

حذف الگوهای مویر با استفاده از ترکیب شبکه های عصبی کانولوشن و

حافظه طولانی کوتاه مدت

پژوهشگر:

استاد راهنما:

استاد مشاور:

خرداد ۱۴۰۲

عنوان	شماره صفحه
فصل ۱: کلیات تحقیق	۷
۱-۱ مقدمه	۸
۲-۱ بیان مساله	۸
۳-۱ اهمیت و ضرورت انجام تحقیق	۱۱
۴-۱ نوآوری تحقیق	۱۲
۵-۱ اهداف تحقیق	۱۲
۶-۱ هدف کاربردی	۱۲
۷-۱ فرضیه پژوهش	۱۳
۸-۱ سوالات پژوهش	۱۳
۹-۱ روش و مراحل انجام تحقیق	۱۳
۱۰-۱ واژه ها و اصطلاحات تخصصی	۱۵
۱۱-۱ روش و ابزار گردآوری اطلاعات (در صورت لزوم)	۱۶
۱۲-۱ روش ها و ابزار تجزیه و تحلیل داده ها (در صورت لزوم)	۱۶
۱۳-۱ جمع بندی	۱۶
فصل ۲: مفاهیم اولیه و پیشینه پژوهش	۱۷
۱-۲ مقدمه	۱۸
۲-۲ معرفی پدیده ی مارم	۱۸
۳-۲ تاریخچه ی علمی مارم	۲۰
۴-۲ روش اندازه گیری تغییر فاز: [۲۷]	۲۲
۱-۴-۲ مویر سایه ای! [۲۸]	۲۲
۲-۴-۲ مویر انعکاسی: [۲۹]	۲۴
۳-۴-۲ مویر پروژکتوری [۳۰]	۲۹
۵-۲ پیشینه پژوهش	۳۰
۶-۲ جمع بندی	۳۲
فصل ۳: روش پیشنهادی	۳۴

۳۵	۱-۳ مقدمه.....
۳۵	۲-۳ شبکه های عصبی کانولوشن(CNN).....
۴۰	۱-۲-۳ لایه کانولوشن:.....
۴۱	۲-۲-۳ Pooling لایه:.....
۴۲	۳-۲-۳ لایه تماما متصل شده.....
۴۲	۳-۳ معماری شبکه های عصبی کانولوشن.....
۴۳	۱-۳-۳:LENET.....
۴۳	3-3-2 ALEXNET:.....
۴۴	۳-۳-ZF۳:.....
۴۵	۴-۳-۳:GOOGLENET.....
۴۵	۵-۳-۳:VGGNET.....
۴۶	۶-۳-۳:RESNET.....
۴۷	3-4 آموزش شبکه عصبی کانولوشن.....
۴۸	۱-۴-۳ محاسبه ی گرادیان خطای شبکه ی CNN.....
۴۹	۲-۴-۳ الگوریتم های آموزشی CNN.....
۵۰	۵-۳ حافظه کوتاه مدت طولانی.....
۵۱	۶-۳ LSTM و GRU به عنوان یک راه حل.....
۵۲	۷-۳ مرور شبکه های عصبی بازگشتی.....
۶۰	LSTM۸-۳.....
۶۱	۹-۳ جمع بندی.....
۶۲	فصل ۴ : نتایج و بحث
۶۳	۱-۴ مقدمه.....
۶۳	۲-۴ نتایج و تحلیل.....
۶۹	۳-۴ جمع بندی.....
۷۰	فصل ۵ : نتیجه گیری
۷۱	۱-۵ نتیجه گیری.....
۷۱	۲-۵ پیشنهادات.....

شماره صفحه	عنوان
۱۹.....	شکل ۱-۲: طرح ماره ی ایجاد شده از روی هم افتادگی دو ساختار دوره ای.....
۲۳.....	شکل ۲-۲: هندسه روش سایه مویر.....
۲۴.....	شکل ۳-۲: نمونه ای از سایه مویر.....
۲۵.....	شکل ۴-۲: هندسه روش مویر انعکاسی.....
۲۵.....	شکل ۵-۲: پیکر بندی بیم یک سر گیردار.....
۲۶.....	شکل ۶-۲: چهار قدم برای تکنیک اندازه گیری تغییر فاز بر روی بیم یک سر گیردار.....
۲۷.....	شکل ۷-۲: Wrapped phase map.....
۲۸.....	شکل ۸-۲: Unwrapped phase map.....
۲۹.....	شکل ۹-۲: استرس موجود بر روی بیم.....
۳۰.....	شکل ۱۰-۲: هندیه روش مویر پروژکتوری.....
۳۶.....	شکل ۱-۳: پردازش به صورت گرافیکی.....
۳۶.....	شکل ۲-۳: معماری شبکه های عصبی کانولوشن.....
۳۷.....	شکل ۳-۳: ساختار شبکه ی کانولوشن عمیق.....
۴۰.....	شکل ۴-۳: لایه های مختلف شبکه کانولوشن.....
۴۰.....	شکل ۵-۳: عملیات لایه کانولوشن.....
۴۱.....	شکل ۶-۳: عملیات max pooling.....
۴۲.....	شکل ۷-۳: ساختار یک نورون معمولی و مصنوعی.....
۴۳.....	شکل ۸-۳: شبکه LENET.....
۴۴.....	شکل ۹-۳: شبکه ALEXNET.....
۴۴.....	شکل ۱۰-۳: شبکه ZF.....
۴۵.....	شکل ۱۱-۳: شبکه GOOGLNET.....
۴۶.....	شکل ۱۲-۳: شبکه VGGNet.....
۴۶.....	شکل ۱۳-۳: شبکه RESNET.....
۴۹.....	شکل ۱۴-۳: ساختار شبکه عصبی کانولوشن نمونه به ۶ لایه.....
۵۱.....	شکل ۱۵-۳: LSTM و GRU.....
۵۲.....	شکل ۱۶-۳: پردازش یک به یک دنباله ها.....
۵۳.....	شکل ۱۷-۳: عبور از حالت پنهان به مرحله بعدی.....
۵۵.....	شکل ۱۸-۳: تغییرات برداری بدون تانژانت.....

- شکل ۳-۱۹: تغییرات برداری با تانژانت..... ۵۵
- شکل ۳-۲۰: عملیات گیت فراموشی..... ۵۷
- شکل ۳-۲۱: عملیات گیت ورودی..... ۵۸
- شکل ۳-۲۲: محاسبه سلول حالت..... ۵۹
- شکل ۳-۲۳: عملیات گیت خروجی..... ۶۰
- شکل ۳-۲۴: سلول LSTM و عملیات آن..... ۶۱
- شکل ۴-۱: میانگین خطای پیکسلی MSE روش های مختلف و تعداد دوره ها..... ۶۵
- شکل ۴-۲: مقایسه بین شبکه عمیق چند رزولوشن ما و سایر روش های پیشرفته برای بازیابی تصویر، از جمله Photoshop Descreen، IRCNN، U-Net، VDSR، DnCNN، pyramidCNN، RTV و SDF..... ۶۷
- شکل ۴-۳: مثال دیگری که در آن U-Net امتیاز PSNR بالاتری ایجاد می کند اما اثر حذف مویر بدتری دارد..... ۶۸
- شکل ۴-۴: مطالعه کاربر در مورد بازیابی الگوی مویر..... ۶۹

فهرست جداول

عنوان	شماره صفحه
جدول ۱-۳: الگوریتم های آموزشی مورد استفاده برای شبکه ی کانولوشن پیشنهادی.....	۴۹
جدول ۱-۴: مقایسه کمی بین روش های شرکت در مجموعه آزمون ما با معیارهای مختلف. روش ما به وضوح از روش های دیگر بهتر عمل می کند.....	۶۵
جدول ۲-۴: تعداد متغیرها در یادگیری.....	۶۸


فصل ١: کلیات تحقیق

۱-۱ مقدمه

در این فصل به بیان مقدمات مورد نیاز جهت شناخت ابعاد مختلف انجام این پژوهش پرداخته شده است. مواردی از جمله حذف الگوهای مویر با استفاده از ترکیب شبکه های عصبی کانولوشن و حافظه طولانی کوتاه مدت، بیان موضوع اصلی تحقیق، اهداف، فرضیات و ... نیز در این فصل مورد بررسی قرار گرفته است.

۱-۲ بیان مساله

الگوهای مویر نوعی الگوی تداخل در مقیاس بزرگ است که می توان با روی هم قراردادن دو مجموعه از توری های تکراری [۱] تولید کرد. برای این که الگوی تداخل مویر ظاهر شود، دو توری نباید به طور کامل روی هم دیگر منطبق باشند و همین طور باید از نظر اندازه، زاویه یا فاصله متفاوت باشند (همان طور که در شکل ۱ مشاهده می شود). بسیاری از انواع الگوهای مویر در زندگی واقعی وجود دارند که می توان آن ها را مشاهده کرد، از جمله آن هایی که از خطوط راه راه در آن به وجود می آیند، نظیر پارچه های لباس یا معماری. یکی از رایج ترین الگوهای مویر زمانی رخ می دهد که از صفحه نمایش با دوربین های دیجیتال عکس گرفته شود. هر دو تصویربرداری عناصر دوربین و صفحه نمایش را می توان به عنوان توری در شکل ۱ می توان مشاهده کرد:



و

ه

د

ج

ب

الف

شکل ۱: الف) شبکه مربعی؛ ب) شبکه مربعی به دست آمده است با چرخش ۲۰ درجه در خلاف جهت عقربه های ساعت از ج) همپوشانی بین الف) و ب)؛ د) و ه) دایره های متحد المركز؛ و) همپوشانی بین د) و ه).

در زمان عکس برداری، از شبکه‌ی دوربین برای برهم نهی استفاده می‌کنیم، شبکه صفحه نمایش که منجر به ظاهر شدن الگوی مویر می‌شود که در آرایه پیکسلی نمایشگر کریستال مایع (LCD) با آن تداخل دارد، به عبارت دیگر آرایه دستگاه متصل به شارژ دوربین (CCD) با صفحه نمایش تداخل دارند که منجر به نسل الگوی مویر می‌شود.

اثر مویر نه تنها الگوهای هندسی جالب و زیبایی را ایجاد می‌کند بلکه نقشی حیاتی در ارزیابی توری‌های کپی [۲]، مترولوژی [۳]، میکروسکوپ روشنایی ساختاریافته [۴] و غیره ایفا می‌کند. با این حال، با پیشرفت تکنولوژی و رواج دوربین های دیجیتال پیشرفته این پدیده ممکن است کیفیت بصری تصاویر گرفته شده از صفحه نمایش را کاهش دهد. شکل ۲ نمونه‌ای از مقایسه بین تصویر نهفته و نسخه تخریب شده از آن را نشان می‌دهد. بدیهی است که در شکل (۲-الف) رنگ زنده و خطوط مشخصی دارد. در مقابل آن، در شکل (۲-ب) اطلاعات فضایی و طیفی جزئی از تصویر تخریب شده است، که کاربرد آن را در پردازش بعدی محدود می‌کند، مانند تقسیم‌بندی و تشخیص شی. بنابراین، پس پردازش برای تکنیک‌هایی که می‌توانند به طور خودکار الگوی مویر را از حالت تخریب شده حذف کنند، موثر است.



(ب)



(الف)

شکل ۲: نمونه الگوی مویر: (الف) تصویری با الگوی مویر (ب) نهفته مربوطه تصویر

برخی از الگوریتم‌ها برای حذف الگوی مویر در مراجع مختلف [۵-۹] ارائه شده‌اند. برخی از آن‌ها بر اساس حوزه فضایی هستند. درونیابی به دلیل سادگی آن، شامل درونیابی دو خطی و الگوریتم‌های رنگ-سنجی و گرادیان است. با این حال، الگوهای مویر متنوع هستند، اشکالی مانند نوارهای پهن و بلوک‌های پراکنده از خویش به جا می‌گذارند و ممکن است به طور گسترده در عکس توزیع شوند. علاوه بر این، آن‌ها می‌توانند باعث اعوجاج رنگ شده باشند. همان‌طور که در شکل (۲-الف) نشان داده شده است، رویکردهای ذکر شده ممکن است برای همه موارد قابل اجرا نباشد.

به‌طور کلی، اگرچه روش‌های موجود می‌توانند به برخی نتایج قابل قبول دست یابند، اکثر آن‌ها به شرایط سختی نیاز دارند. سایر روش‌های خودکار نمی‌توانند یک تصویر واضح را با جزئیات حفظ شده یا برای تصاویر با پیچیدگی بالا بازیابی کنند و نظریه هم‌چنان نامشخص است. در واقع، در بسیاری از برنامه‌های کاربردی دنیای واقعی، ما هیچ دانش قبلی در مورد تصاویر تخریب شده و به خوبی تعریف شده نداریم. نتایج با کیفیت بالا و سریع مورد نظر است. بنابراین، مشکل این است که چگونه حذف الگوی مویر به طور موثر و خودکار از یک تصویر واحد بدون از دست دادن اطلاعات طیفی و مکانی باید انجام شود. یک روش

جدید برای حذف الگوی مویر پیشنهاد شده است که تصویر گرفته شده توسط دوربین مدل خود را با مشخص کردن الگوی مویر ساخته می شود.

۱-۳ اهمیت و ضرورت انجام تحقیق

محبوبیت گوشی‌های هوشمند با دوربین‌های دیجیتال، عکاسی با گوشی‌های هوشمند را به یک فعالیت روزانه مهم تبدیل کرده است. الگوهای Moiré می‌توانند به راحتی هنگام عکس‌برداری از اشیاء با بافت غنی ظاهر شوند، مانند صفحه نمایش کامپیوتر، به شدت کیفیت تصویر را کاهش می‌دهد و باعث اختلال از نظر بصری برای افراد می‌شود. پاک‌سازی تصویر یک کار مهم بازیابی تصویر است که هدف آن حذف الگوهای مویر و آشکار کردن تصویر تمیز است [۱۴، ۱۵].

تخریب تصویر که هدف آن حذف تصاویر مویر ناخواسته است، یک مشکل معمولی بازیابی تصویر است. تخریب تصویر با این حال، چالش برانگیزتر از برخی دیگر از وظایف بازیابی تصویر، مانند حذف نویز تصویر و وضوح تصویر فوق العاده است. در یک طیف فرکانس moiré گسترده است و هر دو بخش فرکانس پایین و فرکانس بالا را پوشش می‌دهد. در مقابل، حذف نویز تصویر و وضوح تصویر فوق العاده تنها به پردازش بخشی از تصاویر با فرکانس بالا نیاز دارند. از طرف دیگر، حذف نویز تصویر و وضوح تصویر فوق العاده معمولاً ثابت با تخریب نسبتاً ثابت در تصاویر هستند، در حالی که بافت مویر پویا و با وضوح سنسور، فاصله و جهت متفاوت است. طیف فرکانس وسیع و بافت پویا مویر دو چالش اصلی را در تخریب تصویر ایجاد می‌کند [۱۴].

حذف الگوی Moiré یکی از کارهای مهم بازیابی تصویر در بینایی سطح پایین است. متفاوت از برخی موضوعات تحقیقاتی بازیابی تصاویر، مانند حذف نویز تصویر [۱۶، ۱۷]، وضوح تصویر فوق العاده [۱۸]، رفع تاری تصویر و غیره تخریب تصویر تاکنون مورد توجه کمی قرار گرفته است.

۴-۱ نوآوری تحقیق

استفاده از ترکیب روش‌های شبکه‌های عصبی کانولوشن (CNN) و حافظه طولانی کوتاه مدت (LSTM) برای حذف الگوهای مویر در تصاویر نوآوری این پژوهش می‌باشد و رویکردهایی که آن را در مدیریت طبقه بندی ویژگی‌های مویر بهبود بخشیده است و همچنین می‌توان به مهار و غلبه بر ویژگی‌های اساسی مویر هم به نحوی اشاره کرد.

۵-۱ اهداف تحقیق

هدف اصلی:

✓ ارائه یک سامانه حذف الگو مویر از تصاویر با استفاده از شبکه عصبی کانولوشن

اهداف فرعی:

- ✓ بهبود شناسایی الگوهای مویر
- ✓ افزایش دقت حذف الگو مویر نسبت به روش‌های موجود در ادبیات
- ✓ محفوظ ماندن جزئیات تصاویر بعد از بازیابی
- ✓ داشتن وضوح بالایی از تصاویر بعد از مویرزدایی

۶-۱ هدف کاربردی

برای حذف الگوهای مویر می‌توان از این نرم افزار استفاده کنند، از آن جایی که حذف مویر با استفاده از نرم افزارهایی نظیر فتوشاپ امکان پذیر هست اما مشکلات و تاخیر زمانی خاص خودش را دارد و ما می‌توانیم با شبیه سازی و شناسایی سیستم‌ها و همین‌طور با یادگیری مدل ساخته شده در شبیه سازی مویر را حذف نموده و مویر در عکاسی‌هایی که به صورت بد جلوه می‌یابد، در دنیای دیجیتال جایگاه خوبی به دست آورد. می‌توان این

الگوریتم ذکر شده را روی دوربین های دیجیتال قرار داده و به صورت خودکار اقدامات حذف تصاویر و بازیابی را انجام دهد.

۷-۱ فرضیه پژوهش

۱. مویر معمولاً در شکل ظاهر می شود، نوارهای رنگی که به دلیل زاویه به طور قابل توجهی تغییر می کند.
۲. توزیع های الگوی مویر و جزئیات تصویر در شاخه های رزولوشن مختلف همه ناهمسان هستند.
۳. عامل چالش برانگیزی الگوهای مویر بافت پویا و تحرک پذیر آن ها است.
۴. شدت امواج مویر بسته به میزان تداخل فرکانسی دارند.
۵. شبکه های عصبی عمیق به عنوان یک سیستم یادگیری با هدف شناسایی استخراج ویژگی ها در سیستم حذف مویر توانایی بالایی را ارائه می دهد.
۶. تضمین رویکرد پیشنهادی با استفاده از معیارهای ارزیابی و مقایسه آنها با روش های پیشین

۸-۱ سوالات پژوهش

- آیا توزیع های الگوی مویر و جزئیات تصویر در شاخه های رزولوشن مختلف همه ناهمسان هستند؟
- چرا عامل چالش برانگیزی الگوهای مویر بافت پویا و تحرک پذیر آن هاست؟
- چرا شدت امواج مویر بسته به میزان تداخل فرکانسی دارند؟

۹-۱ روش و مراحل انجام تحقیق

در آغار این فعالیت پژوهشی، مطالعات اولیه با استفاده از مقالات معتبر در مجلات بین المللی مانند IEEE، Elsevier و غیره برای موضوع صورت گرفته است (جمع آوری اطلاعات). بعد از انجام مطالعات اقدام به نگارش پروپوزال نموده ایم. بعد از آن که زمان تایید پروپوزال فرارسید، اقدام به نگارش فصول پایان نامه می

نمایم و از آنجا که روش پیشنهادی باید پیاده سازی شود با استفاده از زبان برنامه نویسی پایتون روش پیشنهادی پیاده سازی خواهد شد. مراجع با نرم افزار endnot رفرنس گذاری شدند.

۱-۱۰ واژه ها و اصطلاحات تخصصی

Moier: یک کلمه‌ی فرانسوی به معنی موج‌دار است. مویر (Moire) در عکاسی زمانی رخ می‌دهد که

یک منظره یا شیء که از آن عکس گرفته شده، دارای الگوهای تکراری مانند خط، نقطه و امثال آن باشد.

Moier Pattern: الگوهای موج‌دار مویر هستند که بر اثر پدیده‌ی مویر به وجود می‌آیند و دارای

الگوهای جذاب و زیبایی هستند.

CNN (شبکه‌های عصبی کانولوشن): نوع خاصی از شبکه‌های عصبی می‌باشد که برای شناسایی و طبقه

بندی تصویر استفاده می‌شود. آنها جدا از ایجاد دید در اتومبیل‌های خودران و روبات‌ها، در زمینه‌هایی مانند

شناسایی اشیاء، چهره‌ها و علائم راهنمایی و رانندگی بسیار مهارت دارند.

در یادگیری عمیق، یک شبکه‌های عصبی کانولوشن دسته‌ای از شبکه‌های عصبی عمیق است که معمولاً برای

تجزیه و تحلیل تصاویر بصری استفاده می‌شود. آن‌ها دارای برنامه‌هایی در تشخیص تصویر و فیلم، طبقه‌بندی

تصویر، تجزیه و تحلیل تصویر پزشکی، پردازش زبان طبیعی هستند.

بازیابی تصویر: جستجو، کاوش و بازیابی تصاویر از یک پایگاه داده بزرگ دیجیتال، در بازیابی تصویر،

تعدادی تصویر با خصوصیات مشابه از پایگاه داده انتخاب می‌شود و شبیه‌ترین آن‌ها برای کاربر بازیابی می‌شود.

شاخص‌گذاری دقیق تصاویر و انتخاب معیار شباهت مناسب، تاثیر قابل‌ملاحظه‌ای روی عملکرد سیستم بازیابی

تصویر می‌گذارد.

CFA: مخفف عبارت "color filter array" به معنی آرایه فیلتر رنگی است. آرایه یا موزاییک فیلتر

رنگی در دوربین‌های مدار بسته، موزاییکی از فیلترهای رنگی ریز (معمولاً قرمز، سبز و آبی) است، که

پیکسل‌های تشکیل دهنده سنسور را پوشش می‌دهند تا اطلاعات رنگی را ثبت کند.

LCD: مخفف Liquid Crystal Display و به معنای صفحه نمایشی با محلول کریستال مایع است. کشف

کریستال های مایع در سال ۱۸۸۸ میلادی توسط گیاه شناس استرالیایی به نام فردریک راینایزر صورت گرفت.

۱-۱۱ روش و ابزار گردآوری طلاعات (در صورت لزوم)

با استفاده از مقالات معتبر در مجلات بین المللی مانند Elsevier، IEEE، ACM و Springer.

۱-۱۲ روش ها و ابزار تجزیه و تحلیل داده ها (در صورت لزوم)

با استفاده از زبان برنامه نویسی پایتون روش پیشنهادی پیاده سازی شده سپس با استفاده از

پارامترهای معتبر روش پیشنهادی با روش های موجود مورد ارزیابی قرار خواهد گرفت.

۱-۱۳ جمع بندی

همان گونه که در این فصل بیان شد، مسئله اصلی این پژوهش حذف الگوهای مویر می باشد که در

بخشهای مختلف مورد بررسی قرار گرفت روش مورد استفاده این پژوهش نیز استفاده از روش شبکه های

عصبی کانولوشن جهت این مسئله می باشد. مقدمات مورد نیاز و اولیه پژوهش در این فصل بیان شد. در

فصل دوم به مفاهیم اولیه و سابقه تحقیقات به انجام رسیده در زمینه مسئله پژوهش پرداخته می شود.

فصل سوم روش پیشنهادی مطرح می شود و در فصل چهارم نتایج و ارزیابی صورت گرفته و در فصل پنجم

نتیجه گیری و پیشنهادات ارائه می شود.

فصل ۲: مفاهیم اولیه و پیشینه پژوهش


۲-۱ مقدمه

در این فصل، ابتدا ادبیات موضوعی پژوهش در زمینه حذف الگوهای مویر پرداخته شده است. در ادامه فصل جدیدترین مطالعات به انجام رسیده در حیطه مسئله حذف الگوهای مویر مورد بررسی قرار گرفته است.

۲-۲ معرفی پدیده ی ماره

واژه ی ماره یا مویره از پارچه ی بافته شده ی ابریشمی گرفته شده است و ریشه ی آن فرانسوی است. در انگلیسی mohair، در عربی مخیر و حتی در بعضی جاها به صورت Mwar-ay نامگذاری شده است. ماره اسم شخص یا مکان خاصی نیست. پدیده ی ماره به صنعت پارچه بافی چینی های باستان برمی گردد. هرگاه دو لایه پارچه ی ابریشمی روی هم قرار گیرند شکل های جالب توجهی دیده می شود. هنرمندان چینی سال های متمادی بدون این که پدیده ی ماره را بشناسند از ویژگی های آن استفاده می کردند آن ها با پوشیدن لباس های دولایه از ابریشم و با حرکت دادن منظم، بدنشان جلوه های زیبایی را به تماشاگران نشان می دادند [۲۳].

پدیده ی ماره زمانی ایجاد می شود که دو یا چند ساختار دوره ای یا شبه دوره ای روی هم نهاده شوند. در چنین حالتی یک ساختار دوره ای جدید با دوره ی درشت تر نمایان می شود. شکل (۲-۱) روی هم افتادگی دو ساختار دوره ای را نشان می دهد فریزهای ماره به خوبی در شکل دیده می شوند. زمانی که دو ساختار داشته باشیم که گام یکی مضرب صحیح یا تقریباً صحیحی از دیگری باشد.



شکل ۱-۲: طرح ماره ی ایجاد شده از روی هم افتادگی دو ساختار دوره ای

و خطوط آن ها تقریباً موازی هم قرار گیرند یک ساختار منظم جدید ظاهر می شود. این ساختار "طرح ماره" یا "فریز ماره" نامیده می شود پدیده ی ماره به دلیل این که ابزار قدرتمندی برای نمایش و اندازه گیری سطح و شکل اجسام می باشد کاربردهای بسیاری در علم و تکنولوژی پیدا کرده است. برای ایجاد طرح های ماره از توری استفاده می شود. توری آرایه ای دوره ای از خطوط یا نقاط شفاف و تاریک است به قسمت های شفاف توری "شکاف" یا "دهانه" توری می گویند. مشابه با آن چه در ساختار موج داریم در توری ها فاصله ی بین دو خط کدر یا دو شکاف را دوره یا گام توری می نامند. منظور از سمت گیری یک توری جهت خط های توری است، که می تواند عمود بر خطوط یا موازی با آن ها باشد. در این جا منظور ما از سمت گیری توری یا طرح ماره، جهت عمود بر خطوط آن هاست. زمانی که خطوط روشن دو توری کاملاً روی هم بیفتند، بیشترین شدت (max) را داشته و فریز ماره ی روشنی داریم در چنین حالتی اگر گام دو توری برابر باشند، فریز مارهی ایجاد شده کاملاً روشن خواهد بود به همین شکل، خط های تیره ی طرح ماره، حاصل روی هم افتادگی خط های تیره ی توری هاست که در این حالت کمترین شدت (min) را داریم.

توریها دقت و حساسیت طرح ماره را کنترل میکنند. هرچه گام توری کوچکتر باشد،

دقت و حساسیت آن در اندازه گیری بیشتر است. البته مشاهده و آشکارسازی فریزهای ماره به آشکارساز حساسیت و توانایی سیستم آشکارساز نیز بستگی دارد در صورتی که از یک سیستم آشکار ساز با حساسیت پایین استفاده شود فریزها قابل مشاهده نیستند در حالی که ماره اتفاق افتاده است. گام و سمت گیری فریزهای ماره به گام و سمت گیری دو ساختار اولیه که بر هم نهاده شده اند و نیز به زاویه ی بین آن ها بستگی دارد که این موضوع با استفاده از روابط هندسی نیز قابل مشاهده است. مثلاً اگر در زاویه ی یکسان نسبت گام توری ها را تغییر دهیم، سمت گیری فریزهای ماره نیز تغییر می کند همچنین نمایانی فریزهای ماره به نسبت گشودگی دهانه و فاصله ی توری های بر هم نهاده بستگی دارد.

۲-۳ تاریخچه ی علمی ماره

پدیده ی ماره اولین بار در سال ۱۸۷۴ توسط ریلی به صورت علمی مورد بررسی قرار گرفت. او از فریزهای ماره برای تشخیص عیوب توری های پراش استفاده کرد. پس از آن در سال های ۱۸۸۷ و ۱۸۸۸ ریگی تحقیقات گسترده تری در مورد آن انجام داد. او درباره فریزهای ماره ی حاصل از بر هم نهی ساختارهای دو بعدی مانند توری های دایره ای و شعاعی در حالتی که مراکز آن ها بر هم منطبق نباشند بحث کرده و همچنین اثر ضریب تراگیل ساختارها را در تشکیل فریزهای ماره مطالعه کرد کار ریگی در بردارنده ی اولین پیشنهاد استفاده از فریزهای ماره در اندازه گیری جابجایی عرضی است در سال های ۱۹۲۴ - ۱۹۲۷ شوستر ، رامان و داتا تحقیقاتی را در مورد بر هم نهی توری های منطقه ای انجام دادند رانکی در سال ۱۹۲۵ بر هم نهی توری خطی با توری دایره ای را تحقیق کرد کارهای بالا به همراه اولین کاربرد در اندازه گیری جابجایی های کوچک توسط گایامبایاسی در سال ۱۹۲۷ و آنالیز تنش سطح توسط برور و گلاسکو در سال ۱۹۴۱ انجام شده اند.

از آغاز دهه ی پنجاه، تکنیک فریز ماره به طور قابل ملاحظه ای گسترش یافت و به ابزار مهمی در سنجه شناسی مبدل شد. همچنین برای مطالعه ی خواص فیزیکی و مکانیکی مواد به کار گرفته شد. از آن

زمان تا دهه شصت استفاده از فریزهای ماره در اندازه گیری تنش و مبدل جابجایی، اندازه گیری ضریب شکست هم راستا کردن وسایل اپتیکی بررسی ناصافی سطوح و غیره... به کار برده شد.

در سال ۱۹۵۱ میتسویشی طرحهای ماره را در شبکه های اتمی بر هم نهاده گزارش کرد.

او طرح های ماره را در ورق نازکی از بلور گرافیت مشاهده نمود. در سال ۱۹۷۰ میدوز، تاکاساکی و واسوسکی برای اولین بار ماره را در بررسی شکل اجسام گزارش کردند. در سال ۱۹۷۵ لومن فریزهای ماره را برای مطالعه ی انتقال اطلاعات و تحلیل فرکانس های فضایی سیستم های اپتیکی و پردازش تصویر به کار برد.

علاوه بر کاربردهای فنی، بالا حوزه ی علمی دیگری که در آن روش ماره مهم بود، بررسی بلورها به وسیله ی میکروسکوپ الکترونی بود که برای تشخیص عیوب بلورها بسیار مناسب است. دلیل اصلی توسعه ی قابل توجه استفاده از روش فریزهای ماره در دهه ی ۷۰، دسترسی عموم به نور لیزر بود. درجه ی بالای همدوسی زمانی و مکانی در لیزرها منجر به توسعه ی روش های ماره در زمینه های مختلف پژوهشی مانند تداخل سنجی اندازه گیری زاویه و فاصله، عیب یابی قطعات اپتیکی تحلیل کشش سطح تنظیم اپتیکی سطح نگاری، بررسی بلورها، انحراف سنجی و... شد. در حال حاضر نیز تکنیک ماره در تحقیقات صنعتی مورد توجه قرار گرفته است. مثلاً می توان از کاربردهای آن در نمایه سنجی سه بعدی و آشکارسازی برآمدگی های کوچک در قطعات نام برد در ۱۹۹۰ کافری و کلاه، تشابه بین تداخل سنجی و روش ماره را بررسی کردند. این کار سرآغاز کاربرد جدید ماره در شاخه های مختلف علمی گردید [۲۴].

در سال ۲۰۰۷ روش معادله ی پارامتریک که یکی از روش های مرسوم در بررسی فریزهای ماره است اصلاح شد تا نتایج آن با روش تحلیل فوریه یکسان شود [۲۵]. همچنین در ۲۰۱۱ فرمول بندی ماره بر اساس میانگین گیری فضایی انجام شد تا جملات فرکانس بالا، نه با روش دستی بلکه با روش میانگین گیری حذف شوند [۲۶].

در سال های اخیر از این روش برای اندازه گیری فاصله ی کانونی عدسی، محاسبه ی تابع انتقال، اپتیکی اندازه گیری ضخامت لایه های شفاف و تیغه ها اندازه گیری مدول یانگ، مطالعه زمین لرزه و ...

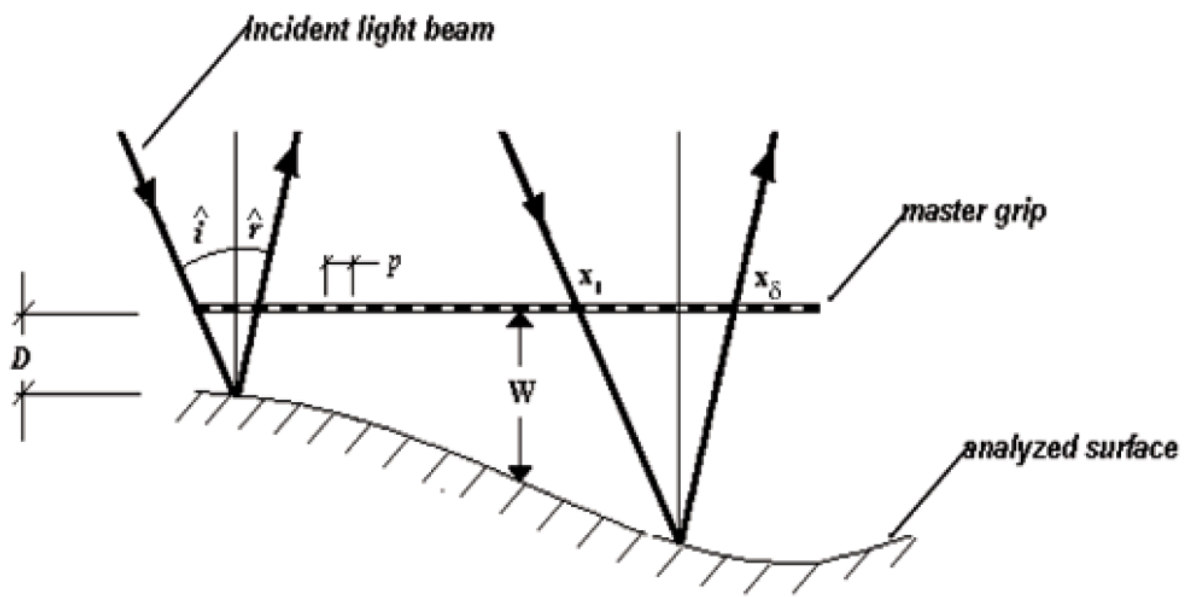
استفاده شده است. در بسیاری از موارد روش ماره با پدیده ی خود تصویرسازی تطبیق گردیده است. به این شکل که خود تصویر یکی از توری ها بر توری دوم قرار می گیرد و نقش یکی از توری های بر هم نهاده را ایفا می کند. کیفیت فریزهای ماره بستگی به کیفیت خود تصویر دارد که عوامل مهمی در آن دخیل هستند. با بررسی فریزهای ماره ی حاصل می توان اطلاعات بسیاری در مورد آن عوامل بدست آورد.

۲-۴ روش اندازه گیری تغییر فاز: [۲۷]


در این روش با استفاده از دوربین و تصویربرداری از الگو مویر و با اندازه گیری تغییر فاز صورت گرفته و یا تداخل ایجاد شده در الگو مویر به بررسی ساختار سطح مورد نظر می پردازند در این بخش به صورت مختصر به روش های ایجاد این الگوها می پردازیم و کارهای انجام شده به این روش ها را بررسی می کنیم.

۲-۴-۱ مویر سایه ای! [۲۸]

در این روش از پدیده ی مویری را که بر اثر شبکه ای دارای خطوط موازی (شبکه مبنا) که در جلوی جسم مد نظر قرار دارد و سایه این شبکه که در نتیجه ی عبور نور موازی شده از شبکه مبنا بر روی جسم مورد نظر می باشد تشکیل می شود را مورد بررسی قرار می دهیم . بر هم نهی سایه تشکیل شده و شبکه مبنا باعث بوجود آمدن پدیده ی مویر می شود. با استفاده از روش اندازه گیری تغییر فاز می توان به بررسی ساختار سه بعدی اجسام پرداخت. در این روش با تصویر برداری از پدیده مویر و با استفاده از پردازش تصویر به ساختار سه بعدی جسم می رسیم . شکل ۲-۲ هندسه این روش را نشان می دهد .



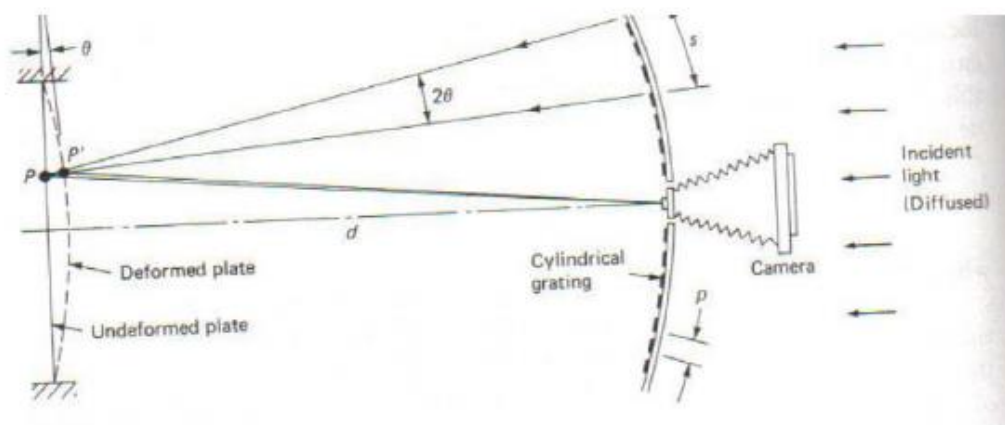
شکل ۲-۲: هندسه روش سایه مویر



شکل ۲-۳: نمونه ای از سایه مویر


۲-۴-۲ مویر انعکاسی: [۲۹]

در این روش ابتدا یک شبکه بر روی جسمی که تغییر شکل آن را می خواهیم اندازه گیری کنیم ایجاد می کنیم . عواملی که تاثیر آن ها بر شکل ساختار را می خواهیم بررسی کنیم (مانند دما ، فشار ، استرس و ...) باعث ایجاد تغییرات در این شبکه می شوند . این تغییرات باعث تغییر فاز الگو مویری که بر اثر این شبکه و یک شبکه ثابت دیگر دلخواه ایجاد شده است می شود که با استفاده از تکنیک اندازه گیری تغییر فاز می توان به ساختار سه بعدی جسم دست یافت. شکل زیر ساختار هندسی این روش را نمایش می دهد .




شکل ۲-۴: هندسه روش مویر انعکاسی

حال به بررسی کارهای صورت گرفته به این روش می پردازیم . در یک کار تحقیقاتی یک دستگاه SEMY با استفاده از این روش ساخته شده است. این دستگاه برای اندازه گیری تغییر شکل ساختار و اندازه گیری استرس باقی مانده در آن بکار می رود . برای مثال یک ساختار بیم یک سر گیردار که بر روی آن توسط FIB یک شبکه مویر ایجاد شده است را بررسی می کنیم . توسط FIB خطوط مویر که از یکدیگر فاصله ۰/۲ میکرون دارند بر روی یک بیم به طول ۶۰ میکرون و عرض ۱۰ میکرون و ضخامت ۲ میکرون ایجاد شده است. این کار قبل از برداشتن لایه قربانی صورت گرفته است. برای برداشتن لایه قربانی از BOE استفاده شده است. شکل این بیم را در تصویر ۲-۵ مشاهده می کنید.



شکل ۲-۵: پیکر بندی بیم یک سر گیردار

با استفاده از دستگاه SEM الگو مویر ایجاد شده اسکن می شود سپس با تغییر مکان بیم دستگاه به اندازه $1/2p$ و $3/2p$ ، ۴ تکه تصویر برای تکنیک تغییر فاز بدست می آید که در شکل ۶-۲ مشاهده می کنید.



شکل ۶-۲: چهار قدم برای تکنیک اندازه گیری تغییر فاز بر روی بیم یک سر گیردار

با استفاده از این چهار الگو ایجاد شده می توان فاز الگو مویر ایجاد شده را بدست آورد (شکل ۷-۲). از آن جایی که تغییرات فاز در این شکل بدست آمده شکل (۷-۲) از ۲ تا ۲ می باشد (wrapped) این تصویر نیاز به یک پروسه unwrapping دارد. (شکل ۸-۲)




شكل ٧-٢: Wrapped phase map



شکل ۲-۸: Unwrapped phase map


تفاده از این اطلاعات و روابط ریاضی می توان به استرس ایجاد شده در ساختار دست یافت .



شکل ۲-۹: استرس موجود بر روی بیم

۲-۴-۳ مویر پروژکتوری [۳۰]

مویر پروژکتوری به روش های مختلفی ایجاد می شود . شکل ۲-۱۰ نمونه ای برای ایجاد این الگو را نمایش می دهد. در این شکل یک نمونه (که به صورت هاشور خورده می باشد) به وسیله آرایه ای از خطوط تاریک و روشن نورافشانی می شود . در این شکل خطوط سیاه رنگ جاهایی است که نور به آن ها می رسد و نقاط خالی فضایی است که به آن نقطه نوری نمی رسد . دوربین خطوط روشن را که توسط خطوط تاریک از هم جدا شده اند را مشاهده می کند. این تصویر ابتدا با همین حالت اولیه بر روی یک فیلم چاپ می شود . یک عکس دیگر که پس از تغییر فرم نمونه ایجاد می شود را بر روی یک عکس دیگر چاپ می کنیم . با قرار دادن این دو تصویر بر روی یکدیگر پدیده الگو مویر ایجاد می شود که به وسیله آن می توان به میزان تغییر شکل دست یافت .



شکل ۲-۱۰: هندیه روش مویر پروژکتوری

۲-۵ پیشینه پژوهش

برای غلبه بر چنین کمبودهایی، روش‌هایی که در حوزه فرکانس عمل می‌کنند پدید آمده‌اند. در سال ۲۰۰۱، براساس آرایه فیلتر رنگ نسبی (CFA) و گلو تزاخ، یک روش درون‌یابی در [۱۰] پیشنهاد شده است که فرآیند هم‌خوانی را توسط مقدار درهم‌آمیخته اطلاعات با فرکانس بالا مولفه سبز را معکوس می‌کند. تصویر تخمین مستعار می‌تواند با الگوی مویر مطابقت داشته باشد بدون توجه به این که الگوی مویر چگونه به نظر می‌رسد، عکس خوب است. این ایده با محاسبه رابطه تفاوت‌های مقیاس خاکستری بین الگوهای تیره و روشن در هر دو الگوی aliasing شبیه‌سازی شده و پهنای R/B برای حذف کروماتیسیم ناشی از اثر مویر. اگرچه این رویکرد برای حذف الگوی مویر بدون اطلاع از آن قابل استفاده است. آرایه CFA، دارای پیش‌نیاز ضروری

است که جزء سبز از تصویر هیچ نام مستعار ندارد. در مقابل، گونزالس و همکاران [۱۱]، از برخی فضای فیلترهای ناچ برای از بین بردن تاثیر آنها در طیف استفاده کرده‌اند. در سال ۲۰۱۷، یانگ و همکاران یک روش تخریبی برای عکاسی با دوربین ارائه کرد، تصاویر از طریق تجزیه لایه بر روی اجزای چند فازی [۱۲] (LDPC)، این مدل تجزیه لایه یک تصویر را به لایه پس‌زمینه و لایه مویر و مدل مخلوط گاوسی قبل هر دوی آنها توسط یک پیچ از قبل آموزش دیده منظم می‌شوند. اگرچه این دو روش می‌توانند بیشتر الگوی مویر را در تصاویر حذف کنند، اطلاعات جزئی تصویر به دلیل تاری ناشی از این دو رویکرد است [۱۲]. اخیراً، در سال ۲۰۱۸، سان و همکاران چند رزولوشن جدید را به طور کامل معرفی کردند شبکه عصبی کانولوشنال (CNN) برای حذف خودکار الگوهای مویر از عکس‌ها [۱۳]. نتایج آن‌ها نشان می‌دهد که مدل عمیق CNN می‌تواند روی مصنوعات مویر در هر باند فرکانسی کار کند. با این حال، روش‌های مبتنی بر یادگیری عمیق به مقدار قابل توجهی نیاز دارند و منابع محاسباتی و مکانیسم چرایی کارکرد آن هنوز نامشخص است.

بازیابی تصویر یک کار مهم در بینایی سطح پایین است. در بازیابی تصویر، تعداد زیادی از تحقیقات اخیر عمدتاً بر روی کارهایی مانند وضوح تصویر فوق [۱۹]، حذف نویز تصویر [۱۷] و محو کردن تصویر تمرکز دارند. مویر کردن نیز یک کار ترمیم تصویر مهم است و حتی دشوارتر از دیگر بازیابی تصویر است. با این حال، در سال‌های اخیر، مویرزدایی دریافت شده است که توجه نادر در این موضوع مطالعات مرتبط نسبتاً کمی روی آن تمرکز می‌کنند.

لیو و همکاران [۷] یک ماتریس کم رتبه و پراکنده مبتنی بر تجزیه روش حذف مویر روی تصاویر بافت اعمال کردند. یانگ و همکاران [۱۲] یک روش تجزیه لایه بر اساس چند فاز ارائه کرده‌اند که اجزاء (LDPC) برای حذف بهتر مویر تولید شده هنگام عکاسی از صفحه نمایش است.

سان و همکاران که یک شبکه تخریب‌کننده مبتنی بر کانولوشن چند مقیاسی شبکه‌های عصبی [۱۳] و مجموعه داده‌های تصویری مویر بزرگ در ImageNet پیشنهاد داده‌اند. این شبکه نتیجه چشم‌گیری در حذف الگوی مویر ارائه کرد.

درسال‌های اخیر، گائو و همکاران [۲۱]، چارچوب چند مقیاسی با افزایش ویژگی شاخه که اطلاعات معنایی را با همکاران افزایش داد که تلفیقی از ویژگی‌های سطح پایین و بالا است. با این حال، آن‌ها پیشنهاد کردند که این روش دارای معماری شبکه قوی نیست و توانایی بیان ویژگی ضعیف است در حالی که ویژگی‌های تصویر ورودی را نمی‌توان به طور کامل استخراج کرد. علاوه‌براین، آن‌ها از کانولوشن انتقالی برای نمونه‌برداری استفاده کرده‌اند که معمولاً نمی‌تواند از اطلاعات به خوبی استفاده کند و باعث ایجاد آرتیفکت در تصاویر تولید شده می‌شود.

لیو و همکاران [۲۲] روشی برای حذف الگوی مویر بر اساس عمق شبکه کانولوشن برای تصاویر اسکرین‌شات پیشنهاد کرده‌اند. این روش می‌تواند به طور موثری بیشتر مویر را حذف کند. با این حال، آن‌ها فقط از ورودی مقیاس با وضوح پایین استفاده کردند و فقط می‌تواند مویر را در یک فرکانس بانند مشخص کند. فرکانس مویر به طور گسترده توزیع شده است، بنابراین در روش آن‌ها الگوی مویر را نمی‌توان به خوبی حذف کرد.

۲-۶ جمع بندی

سابقه تحقیقات به انجام رسیده در زمینه مسئله حذف الگوهای مویر در این فصل مورد بررسی قرار گرفته و نقاط ضعف و قوت هر یک از روش‌های موجود در زمینه مسئله پژوهش ارائه شده است. در فصل بعد با استفاده از تحقیقات و نتایج بیان شده در این فصل، به بررسی ابعاد مختلف روش پیشنهادی پژوهش

در زمینه حذف الگوهای مویر با استفاده از ترکیب شبکه های عصبی کانولوشن و حافظه طولانی کوتاه مدت پرداخته می شود.

فصل ۳: روش پیشنهادی


۳-۱ مقدمه

در این فصل به روش پیشنهادی که بر اساس ترکیب شبکه های عصبی کانولوشن و حافظه طولانی کوتاه مدت برای حذف الگو های مویر پرداخته شده است. روش های شبکه های عصبی کانولوشن و حافظه طولانی کوتاه مدت و نحوه عملکرد آن ها در ادامه تشریح شده است.

۳-۲ شبکه های عصبی کانولوشن (CNN)


شبکه های عصبی کانولوشن یک نوع از شبکه های پیشخور هستند. آنها به طور زیستی از قشر بینایی حیوان الهام گرفته شده اند و کاربردهایی در تشخیص تصویر و ویدئو، سیستم های توصیه ای و پردازش زبان طبیعی دارند.

شبکه های عصبی کانولوشن می تواند با الگو های بینایی مستقیماً تصاویر پیکسلی را با حداقل پیش پردازش تشخیص دهند. آن ها می توانند برای تغییر پذیری بی نهایت (مانند کاراکترهای دست نویس)، و تبدیل هندسی ساده و اعوجاج را تشخیص دهند. آن ها توسط به کارگیری فیلترهای کانولوشن $k \times k$ و w سراسر تصویر را (مانند یک پنجره لغزش)، با رمزگذاری اطلاعات پیکسل میانی توسط استفاده از مقادیر پیکسل ها روی همسایگی شان (مجاورشان پیکسل های $k \times k$ شامل خودشان) کار کنند. شکل ۳-۱ پردازش را به صورت گرافیکی نشان می دهد.



شکل ۱-۳: پردازش به صورت گرافیکی

به طور نرمال، لایه کانولوشن شامل یک لایه کانولوشن خطی پیرو یک تابع فعالیت غیرخطی (مانند یک بخش خطی ثابت و خطی (ReLU) است. یکی از بیشترین موارد استفاده آن برای حل مساله شیب پنهان است زمانی که با استفاده از (عقبگرد) و یک ماکس پولینگ، مقدار شیب بزرگتر از همسایگی‌های پیکسل کوچک محاسبه می‌شود، کاملاً لایه‌های متصل به کار بسته می‌شوند. برای انجام طبقه‌بندی، لایه متصل کامل آخر می‌تواند یک سافت ماکس باشد، خروجی شبکه احتمال هر کلاس را نمایش می‌دهد (برای اینکه مجموع مقادیر خروجی شبکه ۱ است). شکل ۲-۳ معماری شبکه‌های عصبی کانولوشن عمومی را نشان می‌دهد.



شکل ۲-۳: معماری شبکه‌های عصبی کانولوشن

❖ یادگیری عمیق

یادگیری عمیق شبکه های عصبی با بیشتر از ۳ لایه پنهان است. یادگیری عمیق یک ابزار بسیار قوی برای انجام تکنولوژی های جدید در خیلی حوزه ها است در نتیجه بخش های پردازش گرافیکی (GPU)، برنامه ها را جدا می کنند داده و اجزا به دست آمده یک روش خوب برای آموزش شبکه های عصبی پیچیده استفاده می کنند.

مزیت یادگیری عمیق این است، که حتی اگر در کل یک شبکه عصبی تخمین گر عمومی باشد فقط از دو لایه پنهان استفاده می کند که با اضافه نمودن لایه های پنهان بیشتر می تواند با نورون های کمتر و در نتیجه زمان کمتری پردازش و آموزش را انجام دهد.


یک شبکه ی عصبی کانولوشن (CNN) شامل ۳ نوع لایه ی مختلف است:

لایه های کانولوشن

لایه های نمونه برداری جزئی

لایه ی خروجی

لایه های شبکه در یک ساختار پیشرو منظم می شوند. هر لایه ی کانولوشن توسط یک لایه ی نمونه برداری جزئی دنبال شده و پس از آخرین لایه ی، کانولوشن لایه ی خروجی قرار می گیرد. ساختار پیشرو برای یک شبکه CNN نوعی در شکل ۳-۳ نمایش داده شده است.



شکل ۳-۳: ساختار شبکه ی کانولوشن عمیق

لایه های کانولوشن و نمونه برداری جزئی لایه هایی دوبعدی هستند؛ در حالی که لایه ی خروجی به صورت یک بعدی در نظر گرفته می شود در CNN هر لایه ی دوبعدی از چندین صفحه تشکیل می شود که هر صفحه در واقع یک آرایه ی دو بعدی از نرون ها است. خروجی هر صفحه یک نقشه ویژگی ها نامیده می شود.

در یک لایه ی کانولوشن، هر صفحه به یک یا چند نقشه ی ویژگی از لایه ی قبلی متصل است. به هر اتصال یک ماسک (نقاب) کانولوشن اختصاص داده می شود ماسک کانولوشن در حقیقت یک ماتریس دو بعدی از وزن های قابل تنظیم می باشد که گاهی به آن کرنل آموزش پذیر نیز گفته می شود. وظیفه وزن ها در قالب کرنل های آموزش، پذیر یادگیری نوعی فیلتر عصبی دو بعدی به ازای هر کرنل است تا ویژگی های محلی هر تصویر ورودی به لایه های کانولوشن استخراج گردد.

هر صفحه در ابتدا کانولوشن بین ورودی های دو بعدی خودش را با ماسک های کانولوشنی مربوطه اش، محاسبه می کند. پس خروجی های کانولوشن با یکدیگر جمع شده و به یک مقدار اسکالر قابل تنظیم که جمله ی بایاس نامیده می شود افزوده می گردند سرانجام یک تابع فعالسازی روی، نتیجه اعمال می شود تا صفحه خروجی به دست آید.

صفحه خروجی یک ماتریس دو بعدی است و نقشه ی ویژگی نام دارد این نام از این حقیقت ناشی می شود که خروجی، کانولوشن حضور یک مشخصه ی بصری در موقعیت پیکسلی داده شده را نشان می دهد. یک لایه ی کانولوشن یک یا چند نقشه ی ویژگی تولید می کند. سپس هر نقشه ی ویژگی دقیقاً به یک صفحه در لایه ی نمونه برداری جزئی بعدی خود، متصل می گردد.

یک لایه ی نمونه برداری، جزئی دارای تعداد صفحات یکسان با لایه ی کانولوشنی قبل از خودش است. یک صفحه ی نمونه برداری ورودی دو بعدی خودش را به بلوک های غیر همپوشان با اندازه ی پیکسلی ۲۷۲ تقسیم می کند. سپس برای هر بلوک میانگین مجموع چهار پیکسل محاسبه می گردد این مقدار به ازای هر بلوک در یک وزن اسکالر قابل تنظیم ضرب شده و سپس با یک جمله ی بایاس جمع می شود. نتیجه ی حاصله از یک تابع فعالساز عبور کرده و یک خروجی به ازای هر بلوک ۲۷۲ تولید می گردد.

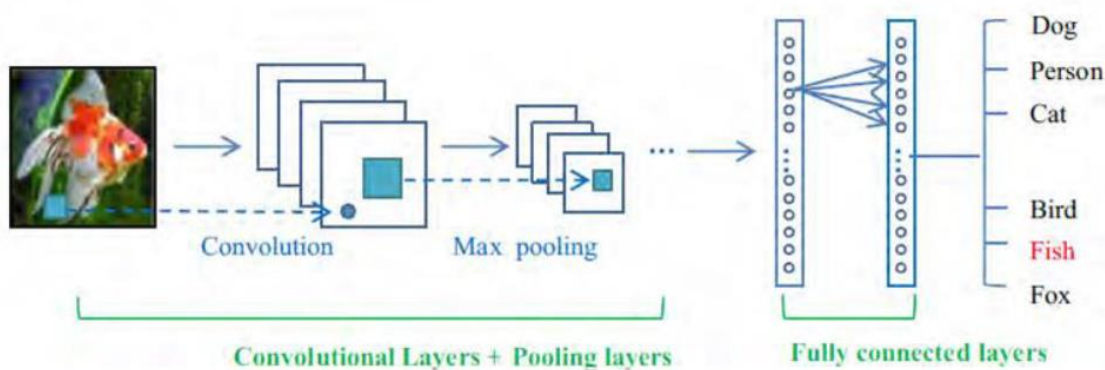
واضح است که هر صفحه ی نمونه بردار اندازه ی ورودی دوبردی خودش را در هر بعد به نصف کاهش می دهد و یک ماتریس دو بعدی با ابعاد نصف ورودی خود تشکیل می دهد که آن را نقشه ی ویژگی لایه ی نمونه بردار به ازای ورودی مربوطه اش می نامیم یک نقشه ی ویژگی در لایه ی نمونه برداری به یک یا چند صفحه در لایه ی کانولوشن بعدی اش متصل می شود.

در آخرین لایه ی کانولوشن هر صفحه دقیقاً به یک نقشه ی ویژگی قبلی متصل می گردد. این لایه از ماسک های کانولوشن با اندازه ی یکسان با نقشه ی ویژگی ورودی اش استفاده می کند. بنابراین، هر صفحه در لایه ی کانولوشن، آخر یک خروجی اسکالر تولید می کند. سپس خروجی های همه ی صفحات در این لایه به لایه ی خروجی متصل می شوند.

لایه ی خروجی عموماً می تواند تعدادی نرون با توابع فعالساز مختلف باشد در اینجا، ما از نرون های سیگموئیدی برای لایه ی خروجی استفاده می کنیم خروجی های این لایه به عنوان خروجی های کل شبکه در نظر گرفته می شود در کاربردهای طبقه بندی الگو این خروجی ها کلاس هر تصویر ورودی را نشان می دهد.

شبکه های عصبی کانولوشن (CNN) یکی از مهم ترین روش های یادگیری عمیق هستند که در آن ها چندین لایه با روشی قدرتمند آموزش می بینند. این روش بسیار کارآمد بوده و یکی از رایج ترین روش ها در کاربردهای مختلف بینایی کامپیوتر است. به طور کلی، یک شبکه عصبی کانولوشن از سه لایه اصلی تشکیل می شود که عبارتند از : لایه کانولوشن لایه Pooling و لایه تماماً متصل. لایه های مختلف وظایف مختلفی را انجام میدهند. در شکل ۳-۴ یک معماری کلی از شبکه عصبی کانولوشن برای دسته بندی تصاویر به صورت لایه به لایه نمایش داده شده است شبکه های عصبی کانولوشن تا حد بسیار زیادی شبیه شبکه های عصبی مصنوعی هستند. این نوع شبکه ها متشکل از نرون هایی با وزن ها و بایاس های قابل یادگیری هستند هر نرون تعدادی ورودی دریافت کرده و سپس حاصل ضرب پیچشی وزن ها در ورودی ها را محاسبه کرده و در انتها با استفاده از یک تابع تبدیل غیرخطی نتیجه ای را ارائه می دهد. کل شبکه

همچنان یک تابع امتیاز مشتق پذیر را ارائه می کند، که در یک طرف آن پیکسل های خام تصویر ورودی و در طرف دیگر آن امتیازات مربوط به هر دسته قرار دارد.



شکل ۳-۴: لایه های مختلف شبکه کانولوشن


۳-۲-۱ لایه کانولوشن:

در این لایه ها ، شبکه عصبی کانولوشن از کرنل های مختلف برای convolve کردن تصویر ورودی و همین طور feature map های میانی استفاده می کند و اینگونه feature map های مختلفی ایجاد می کند. مکانیزم اشتراک وزن در هر feature map باعث کاهش شدید تعداد پارامترها می شود. اتصال محلی ارتباط بین پیکسل های همسایه را یاد میگیرد باعث تغییر ناپذیری و ثبات نسبت به تغییر مکان شیء می شود. به واسطه فواید معرفی شده توسط عملیات convolution ، بعضی از مقالات تحقیقاتی مشهور از آن جهت جایگزینی لایه های تماما متصل استفاده کردند تا با این کار سرعت فرآیند یادگیری را افزایش دهند.

شکل ۳-۵: عملیات لایه کانولوشن

۳-۲-۲: Pooling لایه

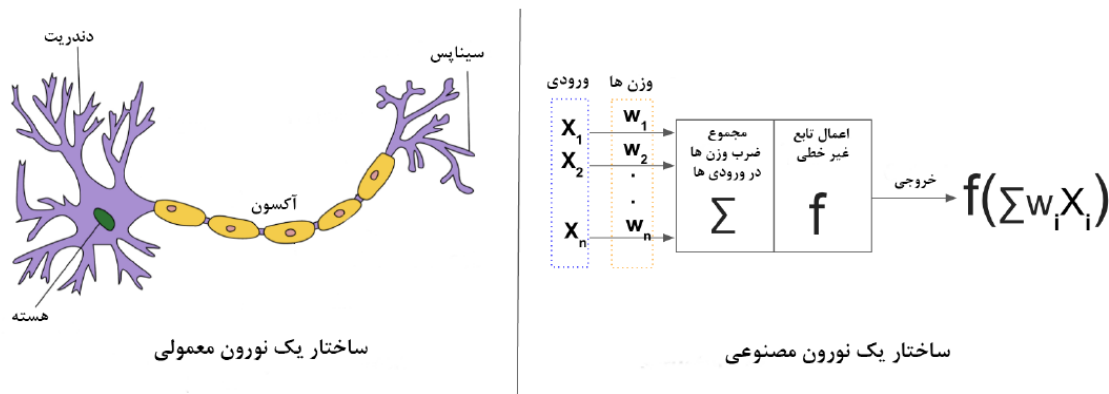
یک لایه pooling معمولاً بعد از یک لایه کانولوشنی قرار می‌گیرد و از آن برای کاهش اندازه feature map ها و پارامترهای شبکه می‌توان استفاده کرد همانند لایه های کانولوشنی لایه های pooling بخاطر در نظر گرفتن پیکسل های همسایه در محاسبات خود، نسبت به تغییر مکان بی تغییر هستند پیاده سازی لایه Pooling با استفاده از تابع max و تابع Average رایج ترین پیاده سازی ها هستند. در شکل ۳-۶ می‌توانید نمونه ای از فرایند max pooling را مشاهده کنید. با استفاده از فیلتر max pooling با اندازه 2×2 و گام ۲ یک feature map با اندازه 9×9 یک خروجی با اندازه 4×4 را ایجاد می‌کند.



شکل ۳-۶: عملیات max pooling

۳-۲-۳ لایه تماما متصل شده

بعد از آخرین لایه Pooling ، همان طور که در شکل ۷-۳ مشاهده می شود لایه های تماما متصل وجود دارند که feature map های ۲ به feature vector یک بعدی جهت ادامه فرآیند feature representation تبدیل می کند. لایه های تماما متصل همانند همتایان خود در شبکه های عصبی مصنوعی سنتی عمل می کنند و تقریبا ۹۰٪ پارامترهای یک شبکه عصبی کانولوشن را شامل می شوند لایه تماما متصل به ما اجازه می دهد تا نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه کنیم. ما می توانیم از این بردار برای دسته بندی تصاویر استفاده کنیم و یا این که از آن جهت ادامه پردازش های بعدی بهره ببریم [۳۱].




شکل ۷-۳: ساختار یک نورون معمولی و مصنوعی

۳-۳ معماری شبکه های عصبی کانولوشن

با پیشرفت های اخیر استفاده CNN در حوزه بینایی ، کامپیوتر مدل های معروفی از شبکه های عصبی کانولوشن به وجود آمدند. این مدل ها برای طراحی شبکه های عصبی کانولوشن به کار می روند. در این بخش ما مدل هایی که بیشتر متداول بوده را مورد مطالعه قرار می دهیم و سپس خصوصیات هر یک را در کاربردهای آن ها به صورت خلاصه عنوان می کنیم.

۳-۳-۱: LENET

اولین کاربردهای موفقیت آمیز شبکه های عصبی کانولوشن توسط یان لچون' در سال ۱۹۹۰ توسعه داده شدند. از میان آن ها، معماری LeNet معروف ترین آن هاست که برای خواندن کدهای پستی ، ارقام و ... مورد استفاده قرار گرفته بود [32].




شکل ۳-۸: شبکه LENET

۳-۳-۲: ALEXNET

این شبکه معماری شبیه LeNet داشت با این تفاوت که عمیق تر و بزرگتر بود و همچنین از ترکیب چندین لایه کانولوشن با هم کرد، در گذشته یک لایه کانولوشن که بعدش یک لایه Pool قرار می گرفت رایج بود AlexNet یک معماری قابل توجه برای شبکه عصبی کانولوشن است که شامل ۵ لایه کانولوشنی و سه لایه تماما متصل است. این معماری تصاویر با اندازه $224 \times 224 \times 3$ را به عنوان ورودی دریافت کرده و سپس با انجام عملیات های convolution و pooling پی در پی و نهایتا ارسال نتایج به لایه های تماما متصل تصویر ورودی را مورد پردازش قرار می دهد این شبکه بر روی مجموعه داده ImageNet آموزش دیده و در آن از تکنیک های مختلف regularization همانند data augmentation و Dropout و... استفاده شده

است. این معماری برنده رقابت ۲۰۱۲ ILSVRC شد و باعث افزایش ناگهانی علاقه به مبحث شبکه های عصبی کانولوشنی عمیق شد [33].



شکل ۳-۹: شبکه ALEXNET

۳-۳-۳ ZF:


برنده رقابت ۲۰۱۳ ILSVRC شبکه کانولوشنی بود که توسط متئو زیلر و راب فرگوس توسعه پیدا کرده بود. بعدها این شبکه به نام ZF که مخفف نام توسعه دهندگان آن است معروف شد. این معماری نسخه بهینه شده ای از AlexNet بود که با تغییر فرآیندهای ، به طور خاص با افزایش اندازه لایه های کانولوشن میانی این بهینه سازی انجام شده بود [34].



شکل ۳-۱۰: شبکه ZF

۳-۳-۴: GOOGLNET

برنده رقابت ۲۰۱۴ ILSVRC هم شبکه عصبی کانولوشنی بود که توسط اسزگدی و همکارانش از طرف گوگل توسعه داده شده بود. ویژگی جدیدی که این معماری عرضه کرده بود توسعه یک ماژول مفهومی بود که به شدت تعداد پارامترهای شبکه را کاهش می داد [35].




شکل ۳-۱۱: شبکه GOOGLNET

۳-۳-۵: VGGNET

برنده جایگاه دوم در رقابت ۲۰۱۴ ILSVRC شبکه عصبی کانولوشنی بود که توسط کارن سایمون یان و آندرو زیسرمن "توسعه داده شده بود که بعدها با نام VGGNet معروف شد. ویژگی جدیدی که این معماری عرضه کرده بود، این بود که نشان داد عمق شبکه یک مولفه حیاتی برای کارایی خوب است و رزتن نهایی بهترین شبکه آن ها شامل ۱۶ لایه CONV/FC و به صورت خوشایندی یک معماری به شدت همگن که تنها دارای فیلتر با اندازه ۳×۳ در لایه کانولوشن و فیلتر ۲×۲ در لایه pooling از ابتدا تا به انتها بود. یک کاستی این شبکه این است که حافظه مصرفی و تعداد پارامتر بسیار زیادی دارد [36].


Classical CNN topology - VGGNet (2013)



شکل ۳-۱۲: شبکه VGGNet

۳-۳-۶: RESNET

برنده جایگاه اول در تمامی زمینه های رقابت ۲۰۱۵ ILSVRC شبکه عصبی کانولوشنی بود که توسط هی و همکارانش از تیم تحقیقاتی مایکروسافت ارائه شده بود. این معماری دارای ۱۵۲ لایه کانولوشنی است که با استفاده از ارتباطات Residual توانسته بود با اضمحلال گرادپانت به خوبی مقابله نماید. آن ها همچنین تابع فعالسازی ReLU را بهبود داده و تابع جدیدی به نام PReLU ارائه دادند تا در کنار الگوریتم مقداردهی اولیه پیشنهادی آن ها به بهترین نحو فعالیت کرده و از مشکل Dead ReLU که در آن واحدهای پردازشی عملاً از فاز آموزش خارج می شوند جلوگیری کند [37].



شکل ۳-۱۳: شبکه RESNET

۳-۴ آموزش شبکه عصبی کانولوشن

آموزش شبکه در واقع حداقل کردن تابع خطا بر حسب خروجی های واقعی شبکه در مقایسه با خروجی های مطلوب شبکه است این کار از طریق اصلاح پارامترهای آزاد شبکه یعنی وزن ها و بایاس ها صورت می گیرد.

به طور کلی فرآیند یادگیری ساختارهای عصبی را می توان به سه نوع تقسیم نمود:

۱. یادگیری با سرپرست

۲. یادگیری بدون سرپرست

۳. یادگیری تقویتی

در یادگیری با سرپرست SL یک سرپرست یا ناظر بر رفتار یادگیرنده نظارت می کند و نحوه عملکرد صحیح را به او یادآور می شود. به بیانی دیگر به سیستم، یادگیر مجموعه ای از زوج های داده متشکل از ورودی شبکه و خروجی مطلوب، اعمال می شود. پس از اعمال ورودی، شبکه خروجی آن با خروجی مطلوب مقایسه شده و سپس خطای یادگیری محاسبه و از آن جهت تنظیم پارامترهای شبکه به گونه ای استفاده می شود که اگر مجدداً به شبکه همان ورودی اعمال شود خروجی، شبکه به خروجی مطلوب نزدیکتر گردد. در یادگیری بدون سرپرست، هیچ گونه ناظر و سرپرستی جهت نظارت بر عملکرد یادگیرنده وجود ندارد و خود سیستم یادگیرنده است که از تشابهات و نزدیکی مشاهداتش اقدام به یادگیری می کند. به عبارت دیگر، تنها بردارهای ورودی سیگنال دریافتی از طرف محیط به شبکه هستند و پارامترهای شبکه تنها توسط پاسخ سیستم اصلاح و تنظیم می شوند.

در یادگیری تقویتی RL که روشی مابین دو حالت بیان شده در فوق می باشد، به شبکه یادگیرنده، بر خلاف روش آموزش با مربی عمل مورد نظر بیان نمی شود بلکه سیستم باید از طریق سعی و خطا، بهترین مسیری را با بیشترین پاداش انتخاب کند نتایج حاصل از هر مرحله با توجه به نسبت سازگاری با هدفه تقویت می شوند. روش آموزش مورد استفاده در ساختار پیشنهادی فعلی روش آموزش همراه با سرپرست است.


پارامترهای شبکه را می توان به دو طریق آموزش داد یا آموزش پس از هر نمونه ی آموزشی صورت می گیرد که به آن روش آموزش ترتیبی یا تصادفی نیز گفته می شود یا این که پس از اعمال همه ی نمونه های آموزشی، بروزرسانی پارامترها انجام می شود که آن را روش آموزش دست های می نامند. روش اول حافظه ی کمتری نیاز دارد ولی پایداری آن نیز پایین تر است. زیرا هر نمونه ی آموزشی می تواند پارامترهای شبکه را به سمت جدیدی سوق دهد. اما روش دوم با وجود این که نیازمند حافظه ی بالاتری است چون باید تغییرات در پارامترها را ذخیره سازی کند پایداری بیشتری خواهد داشت. لذا در ادامه از روش آموزش دسته ای استفاده می کنیم.

فرض کنید K تصویر ورودی و K بردار خروجی مطلوب داشته باشیم. اگر k^x و d^k به ترتیب k -امین تصویر در مجموعه ی آموزش و k -امین بردار خروجی مطلوب متناظر و y_n^k خروجی واقعی باشد، میتوان تابع خطا را به صورت زیر تعریف کرد:

$$E(w) = \frac{1}{K * N_L} \sum_{K=1}^K \sum_{N=1}^{N_L} (y_n^k - d_n^k)^2 \quad ۱-۳$$

۳-۴-۱ محاسبه ی گرادیان خطای شبکه ی CNN

گرادیان خطا از طریق محاسبه ی حساسیت های خطا به دست می آید که به صورت مشتق جزئی تابع خطا نسبت به ورودی جمع وزن دار net به یک، نرون تعریف میشود. ساختار شبکه ی کانولوشن شکل ۳-۱۴ را که دارای ۶ لایه ی فعال است در نظر بگیرید:



شکل ۳-۱۴: ساختار شبکه عصبی کانولوشن نمونه به ۶ لایه

در ساختار بالا، حرف C بیانگر لایه ی کانولوشن و S مشخص کننده ی لایه ی نمونه برداری جزئی است. اندیس ها نیز مشخص کننده ی شماره ی لایه ی فعال هستند. در ادامه روابط گرادیان های خطا برای لایه های مختلف شبکه ی فوق ارائه می گردد.

۳-۴-۲ الگوریتم های آموزشی CNN

در این نوشتار از روش های بهینه سازی مرتبه اول گرادیان نزولی و پس انتشار عدول شونده جهت اصلاح پارامترهای آزاد شبکه عصبی کانولوشن استفاده می کنیم در جدول ۳-۱ الگوریتم های آموزشی مورد استفاده، معرفی شده اند.

جدول ۳-۱: الگوریتم های آموزشی مورد استفاده برای شبکه ی کانولوشن پیشنهادی

روش بهینه سازی	الگوریتم اصلاح پارامترها
----------------	--------------------------

<p>وزن ها و بایاس طبق رابطه ی دلتا به صورت زیر اصلاح می شوند:</p> $\Delta w(t) = -\eta_w \cdot \nabla E_w(t)$ $\Delta b(t) = -\eta_b \cdot \nabla E_b(t)$ <p>η_w و η_b نرخ های آموزشی اسکالر و هواره مثبت هستند.</p>	<p>گرادیان نزولی (GD)</p>
<p>پارامتر ها براساس علامت گرادیان مربوطه بروزرسانی و اصلاح می شوند.</p> $\Delta w_i(t) = -\text{sign}\left\{\frac{\partial E}{\partial w_i}(t)\right\} \times \Delta_i(t)$ <p>که $\Delta_i(t)$ گام تطبیق پذیر مربوط به وزن w_i است و به صورت زیر تعریف می شود:</p> $\Delta w(t) = \begin{cases} \eta^+ \cdot \Delta_i(t-1); & \text{if } \nabla E_{w_i}(t) \cdot \nabla E_{w_i}(t-1) > 0 \\ \eta^- \cdot \Delta_i(t-1); & \text{if } \nabla E_{w_i}(t) \cdot \nabla E_{w_i}(t-1) < 0 \\ \Delta_i(t-1); & \text{otherwise} \end{cases}$	<p>پس انتشار عدول شونده (RPROP)</p>

۳-۵ حافظه کوتاه مدت طولانی

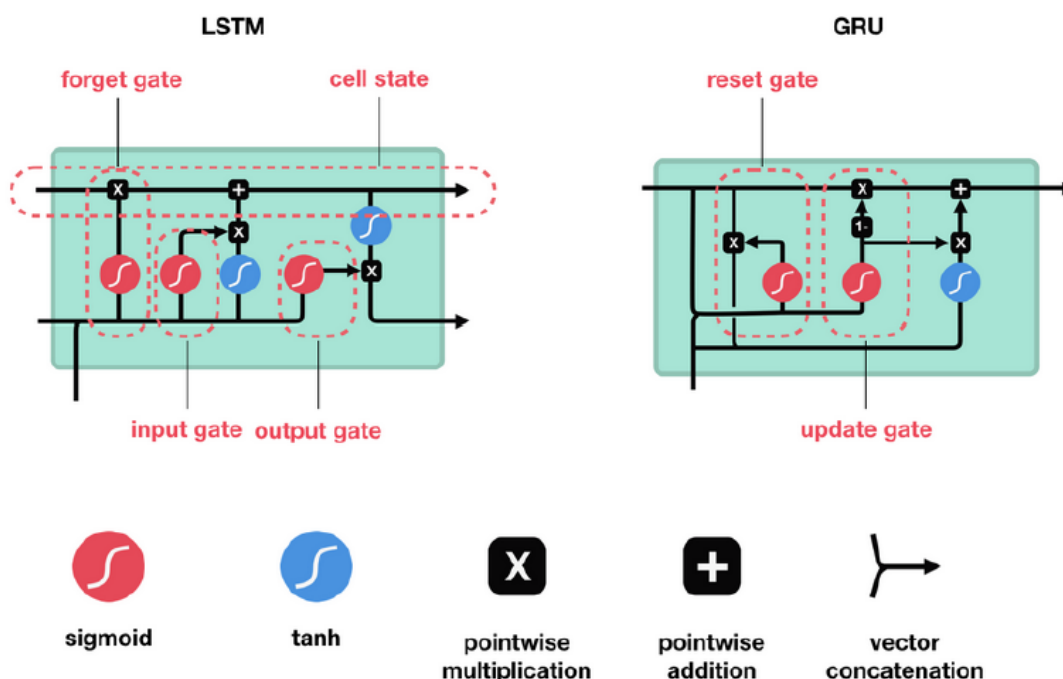
شبکه های حافظه کوتاه مدت طولانی نوع خاصی از شبکه های عصبی بازگشتی هستند که توانایی یادگیری وابستگی های بلند مدت را دارند.

حافظه کوتاه مدت طولانی یک معماری از شبکه عصبی بازگشتی مصنوعی است که در زمینه یادگیری عمیق مورد استفاده قرار می گیرد این شبکه ها نه تنها می تواند نقاط داده های واحد مانند (تصاویر) را پردازش کند بلکه دنباله های کل داده ها (مانند صدا یا فیلم) را نیز پردازش می کند به عنوان مثال برای کارهایی از قبیل تشخیص دست نویس، تشخیص صدا و تشخیص ناهنجاری در ترافیک شبکه کاربرد دارد.

شبکه های حافظه کوتاه مدت طولانی از نظر طبقه بندی پردازش و پیش بینی های مبتنی بر داده های سری زمانی مناسب هستند، زیرا می تواند مدت زمان ناشناخته ای را بین وقایع مهم در یک سری زمانی را ایجاد کند. این شبکه ها برای مقابله با مشکلات گرادیان ناپدید شده که می توانند هنگام آموزش شبکه های عصبی بازگشتی مصنوعی قدیمی رو به رو شوند ایجاد شده اند. عدم حساسیت نسبی نسبت به طول فاصله مزیت شبکه های حافظه کوتاه مدت نسبت به شبکه های عصبی بازگشتی مصنوعی است.

۳-۶ LSTM و GRU به عنوان یک راه حل

LSTM و GRU به عنوان راه حلی برای حافظه کوتاه مدت ایجاد شدند. آن‌ها مکانیسم‌های درونی به نام گیت دارند که می‌توانند جریان اطلاعات را تنظیم کنند.



شکل ۳-۱۵: LSTM و GRU


این گیت‌ها می‌توانند یاد بگیرند که کدام داده‌ها به صورت متوالی برای حفظ یا دور انداختن مهم است. با انجام این کار می‌تواند اطلاعات مربوطه را به زنجیره طولانی دنباله‌ها منتقل کند تا پیشبینی‌های لازم را انجام دهد. تقریباً تمام نتایج مبتنی بر شبکه‌های عصبی بازگشتی با این دو شبکه حاصل می‌شود. حافظه کوتاه مدت طولانی را می‌توان در تشخیص صدا ترکیب صدا و تولید متن به کار برد. حتی می‌توان از آن‌ها برای تولید زیر نویس‌ها برای فیلم‌ها نیز استفاده کرد.

۳-۷ مرور شبکه های عصبی بازگشتی

موارد بسیاری وجود دارد که داده ها به طور طبیعی توالی ایجاد می کنند و در این موارد ترتیب و محتوا به همان اندازه مهم هستند. نمونه های دیگر از داده های دنباله شامل فیلم موسیقی توالی دی ان ای و بسیاری موارد دیگر است. هنگام یادگیری از داده های دنباله ای حافظه کوتاه مدت برای پردازش یک سری از داده های مرتبط با محتوا مفید می شود. به همین منظور محققان یادگیری ماشین به مدت طولانی به شبکه عصبی بازگشتی روی آورده اند.

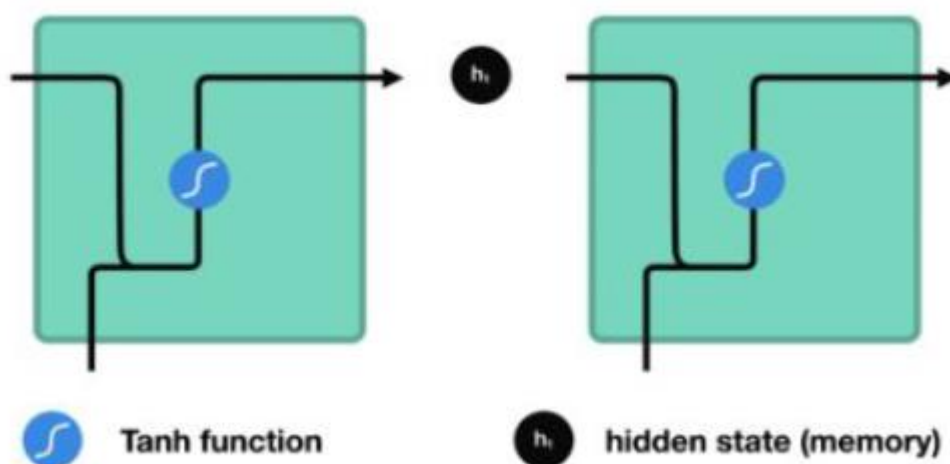
برای درک چگونگی دستیابی به LSTM و GRU شبکه عصبی بازگشتی را بررسی می کنیم شبکه عصبی بازگشتی به این صورت کار می کند

کلمات اول به بردارهای قابل خواندن با ماشین تبدیل می شوند سپس شبکه عصبی بازگشتی دنباله بردارها را یک به یک پردازش می کند.



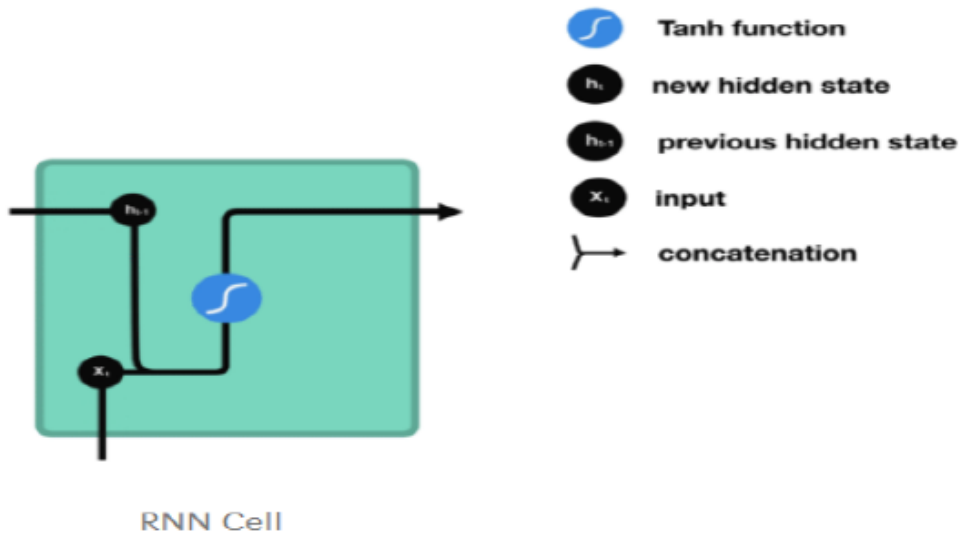
شکل ۳-۱۶: پردازش یک به یک دنباله ها

در حین پردازش، حالت پنهان قبلی را به مرحله بعدی دنباله منتقل می کند. حالت پنهان به عنوان حافظه در شبکه های عصبی عمل می کند. اطلاعات مربوط به داده های قبلی را که شبکه قبلاً دیده بود، در اختیار دارد.




شکل ۳-۱۷: عبور از حالت پنهان به مرحله بعدی

به یک سلول از شبکه عصبی بازگشتی نگاه می کنیم تا ببینیم حالت پنهان را چگونه محاسبه می کند. ابتدا ورودی حالت پنهان قبلی برای تشکیل یک بردار ترکیب می شوند این بردار اکنون اطلاعاتی در مورد ورودی فعلی و ورودی های قبلی دارد بردار از تابع تانژانت عبور می کند و خروجی حالت پنهان جدید یا حافظه شبکه است.




❖ تابع تانژانت

از تابع تانژانت برای تنظیم مقادیر جاری شده از طریق شبکه استفاده می شود تابع تانژانت مقادیر را جمع می کند تا همیشه بین ۱ تا -۱ باشد.



Tanh squishes values to be between -1 and 1



Tanh squishes values to be between -1 and 1


هنگامی که بردارها از طریق شبکه عصبی جریان می یابند به دلیل انجام عملیات مختلف ریاضی تغییرات زیادی را متحمل می شود بنابراین مقداری را تصور کنید مثلا ، همچنان ضرب می شود می بینید که چگونه بعضی از مقادیر می توانند منفجر شوند و نجومی شوند و باعث می شوند سایر مقادیر ناچیز باشند.



شکل ۳-۱۸: تغییرات برداری بدون تانژانت

تابع تانژانت تضمین می کند که مقادیر بین ۱ تا ۱ باقی بماند بنابراین خروجی شبکه عصبی را تنظیم می کند.

می توانید ببینید که چگونه همین مقادیر بالا بین مرزهای مجاز توسط تابع تانژانت باقی می ماند.




شکل ۳-۱۹: تغییرات برداری با تانژانت

بنابراین این یک شبکه عصبی بازگشتی است عملیات داخلی بسیار کمی دارد اما با توجه به شرایط مناسب (مانند دنباله های کوتاه) بسیار خوب کار می کند شبکه عصبی بازگشتی از منابع محاسباتی بسیار کمتری نسبت به انواع تکامل یافته مانند حافظه کوتاه مدت طولانی استفاده می کند.


❖ سیگموئید

گیت ها شامل توابع سیگموئید است. تابع سیگموئید شبیه به تابع تانژانت است به جای جمع کردن مقادیر بین ۱ و ۱-، مقادیر را بین ۰ و ۱ جمع می کند این برای به روزرسانی یا فراموش کردن داده ها مفید است زیرا هر عددی با صفر ضرب می شود صفر است که باعث می شود مقادیر از بین بروند یا فراموش شوند هر عددی با ۱ ضرب می شود همان عدد است بنابراین همان مقدار می ماند یا نگه داشته می شود

شبکه می تواند بیاموزد که کدام داده مهم نیست، بنابراین می تواند فراموش شود یا ببیند کدام داده برای نگهداری مهم است.



Sigmoid squishes values to be between 0 and 1




Sigmoid squishes values to be between 0 and 1

بیا یاد کمی عمیق تر در آنچه که گیت های مختلف انجام می دهند فکر کنیم. بنابراین ما سه گیت مختلف داریم که جریان اطلاعات در یک سلول حافظه کوتاه مدت طولانی را تنظیم می کنند گیت فراموشی، گیت ورودی و گیت خروجی.

❖ گیت فراموشی


ابتدا گیت فراموشی را داریم این گیت تصمیم می گیرد که چه اطلاعاتی باید دور ریخته یا نگهداری شود. اطلاعات مربوط به حالت پنهان قبلی و اطلاعات مربوط به ورودی فعلی از طریق تابع سیگموئید منتقل می شود. مقادیر بین ۰ و ۱ حاصل می شوند که نزدیک به صفر به معنی فراموش کردن است و نزدیک به ۱ به معنای حفظ است.



شکل ۳-۲۰: عملیات گیت فراموشی

❖ گیت ورودی


برای به روزرسانی وضعیت سلول گیت ورودی را داریم ابتدا حالت پنهان و ورودی فعلی را به یک تابع سیگموئید منتقل می کنیم. این تصمیم میگیرد که با تبدیل مقادیر بین ۰ و ۱ به روز شوند. به معنی "مهم نیست" و ۱ به معنی "مهم است". شما همچنین می توانید وضعیت پنهان و ورودی فعلی را در تابع تانژانت قرار دهید تا مقادیر بین ۱ تا -۱ را جمع کنید تا به تنظیم شبکه کمک کنید سپس خروجی تانژانت را با خروجی سیگموئید ضرب می کنید. خروجی سیگموئید تصمیم می گیرد که اطلاعات برای حفظ از خروجی تانژانت مهم است.



شکل ۳-۲۱: عملیات گیت ورودی

❖ سلول حالت


حال باید اطلاعات کافی برای محاسبه سلول حالت داشته باشیم، ابتدا حالت سلولی با وکتور فراموش شده ضرب می شود. در صورت ضرب در مقادیر نزدیک، صفر این احتمال وجود دارد که مقادیر را در سلول حالت کاهش دهد. سپس ما خروجی را از گیت ورودی می گیریم و جمع نقطه به نقطه را انجام می دهیم که حالت را به مقادیر جدیدی که شبکه عصبی مرتبط می داند به روز کند و سلول حالت جدید را به ما می دهد.



شکل ۳-۲۲: محاسبه سلول حالت

❖ گیت خروجی

در نهایت گیت خروجی داریم گیت خروجی تعیین می کند که حالت پنهان بعدی چیست. به یاد داشته باشید که حالت پنهان حاوی اطلاعاتی در مورد ورودی های قبلی است حالت پنهان نیز برای پیش بینی ها استفاده می شود. ابتدا حالت پنهان قبلی و ورودی فعلی را به یک تابع سیگموئید منتقل می کنیم سپس حالت سلول تازه اصلاح شده را به تابع تانژانت منتقل می کنیم. خروجی تانژانت را با خروجی سیگموئید ضرب می کنیم تا تصمیم بگیریم اطلاعات پنهان چه اطلاعاتی را باید داشته باشند خروجی حالت پنهان است سلول حالت جدید و پنهان جدید به مرحله بعدی منتقل می شود.

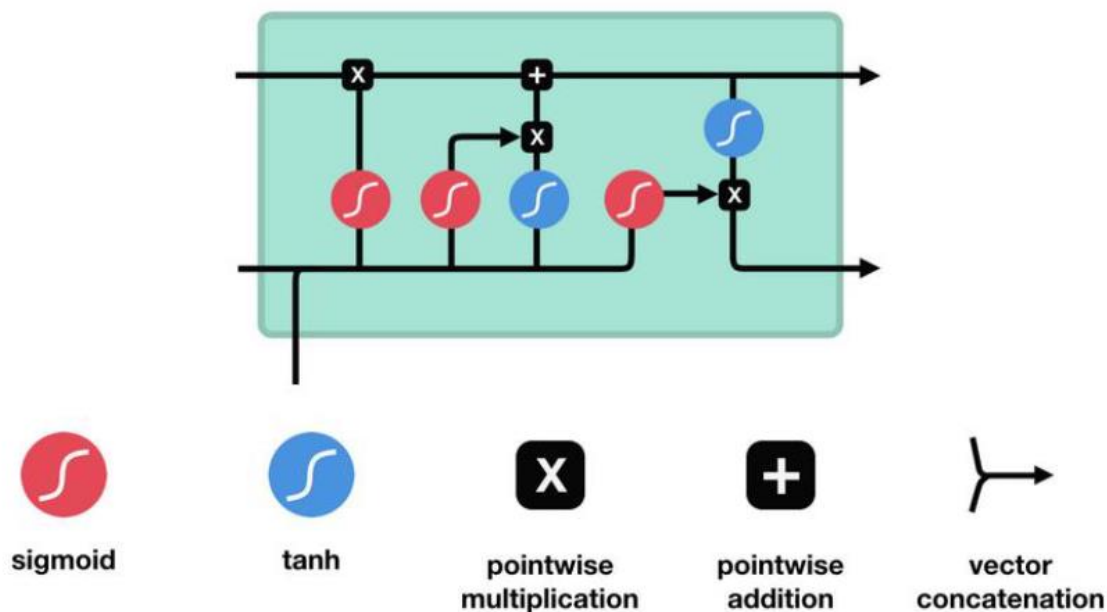


شکل ۳-۲۳: عملیات گیت خروجی

بنابراین گیت فراموشی تصمیم می گیرد مراحل قبلی برای حفظ چه مواردی مهم است گیت ورودی تصمیم می گیرد که چه اطلاعاتی را می توانید به مرحله فعلی اضافه کنید گیت خروجی تعیین می کند که حالت پنهان بعدی چیست.

LSTM ۱-۳

دارای یک جریان کنترل مشابه به عنوان یک شبکه عصبی بازگشتی است. پردازش داده های انتقال اطلاعات را هنگام انتشار به جلو انجام می دهد این اختلافات مربوط به عملیات درون سلول های حافظه کوتاه مدت طولانی است.



شکل ۳-۲۴: سلول LSTM و عملیات آن

۳-۹ جمع بندی

ترکیب شبکه های عصبی کانولوشن و حافظه طولانی کوتاه مدت و نحوه عملکرد آن ها در این فصل تشریح شد. نحوه ترکیب آن ها برای حذف الگو های مویر نیز مطرح شد. در فصل بعدی به نتایج و ارزیابی روش پیشنهادی با روش های موجود پرداخته می شود.

فصل ۴: نتایج و بحث

۴-۱ مقدمه

بعد از تشریح روش پیشنهادی در این فصل به پیاده سازی و نتایج حاصل از پژوهش پرداخته شده است. روش پیشنهادی با استفاده از زبان برنامه نویسی پایتون در سیستم با مشخصات زیر پیاده سازی شده است:

Core i7 :CPU

8 G :Ram

1 T :Hard

2 G :Graphic Card

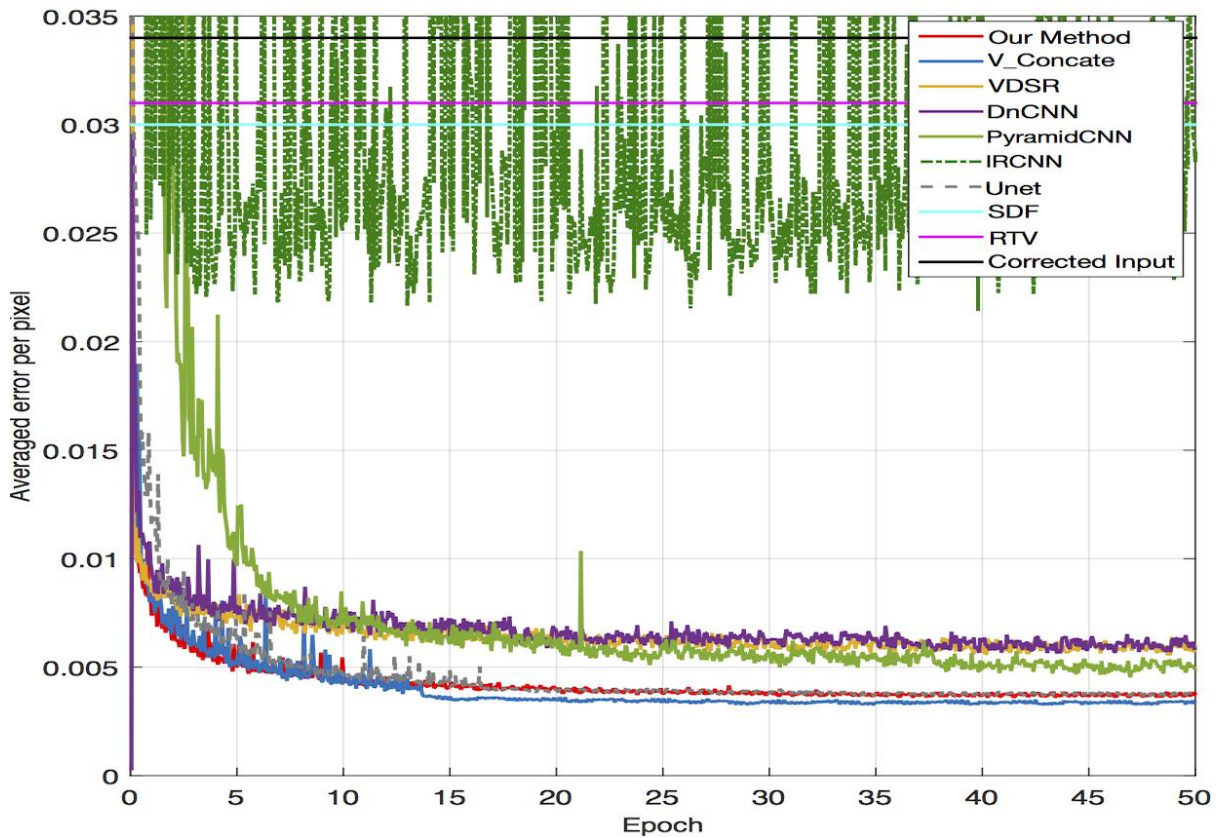
۴-۲ نتایج و تحلیل

در این بخش، به طور تجربی توانایی روش خود را در بهبود کیفیت تصویر و حذف مصنوعات مویر تجزیه و تحلیل می کنیم. از آنجایی که ما از هیچ روش موجودی که دقیقاً همان مشکل را حل می کند آگاه نیستیم، روش خود را با روش های پیشرفته در مشکلات مربوط به بازیابی تصویر، از جمله حذف نویز تصویر، رفع تاری، وضوح فوق العاده و حذف بافت مقایسه می کنیم. ما VDSR را به عنوان نماینده از الگوریتم های وضوح تصویر فوق العاده، DnCNN و IRCNN از جدیدترین روش های حذف نویز تصویر، و RTV و SDF را از میان تکنیک های حذف بافت انتخاب می کنیم. برای اینکه زیرمجموعه ای از عکس های مویر در مجموعه داده ما دارای درجه خاصی از تاری است و تکنیک های تاری زدایی می توانند جزئیات با فرکانس بالا را بازسازی کنند، ما همچنین دو آخرین تکنیک کاهش تاری تصویر مبتنی بر یادگیری، چند مقیاسی هرمی CNN و IRCNN را اضافه می کنیم. علاوه بر این، از آنجایی که ما یک معماری شبکه سلسله مراتبی را اتخاذ می کنیم، شبکه خود را با U-Net نیز مقایسه می کنیم، یک شبکه عصبی موثر برای تقسیم بندی تصویر.

برای انجام یک مقایسه منصفانه، پارامترهای روش‌هایی را که با آن مقایسه می‌کنیم تنظیم می‌کنیم تا به عملکرد بهینه در مجموعه داده ما برسند. هنگامی که یک روش فقط تعداد کمی پارامتر قابل تنظیم دارد، آن پارامترها را تنظیم می‌کنیم تا روش به کمترین میانگین خطا در مجموعه آزمایشی ما دست یابد. هنگامی که یک روش دارای تعداد زیادی پارامتر مانند روش‌های مبتنی بر یادگیری است، ما مدل را در روش با استفاده از مجموعه آموزشی خود آموزش می‌دهیم.

حتی اگر هدف روش‌های غربال‌زدایی از بین بردن افکت مویر متفاوت و ساده‌تر است که در کپی‌های اسکن شده اسناد و تصاویر چاپ‌شده رخ می‌دهد، مطمئناً مرتبط هستند. از آنجایی که چنین روش‌هایی نسبتاً بالغ هستند و در نرم‌افزارهای تجاری ادغام شده‌اند، ما انتخاب می‌کنیم که با عملکرد صفحه‌زدایی در فتوشاپ مقایسه کنیم.

در شکل ۱-۴ و جدول ۱-۴، عملکرد کمی روش‌های مختلف را در مجموعه آزمایشی خود نشان می‌دهیم. از آنجایی که تصویر آلوده و تصویر مرجع در یک جفت به دلایل متعدد، از جمله روشنایی صفحه کامپیوتر و منحنی واکنش شدت دوربین در حین گرفتن تصویر، سطوح شدت متوسط متفاوتی دارند، که عمدتاً به مویر بی ربط هستند. در نتیجه، ما تصمیم گرفتیم تفاوت‌های شدت متوسط را با تنظیم شدت متوسط تصویر آلوده به همان اندازه تصویر مرجع (ورودی تصحیح شده) فاکتور کنیم. همانطور که نشان داده شده است، روش ما و نوع مدل ما، از همه روش‌های شرکت‌کننده در مقایسه در همه معیارهای عملکرد، از جمله PSNR، SSIM و FSIM، بهتر عمل می‌کند. از آنجایی که پارامترهای صفحه‌زدایی در فتوشاپ باید به صورت دستی برای هر تصویر تنظیم شوند، ما نمی‌توانیم میانگین عملکرد را در کل مجموعه آزمایشی نشان دهیم. با این حال، ما آن را از نظر کیفی با روش خود در بخش بعدی مقایسه خواهیم کرد.



شکل ۴-۱: میانگین خطای پیکسلی MSE روش های مختلف و تعداد دوره ها

جدول ۴-۱: مقایسه کمی بین روش های شرکت در مجموعه آزمون ما با معیارهای مختلف. روش ما به وضوح از روش های دیگر بهتر عمل می کند.

	Corrected Input	RTV	SDF	IRCNN	DnCNN	VDSR	PyramidCNN	U-Net	V_Concate	Our method
PSNR Mean (dB)	20.30	20.67	20.88	21.01	24.54	24.68	25.39	26.49	27.12	26.77
PSNR Gain (dB)	-	0.37	0.58	0.71	4.24	4.38	5.09	6.19	7.09	6.47
Ave Error ($\times 10^{-3}$)	34	31	30	28.32	5.82	5.74	4.83	3.81	3.36	3.62
SSIM	0.738	-	-	-	0.834	0.837	0.859	0.864	0.878	0.871
FSIM	0.869	-	-	-	0.901	0.902	0.909	0.912	0.922	0.914


VDSR که به عنوان یک روش با وضوح فوق العاده موثر است، عملکرد معقولی را ارائه می دهد اما قادر به مدیریت کامل جلوه پیچیده مویر نیست. با استفاده از پیکربندی با یک میدان پذیرنده بزرگ، شبکه حذف نویز (DnCNN) عملکردی مشابه با VDSR دارد. هر دو VDSR و DnCNN از یک معماری CNN مسطح استفاده می کنند که وضوح یکسانی را در تمام لایه ها حفظ می کند. با این حال، هر دوی آنها به وضوح توسط شبکه چند رزولوشن ما بهتر عمل کرده اند.

IRCNN با تعریف یک پیشین حذف نویز با پیچش های گشاد شده، از روش های پیشرفته در کارهای بازبازی تصویر پیکسلی بهتر عمل می کند. با این حال، در مجموعه داده ما ضعیف عمل می کند و روند آموزش آن به سختی می تواند با مجموعه آموزشی ما همگرا شود. پس از اصلاح IRCNN با درهم آمیختن کانولوشن های معمولی و پیچش ها، یک مدل اصلاح شده به نام IRCNN-IL به دست می آوریم. مشکل همگرایی در مدل اصلاح شده حل شده است اما عملکرد آن هنوز رضایت بخش نیست. PSNR، SSIM و FSIM به دست آمده توسط IRCNN-IL به ترتیب ۲۱،۵۵، ۰،۷۴۴ و ۰،۸۷۰ است. در تئوری، سر و صدایی که IRCNN با آن مقابله می کند کاملاً متفاوت از الگوهای مویر است که ما سعی در حذف آن داریم. یک تصویر پر سر و صدا معمولاً به عنوان نتیجه یک فرآیند افزایشی مدل سازی می شود که نویز را به سیگنال اصلی اضافه می کند، اما الگوی مویر پدیده ای است که در اثر تداخل نور ایجاد می شود، که فرآیندی متفاوت و بسیار پیچیده تر است. هسته های گشاد شده می توانند صداهای افزودنی را حذف کنند، اما ممکن است برای حذف الگوهای پیچیده مویر کافی نباشند. با توجه به مکانیسم های زیربنایی مختلف نویزهای تصویر و الگوهای مویر، نمی توان مطمئن بود که IRCNN برای بازبازی عکس های مویر موثر است.

در بین تمام روش ها، U-Net به عملکرد عددی نزدیک ترین عملکرد به روش ما دست می یابد. با این حال، ما متوجه شدیم که اگرچه U-Net آمار خوبی تولید می کند، اما نتایج بصری نسبتاً ضعیفی ارائه می دهد که در مقایسه های بصری نشان داده خواهد شد. به همین ترتیب، بالاترین امتیاز را در تمام معیارها ایجاد می کند، اما توانایی آن در حذف بصری الگوهای مویر کمتر از مدل اصلی است.


تکنیک های حذف بافت، RTV و SDF، در حفظ ساختارهای مهم تصویر و در عین حال حذف جزئیات کوچک بافتی تکراری مفید هستند. اما ویژگی های تصویر در مقیاس مشابه عناصر بافت نیز حذف خواهند شد. در زمینه ما، این تکنیک ها برای حذف الگوهای مویر استفاده می شوند و عملکرد ضعیفی در این کار دارند. مشکل در تنظیم اندازه هسته بافت مناسب می تواند دلیل اصلی باشد زیرا یک هسته صاف کننده و بافت بزرگ تصویر را بیش از حد صاف می کند در حالی که یک هسته کوچک نمی تواند مصنوعات مویر در مقیاس بزرگ با فرکانس پایین را حذف کند.

ما به صورت بصری نتایج روش خود را با سایر روش‌های پیشرفته در شکل ۴-۲ مقایسه می‌کنیم. مقایسه‌های بصری اضافی را می‌توان در مواد تکمیلی یافت. توجه داشته باشید که تصاویر ورودی همه از مجموعه تست هستند. از این مقایسه‌ها، مشاهدات زیر را داریم. SDF و RTV ویژگی‌های بافت در مقیاس کوچک را حذف می‌کنند که معمولاً فرکانس‌های بالاتری نسبت به الگوهای مویر دارند. حذف صفحه در فتوشاپ تصویر ورودی را بیش از حد صاف می‌کند. در بین روش‌های مبتنی بر یادگیری عمیق، IRCNN به هیچ وجه قادر به حذف الگوهای مویر نیست، حتی اگر شبکه آن با استفاده از مجموعه آموزشی ما دوباره آموزش داده شده باشد. در همین حال، VDSR، PyramidCNN و DnCNN عملکرد بهتری دارند. با این حال، اعوجاج رنگ هنوز در نتایج آنها قابل توجه است.



شکل ۴-۲: مقایسه بین شبکه عمیق چند رزولوشن ما و سایر روش‌های پیشرفته برای بازیابی تصویر، از جمله SDF و RTV، pyramidCNN، DnCNN، VDSR، U-Net، IRCNN، Photoshop Descreen

به جز روش‌های ما، U-Net بالاترین امتیاز را از همه معیارهای کیفیت کسب می‌کند. اما مصنوعات مویر بیشتری در نتایج آن نسبت به نتایج VDSR و DnCNN باقی مانده است. همانطور که قبلاً بیان کردیم، حتی اگر یک معیار کیفیت، مانند PSNR، می‌تواند کیفیت کلی تصویر را اندازه‌گیری کند، نمی‌تواند دقیقاً تأثیر را در حذف الگوی مویر اندازه‌گیری کند. ما یک مثال را در شکل ۳-۴ نشان می‌دهیم و مواد تکمیلی که U-Net PSNR های بالاتر اما نتایج بصری بدتری تولید می‌کند. روش ما قوی‌ترین معماری شبکه را دارد و تصاویر خروجی را نزدیک‌ترین به تصاویر مرجع حقیقت پایه تولید می‌کند.




شکل ۳-۴: مثال دیگری که در آن U-Net امتیاز PSNR بالاتری ایجاد می‌کند اما اثر حذف مویر بدتری دارد.

همانطور که در جدول ۲-۴ نشان داده شده است. تعداد متغیرها در روش ما به ترتیب U-Net و PyramidCNN است در حالی که شبکه پیشنهادی ما از نظر کیفی و کمی از هر دوی آنها بهتر است. انواع مدل ما، V B15 و V C32، دارای تعداد پارامترهای مشابهی مانند VDSR و DnCNN هستند، با این حال نمرات PSNR بالاتری دارند.

جدول ۲-۴: تعداد متغیرها در یادگیری

	V_B123	V_B15	V_C32	V_Concate	Our method
# var	9.28	7.42	4.11	16.14	15.44
	IRCNN-IL	VDSR	DnCNN	PyramidCNN	U-Net
# var	3.35	6.67	7.04	14.15	24.62

با توجه به محدودیت معیارهای تصویر در اندازه‌گیری مصنوعات مویر، ما همچنین یک مطالعه کاربری برای مقایسه روش‌های مختلف انجام داده‌ایم که شامل ۲۰ سؤال است. هر سؤال شامل شش نتیجه مرتب شده تصادفی است که توسط VDSR، DnCNN، PyramidCNN، U-Net، V Concat و روش ما بر روی یک تصویر آزمایشی انتخاب شده به‌طور تصادفی تولید شده‌اند. ۶۰ شرکت‌کننده باید ۱ تا ۲ تصویر را انتخاب کنند که از نظر آنها جذاب‌ترین و راحت‌تر باشد. پس از میانگین‌گیری آرا از هر ۲۰ سؤال، آمار موجود در شکل ۴-۴ را بدست می‌آوریم. واضح است که مدل پیشنهادی نسبت به سیستم بینایی انسان ارجحیت بیشتری دارد، اگرچه U-Net و V Concat امتیازات بالایی را تحت معیارهای عددی کیفیت تصویر خاص به دست می‌آورند.



شکل ۴-۴: مطالعه کاربر در مورد بازیابی الگوی مویر

۳-۴ جمع بندی

در این فصل ابتدا مقدماتی درباره زبان برنامه نویسی و سیستمی که روش پیشنهادی روی آن پیاده سازی شده معرفی شد. سپس به نحوه پیاده سازی روش پیشنهادی پرداخته شده و در نهایت نتایج حاصل از پژوهش تشریح شد. نتایج نشان داد که روش پیشنهادی می‌تواند باعث حذف الگو مویر شود.

فصل ۵: نتیجه گیری

۵-۱ نتیجه گیری

برای نتیجه گیری، ما یک شبکه کاملاً پیچیده چند رزولوشن جدید برای حذف خودکار الگوهای مویر از عکس ها و همچنین ایجاد یک معیار در مقیاس بزرگ با ۱۰۰۰۰۰ جفت تصویر برای ارزیابی الگوریتم‌های حذف الگوی مویر ارائه کردیم.. اگرچه یک الگوی مویر می‌تواند در طیف وسیعی از فرکانس‌ها باشد، شبکه پیشنهادی ما به لطف تجزیه و تحلیل چند وضوح غیرخطی عکس‌های مویر، می‌تواند مصنوعات مویر را در هر باند فرکانسی حذف کند. مردم به دلایلی بیش از حد انتظار مانند راحتی، سادگی و کارایی دوست دارند از تلفن همراه خود برای ضبط محتوا بر روی صفحه نمایش استفاده کنند. روش پیشنهادی و معیار جمع‌آوری شده در مقیاس بزرگ با هم راه‌حل مناسبی برای مشکل بازسازی عکس مویر ارائه می‌دهند. روش پیشنهادی این پژوهش بر اساس الگوریتم‌های شبکه عصبی کانولوشن و حافظه طولانی کوتاه مدت می‌باشد. نتایج نشان داد که روش پیشنهادی به خوبی می‌تواند باعث حذف الگو مویر در تصاویر شود.

۵-۲ پیشنهادات

در آینده، می‌خواهیم دسته‌های مختلف الگوهای مویر را بررسی کنیم و روش خود را بهبود ببخشیم تا بتواند مصنوعات مویر را با توجه به برجستگی‌های دسته‌بندی‌شان حذف کند. علاوه بر این، بررسی وجود شاخصی که می‌تواند سطح مصنوعات مویر را بهتر توصیف کند و روند آموزش را هدایت کند، جالب خواهد بود. همچنین قصد داریم با افزودن نمونه‌های بیشتر تحت شرایط مختلف عکسبرداری و برای انواع مختلف صفحه‌نمایش دستگاه، مجموعه داده خود را گسترش دهیم. ما بر این باوریم که با یک مجموعه داده بزرگتر، روش ما می‌تواند نتایج بهتری را ایجاد کند.

- [١] T. Tu and W.-B. Goh, "Moiré patterns from a CCD camera-are they annoying artifacts or can they be useful?," 2009.
- [٢] J. Guild, *The interference systems of crossed diffraction gratings: theory of moiré fringes*. Clarendon Press, 1956.
- [٣] S. MALLICK " ,DIFFRACTION GRATINGS AS MEASURING SCALES. PRACTICAL GUIDE TO METROLOGICAL USE OF MOIRE FRINGES," ed, 1965.
- [٤] M. G. Gustafsson, "Surpassing the lateral resolution limit by a factor of two using structured illumination microscopy," *Journal of microscopy* ,vol. 198, no. 2, pp. 82-87, 2000.
- [٥] B. Ham, M. Cho, and J. Ponce, "Robust image filtering using joint static and dynamic guidance," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 4823-4831 .
- [٦] L. Karacan ,E. Erdem, and A. Erdem, "Structure-preserving image smoothing via region covariances," *ACM Transactions on Graphics (TOG)*, vol. 32, no. 6, pp. 1-11, 2013.
- [٧] F. Liu, J. Yang, and H. Yue, "Moiré pattern removal from texture images via low-rank and sparse matrix decomposition," in *2015 Visual Communications and Image Processing (VCIP)*, 2015: IEEE, pp. 1-4 .
- [٨] J. Ok, S. Youn, G. Seo, E. Choi, Y. Baek, and C. Lee, "Paper check image quality enhancement with Moire reduction," *Multimedia Tools and Applications*, vol. 76, no. 20, pp. 21423-21450, 2017.
- [٩] D. N. Sidorov and A. C. Kokaram, "Suppression of moiré patterns via spectral analysis," in *Visual Communications and Image Processing 2002*, 2002, vol. 4671: SPIE, pp. 895-906 .
- [١٠] J. W. Glotzbach, R. W .Schafer, and K. Illgner, "A method of color filter array interpolation with alias cancellation properties," in *Proceedings 2001 international conference on image processing (Cat. No. 01CH37205)*, 2001, vol. 1: IEEE, pp. 141-144 .
- [١١] W. K. Pratt, *Digital image processing: PIKS Scientific inside*. Wiley Online Library, 2007.
- [١٢] J. Yang, X. Zhang, C. Cai, and K. Li, "Demoiréing for screen-shot images with multi-channel layer decomposition," in *2017 IEEE Visual Communications and Image Processing (VCIP :٢٠١٧)* ,(IEEE, pp. 1-4 .

- [۱۳] Y. Sun, Y. Yu, and W. Wang, "Moiré photo restoration using multiresolution convolutional neural networks," *IEEE Transactions on Image Processing*, vol. 27, no. 8, pp. 4160-4172, 2018.
- [۱۴] X. Cheng, Z. Fu, and J. Yang, "Multi-scale dynamic feature encoding network for image demoiréing," in *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, 2019: IEEE, pp. 3486-3493 .
- [۱۵] X. Cheng, Z. Fu, and J. Yang, "Improved multi-scale dynamic feature encoding network for image demoiréing," *Pattern Recognition*, vol. 116, p. 107970, 2021.
- [۱۶] I. Hong, Y. Hwang, and D. Kim, "Efficient deep learning of image denoising using patch complexity local divide and deep conquer," *Pattern Recognition*, vol. 96, p. 106945, 2019.
- [۱۷] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising," *IEEE transactions on image processing*, vol. 26, no. 7, pp. 3142-3155, 2017.
- [۱۸] C. Dong, C. C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks," *IEEE transactions on pattern analysis and machine intelligence*, vol. 38, no. 2, pp. 295-307, 2015.
- [۱۹] W. Shi *et al.*, "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 1874-1883 .
- [۲۰] Z. Wei, J. Wang, H. Nichol, S. Wiebe, and D. Chapman, "A median-Gaussian filtering framework for Moiré pattern noise removal from X-ray microscopy image," *Micron*, vol. 43, no. 2-3, pp. 170-176, 2012.
- [۲۱] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *2009 IEEE conference on computer vision and pattern recognition*, 2009: Ieee, pp. 248-255 .
- [۲۲] B. Liu, X. Shu, and X. Wu, "Demoiréing of Camera-Captured Screen Images Using Deep Convolutional Neural Network," *arXiv preprint arXiv:1804.03809*, 2018.

[23] امینی، جعفر ، "اندازه گیری مدول یانگ با استفاده از روش مواره" | مجله رشد آموزش فیزیک، دوره بیست و پنجم شماره ۱ صفحه ۴۷-۴۰ ، پاییز ۱۳۸۸ .

[24] K.Patorski, M.Kujawiska "Handbook of the moiré fringe technique" Elsevier, Netherland, chapter 1, (1993).

[25] M. Abolhassani and M. Mirzaei, "Unification of formulation of moiré fringe spacing in parametric equation and Fourier analysis methods," *Opt. Vol.46* (32), pp.7924–7926, (2007).

[26] M. Abolhassani, "Formulation of moiré fringes based of spatial averaging," *Opt. Vol. 122*, pp.510-513, (2011).

[٢٧] Perrin Smith Neto “The Shadow Moiré Method using the Phase Shifting Technique and Digital Image Processing: Computational Implementation and Application to the 3D-Reconstruction of a Buckled Plate “ J. Braz. Soc. Mech. Sci. vol.22 n.3 Campinas 2000.

[٢٨] J. Degrieck, W. Van Paeppegem, P. Boone ” Application of digital phase-shift shadow Moiré to micro deformation measurements of curve surfaces” Department of Mechanical Construction and Production, Ghent University, Sint-Pietersnieuwstraat , Belgium 2001.

[٢٩] Huimin Xiea , Haixia Shanga, Fulong Daia , Biao Lib, Yongming Xingc “Phase shifting SEM moire method “ Department of Engineering Mechanics Tsinghua University, Beijing 100084, P. R. China 2004.

[٣٠] Daniel Post , Bongtae Han ,Peter Ifju , *High Sensitivity Moire* , Springer-Verlag New York, Inc., 175 Fifth Avenue, New York, NY 10010, USA, 1994 , pp.124-127.

[31] Chino, D.Y., Avalhais, L.P., Rodrigues, J.F. and Traina, A.J., 2015, August. Bowfire: detection of fire in still images by integrating pixel color and texture analysis. In 2015 28th SIBGRAPI Conference on Graphics, Patterns and Images (pp. 95-102). IEEE.

[32] LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), pp.2278-2324.

[33] Krizhevsky, A., Sutskever, I. and Hinton, G.E., 2012. Imagenet classification with deep convolutional neural networks. In Advances in neural information processing systems (pp. 1097-1105).

[34] Zeiler, M.D. and Fergus, R., 2014, September. Visualizing and understanding convolutional networks. In European conference on computer vision (pp. 818-833). Springer, Cham.

[35] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A., 2015. Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).

[36] Simonyan, K. and Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

[37] He, K., Zhang, X., Ren, S. and Sun, J., 2016. Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).