلخواه بزرگ می‌شود. این نشان دهنده بدمطرح بودن این مسئله است؛ زیرا نشان می‌دهد شرط سوم از شرایط خوش‌تعريفی صادق نیست. همچنین این مثال اثر حذف فرکانس‌های بالا را که قبلاً به آن اشاره شد، نشان می‌دهد. می‌توان انتظار داشت برای بازیافت f از روی g نیاز باشد فرکانس‌های بالای g را بیشتر از فرکانس‌های پایین آن تقویت کرد. حال اگر g و آشته به نویز باشد، این نویز نیز تقویت می‌شود؛ به‌ویژه نویزهایی با فرکانس بالا. این نکته یکی از مشکلات در حل مسائل معکوس است.

یک راه برای حل تقریبی رابطه (۶)، کمینه کردنتابع هزینه کمترین مربعات خطاط است:

$$\min_{\mathbf{x}} \|\mathbf{Ax} - \mathbf{y}\|_2 \quad (10)$$

مسئله (۱۰) بدمطرح گسته^۲ است اگر هر دو شرط مقابل را برآورده کند [۱۲]: ۱. \mathbf{A} دارای دسته‌ای از مقادیر تکین کوچک باشد یا اینکه مقادیر تکین \mathbf{A} به تدریج به صفر برسند؛ ۲. نسبت بزرگ‌ترین به کوچک‌ترین مقدار تکین غیر صفر بزرگ باشد.

شرط دوم بیان می‌دارد که ماتریس \mathbf{A} بحالات است؛ یعنی جواب به طور بالقوه، خیلی به اغتشاش حساس است. شرط اول

تقسیم مؤلفه تصادفی بزرگی را ایجاد خواهد کرد که معمولاً مؤلفه \mathbf{x} در آن راستا در مقابل آن، ناچیز خواهد بود و در نتیجه، مؤلفه $\hat{\mathbf{x}}$ در آن راستا کاملاً تحت تأثیر نویز است. پس نتیجه‌ای که می‌توان از این بحث گرفت، این است که برای مسائل بدمطروح نمی‌توان از روش‌های معمول مانند شبه معکوس یا همان کمترین مربعات خطای استفاده کرد.

برای نشان دادن این مطلب به طور عملی، آزمایشی در شکل (۴) انجام گرفته است. در این آزمایش، قرار است تصویر تارشده‌ای که نویز به آن اعمال شده، تاریزدایی شود. عمل تاریزدایی یک مسئله معکوس و بدمطوح است که به مسئله ابرتفکیک‌پذیری نیز ارتباط دارد. در شکل (۴)، ردیف اول از چپ به راست تصویر اصلی، تصویر تارشده، تصویر تارشده نویزی و تصویر بازیابی شده با رابطه (۱۵) نشان داده شده است. تصویر بازیابی شده به شدت تحت تأثیر نویز است. نکته جالب در این آزمایش، این است که اعمال رابطه (۱۵) به تصویر تارشده بدون نویز، منجر به ایجاد تصویری می‌شود که اختلاف آن با تصویر اصلی، بسیار ناچیز است.

۳.۳. روش‌های منظم‌سازی^۳

هدف مسئله معکوس یافتن جوابی است که در رابطه (۶) صدق کند؛ اما همان‌طور که در قسمت قبل دیدیم، یافتن این جواب مشکل است. در حال حاضر، تنها معیاری که نشان‌دهنده مناسب‌بودن جواب $\hat{\mathbf{x}}$ است، نزدیک‌بودن $\mathbf{A}\hat{\mathbf{x}}$ تا حد امکان به \mathbf{y} می‌باشد. یکی از کمیت‌هایی که می‌تواند میزان این معیار را تعیین کند، نرم باقیمانده^۴ است:

$$C(\mathbf{x}) = \|\mathbf{y} - \mathbf{A}\hat{\mathbf{x}}\|^2 \quad (۱۶)$$

البته همان‌طور که در قسمت قبل دیدیم، انتخاب تصویری که $C(\mathbf{x})$ را کمینه کند، معمولاً منجر به تصویر مناسبی نمی‌شود؛ زیرا که اگر ماتریس \mathbf{A} مرتبه کامل نباشد، تصاویر زیادی وجود دارند که رابطه بالا را کمینه می‌کنند. مشکل اصلی در مسائل بدمطوح گسته^۵ (۶) و (۱۰) این است که به علت وجود دسته‌ای

[۱۲ و ۴۱] که نشان می‌دهد اگر σ_r عدد کوچکی باشد، عدد وضعیت ماتریس \mathbf{A} بزرگ خواهد بود.

در صورت خوش‌تعريف‌بودن (۱۰)، می‌توان از شبه معکوس^۶ Moore-Penrose^۷ برای حل تقریبی آن استفاده کرد [۴۲]. در ادامه، با کمک SVD اعمال این روش بر مسائل بدمطوح بررسی می‌شود. برای کمینه‌کردن مجموع مربعات باقیمانده^۸ $e_{SSR} = \|\mathbf{Ax} - \mathbf{y}\|^2$ ، مشتق آن را نسبت به \mathbf{x}

$$\hat{\mathbf{x}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y} \quad (۱۳)$$

که $\hat{\mathbf{x}}$ جواب تقریبی مورد نظر بوده و عبارت $(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$ شبیه معکوس \mathbf{A} است. اگر معادل \mathbf{A} و \mathbf{A}^T را از تحلیل SVD در این رابطه قرار دهیم، داریم $= (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T = \sum_{k=1}^r \frac{1}{\sigma_k} \mathbf{v}_k \mathbf{u}_k^T$ خواهیم داشت:

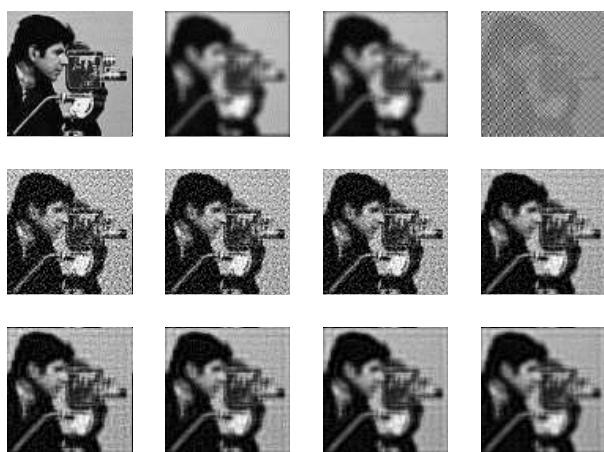
$$\hat{\mathbf{x}} = \sum_{k=1}^r \frac{(\mathbf{u}_k^T \mathbf{y})}{\sigma_k} \mathbf{v}_k \quad (۱۴)$$

با توجه به اینکه اندازه‌گیری داده‌ها همواره با مقداری خطای همراه خواهد بود؛ از این‌رو، داده \mathbf{y} را می‌توان به صورت $\mathbf{y}_{exact} + \mathbf{n}$ نوشت که در آن، \mathbf{n} نویز بوده و داده بدون نویز است. با جایگذاری این عبارت در رابطه (۱۴) خواهیم داشت $\hat{\mathbf{x}} = \sum_{k=1}^r \frac{1}{\sigma_k} \mathbf{v}_k \mathbf{u}_k^T (\mathbf{y}_{exact} + \mathbf{n})$ و در نهایت، با فرض مرتبه کامل بودن ماتریس \mathbf{A} (یعنی $n = r$)، نتیجه زیر حاصل می‌شود.

$$\hat{\mathbf{x}} = \mathbf{x} + \sum_{k=1}^n \frac{(\mathbf{u}_k^T \mathbf{n})}{\sigma_k} \mathbf{v}_k \quad (۱۵)$$

رابطه (۱۵) نشان می‌دهد جواب به دست آمده از روش شبه معکوس برابر است با مجموع تصویر واقعی و عبارتی که به علت وجود نویز ایجاد شده است. خطای ایجاد شده در راستای \mathbf{v}_k در فضای تصویر از مؤلفه نویز در راستای \mathbf{u}_k^T که بر مقدار تکین σ_k تقسیم شده است، به وجود می‌آید. اگر فرض کنیم برخی از مقادیر تکین σ_k کوچک باشند، آنگاه این

باقی‌مانده کنترل می‌کند. به‌روشنی مشخص است که مقدار بزرگ λ (معادل با منظم‌سازی زیاد)، موجب ایجاد جوابی با اندازه کوچک، ولی به قیمت معیار باقی‌مانده بزرگ می‌شود؛ در حالی که مقدار کوچک λ (معادل با منظم‌سازی کم) اثری معکوس دارد؛ به‌طوری‌که اگر λ را مساوی صفر قرار دهیم، به مسئله کمترین مربعات خطای می‌رسیم؛ بنابراین، پارامتر منظم‌سازی کمیتی مهم است که خواص جواب منظم‌شده را کنترل می‌کند. برای تعیین مقدار بهینه λ معمولاً از تحلیل منحنی L^2 استفاده می‌شود. برای اطلاعات بیشتر به [۱۲] مراجعه شود.



شکل (۴): ردیف اول از چپ به راست: تصویر اصلی، تصویر تارشده، تصویر تارشده نویزی و تصویر بازیافت شده با روش شبیه معکوس. ردیف دوم و سوم: تاریزدایی به‌روش منظم‌سازی تیخونوف به‌ازای مقادیر مختلف λ

در پایان این بخش، مثال تاریزدایی را با روش منظم‌سازی بر روی تصویر تارشده نویزی بررسی می‌کنیم. در شکل (۴)، سطرهای دوم و سوم تصاویر تاریزدایی شده به‌روش تیخونوف، به‌ازای مقادیر مختلف λ نشان داده شده است. مقدار λ در این بازسازی‌ها از چپ به راست و از بالا به پایین افزایش پیدا می‌کند. همان‌گونه که دیده می‌شود، به‌ازای مقادیر کم λ تصویر برگرفته و با افزایش آن تصویر هموارتر می‌شود.

۴. رهیافت‌های ابرتفکیک‌پذیری

رهیافت‌های موجود برای حل مسئله SR را می‌توان به چهار دسته تقسیم‌بندی کرد [۱۵] که عبارت‌اند از: ۱. رهیافت مبتنی بر

5. L-Curve Analysis

از مقادیر تکین کوچک برای ماتریس A ، این مسائل اساساً فرومیان ^۱ هستند؛ ازین‌رو، برای پایدار کردن مسئله و به‌دست آوردن جواب مفید، لازم است اطلاعاتی اضافی درباره جواب مطلوب به معادله وارد کنیم. این عمل هدف منظم‌سازی است و جواب حاصل از تکنیک منظم‌سازی را جواب منظم‌شده ^۲ گویند. از آنجاکه روش‌های تحلیلی تنها در صورت انتخاب معیارهای ساده برای منظم‌سازی وجود دارد،تابع ساده (Ω) به عنوان قید دوم معرفی می‌شود. این تابع نمایانگر شرایط نامطلوب جواب است و قرار است کمینه شود. رهیافت غالب برای منظم‌سازی مسائل بدمطرح گستته این است که جواب یا تقریبی از آن معیار ^۲ λ کوچکی داشته باشد؛ ازین‌رو، تابع (Ω) معمولاً شکل کلی زیر را دارد [۱۲].

$$\Omega(\mathbf{x}) = \|L(\mathbf{x} - \mathbf{x}^*)\|_2^2 \quad (17)$$

در ساده‌ترین حالت، ماتریس L ماتریس همانی I_n و $\mathbf{x}^* = \mathbf{0}$ است که منجر به $\|\mathbf{x}\|_2^2 = \Omega(\mathbf{x}) = 0$ می‌شود؛ یعنی دنبال جوابی هستیم که اندازه کوچکی داشته باشد. حالت بعدی زمانی است که اطلاعاتی از قبل درباره جواب مناسب داشته باشیم؛ ازین‌رو، ترجیح می‌دهیم جواب بازیافت‌شده به یک جواب پیش‌فرض مانند \mathbf{x}^* نزدیک باشد. حالت کلی‌تر این است که ماتریس L تقریبی گستته از یک مشتق‌گیر باشد. به عبارت $\|\mathbf{x} - \mathbf{x}^*\|_2$ نیمه معیار جواب ^۳ نیز گفته می‌شود.

حال باید جوابی را جست‌وجو کرد که بین کمینه‌شدن قید جانبی (Ω) و کمینه‌شدن معیار باقی‌مانده، یعنی $\|\mathbf{Ax} - \mathbf{y}\|_2$ تعادل ایجاد کند. روش‌های منظم‌سازی مختلفی وجود دارد که یکی از متداول‌ترین و معروف‌ترین آن‌ها منظم‌سازی تیخونوف ^۴ [۱۴] است. در این روش، جواب منظم‌شده $\lambda \mathbf{x}$ جوابی است که مجموعی وزن‌دار از معیار باقی‌مانده و قید جانبی را کمینه کند:

$$\mathbf{x}_\lambda = \arg \min \{\|\mathbf{Ax} - \mathbf{y}\|_2^2 + \lambda^2 \|\mathbf{L}(\mathbf{x} - \mathbf{x}^*)\|_2^2\} \quad (18)$$

پارامتر منظم‌سازی λ وزن قید جانبی را نسبت به معیار

-
1. Underdetermined
 2. Regularized Solution
 3. Solution semi-Norm
 4. Tikhonov Regularization

اطلاعات متفاوت از دیگر تصاویر است، تصویر نهایی دقت بیشتری خواهد داشت. رهیافت مبتنی بر درون یابی معمولاً شامل سه مرحله است [۱]: ۱. مرحله ثبت تصاویر LR؛ ۲. مرحله درون یابی برای ایجاد تصویر HR؛ ۳. مرحله تاریزدایی تصویر ایجاد شده در مرحله دوم.

مرحله درون یابی نقشی کلیدی در این رهیافت بازی می‌کند. روش‌های مختلفی برای درون یابی وجود دارد. ساده‌ترین روش درون یابی نزدیک‌ترین همسایه است که به هر پیکسل نامشخص، شدت نوری برابر با همسایه‌اش می‌دهد. عیب این روش درون یابی ایجاد تصویری بلاکی است. روش دیگر برای درون یابی، درون یابی نایکنواخت [۱۷] است که از قضیه نمونه‌برداری چندکاناله تعمیم یافته^۴ استفاده می‌کند.

از مزایای رهیافت درون یابی بار محاسباتی پایین آن است که برای کارهای بلاذرنگ مفید است؛ البته بهینه‌بودن این روش تضمین نمی‌شود؛ زیرا خطای درون یابی در آن لحاظ نمی‌شود. همچنین خطای ثبت می‌تواند به سادگی به مراحل دیگر انتشار پیدا کند.

در [۱۸] از روش کمترین مربعتات متحرک^۵ برای تخمین روشنایی هر پیکسل از تصویر HR توسط تقریب چندجمله‌ای با استفاده از مقدار روشنایی پیکسل‌های معلوم استفاده شده است. در این روش، درجه و ضرایب چندجمله‌ای برای هر پیکسل، به‌طور تطبیقی تعیین می‌شود.

مراحل بیان شده در این رهیافت را می‌توان به‌طور تکراری اجرا کرد؛ از این‌رو، مرجع [۱۹] الگوریتم پس افکنش تکراری^۶ را پیشنهاد داده است که در آن، تصویر HR با افکنش متولی اختلاف بین تصویر LR مشاهده شده و تصویر LR شبیه‌سازی شده برآورد می‌شود؛ البته در این الگوریتم، به‌دلیل بدمعطرح بودن مسئله SR، ممکن است جواب‌ها یکتا نباشند که از معایب این روش به حساب می‌آید.

افکنش بر روی مجموعه‌های محدب^۷ روشی است که در

حوزه فرکانس؛ ۲. رهیافت مبتنی بر درون یابی؛ ۳. رهیافت مبتنی بر یادگیری؛ ۴. رهیافت مبتنی بر منظم‌سازی. در ادامه، هریک از این رهیافت‌ها را به‌طور خلاصه بررسی می‌کنیم.

۱.۴. رهیافت مبتنی بر حوزه فرکانس

مسئله SR در ابتدا توسط تسای و هوانگ [۱۶] در سال ۱۹۸۴ مطرح شد. ایشان رهیافت حوزه فرکانس را برای حل مسئله SR پیشنهاد دادند. در این روش، از درهم‌آمیختگی^۱ که در تصاویر LR وجود دارد، برای بازسازی تصویر HR استفاده می‌شود. این روش بر پایه این سه اصل استوار است: ۱. خاصیت جابجایی تبدیل فوریه؛ ۲. ارتباط درهم‌آمیختگی بین تبدیل فوریه پیوسته تصویر HR و تبدیل فوریه گسسته تصاویر LR؛ ۳. فرض اینکه تصویر HR باند محدود است.

مهمنترین مزیت روش حوزه فرکانس، سادگی تئوری آن است. بدین معنی که ارتباط بین تصاویر LR و تصویر HR به‌روشنی در حوزه فرکانس، نمایش داده می‌شود. از دیگر مزایای این روش، امکان پیاده‌سازی موازی آن است که موجب افزایش سرعت می‌شود. با وجود این، در این روش، نوع حرکت تصاویر نسبت به هم، فقط محدود به انتقال کلی است و تاری اعمال شده به تصاویر خطی و نامتغیر با مکان^۲ فرض می‌شود؛ در حالی که در عمل ممکن است تصاویر نسبت به هم حرکت‌های پیچیده‌تری مانند چرخش، تغییر مقیاس و ترکیبی از آن‌ها را داشته باشند. از دیگر معایب این روش، این است که اعمال دانش پیشین در حوزه مکان برای منظم‌سازی آن مشکل است [۱]. به عبارت دیگر، اطلاعات قبلی در حوزه مکان را نمی‌توان به راحتی در روابط حوزه فرکانس وارد کرد. با توجه به معایب گفته شده، امروزه این روش کاربرد چندانی ندارد.

۱.۴. رهیافت مبتنی بر درون یابی

در این رهیافت، تصویر HR با افکنش^۳ تمام تصاویر LR بر روی تصویر مرجع و سپس ترکیب‌کردن اطلاعات موجود در آن‌ها به دست می‌آید. ازانجاكه هر تصویر دارای مقداری

4. Generalized Multichannel Sampling Theorem

5. Moving Least Square (MLS)

6. Iterative Back-Propagation

7. Projection onto Convex Sets(POCS)

1. Aliasing

2. Linear Space Invariant (LSI)

3. Projection

هدف آن جستجو برای نمایش خلوت هر وصله از ورودی LR و استفاده از نمایش خلوت تصویر برای تولید خروجی HR است. با آموزش دو دیکشنری برای وصله‌های LR و HR، نمایش خلوت وصله LR با استفاده از دیکشنری LR ایجاد و به دیکشنری HR اعمال می‌شود تا وصله HR متاناظر به وجود آید. صحت این روش که نتایج امیدبخشی در پس دارد، در [۲۵] از منظر تئوری یادگیری به اثبات رسیده است.

شکل (۵) تعدادی از عناصر موجود در یک دیکشنری HR را نشان می‌دهد. این عناصر با استفاده از یکصد هزار زوج تصویر با دقت زیاد و دقت کم از تصاویر مختلف آموزشی ایجاد شده‌اند و اندازه هر یک 9×9 می‌باشد.



شکل (۵): برخی از عناصر یک دیکشنری HR که برای بازسازی وصله‌های تصویر HR استفاده می‌شود [۲۴].

۳.۴. رهیافت منظم‌سازی برای ابرتفکیک پذیری^۷

همان‌طور که گفته شد، مسئله SR یک مسئله بدمطروح است و برای پیاساختن مسائل معکوس بدمطروح، از روش‌های منظم‌سازی استفاده می‌شود. روش‌های منظم‌سازی به دو دسته منظم‌سازی قطعی^۸ و منظم‌سازی تصادفی^۹ تقسیم‌بندی می‌شوند.

۱.۴.۴. منظم‌سازی قطعی

منظم‌سازی قطعی در بخش قبل، برای مسائل معکوس بیان شد. برای یافتن تصویر مطلوب در رابطه (۳) می‌توان جوابی را جستجو کرد که تابع هزینه^۲ $\sum_{k=1}^K \| \mathbf{y}_k - \mathbf{W}_k \mathbf{x} \|^2$ را کمینه کند؛ البته تابع هزینه مذکور به تنها برای حل مسئله SR کافی نیست [۲۶]؛ ازین‌رو، با استفاده از روش منظم‌سازی به راه حل تکراری زیر می‌رسیم [۱]:

[۲۰] برای ایجاد یک تصویر HR که هم با تصاویر LR و هم با دانش قبلی راجع به تصویر HR سازگار باشد، پیشنهاد شده است. این اطلاعات با استفاده از مجموعه‌های قید^۱ بیان می‌شوند. این مجموعه‌ها در فضای جواب واقع هستند و اشتراک آن‌ها جواب‌های مجاز را مشخص می‌کند. پیاده‌سازی الگوریتم ساده است؛ اما تضمینی برای جواب یکتا وجود نداشته و هزینه محاسباتی آن زیاد است.

۲.۴. رهیافت مبتنی بر یادگیری

روش‌های یادگیری نیز برای حل مسئله SR پیشنهاد شده‌اند. برخلاف دیگر رهیافت‌ها، در این رهیافت، تنها یک تصویر LR وجود دارد و اطلاعات فرکانس بالای آن براساس ویژگی‌های محلی آن، از روی تصاویر آموزشی به دست می‌آید. در [۲۱] یک روش برای تولید جزئیات فرکانس بالای تصویر LR با استفاده از مجموعه داده آموزشی پیشنهاد شده است که الگوریتم آن دو مرحله دارد: مرحله یادگیری برونو خط^۰ و مرحله بازسازی SR. در مرحله یادگیری، وصله‌های تصویر^۳ به عنوان تصاویر مرجع^۴ در نظر گرفته می‌شود و با شبیه‌سازی سیستم تصویربرداری، از آن‌ها تصاویر کم دقت ایجاد می‌شود. به این ترتیب، زوج وصله‌های LR و وصله‌های HR متاناظر به صورت مجموعه داده جمع‌آوری می‌شود. در مرحله بازسازی SR وصله‌های تصویر LR استخراج و با وصله‌های داخل مجموعه داده مقایسه می‌شود. سپس وصله‌ای با بهترین تطابق براساس معیار شباهت مشخصی انتخاب و وصله HR متاناظر با آن، برای ساخت تصویر HR استفاده می‌شود.

تحقیقات اخیر در زمینه مطالعه آماری تصویر نشان می‌دهد وصله‌های تصویر را می‌توان به صورت ترکیب خطی خلوت از عناصر یک دیکشنری فوق کامل^۶ از وصله‌های تصویر نمایش داد [۲۲-۲۴]. با توجه به این نکته، الگوریتمی ارائه شده که

-
1. Constraint Sets
 2. Off-line
 3. Image Patches
 4. Ground Truth
 5. Sparse Linear Combination
 6. Over-complete

اطلاعات موجود در حیطه مسئله، به هریک از آنها یک توزیع احتمال منسوب می‌شود [۴۲]. به این ترتیب، تصویر \mathbf{x} و بردار حرکت \mathbf{d} به عنوان نمونه‌هایی از میدان‌های تصادفی^۳ با توزیع‌های احتمال پیشینی که داشت قبلی ما را درباره تصویر HR و بردارهای حرکت مدل می‌کنند، بیان می‌شوند. همچنین تصاویر مشاهده شده \mathbf{y} که تابعی از \mathbf{x} و \mathbf{d} هستند، نمونه‌هایی از یک میدان تصادفی در نظر گرفته می‌شوند که یک توزیع احتمال شرطی فرایند ایجاد آنها را از روی \mathbf{x} و \mathbf{d} مدل می‌کند.

توزیع‌های احتمالی بیان شده به پارامترهایی وابسته‌اند که آنها را با Ω نشان می‌دهیم. با فرض معلوم بودن Ω ، توزیع احتمال توأم که رابطه بین داده‌های مشاهده شده و کمیت‌های مجهول را در مسئله SR مدل می‌کند، به صورت زیر است:

$$P(\mathbf{x}, \mathbf{d}, \mathbf{y}) = P(\mathbf{x}, \mathbf{d})P(\mathbf{y}|\mathbf{x}, \mathbf{d}) \quad (20)$$

۱.۵ استنتاج بیز

بعد از مدل کردن مسئله SR در چهارچوب بیز، استنتاج بیز با تعیین توزیع احتمال پسین^۴ به صورت زیر انجام می‌گیرد:

$$P(\mathbf{x}, \mathbf{d}|\mathbf{y}) = \frac{P(\mathbf{x}, \mathbf{d})P(\mathbf{y}|\mathbf{x}, \mathbf{d})}{P(\mathbf{y})} \quad (21)$$

با توجه به رابطه بالا یکی از روش‌های تعیین \mathbf{x} و \mathbf{d} راه حل پیشینه احتمال پسین است:

$$\begin{aligned} \hat{\mathbf{x}}, \hat{\mathbf{d}} &= \arg \max_{\mathbf{x}, \mathbf{d}} P(\mathbf{x}, \mathbf{d}|\mathbf{y}) \\ &= \arg \max_{\mathbf{x}, \mathbf{d}} \{P(\mathbf{x}, \mathbf{d})P(\mathbf{y}|\mathbf{x}, \mathbf{d})\} \end{aligned} \quad (22)$$

بسته به تابع چگالی احتمال پیشین و تابع چگالی احتمال شرطی در روابط بالا، ممکن است یافتن راه حل تحلیلی برای (۲۲) مشکل باشد؛ از این‌رو، از روش‌های عددی برای حل آن استفاده می‌شود. مشکل اصلی در حل عددی این روابط، تخمین هم‌زمان متغیرهای \mathbf{x} و \mathbf{d} است. در کارهای انجام شده در زمینه SR اغلب از دو روش زیر برای غلبه بر این مشکل استفاده می‌شود [۳].

- **روش تناوبی**^۵: این روش از رویه تناوبی کاهش مختصات^۱ مختصات^۱ استفاده می‌کند. فرض می‌کنیم $\hat{\mathbf{x}}^q$ تخمین فعلی

$$\begin{aligned} \hat{\mathbf{x}}^{n+1} &= \hat{\mathbf{x}}^n + \beta \left[\sum_{k=1}^K \mathbf{W}_k^T (\mathbf{y}_k - \mathbf{W}_k \hat{\mathbf{x}}^n) \right. \\ &\quad \left. - \lambda \mathbf{C}^T \mathbf{C} \hat{\mathbf{x}}^n \right] \end{aligned} \quad (19)$$

که در آن، β پارامتر همگرایی بوده و \mathbf{W}_k^T شامل عملگر افزایش تعداد نمونه^۱، تاری و تغییرات هندسی است.

۲.۴.۴ منظم‌سازی تصادفی

روش دیگر منظم‌سازی، منظم‌سازی تصادفی است که معمولاً از چهارچوب بیز در آن استفاده می‌شود. رهیافت منظم‌سازی تصادفی امکان اعمال داشت قبلی درباره مسئله را به طور کارا در اختیار قرار می‌دهد [۲]. در این رهیافت، همه پارامترها و متغیرهای مشاهده شده به صورت متغیر تصادفی در نظر گرفته می‌شوند و براساس اطلاعات موجود، در حیطه مسئله، یعنی همان داشت قبلی، به هریک از آنها یک توزیع احتمال متسابه می‌گردد که به آن، توزیع پیشین^۲ گفته می‌شود. سپس با استفاده از چهارچوب بیز، توزیع احتمالی متغیرهای مورد نظر براساس توزیع‌های احتمالی پیشین و توزیع احتمالی شرطی به دست می‌آید. این روش منظم‌سازی معمولاً جامع‌تر از روش منظم‌سازی قطعی است؛ به طوری که در حالتی که نویز اعمال شده در فرایند تصویربرداری از نوع نرمال جمع‌شونده باشد، رهیافت منظم‌سازی قطعی متناظر است با تخمین درست‌نمایی پیشینه که یک حالت خاص از رهیافت منظم‌سازی تصادفی است [۲۷]؛ از این‌رو، این رهیافت در بخش بعد با تفضیل بیشتر تشریح می‌شود.

۵. چهارچوب بیز برای حل مسئله SR

در این بخش، راه حل مسئله SR را با روش منظم‌سازی تصادفی در قالب مدل بیز بیان می‌کنیم. در ادامه، منظور از \mathbf{y} و \mathbf{d} به ترتیب، بردار همه تصاویر مشاهده شده و بردار همه حرکت‌هاست که از روی هم قرار گرفتن بردارهای \mathbf{y}_k و \mathbf{d}_k ایجاد می‌شوند. در مدل بیز، همه پارامترها و متغیرهای مشاهده شده به صورت متغیر تصادفی در نظر گرفته می‌شوند و براساس

$$P(y_k|x, d_k) \propto \exp \left[-\frac{1}{2\sigma^2} \|y_k - A H_k C(d_k)x\| \right] \quad (26)$$

با توجه به رابطه بالا و با فرض استقلال بین مشاهدات، توزیع شرطی تصاویر مشاهده شده برابر است با $P(y|x, d) = \prod_{k=1}^K P(y_k|x, d_k)$ که در آن، K عدد تصاویر LR است.

طبق رابطه (۲۶) برای محاسبه $P(y_k|x, d)$ نیاز است بردارهای حرکت یا جابجایی d_k تعیین شوند. برای تخمین بردارهای حرکت، فرض می‌کنیم به مجموعه تصاویر LR یعنی بردارهای حرکت، دسترسی داریم. اغلب روش‌های y که شامل y_1 تا y_K است، دسترسی داریم. ابتدا y_k ها را با استفاده از تخمین حرکت در تصاویر HR، ابتدا y_k ها یعنی تخمینی از x یا درون‌یابی بزرگ‌نمایی می‌کند تا u_k ها یعنی تخمینی از x یا همان تصویر HR به دست آید. برای محاسبه بردارهای جابجایی نیاز است تصویری مانند u_r به عنوان تصویر مرجع انتخاب شود (مثلاً تصویر اول) و سپس جابجایی بقیه تصاویر u_k نسبت به آن محاسبه گردد. این جابجایی را که در رابطه زیر صدق می‌کند، با $d_{k,r}(x, y)$ نمایش می‌دهیم.

$$\begin{aligned} u_k(x, y) &= u_r(x + d_{k,r}^x(x, y), \\ &\quad y + d_{k,r}^y(x, y)) \end{aligned} \quad (27)$$

که $d_{k,r}^y$ و $d_{k,r}^x$ مؤلفه‌های $d_{k,r}$ هستند.

حال با توجه به رابطه بالا، در این قسمت، تعدادی از مدل‌های حرکت یا تغییرات هندسی بیان می‌شود. ساده‌ترین مدل حرکت، مدل حرکت انتقالی^۳ است که می‌تواند بر روی کل تصویر یا ناحیه‌ای خاص از تصویر اعمال شود. این مدل به صورت $u_k(x, y) = u_r(x + p_1, y + p_2)$ بیان می‌شود. در کارهای انجام‌شده، چندین روش برای تخمین حرکت انتقالی بیان شده است که پرکاربردترین آن تطبیق بلاک سلسه‌مراتبی^۴ [۲۸] است. همبستگی زاویه^۵ نیز در اینجا مورد استفاده قرار گرفته است [۲۹].

مدل دیگر برای تغییرات هندسی که انعطاف‌پذیری بیشتری دارد، مدل جابجایی و چرخش به دور مبدأ است:

از تصویر HR باشد که در آن، q اندیس تکرار است. ابتدا تخمینی از بردار جابجایی با حل رابطه زیر به دست می‌آید:

$$\hat{d}^q = \arg \max_{\mathbf{d}} \{P(\hat{\mathbf{x}}^q, \mathbf{d})P(y|\hat{\mathbf{x}}^q, \mathbf{d})\} \quad (23)$$

سپس تصویر \mathbf{x} با فرض اینکه بردار جابجایی بالا دقیق است، طبق رابطه زیر به دست می‌آید:

$$\hat{\mathbf{x}}^q = \arg \max_{\mathbf{x}} \{P(\mathbf{x}, \hat{d}^q)P(y|\mathbf{x}, \hat{d}^q)\} \quad (24)$$

آنگاه اندیس q به $q+1$ تبدیل می‌شود و جواب‌های روابط فوق دوباره به دست می‌آیند. این روشی تا رسیدن به همگرایی تکرار می‌شود.

- **روش ترتیبی:** در این روش، فرض می‌شود \mathbf{d} یا مشخص است یا از قبل برآورده شده است. این مقدار \mathbf{d} را با $\bar{\mathbf{d}}$ نمایش می‌دهیم. حال طبق رابطه (۲۴) تصویر HR را به دست می‌آوریم که در آن، به جای \hat{d}^q باید \bar{d} را قرار داد. البته این روش برخلاف روش قبل، روشی تکراری نیست. از آنچه که در روش ترتیبی، تخمین بردار \mathbf{d} به صورت مجزا از تخمین تصویر HR انجام می‌شود، هرگونه خطأ در تخمین \mathbf{d} به مرحله تخمین HR منتقل می‌شود و در نتیجه، این روش خطأپذیری بیشتری نسبت به روش تناوبی دارد.

با توجه به اینکه $P(\mathbf{x}, \mathbf{d}) = P(\mathbf{x})P(\mathbf{d}|\mathbf{x})$ ، رابطه (۲۲) را می‌توان به شکل زیر نوشت:

$$\hat{\mathbf{x}}, \hat{\mathbf{d}} = \arg \max_{\mathbf{x}, \mathbf{d}} \{P(\mathbf{x})P(\mathbf{d}|\mathbf{x})P(y|\mathbf{x}, \mathbf{d})\} \quad (25)$$

طبق رابطه (۲۵) با داشتن سه توزیع $P(\mathbf{d}|\mathbf{x})$ ، $P(\mathbf{y}|\mathbf{x}, \mathbf{d})$ و $P(\mathbf{x})$ می‌توان تصویر HR را بازسازی کرد. در اینجا تابع احتمال شرطی $P(y|\mathbf{x}, \mathbf{d})$ و در ادامه، دو توزیع دیگر بررسی خواهد شد. تابع چگالی احتمال شرطی $P(y_k|\mathbf{x}, \mathbf{d})$ مربوط به تصویر y_k از رابطه (۱) و با توجه به نوع نویز به دست می‌آید؛ برای مثال، اگر نویز n_k در رابطه (۱) از نوع گوسی با میانگین صفر و واریانس^۲ σ^2 باشد، تابع چگالی احتمال شرطی زیر به دست می‌آید [۳]. فرض انواع دیگر نویز، توزیع شرطی متفاوتی را به دست خواهد داد.

کیفیت تصویر HR بازسازی شده تا حد زیادی به داشتن پیشین ما درباره ساختار \mathbf{x} که با چگالی احتمال $\mathbf{P}(\mathbf{x})$ بیان می‌شود، بستگی دارد. چندین انتخاب برای $\mathbf{P}(\mathbf{x})$ ممکن است. برخی از روش‌های SR به همه تصاویر HR ممکن احتمال یکسانی می‌دهند. این فرض متناظر است با پیشین بدون اطلاعات^۳ که نمایش آن به صورت $\propto \text{constant}$ است.

در این صورت، تصویر HR برابر است با:

$$\hat{\mathbf{x}} = \arg \max_{\mathbf{x}} \mathbf{P}(\mathbf{y}_k | \mathbf{x}, \mathbf{d}) \quad (32)$$

و با جایگذاری رابطه^{۲۶} در رابطه^{۳۲} تصویر HR به دست می‌آید.

علاوه بر مدل پیشین بدون اطلاعات، مدل دیگر برای $\mathbf{P}(\mathbf{x})$ براساس فرض هموار بودن تصاویر طبیعی است. یک راه برای مدل‌سازی این ایده، استفاده از توزیع پیشین زیر است:

$$\mathbf{P}(\mathbf{x}) \propto \exp \left[-\frac{\lambda}{2} \|\mathbf{Q}\mathbf{x}\|^2 \right] \quad (33)$$

که \mathbf{Q} نمایانگر یک فیلتر بالاگذر خطی است که تخمین‌هایی را که هموار نیستند، جریمه و λ واریانس توزیع را کنترل می‌کند و با آن نسبت عکس دارد.

در اینجا ذکر این نکته ضروری است که توزیع‌های احتمال پیشین و احتمال شرطی به پارامترهایی وابسته‌اند که آنها را با Ω نشان می‌دهیم. پارامترهای توزیع پیشین ابرپارامتر^۵ نامیده می‌شوند. اغلب مقدار این پارامترها علوم فرض می‌شود؛ هر چند در عمل ممکن است مقدار آنها مشخص نباشد. چهارچوب بیز این قابلیت را دارد که در صورت معلوم نبودن بتوان آن را تخمین زد. زمانی که Ω نامشخص باشد، می‌توان از چهارچوب سلسله‌مراتبی بیز استفاده کرد که در آن، دانش قبلی در مورد مقدار Ω مدل می‌شود. توزیع احتمال این ابرپارامترها، توزیع ابرپیشین^۶ نامیده می‌شود. این مدل‌سازی سلسله‌مراتبی، توزیع احتمال توأم کلی^۷ زیر را در پی دارد.

$$\mathbf{P}(\Omega, \mathbf{x}, \mathbf{d}, \mathbf{y}) = \mathbf{P}(\Omega) \mathbf{P}(\mathbf{x}, \mathbf{d} | \Omega) \mathbf{P}(\mathbf{y} | \Omega, \mathbf{x}, \mathbf{d}) \quad (34)$$

$$\mathbf{u}_k(x, y) = \mathbf{u}_r(x \cos \theta - y \sin \theta + a, x \sin \theta + y \cos \theta + b) \quad (28)$$

تخمین زاویه چرخش و جابجایی با استفاده از اولین جمله از بسط سری تیلور انجام شده است [۱۹ و ۳۰].

با پیچیده‌تر کردن مدل به تبدیل مستوی^۱ می‌رسیم که انتقال، چرخش و تغییر مقیاس از حالات خاص آن است. این مدل در [۱۹ و ۳۱] استفاده شده است. مدل دیگر تبدیل دو خطی^۲ است که در [۳۲] از آن استفاده شده است. همچنین از روش‌های مرتبط به الگوریتم Lucas-Kanade نیز برای تخمین جابجایی در این مدل‌ها استفاده شده است [۳۳].

تطبیق ویژگی^۳ نیز در تخمین جابجایی در SR استفاده شده است که می‌توان به الگوریتم تشخیص ویژگی Harris اشاره کرد [۳۴ و ۳۵]. همچنین مقایسه‌ای بین الگوریتم‌های مبتنی بر Lucas-Kanade و الگوریتم‌های تطبیق ویژگی برای SR در [۳۶] انجام شده است. علاوه بر روش‌های بیان شده در زمینه تخمین حرکت در مسئله SR، کارهایی با استفاده از روش‌های تخمین حرکت در مسئله Blind Deconvolution نیز در این زمینه صورت گرفته است [۳۷].

حال نوبت به بررسی مدل‌های پیشین برای تصاویر HR یعنی $\mathbf{P}(\mathbf{x})$ می‌رسد. با داشتن این توزیع، آنچه برای مدل‌سازی بیز در مسئله SR نیاز است، یعنی همه کمیت‌های سمت راست رابطه زیر فراهم خواهد بود:

$$\mathbf{P}(\mathbf{x}, \mathbf{d}, \mathbf{y}_k) = \mathbf{P}(\mathbf{x}) \mathbf{P}(\mathbf{d} | \mathbf{x}) \mathbf{P}(\mathbf{y}_k | \mathbf{x}, \mathbf{d}) \quad (29)$$

و تصویر HR با حل معادله زیر به دست می‌آید:

$$\hat{\mathbf{x}} = \arg \max_{\mathbf{x}} \mathbf{P}(\mathbf{x}) \mathbf{P}(\mathbf{d} | \mathbf{x}) \mathbf{P}(\mathbf{y}_k | \mathbf{x}, \mathbf{d}) \quad (30)$$

در اغلب روش‌هایی که در مقالات پیشنهاد شده، فرض شده است که روشنایی تصویر و بردارهای حرکت مستقل از هم هستند؛ یعنی $\mathbf{P}(\mathbf{d} | \mathbf{x}) = \mathbf{P}(\mathbf{d})$. با در نظر گرفتن این استقلال رابطه بالا به رابطه زیر تبدیل می‌شود:

$$\hat{\mathbf{x}} = \arg \max_{\mathbf{x}} \mathbf{P}(\mathbf{x}) \mathbf{P}(\mathbf{y}_k | \mathbf{x}, \mathbf{d}) \quad (31)$$

4. Non-informative Prior

5. Hyperparameter

6. Hyperprior Distribution

7. Joint Global Probability Distribution

1. Affine Transform

2. Bilinear Transformation

3. Feature Matching

تولیدشده توسط یک زنجیر مارکوف، توزیع پسین را تقریب می‌زنند. ساده‌ترین مثال برای MCMC نمونه‌بردار گیز است. زمانی که نمونه‌ها جمع‌آوری شد، می‌توان از آن‌ها جهت یافتن خواص توزیع و پیشینه‌کردن آن استفاده کرد.

۶. جمع‌بندی

تهیه تصاویر با تفکیک‌پذیری زیاد در کاربردهای مختلف، از ارزش بالایی برخوردار است. برای دستیابی به تصاویری با تفکیک‌پذیری زیاد، دو رهیافت سخت‌افزاری و نرم‌افزاری وجود دارد. با توجه به محدودیت‌های سخت‌افزار و نیز برای جلوگیری از افزایش هزینه، رهیافت نرم‌افزاری مورد توجه بسیاری از محققان قرار گرفته است. این رهیافت نرم‌افزاری که ابرتفکیک‌پذیری نام دارد، روشی است که توسط آن می‌توان با استفاده از یک یا چند تصویر با تفکیک‌پذیری کم از صحنه، تصویری با تفکیک‌پذیری زیاد از آن صحنه ایجاد کرد.

روش‌های گوناگونی برای مسئله ابرتفکیک‌پذیری پیشنهاد شده است که به‌علت بدمطربودن این مسئله، روش‌های منظم‌سازی از جایگاه ویژه‌ای برخوردار هستند. در این روش‌ها از اطلاعات موجود درباره تصاویر برای منظم‌سازی استفاده می‌شود. روش‌های منظم‌سازی به دو دسته قطعی و تصادفی تقسیم می‌شوند. در روش منظم‌سازی تصادفی، همه پارامترها و متغیرهای مشاهده شده به صورت متغیر تصادفی در نظر گرفته می‌شوند و اطلاعات موجود درباره هریک به صورت یک توزیع احتمال پیشین به آن متنسب می‌شود. روش منظم‌سازی تصادفی با استفاده از چهارچوب بیز توزیع احتمالی متغیرهای مورد نظر را براساس توزیع‌های احتمال پیشین و توزیع احتمال شرطی به‌دست می‌دهد. همچنین چهارچوب بیز این قابلیت را دارد که پارامترهای نامعلوم توزیع‌های مذکور را با استفاده از داده‌های مسئله مشخص کند.

هرچند رهیافت ابرتفکیک‌پذیری مبتنی بر یادگیری در دسته روش‌های منظم‌سازی قرار ندارد، اساساً این روش هم از نوعی منظم‌سازی استفاده می‌کند. درواقع، دیکشنری‌های مورد استفاده در این روش، به نوعی اطلاعاتی درباره تصاویر به الگوریتم وارد می‌کند. با توجه به نتایج امیدبخش این روش و روش

که $\mathbf{P}(\mathbf{y}|\Omega, \mathbf{x}, \mathbf{d})$ درست‌نمایی مشاهدات^۱ نام دارد. عموماً \mathbf{x} و \mathbf{d} با معلوم‌بودن مقدار Ω مستقل فرض می‌شوند:

$$\mathbf{P}(\mathbf{x}, \mathbf{d}|\Omega) = \mathbf{P}(\mathbf{x}|\Omega)\mathbf{P}(\mathbf{d}|\Omega) \quad (35)$$

تحت چهارچوب سلسه‌مراتبی بیز، مسئله SR تبدیل به یافتن احتمال پسین به صورت زیر می‌شود:

$$\mathbf{P}(\Omega, \mathbf{x}, \mathbf{d}|\mathbf{y}) \propto \mathbf{P}(\Omega)\mathbf{P}(\mathbf{x}, \mathbf{d}|\Omega)\mathbf{P}(\mathbf{y}|\Omega, \mathbf{x}, \mathbf{d}) \quad (36)$$

در قسمت‌های قبل، توزیع‌های $\mathbf{P}(\mathbf{x}, \mathbf{d}|\Omega)$ و $\mathbf{P}(\mathbf{y}|\Omega, \mathbf{x}, \mathbf{d})$ با فرض معلوم‌بودن Ω بررسی شد. در اصطلاحات مربوط به مدل‌سازی سلسه‌مراتبی بیز، فرمول‌بندی $\mathbf{P}(\Omega)$ مرحله دوم^۲ را تشکیل می‌دهد؛ مرحله اول فرمول‌بندی $\mathbf{P}(\mathbf{y}|\Omega, \mathbf{x}, \mathbf{d})$ و $\mathbf{P}(\mathbf{x}, \mathbf{d}|\Omega)$ است.

در بسیاری از کارهای انجام‌شده، زمانی که Ω نامعلوم است، از مدل $\mathbf{P}(\Omega) = \text{constant}$ استفاده شده است. روش نیست که این بهترین انتخاب برای توزیع $\mathbf{P}(\Omega)$ نیست. در [۳] مدل‌های دیگری برای ابر پیشین بیان شده است. بعد از انتخاب $\mathbf{P}(\Omega)$ ، یک راه برای حل مسئله SR استفاده از^۳ MAP است:

$$\{\hat{\mathbf{x}}, \hat{\mathbf{d}}, \hat{\Omega}\}_{\text{MAP}} = \arg \max_{\mathbf{x}, \mathbf{d}, \Omega} \mathbf{P}(\mathbf{x}, \mathbf{d}, \Omega|\mathbf{y}) \quad (37)$$

از الگوریتم بیشینه‌سازی امید^۴ که روش متداولی برای حل تکراری مسائل MAP و ML است، نیز برای حل مسئله SR استفاده شده است [۳۸ و ۳۹]. در مسائلی که به‌علت مشخص‌بودن توزیع پسین نمی‌توان از EM استفاده کرد، روش‌های بیز تغییراتی^۵ که تعمیمی از الگوریتم EM هستند، با تقریب‌زدن $\mathbf{P}(\mathbf{x}, \mathbf{d}, \Omega|\mathbf{y})$ به توزیعی ساده‌تر مشکل را برطرف می‌کنند. روش بیز تغییراتی در [۲] استفاده شده است.

در نهایت، زمانی که راه حل تحلیلی در دست نیست، متداول‌ترین رهیافت برای SR شبیه‌سازی توزیع پسین، یعنی رابطه^۶ (۳۶) است. از لحاظ نظری، این روش بر روی مدل‌هایی در فضاهای چندبعدی و با پیچیدگی دلخواه، اجرایشدنی است. روش‌های^۷ MCMC با استفاده از آمار نمونه‌های

-
1. Likelihood of Observation
 2. Second stage
 3. Maximum a Posteriori
 4. Expectation Maximization (EM)
 5. Variational Bayesian
 6. Markov Chain Monte Carlo (MCMC)

در خصوص تصاویر و به کارگیری این اطلاعات به طور کارا در الگوریتم است.

منظمسازی تصادفی، می‌توان نتیجه گرفت موفقیت الگوریتم‌های ابرتفکیک‌پذیری در گرو استخراج و مدل‌کردن اطلاعات مفید

مراجع

- [1] Park, Sung Cheol, Min Kyu Park, and Moon Gi Kang. "Super-resolution image reconstruction: a technical overview." *Signal Processing Magazine, IEEE* 20.3 (2003): 21-36.
- [2] Babacan, S. Derin, Rafael Molina, and Aggelos K. Katsaggelos. "Variational Bayesian super resolution." *Image Processing, IEEE Transactions on* 20.4 (2011): 984-999.
- [3] Katsaggelos, Aggelos K., Rafael Molina, and Javier Mateos. "Super resolution of images and video." *Synthesis Lectures on Image, Video, and Multimedia Processing* 1.1 (2007): 1-134.
- [4] Z. Wang and F. Qi, "On ambiguities in super-resolution modeling", *IEEE Signal Process. Lett.*, vol. 11, pp. 678–681, 2004.
- [5] C. W. Groetsch, *the Theory of Tikhonov Regularization for Fredholm Equations of the First Kind*, Pitman, Boston, 1984.
- [6] C. T. H. Baker, *the Numerical Treatment of Integral Equations*, Clarendon Press, Oxford, UK, 1977.
- [7] L. M. Delves and J. Walsh (Eds.), *Numerical Solution of Integral Equations*, Clarendon Press, Oxford, 1974.
- [8] L. M. Delves and J. L. Mohamed, *Computational Methods for Integral Equations*, Cambridge University Press, Cambridge, UK, 1985.
- [9] Hansen, Per Christian. "Deconvolution and regularization with Toeplitz matrices."
- [10] Vogel, Curtis R. *Computational methods for inverse problems*. Vol. 10. Siam, 2002.
- [11] Cheney, E. Elliott Ward, and David Ronald Kincaid. *Numerical mathematics and computing*. Cengage Learning, 2012.
- [12] Hansen, Per Christian. *Rank-deficient and discrete ill-posed problems: numerical aspects of linear inversion*. Vol. 4. Siam, 1998.
- [13] Colin Fox, Geoff K. Nicholls, Sze M. Tan, "An Introduction To Inverse Problems", Course notes for ELEC 404, 2010 Edition.
- [14] A. N. Tikhonov & V. Y. Arsenin, *Solutions of Ill-Posed Problems*, Winston & Sons, Washington, D.C., 1977.
- [15] Tian, Jing, and Kai-Kuang Ma. "A survey on super-resolution imaging." *Signal, Image and Video Processing* 5.3 (2011): 329-342.
- [16] R.Y. Tsai and T.S. Huang, "Multiple frame image restoration and registration," in *Advances in Computer Vision and Image Processing*. Greenwich, CT:JAI Press Inc., (1984): 317-339.
- [17] Ur, Hanoch, and Daniel Gross. "Improved resolution from subpixel shifted pictures." *CVGIP: Graphical Models and Image Processing* 54.2 (1992): 181-186.
- [18] Bose, Nirmal K., and Nilesh A. Ahuja. "Superresolution and noise filtering using moving least squares." *Image Processing, IEEE Transactions on* 15.8 (2006): 2239-2248.
- [19] Irani, Michal, and Shmuel Peleg. "Improving resolution by image registration." *CVGIP: Graphical models and image processing* 53.3 (1991): 231-239.
- [20] Patti, Andrew J., M. Ibrahim Sezan, and A. Murat Tekalp. "Superresolution video reconstruction with arbitrary sampling lattices and nonzero aperture time." *Image Processing, IEEE Transactions on* 6.8 (1997): 1064-1076.
- [21] Hertzmann, Aaron, et al. "Image analogies." Proceedings of the 28th annual conference on Computer graphics and interactive techniques. ACM, 2001.
- [22] Wang, Jinjun, Shenghuo Zhu, and Yihong Gong. "Resolution enhancement based on learning the sparse association of image patches." *Pattern Recognition Letters* 31.1 (2010): 1-10.
- [23] Kim, Kwang In, and Younghée Kwon. "Single-image super-resolution using sparse regression and natural image prior." *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 32.6 (2010): 1127-1133.
- [24] Yang, Jianchao, et al. "Image super-resolution via sparse representation." *Image*

- Processing, IEEE Transactions on 19.11 (2010): 2861-2873.
- [25] Tang, Yi, et al. "Greedy regression in sparse coding space for single-image super-resolution." Journal of Visual Communication and Image Representation 24.2 (2013): 148-159.
- [26] Farsiu, Sina, et al. "Advances and challenges in super-resolution." International Journal of Imaging Systems and Technology 14.2 (2004): 47-57.
- [27] M. Elad, A. Feuer. "Restoration of single super-resolution image from several blurred, noisy and down-sampled measured images" IEEE Trans. Image Process 6(1997): 1646 – 1658
- [28] Borman, Sean, Mark Robertson, and Robert L. Stevenson. "Block-matching sub-pixel motion estimation from noisy, under-sampled frames-an empirical performance evaluation." SPIE Visual Communications and Image Processing. Vol. 3653. No. 2. 1999.
- [29] Tekalp, A. Murat, and A. Murat Tekalp. Digital video processing. Vol. 1. Upper Saddle River, NJ: Prentice Hall PTR, 1995.
- [30] Keren, Danny, Shmuel Peleg, and Ran Brada. "Image sequence enhancement using sub-pixel displacements." Computer Vision and Pattern Recognition, 1988. Proceedings CVPR'88., Computer Society Conference on. IEEE, 1988.
- [31] Irani, Michal, and Shmuel Peleg. "Motion analysis for image enhancement: Resolution, occlusion, and transparency." Journal of Visual Communication and Image Representation 4.4 (1993): 324-335.
- [32] Cheeseman, Peter, et al. "Super-resolved surface reconstruction from multiple images." Maximum Entropy and Bayesian Methods. Springer Netherlands, 1996. 293-308.
- [33] Baker, Simon, and Iain Matthews. "Lucas-kanade 20 years on: A unifying framework." International Journal of Computer Vision 56.3 (2004): 221-255.
- [34] Capel, David. Image mosaicing and super-resolution. Springer, 2004.
- [35] Capel, David, and Andrew Zisserman. "Computer vision applied to super resolution." Signal Processing Magazine, IEEE 20.3 (2003): 75-86.
- [36] Lim, Douglas. Achieving accurate image registration as the basis for super-resolution. Diss. Master Thesis, The School of Computer Science and Software Engineering, The University of Western Australia, 2003.
- [37] Šroubek, F., and Jan Flusser. "Resolution enhancement via probabilistic deconvolution of multiple degraded images." Pattern Recognition Letters 27.4 (2006): 287-293.
- [38] Tom, Brian C., and Aggelos K. Katsaggelos. "Reconstruction of a high resolution image from multiple degraded mis-registered low resolution images." Proc. SPIE. Vol. 2308. 1994.
- [39] Tom, Brian C., and Aggelos K. Katsaggelos. "Reconstruction of a high-resolution image by simultaneous registration, restoration, and interpolation of low-resolution images." Image Processing, 1995. Proceedings., International Conference on. Vol. 2. IEEE, 1995.
- [40] Andrieu, Christophe, et al. "An introduction to MCMC for machine learning." Machine learning 50.1-2 (2003): 5-43.
- [41] Trefethen, Lloyd N., and David Bau III. Numerical linear algebra. Vol. 50. Siam, 1997.
- [42] Bishop, Christopher M. Pattern recognition and machine learning. Vol. 1. New York: Springer, 2006.