

## طبقه‌بندی پوشش‌های جنگلی با استفاده از داده‌های شبیه‌سازی شده پلاریمتری فشرده و شبکه‌های یادگیری عمیق

سحر ابراهیمی<sup>۱\*</sup>، حمید عبادی<sup>۲</sup>، امیر آقابالائی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد فتوگرامتری، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- استاد گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۳- دانش‌آموخته دکتری سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۳۹۹/۱۰/۰۶ تاریخ پذیرش مقاله: ۱۴۰۰/۰۶/۱۶

### چکیده

در دو دهه اخیر از میان مدهای مختلف تصویربرداری تصاویر رادار با روزه مجازی (SAR)، مد پلاریمتری فشرده (CP) بسیار مورد توجه واقع شده است. از جمله این مزایا می‌توان به کاهش پیچیدگی سیستم تصویربرداری، کاهش حجم و نرخ داده و همچنین عرض نوار برداشت بزرگتر اشاره نمود. وجود چنین مزایایی باعث می‌شود که این داده‌ها برای پایش اهداف در مقیاسی وسیع، به عنوان مثال طبقه‌بندی جنگل، مفید واقع شوند. اکثر روش‌های ارائه شده برای طبقه‌بندی جنگل با استفاده از این مد بر پایه استخراج ویژگی از تصور عمل می‌کنند. دقت این روش‌ها به تمایز ویژگی‌های استخراج شده بستگی دارد. در این میان، شبکه‌های یادگیری عمیق مرحله استخراج ویژگی را تا حد زیادی خودکار نموده و به نتایج چشم‌گیری به خصوص در امر طبقه‌بندی دست یافته‌اند. در این تحقیق قابلیت شبکه‌های یادگیری عمیق با استفاده از داده‌های CP در طبقه‌بندی جنگل مورد بررسی قرار می‌گیرد. منطقه مطالعاتی در این تحقیق جنگل پتاواوا واقع در ایالت آنتاریو کشور کانادا و داده‌های مورد استفاده داده‌های شبیه‌سازی شده CP، داده‌های تمام پلاریمتری (FP) و نیز داده‌های بازسازی شده از CP (PQ) اخذ شده از سنجنده رادارست - ۲ در باند C هستند. شبکه عمیق مناسب به منظور استخراج خودکار ویژگی‌ها طراحی شده و طبقه‌بندی بر روی داده‌های CP، FP و PQ انجام می‌گیرد. نتایج حاصل از طبقه‌بندی مدها با یکدیگر و همچنین با طبقه‌بندی‌کننده ویشارت و ماشین بردار پشتیبان (SVM) مقایسه و ارزیابی شدند. نتایج این تحقیق نشان می‌دهند که استفاده از شبکه‌های یادگیری عمیق، دقت حاصل از طبقه‌بندی را در بهترین مد CP به ۸۲٫۰۱٪ و در بهترین مد PQ به ۸۲٫۶۳٪ می‌رساند. دقت نتایج حاصل از روش پیشنهادی، در مدهای  $\pi/4$ ، DCP و CTLR از مدهای CP نسبت به روش SVM به ترتیب حدود ۵٪، ۸٪ و ۵٪ و نسبت به روش ویشارت به ترتیب ۱۵٪، ۲۰٪ و ۱۶٪ بهبود یافته است. همچنین در مدهای PQ\_DCP و PQ\_CTLR نیز نسبت به هر دو روش SVM و ویشارت افزایش دقت به چشم می‌خورد.

کلید واژه‌ها: رادار با روزه مجازی، پلاریمتری فشرده، شبکه عصبی پیچشی، طبقه‌بندی گونه‌های جنگلی.

\* نویسنده مکاتبه کننده: تهران، خیابان ولی عصر، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی.

تلفن: ۰۹۱۹۲۷۸۳۱۲

## ۱- مقدمه

از جمله کاربردهای مهم سنجش از دور تهیه نقشه‌های پوششی است. زمین دارای پوشش‌های متنوعی از جمله مناطق شهری، آب، زمین‌های کشاورزی، جنگل و غیره است که داشتن نقشه‌های طبقه‌بندی‌شده از هر یک از موارد مذکور، نقش مهمی در مدیریت و برنامه‌ریزی صحیح ایفا می‌کند. در این میان جنگل‌ها با پوشش حدود ۳۱٪ از سطح زمین و به دلیل نقش حیاتی در فرآیندهای زیست محیطی، یکی از مهم‌ترین اکوسیستم‌های زمین هستند. به منظور حفظ این منابع پرارزش، تهیه نقشه‌های طبقه‌بندی‌شده با هدف مدیریت منابع و توسعه پایدار، امری ضروری است که فناوری سنجش از دور به خوبی این امکان را فراهم آورده است.

از میان داده‌های مختلف سنجش از دوری، داده‌های رادار با روزهی مجازی ( $SAR^1$ )، به دلیل عدم وابستگی به خورشید و در نتیجه امکان اخذ تصویر در کل مدت شبانه‌روز، امکان تصویربرداری در هر نوع شرایط جوی و قابلیت نفوذ در اهداف (در طول موج‌های بلند) بسیار مورد توجه می‌باشند.

با پیشرفت تکنیک‌های اخذ داده  $SAR$ ، مدهای تصویربرداری مختلفی از جمله پلاریمتری یگانه ( $SP^2$ )، پلاریمتری دوگانه ( $DP^3$ )، تمام پلاریمتری ( $FP^4$ ) و پلاریمتری فشرده ( $CP^5$ ) به سامانه‌های تصویربرداری راداری اعمال گردیده است [۱]. سیستم‌های تصویربرداری در مد  $FP$ ، دو پلاریزاسیون متعامد افقی ( $H^6$ ) و عمودی ( $V^7$ ) را ارسال و چهار پلاریزاسیون به

صورت ارسال و دریافت افقی ( $HH$ )، ارسال افقی و دریافت عمودی ( $HV$ )، ارسال عمودی و دریافت افقی ( $VH$ ) و ارسال و دریافت عمودی ( $VV$ ) را ثبت می‌کنند که امکان استخراج اطلاعات بیشتری را از هدف می‌دهد که همین موضوع، مزیت اساسی این سیستم‌های تصویربرداری در مقابل سیستم‌های تصویربرداری  $SP$  می‌باشد.

مد  $CP$  به عنوان زیر مجموعه‌ای از مد  $DP$  تعریف گردیده و دارای مزایایی مهمی در مقایسه با دیگر مدهای تصویربرداری پلاریمتری  $SAR$  ( $PolSAR^8$ ) می‌باشد. از جمله این مزایا می‌توان به کاهش پیچیدگی، کاهش حجم تصویربرداری و نیز هزینه کم‌تر اشاره کرد. هم‌چنین فرکانس تکرار پالس ( $PRF^9$ ) و نرخ اخذ داده که در مورد مد  $FP$  مشکلی اساسی تلقی می‌گردد، در مورد مد  $CP$  بسیار کم‌تر است. مزیت دیگر مد  $CP$  فواصل کوتاه بازبینی ماهواره‌ای ( $10^4$  روز) است [۲]. هم‌چنین مد  $CP$  دارای عرض تصویربرداری دو برابر نسبت به  $FP$  می‌باشد. به همین علت استفاده از مد  $CP$  هنگامی که منابع سیستم‌های  $FP$  محدود هستند یا در دسترس نمی‌باشند، یک استراتژی موثر می‌باشد [۳]. مزیت مهم دیگر این است که مد تصویربرداری  $CP$  بر پایه تعدادی فرض اولیه معلوم می‌تواند داده شبه  $FP$  ( $PQ^{11}$ ) را بازسازی کند [۴]. وجود چنین مزیت‌هایی، اهمیت سیستم‌های تصویربرداری در مد  $CP$  در کاربردهای مختلف از جمله طبقه‌بندی نمایان می‌سازد.

روش‌های طبقه‌بندی تصاویر  $PolSAR$  عمدتاً روش‌هایی

<sup>۱</sup> Synthetic Aperture RADAR

<sup>۲</sup> Single Polarimetry

<sup>۳</sup> Dual Polarimetry

<sup>۴</sup> Full Polarimetry

<sup>۵</sup> Compact Polarimetry

<sup>۶</sup> Horizontal

<sup>۷</sup> Vertical

<sup>۸</sup> Polarimetric SAR

<sup>۹</sup> Pulse Repetition Frequency

<sup>۱۰</sup> Revisiting Time

<sup>۱۱</sup> Pseudo Quad

نیز مفید واقع شود.

از میان مقالاتی که در حوزه طبقه‌بندی با تصاویر *CP* کار شده است، تاکنون هیچ‌یک به بررسی عملکرد شبکه‌های یادگیری عمیق برای تفکیک گونه‌های جنگلی نپرداخته‌اند [۱۲، ۱۳ و ۱۴]. بر این اساس، هدف از انجام این تحقیق ارائه روشی بر اساس شبکه *CNN* برای انجام طبقه‌بندی گونه‌های جنگلی با استفاده از تصاویر *CP* می‌باشد. در این مقاله، ابتدا معماری شبکه *CNN* مورد نظر معرفی و پارامترهای آن بهینه‌سازی می‌شوند. سپس عمل طبقه‌بندی با استفاده از شبکه *CNN* بر روی داده‌های *CP*، *FP* و نیز *PQ* انجام می‌گیرد.

مقاله پیش رو شامل شش بخش است. در بخش اول به مقدمه و بیان مساله پرداخته شد. در بخش ۲ به مبانی نظری مرتبط با این تحقیق پرداخته می‌شود. بخش ۳ به معرفی منطقه مطالعاتی و نیز داده‌های مورد استفاده می‌پردازد. در بخش ۴ روش پیشنهادی مورد استفاده در این تحقیق ارائه می‌گردد. در بخش ۵ نتایج حاصل ارائه شده و به بحث و بررسی در مورد نتایج پرداخته می‌شود. در نهایت، بخش آخر به جمع‌بندی و ارائه پیشنهادات می‌پردازد.

## ۲- مبانی نظری تحقیق

این بخش شامل دو قسمت می‌باشد؛ در قسمت اول به معرفی مدهای *CP* پرداخته می‌شود. در قسمت دوم مروری کوتاه بر شبکه‌های *CNN* و لایه‌های مختلف آن انجام می‌پذیرد.

### ۲-۱- مدهای *CP*

مدهای مختلف *CP* را می‌توان در شکل (۱) ملاحظه نمود. نکته قابل توجه این است که مدهای دایره‌ای می‌توانند در دو حالت چپ‌گرد و راست‌گرد برداشت شوند. در ادامه هر مد توضیح داده شده است.

شامل ماشین بردار پشتیبان ( $SVM^1$ ) و جنگل تصادفی ( $RF^2$ ) می‌باشند که مبتنی بر شبکه‌های عصبی نیستند. این روش‌ها که در طبقه‌بندی جنگل نیز استفاده شده‌اند، اگرچه به نتایج خوبی رسیده‌اند، اما دقت طبقه‌بندی در آن‌ها به تمایز میان ویژگی‌های استخراج شده بستگی دارد که این ویژگی‌ها را باید به صورت دستی طراحی و تنظیم کرد [۵، ۶ و ۷]. ویژگی‌های استخراج شده به صورت دستی، نیاز به تحقیقات طولانی مدت و تجربه زیاد دارد. استخراج دستی ویژگی‌های مناسب در روش‌های یادگیری ماشین دشوار و زمان‌بر می‌باشد [۸]. بر این اساس یادگیری عمیق ( $DL^3$ ) به عنوان شاخه‌ای از یادگیری ماشین، می‌تواند ویژگی‌های متمایز را به صورت خودکار استخراج کند. در سال‌های اخیر روش‌های یادگیری عمیق به سرعت گسترش یافته و روش‌های مبتنی بر آن در طبقه‌بندی تصاویر، قطعه‌بندی<sup>۴</sup> تصاویر، پردازش زبان‌های طبیعی و غیره از روش‌های قبلی پیشی گرفته‌اند [۸]. استفاده از شبکه‌هایی با معماری یادگیری عمیق به خصوص در بحث طبقه‌بندی به نتایج چشم‌گیری دست یافته است. از جمله پژوهش‌های انجام‌شده در طبقه‌بندی تصاویر پلاریمتری *SAR* می‌توان به پژوهش‌هایی اشاره نمود که با استفاده از انواع مختلفی از شبکه‌های یادگیری عمیق صورت پذیرفته‌اند [۹، ۱۰ و ۱۱]. از میان معماری‌هایی معرفی شده برای شبکه‌های یادگیری عمیق، شبکه‌های عصبی پیچشی ( $CNN^5$ ) توانمندی خود را در حوزه طبقه‌بندی تصاویر اثبات کرده‌اند. بنابراین به نظر می‌رسد که استفاده از این شبکه‌ها در طبقه‌بندی انواع تصاویر پلاریمتری از جمله تصاویر *CP*

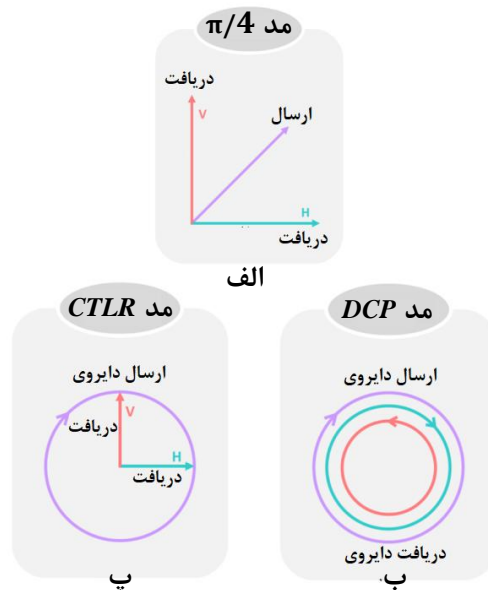
<sup>۱</sup> Support Vector Machine

<sup>۲</sup> Random Forest

<sup>۳</sup> Deep Learning

<sup>۴</sup> Segmentation

<sup>۵</sup> Convolutional Neural Network



شکل ۱: مدهای مختلف CP. (الف) مد ارسال و دریافت خطی  $\pi/4$  (ب) مد ارسال و دریافت دایروی (DCP) و (پ) مد ارسال دایروی-دریافت خطی (CTRL).

گرد ارسال و مولفه خطی دریافت می‌شود. در سیستم-های تصویربرداری DP، اطلاعات فاز نسبی در دسترس نیست. پلاریمتری پیوندی یک ساختار بهینه برای کاربردهایی است که مشاهدات زمینی ارتباط دارند [۱۵].

بر اساس جدول (۱) ماتریس کوواریانس مدهای CP را می‌توان از ضرب بردار  $\vec{k}$  در ترانهاده مزدوج آن بدست آورد. در این جدول S ماتریس پراکنش سینکله<sup>۵</sup> و  $S_{HH}$ ،  $S_{HV}$  و  $S_{VH}$  مولفه‌های این ماتریس می‌باشند.  $\vec{k}$  بردار پائولی، RR نشان‌دهنده ارسال و دریافت در حالت دایروی راستگرد، LL نشان‌دهنده ارسال و دریافت در حالت دایروی چپگرد، L ارسال دایروی چپگرد، R ارسال دایروی راستگرد و i عدد یکه موهومی است.

مد  $\pi/4$ : این مد اولین مد تصویربرداری CP بود که توسط سوئیریس<sup>۱</sup> و همکاران معرفی شد [۴]. در این مد سیستم تصویربرداری SAR یک میدان پلاریزه شده خطی با زاویه ۴۵ درجه نسبت به جهت افقی یا عمودی ارسال و مولفه‌های افقی و عمودی دریافت می‌کند [۱۵].

مد  $DCP^2$ : در این مد، پلاریزاسیون دایروی راستگرد ارسال شده و پلاریزاسیون‌های دایروی راستگرد و چپگرد دریافت می‌شوند [۱۵].

مد  $CTRL^3$ : این مد به نام پلاریمتری ترکیبی<sup>۴</sup> معروف است. در پلاریمتری ترکیبی، تنها یک پلاریزاسیون ارسال و دو پلاریزاسیون متعامد در راستای فاز نسبی دریافت می‌گردد که با سیستم‌های تصویربرداری DP تفاوت دارد. در این مد مولفه دایروی راستگرد یا چپ-

<sup>۱</sup> Souyris

<sup>۲</sup> Dual Circular Polarimetry

<sup>۳</sup> Circular Transmit Linear Receive

<sup>۴</sup> Hybrid Polarimetry

<sup>۵</sup> Sinclair Matrix

جدول ۱: بردارهای پراکنش مدهای CP [۱۶].

مد	بردار پراکنش
$\pi/4$	$\vec{k}_{\pi/4} = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} + S_{HV} \\ S_{VV} + S_{HV} \end{bmatrix}$
DCP	$\vec{k}_{RR,LL} = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} - S_{VV} + i 2S_{HV} \\ S_{VV} - S_{HH} + i 2S_{HV} \end{bmatrix}$
CTLR	$\vec{k}_{CTLR\_L,R} = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} \pm iS_{HV} \\ \pm iS_{VV} + S_{HV} \end{bmatrix}$

المان‌های ورودی محاسبه می‌گردد [۱۸]. بر روی خروجی پیچش یک تابع فعالساز<sup>۵</sup> اعمال می‌شود. تابع فعالساز در واقع نوعی تابع تصمیم‌گیری غیرخطی است که به یادگیری الگوهای پیچیده کمک می‌کند [۱۹]. به تعداد کرنل‌ها یا فیلترهای اعمال شده، یک نقشه ویژگی<sup>۶</sup> از ورودی ساخته می‌شود.

معمولاً به دنبال تعدادی مشخص از لایه‌های پیچش، از لایه ادغام استفاده می‌شود. هدف اصلی برای استفاده از این لایه، کم کردن بار محاسباتی شبکه از طریق کاهش نمونه‌ها<sup>۷</sup> و ابعاد نقشه‌های ویژگی است. این امر موجب می‌شود مشکل بیش‌برازش<sup>۸</sup> در شبکه کاهش یافته و آموزش شبکه به درستی انجام بگیرد. پس از آخرین لایه ادغام، نقشه‌های ویژگی تولید شده، وارد یک سری لایه تمام متصل می‌شوند. ورودی‌های این لایه‌ها بردارهای یک بعدی هستند که همگی به هم متصل می‌باشند. این لایه‌ها در واقع همان لایه‌های مخفی<sup>۹</sup> شبکه‌های عصبی معمولی می‌باشند.

## ۲-۲- شبکه عصبی پیچشی

شبکه CNN که برای اولین بار توسط فوکوشیما معرفی شد، یکی از مهم‌ترین معماری‌های شبکه‌های یادگیری عمیق، به ویژه در حوزه طبقه‌بندی تصاویر محسوب می‌گردد [۱۷]. لایه‌های مختلفی که در این شبکه وجود دارد، نقش‌های مختلفی دارند. در ادامه به معرفی این لایه‌ها پرداخته خواهد شد.

تمامی این لایه‌ها به صورت یک مجموعه به هم متصل هستند، به طوری که خروجی هر لایه، ورودی لایه بعد محسوب می‌شود. این ترتیب سلسله مراتبی منجر به استخراج ویژگی‌های سطح بالا از ورودی می‌شود. شبکه‌های CNN دارای سه لایه اصلی پیچش<sup>۱</sup>، ادغام<sup>۲</sup> و تمام متصل<sup>۳</sup> می‌باشند. شکل (۲) نمونه یک شبکه عصبی پیچشی را به همراه لایه‌های مختلف آن نشان می‌دهد.

لایه پیچش را می‌توان مهم‌ترین لایه شبکه CNN دانست. پیچش نوعی عملگر خطی است که برای استخراج ویژگی از آن استفاده می‌شود. در این لایه آرایه‌ای کوچکی از اعداد، به نام کرنل<sup>۴</sup>، به ورودی اعمال شده، ضرب نقطه‌ای هر یک از المان‌های این آرایه با

<sup>۵</sup> Activation Function

<sup>۶</sup> Feature Map

<sup>۷</sup> Down Sampling

<sup>۸</sup> Overfitting


<sup>۹</sup> Hidden Layers

<sup>۱</sup> Convolution Layer

<sup>۲</sup> Pooling

<sup>۳</sup> Fully-Connected

<sup>۴</sup> Kernels



شکل ۲: شبکه عصبی پیش‌پیش VGG16.

دارد. مساحت منطقه مورد بررسی بیش از ۱۰۰ کیلومتر مربع می‌باشد. گونه‌های درختی موجود در منطقه به طور کلی به دو دسته سخت‌چوب و نرم‌چوب تقسیم شده و کلاس‌های مورد بررسی در تصویر شامل ۶ کلاس بلوط قرمز<sup>۸</sup> (سخت چوب)، کاج سفید<sup>۹</sup> (نرم چوب)، صنوبر سیاه<sup>۱۰</sup> (نرم چوب)، منطقه شهری، آب و پوشش‌های گیاهی هستند. داده مورد استفاده در این تحقیق، با استفاده از سنجنده رادارست-۲ در تاریخ ۴ آگوست سال ۲۰۰۹ در مد *FP* اخذ شده است. داده مذکور به صورت تک منظره مختلط ( $SLC^{11}$ ) و در باند *C* اخذ شده و قدرت تفکیک آن در جهت رنج ۱۱ متر و در جهت آزیموت ۹ متر می‌باشد.

شکل (۳- الف) و شکل (۳- ب) به ترتیب تصویر اخذ شده با نمایش رنگی کاذب بر اساس بردار پائولی و تصویر گرفته‌شده از منطقه را در سامانه گوگل‌ارث نمایش می‌دهد.

نمونه‌های داده‌های مرجع زمینی (آموزشی و آزمایشی) از نقشه‌های سال ۲۰۰۲ منطقه، تصاویر فتوگرامتری و نیز برداشت‌های زمینی جمع‌آوری شده و برای تاریخ اخذ تصویر بروزرسانی شده‌اند. در جدول (۲) تعداد نمونه‌های آموزشی و آزمایشی مربوط به هر کلاس مشاهده می‌گردد.

آموزش شبکه طی دو مرحله انجام می‌گیرد: پیش‌رو<sup>۱</sup> و پس‌انتشار خطا<sup>۲</sup>. در مرحله پیش‌رو، داده ورودی به همراه وزن‌های اولیه از میان لایه‌های مختلف عبور می‌کند تا تابع هزینه<sup>۳</sup> بر اساس مقادیر واقعی محاسبه گردد. سپس در مرحله پس‌انتشار خطا با قاعده مشتق زنجیری<sup>۴</sup>، وزن‌ها بر اساس تابع هزینه و بر اساس میزان اثرگذاری‌شان بر روی پارامترها به‌روزرسانی می‌شوند. این دو مرحله طی روندی تکراری ادامه می‌یابد تا زمانی که شبکه به همگرایی مطلوب برسد. پس از آن، از شبکه آموزش‌دیده می‌توان برای پیش‌بینی داده‌های جدید استفاده نمود. لازم به ذکر است که تعیین معماری مناسب بر اساس داده و سخت‌افزارهای موجود، نقش مهمی در میزان دقت شبکه بازی می‌کند.

یک مورد مهم در مورد شبکه‌های *CNN* این است که بر خلاف روش *SVM* که پیکسل‌مبنا عمل می‌کنند، این شبکه‌ها بر اساس صحنه تصویری عمل کرده و برای هر پیکسل اطلاعات همسایگی را نیز در نظر می‌گیرند. به بیان دیگر این شبکه‌ها پچ‌مبنا<sup>۵</sup> هستند.

### ۳- منطقه مطالعاتی و داده‌های تحقیق

منطقه مورد مطالعه یک جنگل تحقیقاتی به نام پتاواوا<sup>۶</sup> می‌باشد که در ایالت آنتاریو<sup>۷</sup> واقع در کشور کانادا، قرار

<sup>۱</sup> Feedforward

<sup>۲</sup> Backpropagation

<sup>۳</sup> Cost function

<sup>۴</sup> Chain rule

<sup>۵</sup> Patch-wise

<sup>۶</sup> Petawawa

<sup>۷</sup> Ontario

<sup>۸</sup> Red Oak (*Quercus rubra L.*)


<sup>۹</sup> White Pine (*Pinus strobus L.*)

<sup>۱۰</sup> Black Spruce (*Picea mariana (Mill) B.S.P*)

<sup>۱۱</sup> Single Look Complex



(ب)



(الف)

شکل ۳: (الف) نمونه تصویر برداشت‌شده سنجنده رادارست-۲، (ب) تصویر منطقه گرفته‌شده از گوگل‌ارث.

جدول ۲: تعداد نمونه‌های آموزشی و آزمایشی برای هر کلاس.

تعداد نمونه آزمایشی	تعداد نمونه آموزشی	کلاس
۷۷۲	۹۸۰	بلوط قرمز
۳۷۵	۳۰۵	کاج سفید
۷۸۲	۹۰۰	صنوبر سیاه
۴۹۴	۵۷۰	منطقه شهری
۸۱۰	۱۰۴۷	آب
۶۳۱	۹۷۸	پوشش‌های گیاهی
۳۸۶۴	۴۷۸۰	کل

گیرد. نکته قابل توجه در این مرحله این است که به منظور ورود تصاویر به شبکه *CNN*، پچ‌های تصویری بایستی از تصویر استخراج شوند. یک پچ تصویری در واقع یک محدوده همسایگی با ابعاد مشخص در اطراف پیکسل دارای برچسب در تصویر می‌باشد. به منظور آموزش صحیح شبکه، ۲۰٪ از پچ‌های استخراج‌شده از تصویر در مناطق دارای برچسب، به عنوان پچ اعتبارسنجی جدا می‌شود. روند آموزش بر روی پچ‌های آموزشی انجام می‌پذیرد و در هر بار تکرار دقت شبکه بر اساس پچ‌های اعتبارسنجی انجام می‌گیرد. روند تکرار تا جایی ادامه می‌یابد که خطای آموزش به صفر نزدیک شود.

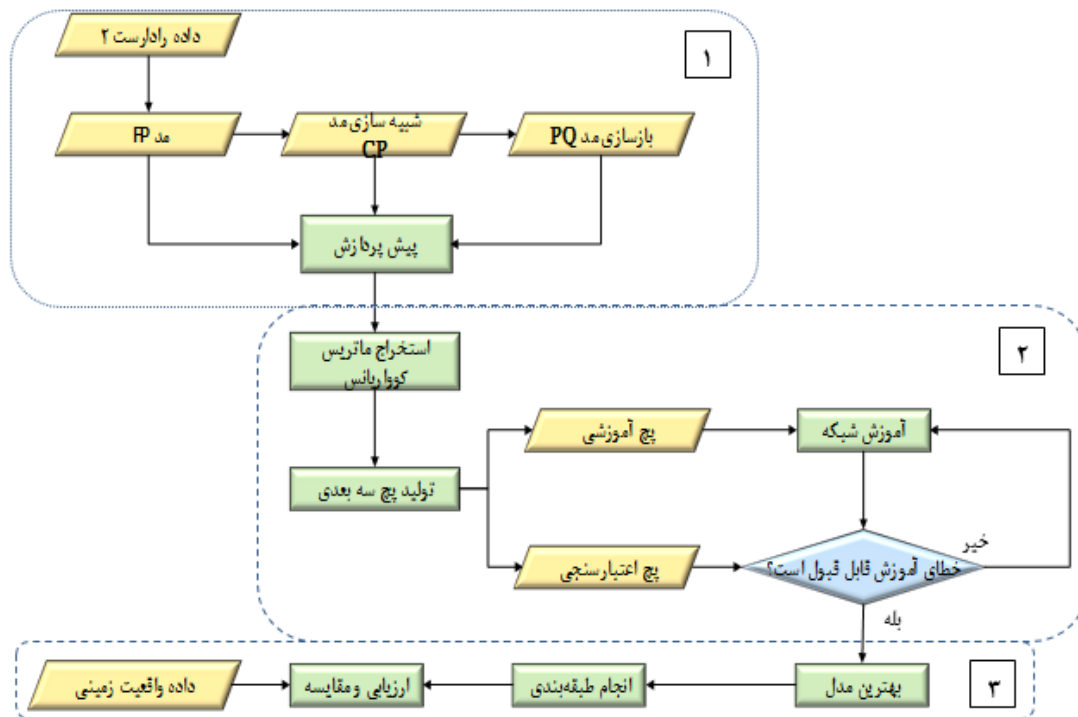
#### ۴- روش پیشنهادی تحقیق

در ادامه به شرح روند کلی انجام تحقیق و مراحل مختلف آن پرداخته می‌شود.

##### ۴-۱- شرح روند کلی

بر اساس شکل (۴)، روند انجام این تحقیق شامل سه بخش اصلی می‌باشد. در بخش اول، داده‌های مربوطه، شامل داده‌های *CP*، *FP* و *PQ* بایستی آماده‌سازی شده و عملیات پیش‌پردازش انجام پذیرد. پس از انجام پیش‌پردازش، ماتریس‌های کوواریانس از هر یک از مدهای مذکور استخراج می‌گردد.

در بخش دوم، مراحل لازم جهت تعیین معماری مناسب برای شبکه *CNN* و آموزش شبکه انجام می-



شکل ۴: روش پیشنهادی در این تحقیق.

محیط گوگل کولبریتوری<sup>۲</sup> تحت پایتون استخراج می-شود. برای بازسازی مدهای  $PQ$  از مدهای  $CP$  نیز از روش سوئیریس استفاده می‌گردد. به منظور تصحیح نویز اسپیکل از فیلتر باکس کار<sup>۳</sup> با ابعاد  $7 \times 7$  بهره برده می‌شود چرا که با توجه به عوارض موجود، حساسیت به لبه‌ها اهمیتی ندارد. تصحیحات هندسی و زمین مرجع سازی نیز توسط مدل رقومی ارتفاعی منطقه و در نرم افزار ای اس اف مپ ردی<sup>۴</sup> انجام می‌گردد.

#### ۴-۳- تعیین معماری شبکه

پس از آماده سازی داده‌ها، از پیکسل‌ها آموزشی، پچ استخراج می‌گردد. ۲۰٪ این پچ‌ها به عنوان پچ اعتبارسنجی کنار گذاشته می‌شوند. بنابراین در مجموع

در بخش سوم، پس از دستیابی به بهترین مدل آموزش یافته، پیش بینی بر روی تمام پیکسل‌های تصویر انجام گرفته و خروجی به صورت یک تصویر تماماً برچسب گذاری شده استخراج می‌گردد. پس از آن دقت نقشه خروجی بر اساس داده‌های واقعیت زمینی و با معیارهای ماتریس ابهام، دقت کلی و دقت کلاسی ارزیابی می‌گردد. در نهایت تمامی نتایج حاصل با یکدیگر و نیز با طبقه کننده‌های  $SVM$  و ویشارت مقایسه می‌شوند.

#### ۴-۲- آماده سازی و پیش پردازش داده‌ها


به منظور پیش پردازش داده‌ها از نرم افزار پلسار پرو<sup>۱</sup> ورژن ۶ استفاده شده و ماتریس‌های کوواریانس مدهای مختلف  $CP$  بر اساس روابط موجود در جدول (۱) و در

<sup>۲</sup> Google Colabritory

<sup>۳</sup> BoxCar

<sup>۴</sup> ASF MapReady

<sup>۱</sup> PolSARpro



شکل ۵: معماری در نظر گرفته شده برای شبکه CNN در این تحقیق.

به منظور جلوگیری از بیش‌برازش شدن شبکه، بعد از هر لایه پیش‌پردازش از یک لایه نرمال‌سازی دسته‌ای<sup>۴</sup> استفاده شده، همچنین لایه حذف تصادفی<sup>۵</sup> پس از لایه تمام متصل اول و نیز نرم  $L_2$  در هر لایه استفاده شده است. همچنین به منظور بهینه‌سازی از روش آدام<sup>۶</sup> با نرخ یادگیری پایه ۰/۰۰۱ استفاده گردیده است. این نرخ در صورت کاهش نیافتن خطا بعد از ۵ اپک، نصف می‌شود. فرآیند آموزش در ۱۰۰ اپک انجام می‌گیرد و اندازه دسته‌های ورودی ۳۲ می‌باشد. همچنین با توجه به تعداد کم داده‌های آموزشی از تکنیک افزایش داده<sup>۷</sup>

<sup>۴</sup> Batch Normalization

<sup>۵</sup> Dropout

<sup>۶</sup> Adam

<sup>۷</sup> Image Data Augmentation

۳۸۲۴ پیچ آموزشی و ۹۵۶ پیچ اعتبارسنجی به ابعاد ۱۵ × ۱۵ استخراج شدند. به منظور استفاده از تمام پیکسل‌های آموزشی موجود در تصویر، بخصوص پیکسل‌هایی که در گوشه‌های تصویر قرار دارند، از پدینگ آینه‌ای<sup>۱</sup> استفاده می‌گردد.

شکل (۵) معماری طراحی شده را برای شبکه CNN نمایش می‌دهد. در این شبکه در مجموع از ۴ لایه پیش‌پردازش برای استخراج ویژگی‌های بهینه استفاده گردیده است. تابع فعالساز در نظر گرفته شده برای هر لایه پیش‌پردازش  $ReLU^2$  می‌باشد. تعداد و ابعاد فیلترها در دو لایه اول پیش‌پردازش به ترتیب ۱۶ و  $5 \times 5$  و در دو لایه پیش‌پردازش دوم ۳۲ و  $4 \times 4$  می‌باشد. بعد از هر دو لایه پیش‌پردازش، از لایه ادغام بیشینه<sup>۳</sup> با ابعاد  $2 \times 2$  برای استخراج ویژگی‌های سطح بالاتر و نیز کاهش نمونه‌ها استفاده می‌گردد. برای ترکیب ویژگی‌های استخراج شده، پس از لایه ادغام دوم از یک لایه تمام متصل با ۲۵۰ نورون و با تابع فعالساز  $ReLU$  استفاده می‌شود. در نهایت در لایه تمام متصل آخر با تابع فعالساز سافت‌مکس احتمال تعلق به هر کلاس محاسبه می‌گردد. نوع معماری شبکه بر اساس ساختار شبکه VGG (دو پیش‌پردازش، ادغام، دو پیش‌پردازش و ...) انتخاب شده است. در دو لایه پیش‌پردازش اول، از تعداد فیلتر کمتر با ابعاد بزرگتر و در دو لایه پیش‌پردازش دوم (به دلیل کاهش ابعاد تصویر پس از اولین لایه ادغام برای انتخاب بهترین ویژگی‌ها) از تعداد فیلتر بیشتر با ابعاد کوچکتر استفاده می‌شود. تعداد نورون‌های لایه‌های تمام متصل اول به صورت ابرپارامتر بوده که با تست ۵۰، ۱۰۰، ۱۵۰، ۲۰۰، ۲۵۰ و ۳۰۰ نورون، تعداد بهینه ۲۵۰ انتخاب شده است. تعداد نورون ۶ در لایه تمام متصل آخر به تعداد کلاس‌های انتخابی در تصویر می‌باشد.

<sup>۱</sup> Mirror Padding

<sup>۲</sup> Rectified Linear Unit

<sup>۳</sup> Max Pooling

ماتریس ابهام، دقت کلی و دقت‌های کلاسی استخراج می‌گردد و برای درک بصری بهتر، نتایج به صورت تصاویر طبقه‌بندی شده نمایش داده می‌شود.

#### ۵- نتایج، بحث و بررسی

برای درک بهتر عملکرد و دقت شبکه، نتایج حاصل از انجام طبقه‌بندی با روش پیشنهادی، ابتدا در مدهای  $FP$ ،  $CP$  و  $PQ$  با یکدیگر مقایسه می‌گردند. سپس نتایج حاصل از طبقه‌بندی به روش پیشنهادی با نتایج حاصل از طبقه‌بندی‌کننده‌های  $SVM$  و روش آماری ویشارت ارائه شده در پژوهش آقابالائی (۲۰۱۶) مقایسه می‌شوند [۲۰].

شکل (۶) نتایج طبقه‌بندی حاصل از مدهای  $CP$ ،  $FP$  و  $PQ$  را با استفاده از روش پیشنهادی نمایش می‌دهد. همچنین در جدول (۳) دقت‌های کلی و کلاسی هر یک از مدهای  $CP$ ،  $FP$  و  $PQ$  با استفاده از روش پیشنهادی مشاهده می‌گردد.


به صورت مجازی بهره برده می‌شود. بدین صورت که در هر اپک یک سری عملیات از جمله چرخش، جابجایی در راستاهای مختلف و غیره به صورت تصادفی به تصاویر اعمال می‌شوند. در این حالت تصویر تبدیل یافته از تصویر جدید، به صورت یک داده جدید تلقی می‌شود که در نهایت این امر موجب بالا رفتن دقت آموزش می‌گردد.

#### ۴-۴- طبقه‌بندی تصاویر


پس از اتمام فرآیند آموزش مدل، بهترین مدل بدست می‌آید. در این مرحله تمامی پیکسل‌های تصویر به مدل داده شده و احتمال تعلق هر پیکسل به هر کلاس توسط مدل آموزش‌دیده محاسبه می‌گردد. در آخر پیکسل به کلاسی که بیشترین احتمال را بدست آورده، تعلق می‌گیرد. بدین ترتیب برچسب تمام پیکسل‌های تصویری بدست می‌آیند. در نهایت برای هر تصویر با استفاده از داده‌های واقعی زمینی (داده‌های آزمایشی)

جدول ۳: نتایج حاصل از طبقه‌بندی بر روی مدهای  $FP$ ،  $CP$  و  $PQ$  با استفاده از روش پیشنهادی (بر حسب درصد).


مد / کلاس	بلوط قرمز	کاج سفید	صنوبر سیاه	منطقه شهری	آب	پوشش‌های گیاهی	کل
$\pi/4$	۸۰٫۱۸	۷۵٫۷۳	۸۲٫۳۵	۴۵٫۳۴	۱۰۰	۸۲٫۵۷	۸۰٫۲۸
$DCP$ راستگرد	۷۸٫۱۱	۷۰٫۴۰	۸۵٫۰۴	۵۷٫۰۹	۱۰۰	۸۳٫۲۰	۸۱٫۵۰
$DCP$ چپگرد	۷۳٫۸۳	۷۲٫۸۰	۸۰٫۵۶	۷۲٫۸۷	۸۸ ۹۹	۸۳٫۵۲	۸۲٫۰۱
$CTLR$ راستگرد	۶۱٫۰۱	۷۲٫۲۷	۷۴٫۹۴	۶۰٫۳۲	۱۰۰	۸۳٫۶۸	۷۶٫۷۱
$CTLR$ چپگرد	۶۵٫۶۷	۷۳٫۳۳	۷۵٫۷۰	۵۲٫۶۳	۱۰۰	۸۲٫۲۰	۷۶٫۸۴
$FP$	۶۱٫۱۴	۷۰٫۴۰	۸۰٫۳۱	۵۷٫۸۹	۱۰۰	۸۲٫۵۷	۷۷٫۱۵
$PQ_{\pi/4}$	۶۲٫۹۵	۷۱٫۲۰	۷۷٫۱۱	۳۹٫۲۷	۱۰۰	۸۲٫۵۷	۷۴٫۵۳
$PQ_{DCP}$ راستگرد	۷۶٫۰۴	۷۸٫۱۳	۸۹٫۷۷	۵۶٫۴۸	۱۰۰	۸۲٫۷۳	۸۲٫۶۳
$PQ_{DCP}$ چپگرد	۶۹٫۹۵	۸۰٫۸۰	۸۰٫۹۵	۶۱٫۹۴	۱۰۰	۸۳٫۹۹	۸۰٫۸۰
$PQ_{CTLR}$ راستگرد	۶۳٫۳۴	۸۲٫۱۳	۸۴٫۷۸	۴۶٫۳۶	۱۰۰	۸۳٫۶۸	۷۸٫۳۴
$PQ_{CTLR}$ چپگرد	۵۷٫۲۵	۹۱٫۴۶	۷۹٫۱۶	۵۰٫۴۰	۱۰۰	۷۸٫۶۱	۷۶٫۵۸




(ب)




(الف)




(ت)



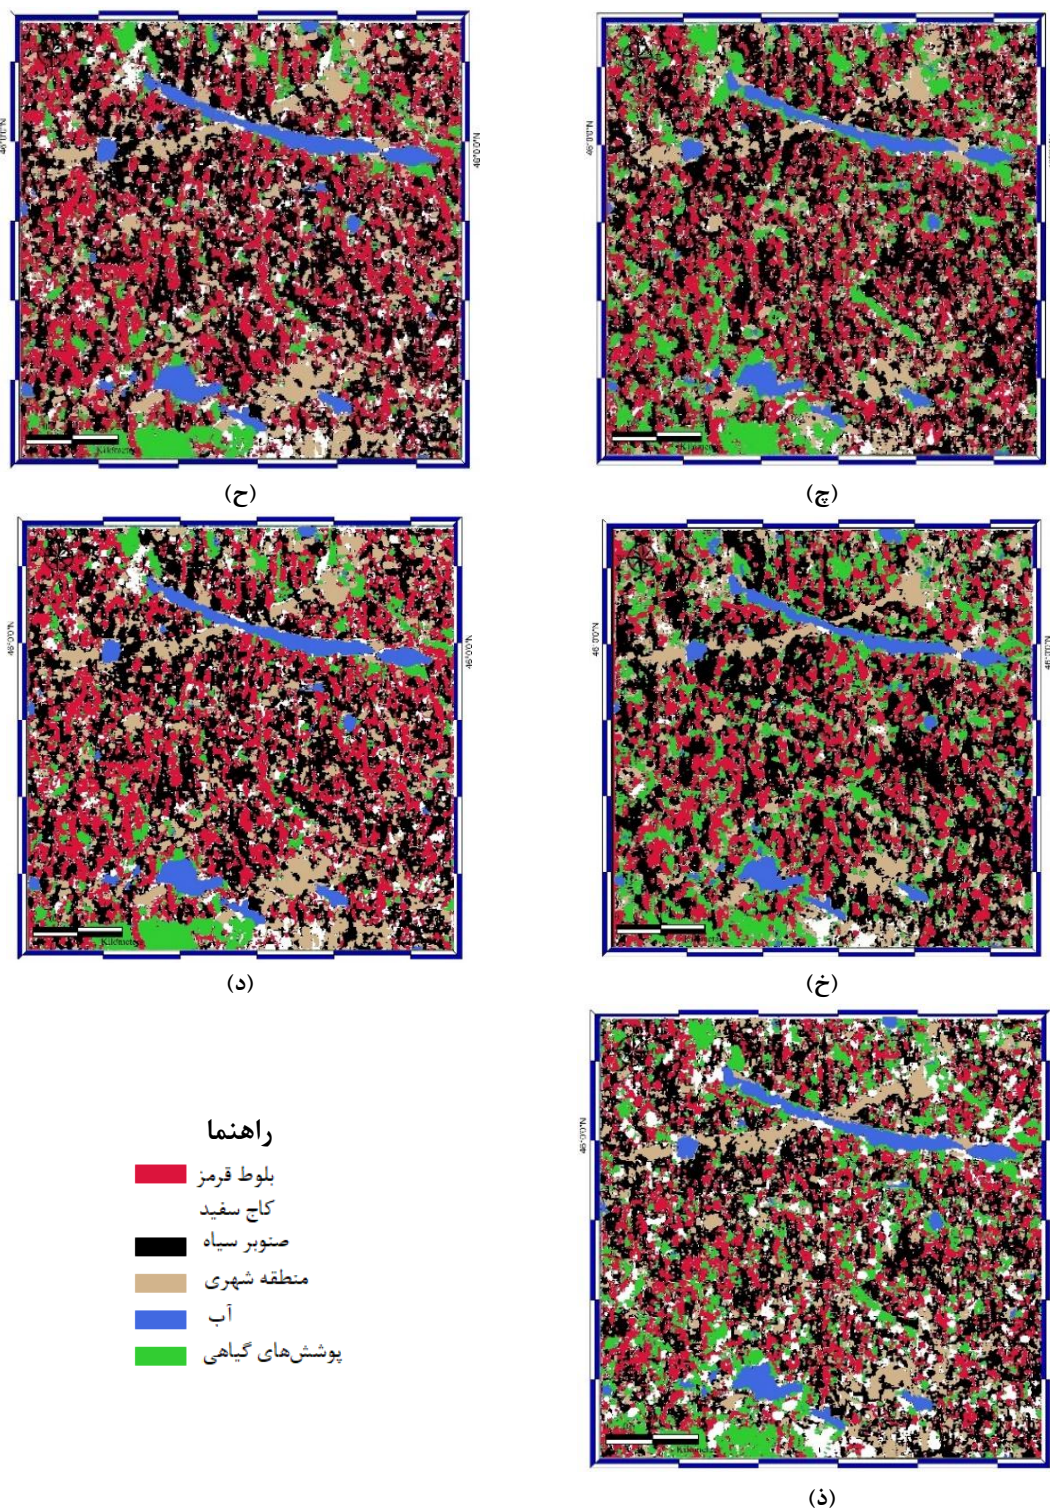
(پ)



(ج)



(ث)




شکل ۶: نتایج طبقه بندی حاصل از مدهای  $CP$ ،  $FP$  و  $PQ$  با استفاده از روش پیشنهادی. الف) مد  $\pi/4$  (ب) مد  $DCP$  چپ‌گرد، پ) مد  $DCP$  راست‌گرد، ت) مد  $CTLR$  چپ‌گرد، ث) مد  $CTLR$  راست‌گرد، ج) مد  $FP$ ، چ) مد  $PQ_{\pi/4}$  (ح) مد  $PQ_{DCP}$  چپ‌گرد، خ) مد  $PQ_{DCP}$  راست‌گرد، د) مد  $PQ_{CTLR}$  چپ‌گرد، ذ) مد  $PQ_{CTLR}$  راست‌گرد.

نباشد از پچ‌های شامل این کلاس ویژگی‌های مناسبی استخراج کرده و در نهایت دقت طبقه‌بندی در این کلاس کاهش یابد. در تمامی حالات دقت کلاس آب، ۱۰۰٪ است که به دلیل پیچیدگی کمتر آن نسبت به سایر کلاس‌ها به راحتی از بقیه تفکیک می‌گردد.

شکل (۷) دقت‌های کلاسی حاصل از روش پیشنهادی در مدهای مختلف  $CP$  و نیز مد  $FP$  نمایش می‌دهد. علت بهتر عمل کردن مد  $CP$  به صورت کلی آن است که ابرپارامترهای شبکه  $CNN$  با استفاده از داده‌های  $CP$  تعیین شده‌اند. جدول (۴) نتایج حاصل از طبقه‌بندی با استفاده از مدهای  $CP$  را به روش پیشنهادی و نیز روش‌های  $SVM$  و ویشارت نمایش می‌دهد [۲۰]. بر این اساس، روش پیشنهادی در تمامی مدهای  $CP$ ، از روش‌های  $SVM$  و ویشارت بهتر عمل می‌کند. بر اساس جدول (۴) بالاترین دقت طبقه‌بندی با استفاده از روش‌های ویشارت و  $SVM$  به مد  $\pi/4$  و با استفاده از روش پیشنهادی این تحقیق به مد  $DCP$  (با اختلاف کمی از مد  $\pi/4$ ) تعلق دارد. همچنین برخلاف دو روش  $SVM$  و ویشارت، پایین‌ترین دقت مدهای  $CP$  در طبقه‌بندی به روش پیشنهادی به مد  $CTLR$  (ارسال دایرووی - دریافت خطی) تعلق دارد. با توجه به این موضوع به نظر می‌رسد که ارسال و دریافت پلاریزاسیون دایرووی در حالت پچ‌مبنا و با در نظر گرفتن پیکسل‌های همسایه در روش پیشنهادی عملکرد بهتری داشته باشد. همین مساله موجب گردیده است که نتایج طبقه‌بندی با استفاده از روش پیشنهادی در این تحقیق در مد  $DCP$ ، نسبت به روش  $SVM$  حدود ۱۴٪ در حالت راستگرد و چپگرد بهبود یافته باشد. این اختلاف دقت در مقایسه با روش ویشارت به حدود ۲۰٪ در حالت چپگرد و راستگرد می‌رسد. بهبود دقت نتیجه طبقه‌بندی به روش پیشنهادی در مد  $\pi/4$  در مقایسه با روش‌های  $SVM$  و ویشارت به ترتیب حدود ۵٪ و ۱۵٪ می‌باشد. هم‌چنین میزان بهبود نتایج برای مد  $CTLR$  در حالت راستگرد و چپگرد، حدود ۸٪ نسبت به روش  $SVM$  و ۱۶٪ نسبت به روش ویشارت می‌باشد.

با توجه به جدول (۳)، مدهای  $DCP$  در حالت چپگرد،  $DCP$  در حالت راستگرد و  $\pi/4$  به ترتیب با دقت‌های کلی ۸۲٫۰۱٪، ۸۱٫۵٪ و ۸۰٫۲۸٪، بیشترین دقت کلی را میان مدهای  $CP$  دارند. دقت مد  $CTLR$  در دو حالت راستگرد و چپگرد حدود ۶٪ از بقیه مدها پایین‌تر است. دقت مد  $DCP$  در دو حالت چپگرد و راستگرد تقریباً با هم برابر است. این موضوع برای مد  $CTLR$  در دو حالت چپگرد و راست نیز مصداق دارد و نشان می‌دهد که راستگرد یا چپگرد بودن پلاریزاسیون ارسالی در این مدها به صورت کلی تفاوت چندانی در نتایج طبقه‌بندی ایجاد نمی‌کند. در میان مدهای بازسازی-شده  $QP$ ، مدهای  $PQ\_DCP$  در دو حالت چپگرد و راستگرد دارای بیشترین دقت می‌باشند؛ اما مد  $PQ\_pi/4$  کم‌ترین دقت طبقه‌بندی را دارد. طبق انتظار دقت‌های کلاسی مد  $PQ\_pi/4$  شباهت زیادی در تمامی کلاس‌ها (بجز کلاس منطقه شهری) با مد  $FP$  دارد. اختلاف دقت کلاس منطقه شهری در این دو مد را می‌توان به دلیل اعمال فرض تقارن بازتابی در هنگام بازسازی با الگوریتم سوئیریس توجیه نمود [۲۱].

حال به بررسی دقت‌های کلاسی در هر مد پرداخته می‌شود. در میان مدهای  $CP$ ، مد  $\pi/4$  به صورت کلی در مورد کلاس‌های بلوط قرمز و کاج سفید بهتر از بقیه مدها عمل می‌کند و در کلاس صنوبر سیاه نیز با بهترین دقت بدست آمده توسط مد  $DCP$ ، اختلاف اندکی دارد. این امر به دلیل زاویه‌دار بودن پلاریزاسیون  $\pi/4$  رخ می‌دهد که موجب می‌شود در مناطق دارای شیب عملکرد بهتری داشته باشد [۲۲]. در تمامی مدها کلاس منطقه شهری دارای پایینترین دقت کلاسی است. از آنجا که این کلاس شامل عوارض مختلف (منطقه شهری، جاده و غیره) بوده و روش پیشنهادی نیز برای طبقه‌بندی از صحنه‌های تصویری (پچ) استفاده می‌کند، بدیهی است که شبکه با ویژگی‌های متفاوت آموزش می‌بیند. از طرفی پیکسل‌های شامل این مناطق در کنار پیکسل‌های مناطق جنگلی قرار گرفته‌اند. همین امر موجب می‌گردد که شبکه قادر



شکل ۷: مقایسه دقت‌های کلاسی حاصل از روش پیشنهادی در مدهای  $FP$  و  $CP$ .

جدول ۴: مقایسه نتایج حاصل از طبقه‌بندی با استفاده از مدهای  $CP$  به روش پیشنهادی با روش‌های  $SVM$  و ویشارت [۲۰] (بر حسب درصد).

روش/مد	$\pi/4$	$DCP$ راستگرد	$DCP$ چپگرد	$CTRLR$ راستگرد	$CTRLR$ چپگرد
ویشارت	۶۵٫۲۹	۶۰٫۷۴	۶۱٫۱۸	۶۰٫۹۹	۶۱٫۱۸
$SVM$	۷۵٫۴۶	۶۶٫۸۹	۶۸٫۶۸	۶۸٫۹۶	۶۸٫۱۶
روش پیشنهادی این تحقیق	۸۰٫۲۸	۸۱٫۵	۸۲٫۰۱	۷۶٫۷۱	۷۶٫۸۴

جدول (۵) نتایج بدست آمده از طبقه‌بندی به روش پیشنهادی را در مقایسه با روش‌های  $SVM$  و ویشارت، برای مدهای  $FP$  و مدهای بازسازی شده  $PQ$  نمایش می‌دهد [۲۰]. بر اساس این جدول، نتیجه طبقه‌بندی به روش پیشنهادی نسبت به روش ویشارت در تمام مدها بهبود یافته، اما در مدهای  $FP$  و  $PQ_{\pi/4}$  در مقایسه با روش  $SVM$  عملکرد ضعیف‌تری داشته است.

همچنین نتایج طبقه‌بندی در مد  $FP$  به روش پیشنهادی این تحقیق به نتیجه مد بازسازی شده از  $\pi/4$  نزدیک است. در مدهای  $PQ_{CTRLR}$  و  $PQ_{DCP}$  عملکرد روش پیشنهادی در تمامی حالات چپگرد و راستگرد از روش‌های  $SVM$  و ویشارت بهتر بوده است. میزان این بهبود برای مد  $DCP$  در دو حالت چپگرد و راستگرد در مقایسه با روش‌های  $SVM$  و ویشارت به

در مقایسه با روش‌های مذکور به ۳٪ و ۱۴٪ می‌رسد.

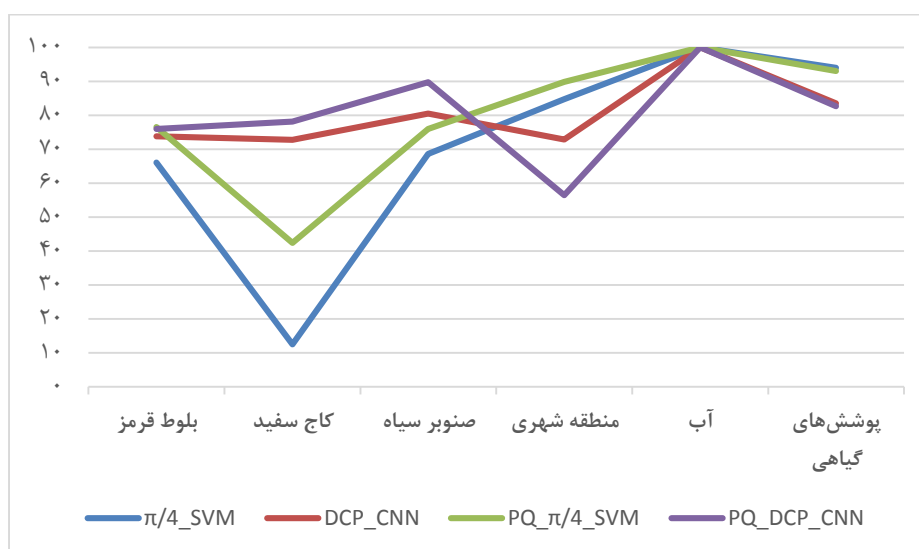
ترتیب حدود ۹٪ و ۱۹٪ است. این در حالی است که در مد *CTRL* میزان بهبود در دو حالت چپگرد و راستگرد

جدول ۵: مقایسه نتایج حاصل از طبقه‌بندی با استفاده از مدهای *PQ* و *FP* به روش پیشنهادی با روش‌های *SVM* و *بیشارت* (۲۰٪) (بر حسب درصد).

روش امد	<i>FP</i>	<i>PQ_π/4</i>	<i>PQ_DCP</i> راست‌گرد	<i>PQ_DCP</i> چپ‌گرد	<i>PQ_CTRL</i> راست‌گرد	<i>PQ_CTRL</i> چپ‌گرد
بیشارت	۷۲٫۵۶	۷۰٫۴۷	۶۳٫۶۳	۶۲٫۳۹	۵۹٫۵۴	۶۲٫۴۷
<i>SVM</i>	۸۴٫۰۵	۸۲٫۴۲	۷۳٫۹۱	۷۳	۷۸٫۷۲	۷۳٫۹۶
روش پیشنهادی این تحقیق	۷۷٫۱۵	۷۴٫۵۳	۸۲٫۶۳	۸۰٫۸۰	۷۸٫۳۴	۷۶٫۵۸

کاج سفید چشمگیرتر است. به طوری که بهترین مد *CP* به روش پیشنهادی حدود ۶۰٪ از روش *SVM* بهبود یافته است. این میزان بهبود در مد *PQ* حدود ۳۰٪ می‌باشد. همچنین در دو کلاس درختی دیگر نیز روش پیشنهاد این مقاله نسبت به روش *SVM* عملکرد بهتری داشته است که نشان می‌دهد ویژگی‌های استخراج شده توسط شبکه *CNN* به خوبی قادر به تفکیک گونه‌های جنگلی هستند.

در نهایت در شکل (۸)، به مقایسه دقت‌های کلاسی بهترین مدهای *CP* و *PQ* در روش *SVM* (مدهای  $\pi/4$  و  $PQ_{\pi/4}$ ) و روش پیشنهادی (*DCP* و *PQ\_DCP*) پرداخته می‌شود. همانطور که از نمودار نیز می‌توان مشاهده نمود، روش پیشنهادی (خطوط قرمز و بنفش) در هر دو مد *CP* و *PQ* نسبت به روش *SVM* (خطوط آبی و سبز) در کلاس‌های گونه‌های درختی عملکرد بهتری دارند. میزان بهبود عملکرد به خصوص در کلاس



شکل ۸: مقایسه نتایج حاصل از طبقه‌بندی بهترین مدها در روش پیشنهادی و روش *SVM* (۲۰٪) (بر حسب درصد).

## ۶- جمع بندی، نتیجه گیری و پیشنهادات آتی تحقیق

در این تحقیق از شبکه عمیق *CNN* به منظور طبقه بندی گونه های جنگل با استفاده از داده های *CP* استفاده گردید و نتایج حاصل با نتایج مد *FP* و نیز طبقه بندی کننده های *SVM* و ویشارت مقایسه شدند. بر اساس تحقیق پیش رو، مد *DCP* بهترین عملکرد را در میان مدهای *CP* داشت. این موضوع در مورد مدهای *PQ* نیز صادق بود. مدهای چپگرد و راستگرد در مجموع عملکرد تقریباً یکسانی از خود نشان دادند. مد *FP* دقت پایین تری با استفاده از روش پیشنهادی از خود نشان داد که به دلیل تعیین ساختار شبکه *CNN* بر اساس مدهای *CP* قابل توجیه بود.

در مقایسه با طبقه بندی کننده های *SVM* و ویشارت، روش پیشنهادی در هر دو مد *CP* و *PQ* عملکرد بسیار بهتری از خود نشان داد. دقت نتایج حاصل از روش پیشنهادی، در مدهای  $\pi/4$ ، *DCP* و *CTRL* از مدهای *CP*، نسبت به روش *SVM* به ترتیب حدود ۰/۵، ۰/۸ و ۰/۵٪ و نسبت به روش ویشارت به ترتیب ۰/۱۵، ۰/۲۰ و ۰/۱۶٪ بهتر بود.

همچنین در طبقه بندی با استفاده از مدهای بازسازی شده دایروی (*PQ\_DCP* و *PQ\_CTRL*) نیز، روش پیشنهادی این تحقیق از طبقه بندی کننده های *SVM* و ویشارت بهتر عمل نمود.

با مقایسه دقت های کلاسی حاصل از روش پیشنهادی با روش های *SVM* و ویشارت نیز می توان ملاحظه کرد که روش پیشنهادی عملکرد بهتری در تفکیک گونه ها، بخصوص گونه های درختی داشته است. از آنجایی که روش پیشنهادی بر مبنای شبکه *CNN* یک روش پچ-مبناست، می توان اظهار داشت که روش های یادگیری عمیق پچ-مبنا با در نظر گرفتن پیکسل به همراه همسایگی های آن بهتر می توانند گونه های درختی را از یکدیگر تفکیک نمایند.

در نهایت می توان اظهار داشت که مد *CP* با داشتن مزیت هایی همچون دو برابر بودن عرض نوار برداشت،

زمان بازبینی ماهواره کم تر (۴ روز) و همچنین کاهش نرخ فرکانس تکرار پالس و پیچیدگی نسبت به مد می-توانند در کاربردهای مختلف مورد استفاده قرار بگیرند. همچنین مد *CP* با وجود این که نسبت به مد *FP* اطلاعات کاملی از هدف ارائه نمی دهند، وجود آن ها هنگامی که در برداشت داده های *FP* محدودیت وجود دارد، می تواند رویکرد مناسبی باشد.

از طرف دیگر عملکرد شبکه *CNN* که از انواع شبکه های یادگیری عمیق می باشد، در این تحقیق بررسی گردید. نتایج بدست آمده نشان دادند که شبکه های یادگیری عمیق در صورت تعیین ساختار و ابرپارامترهای مناسب، تعداد داده کافی و نیز سیستم پردازنده مناسب می توانند عملکرد بسیار خوبی در طبقه بندی گونه های مختلف داشته و به نتایج قابل قبولی دست یابند.

در آخر برای تحقیقات آتی پیشنهاد می شود جهت بهبود نتایج حاصل از این تحقیق، از داده های راداری در باند *L* یا *P* به دلیل نفوذ بیشتر و دریافت اطلاعات بیشتر از عوارض استفاده گردد. همچنین انواع دیگر شبکه های یادگیری عمیق از جمله شبکه های خودرمننگار<sup>۱</sup>، باور عمیق<sup>۲</sup> و یا انواع دیگر ساختارهای *CNN* می توانند مورد بررسی قرار بگیرند.

<sup>۱</sup> Autoencoder

<sup>۲</sup> Deep Blief Networks

## مراجع

- [1] L. Xie, H. Zhang, H. Li, and C. Wang, "A unified framework for crop classification in southern China using fully polarimetric, dual polarimetric, and compact polarimetric SAR data," *Int. J. Remote Sens.*, vol. 36, no. 14, pp. 3798–3818, Jul. 2015.
- [2] H. Chen, D. G. Goodenough, and S. R. Cloude, "Mapping forest fire scars with simulated RCM compact-pol data," in *2014 IEEE Geoscience and Remote Sensing Symposium*, Jul. 2014, pp. 1572–1575.
- [3] R. Sabry and P. W. Vachon, "Advanced polarimetric synthetic aperture radar (SAR) and Electro-Optical (EO) data fusion through unified coherent formulation of the scattered em field," *Prog. Electromagn. Res.*, vol. 84, pp. 189–203, 2008.
- [4] J.-C. Souyris, P. Imbo, R. Fjortoft, Sandra Mingot, and Jong-Sen Lee, "Compact polarimetry based on symmetry properties of geophysical media: the  $\pi/4$  mode," *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 3, pp. 634–646, Mar. 2005.
- [5] A. Aghabalaei, Y. Maghsoudi, and H. Ebadi, "Forest classification using extracted PolSAR features from Compact Polarimetry data," *Adv. Sp. Res.*, vol. 57, no. 9, pp. 1939–1950, 2016.
- [6] M. Jafari, Y. Maghsoudi, and M. J. Valadan Zoej, "A new method for land cover characterization and classification of polarimetric SAR data using polarimetric signatures," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, no. 7, pp. 3595–3607, 2015.
- [7] A. Masjedi, M. J. Valadan Zoej, and Y. Maghsoudi, "Classification of Polarimetric SAR Images Based on Modeling Contextual Information and Using Texture Features," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 2, pp. 932–943, 2016.
- [8] L. Wang, X. Xu, H. Dong, R. Gui, and F. Pu, "Multi-pixel simultaneous classification of polsar image using convolutional neural networks," *Sensors (Switzerland)*, vol. 18, no. 3, pp. 1–18, 2018.
- [9] A. G. Mullissa, C. Persello, and A. Stein, "Polsarnet: A deep fully convolutional network for polarimetric sar image classification," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 12, no. 12, pp. 5300–5309, 2019.
- [10] B. Hou, X. Guo, W. Hou, S. Wang, X. Zhang, and L. Jiao, "PolSAR Image Classification Based on DBN and Tensor Dimensionality Reduction," in *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, Jul. 2018, pp. 8448–8450.
- [11] L. Zhang, W. Ma, and D. Zhang, "Stacked Sparse Autoencoder in PolSAR Data Classification Using Local Spatial Information," *IEEE Geosci. Remote Sens. Lett.*, vol. 13, no. 9, pp. 1359–1363, 2016.
- [12] F. Mohammadimanesh, B. Salehi, M. Mahdianpari, B. Brisco, and E. Gill, "Full and simulated compact polarimetry SAR responses to Canadian wetlands: Separability analysis and classification," *Remote Sens.*, vol. 11, no. 5, 2019.
- [13] X. Zhang, J. Zhang, M. Liu, and J. Meng, "Assessment of C-band compact polarimetry SAR for sea ice classification," *Acta Oceanol. Sin.*, vol. 35, no. 5, pp. 79–88, 2016.
- [14] Y. Izumi, S. Demirci, M. Z. bin Baharuddin, T. Watanabe, and J. T. S. Sumantyo, "Analysis of dual- and full-circular polarimetric SAR modes for rice phenology monitoring: An experimental investigation through ground-based measurements," *Appl. Sci.*, vol. 7, no. 4, pp. 1–16, 2017.
- [15] K. Dasari and A. Lokam, "Exploring the Capability of Compact Polarimetry (Hybrid Pol) C Band RISAT-1 Data for Land Cover Classification," *IEEE Access*, vol. 6, pp. 57981–57993, 2018.

- [16] D. Haldar, A. Das, S. Mohan, O. Pal, R. S. Hooda, and M. Chakraborty, "ASSESSMENT OF L-BAND SAR DATA AT DIFFERENT POLARIZATION COMBINATIONS FOR CROP AND OTHER LANDUSE CLASSIFICATION," *Prog. Electromagn. Res. B*, vol. 36, pp. 303–321, 2012.
- [17] K. Fukushima, "Neocognitron: A hierarchical neural network capable of visual pattern recognition," *Neural Networks*, vol. 1, no. 2, pp. 119–130, Jan. 1988.
- [18] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional neural networks: an overview and application in radiology," *Insights Imaging*, vol. 9, no. 4, pp. 611–629, Aug. 2018.
- [19] A. Khan, A. Sohail, U. Zahoora, and A. S. Qureshi, "A survey of the recent architectures of deep convolutional neural networks," *Artif. Intell. Rev.*, vol. 53, no. 8, pp. 5455–5516, Dec. 2020.
- [20] "Forest Cover Classification Using Compact Polarimetry Data TT -," *ISSGE*, vol. 5, no. 3, pp. 1–14, 2016.
- [21] M. E. Nord, T. L. Ainsworth, J. Sen Lee, and N. J. S. Stacy, "Comparison of compact polarimetric synthetic aperture radar modes," *IEEE Trans. Geosci. Remote Sens.*, vol. 47, no. 1, pp. 174–188, 2009.
- [22] T. L. Ainsworth, J. P. Kelly, and J. S. Lee, "Classification comparisons between dual-pol, compact polarimetric and quad-pol SAR imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 64, no. 5, pp. 464–471, 2009.



## Forest Classification Using Simulated Compact Polarimetry Data and Deep Learning Networks

Sahar Ebrahimi<sup>1\*</sup>, Hamid Ebadi<sup>2</sup>, Amir Aghabalaei<sup>3</sup>

1- Ms.c student of photogrammetry in Department of Geomatics Engineering, K. N. Toosi University of Technology

2- Professor in Department of Geodesy and Geomatics Engineering, K.N.Toosi University of Technology

3- Graduated PHD from Department of Geomatics Engineering, K. N. Toosi University of Technology

### Abstract

In the last two decades, among various Synthetic Aperture RADAR (SAR) imaging modes, Compact Polarimetry (CP) mode has drawn a lot of attention due to less complex imaging system, mass and data rate reduction, and also greater swath width. Having such advantages makes this data very useful for large-scale target mapping, such as forest classification. Different methods have been proposed for forest classification using CP mode, all of which are based on feature extraction. The accuracy of these methods depends on the discrimination of the extracted features. Among these methods, deep learning networks have almost automated the feature extraction phase and obtained impressive results, especially in the classification task. In this paper, the ability of deep learning networks is investigated by using CP mode data in forest classification. The study area of this paper is Petawawa forest located in Ontario, Canada, and the data being used are simulated CP data, Full Polarimetric (FP) data, and also reconstructed Pseudo Quad (PQ) data acquired from RADARSAT-2 in C-band. The proper deep learning network for automatic feature extraction is designed and the classification is performed on CP, FP, and PQ data. The results from all mode classifications are evaluated and compared with each other and also with the results from Wishart classifier and Support Vector Machine (SVM). The results of this paper show that using deep learning networks improves the classification accuracy of CP and PQ modes.

**Key words:** SAR, Compact Polarimetry, Convolutional Neural Networks, Forest Classification