

## تحلیل روش‌های یادگیری انتقالی در بهینه‌سازی تشخیص بیماری‌های درخت سیب

محمد روستائی<sup>۱</sup>، محسن نوروزی<sup>۲</sup>

۱- دانشجوی کارشناسی ارشد هوش مصنوعی و رباتیک، دانشگاه جامع امام حسین (ع)، تهران، ایران (نویسنده مسئول). رایانامه: M.Roustaiei@ihu.ac.ir

۲- پژوهشگر دانشکده کامپیوتر، شبکه و ارتباطات، دانشگاه جامع امام حسین (ع)، تهران، ایران. رایانامه: M.Norouzi@ihu.ac.ir

تاریخ دریافت: ۱۴۰۲/۰۸/۱۶ تاریخ ویرایش: ۱۴۰۲/۱۰/۱۶ تاریخ پذیرش: ۱۴۰۲/۱۱/۱۷ تاریخ چاپ: ۱۴۰۳/۰۱/۲۰ صص: ۲۳-۳۳

### چکیده

تشخیص صحیح بیماری‌های برگ سیب برای جلوگیری از کاهش عملکرد کمی و کیفی محصول ضروری است. با پیشرفت روش‌های یادگیری عمیق، تشخیص این بیماری‌ها بهبود می‌یابد اما محدودیت‌های داده‌ای مانعی جدی به‌شمار می‌آید. این پژوهش الگوهای یادگیری عمیق پیش‌آمخته را با تنظیمات دقیق ارزیابی می‌کند و نشان می‌دهد که حتی با داده‌های محدود نیز می‌توان با دقت زیادی بیماری‌ها را تشخیص داد. الگوهای انتخابی نسبت به روش‌های مرسوم عملکرد بهتری دارند و یادگیری انتقالی را به‌عنوان راهبرد مؤثری در مقابله با داده‌های محدود و تنوع بیماری‌ها معرفی می‌کنند. این الگوها به کشاورزان و متخصصان باغبانی کمک می‌کند تا با سرعت و کارایی بیشتری بیماری‌های برگ سیب را شناسایی و مدیریت کنند. همچنین، این الگوها علاوه بر کشاورزان برای مشاوران کشاورزی، دانشجویان علوم کشاورزی و پژوهشگران فعال در این زمینه نیز قابل استفاده است. علاوه بر این، این روش‌ها با سایر بیماری‌ها و گیاهان نیز قابل انطباق هستند و نویدبخش پیشرفت در سامانه‌های تشخیص بیماری‌های گیاهی در آینده خواهند بود. مطالعه حاضر می‌تواند در بهینه‌سازی و خودکارسازی فرآیندهای باغبانی انقلابی ایجاد کند و به تحول در مدیریت بیماری‌های گیاهی بیانجامد.

**کلیدواژه‌ها:** تشخیص بیماری‌های گیاه، طبقه‌بندی، کشاورزی هوشمند، یادگیری انتقالی، یادگیری عمیق، یادگیری پیش‌آمخته.

## مقدمه

از محصولات باغات در سطح جهان هستند. تشخیص و شناسایی بیماری در مدیریت به حداقل رساندن هدررفت محصول نقش اساسی دارد. از آنجا که بازرسی چشمی برای تشخیص بیماری بسیار مهم است، یادگیری عمیق گزینه‌ای عالی برای حل این مشکل است. در این مطالعه، الگوهایی را ارائه می‌دهیم که با استفاده از یادگیری انتقالی به‌عنوان یک روش یادگیری عمیق نوین، می‌توانند بیماری‌های برگ سیب را با دقت زیاد تشخیص دهند. مجموعه داده‌های بزرگی که از بیماری‌های برگ سیب جمع‌آوری شده است، به ما امکان می‌دهد این الگوها را بهبود داده و بیماری‌های برگ سیب را دقیق‌تر تشخیص دهیم. با استفاده از روش‌های یادگیری انتقالی، تلاش می‌کنیم تا بهره‌وری سامانه‌های تشخیص بیماری را به حداکثر برسانیم و به پژوهشگران این حوزه و در نهایت باغبانان کمک کنیم تا با بیماری‌های برگ سیب مؤثرتر مبارزه کنند.

در ادامه، ابتدا مطالعات پیشین در زمینه تشخیص بیماری‌های برگ سیب و یادگیری انتقالی را مرور می‌کنیم. سپس مراحل انجام مطالعه را توضیح داده و عملکرد الگوهای مختلف یادگیری انتقالی را ارزیابی و بررسی می‌کنیم. در نهایت، با استفاده از انواع مختلف الگوهای یادگیری انتقالی نتایج آزمایش‌های عملی را ارائه می‌دهیم و این نتایج را تحلیل و بررسی می‌کنیم.

وانگ<sup>۶</sup> و همکاران (۲۰۱۷) با استفاده از یک شبکه عصبی درهم‌پیچیده<sup>۷</sup> توانستند شدت بیماری‌های گیاهان را برآورد کنند. آن‌ها تصاویر برگ‌های سیاه شده سیب را با چهار درجه شدت برچسب‌گذاری کردند و توانستند به دقتی بیش از ۹۰ درصد دست یابند. آگاروال<sup>۸</sup> و همکاران (۲۰۱۹) نیز از یک رویکرد مبتنی بر شبکه عصبی درهم‌پیچیده برای شناسایی بیماری

بیماری‌های درختان سیب یکی از عوامل اساسی تهدیدکننده تولید این محصول راهبردی است. این بیماری‌ها می‌توانند عملکرد محصول را کاهش داده و به درخت خسارت بزنند و در نهایت به اقتصاد باغداران ضربه جدی وارد کنند. در طول سال‌ها، تشخیص دقیق و سریع بیماری‌های برگ سیب موضوعی بااهمیت بوده است، طوری که باغبانان و کارشناسان باغبانی در پی یافتن روش‌های نوآورانه‌ای برای شناسایی و مدیریت بهینه این بیماری‌ها بوده‌اند.

در سال‌های اخیر و با پیشرفت فناوری و علم داده، یادگیری ماشین<sup>۱</sup> و به‌خصوص یادگیری عمیق<sup>۲</sup> به‌عنوان یکی از روش‌های پرکاربرد در تشخیص انواع بیماری‌ها در حوزه کشاورزی، سلامت و همچنین تشخیص اشیاء<sup>۳</sup> در تصاویر، توجه پژوهشگران را به خود جلب کرده است. اما در تشخیص بیماری‌های برگ سیب، چالش‌هایی وجود دارد که باعث می‌شود استفاده صرف از روش‌های یادگیری عمیق با محدودیت‌هایی روبرو باشد. یکی از این چالش‌ها کمبود داده‌های آموزشی است. با توجه به نوع بیماری‌ها و تنوع آن‌ها، مجموعه داده‌های کامل و کافی برای آموزش الگوهای عمیق وجود ندارد و این موضوع می‌تواند بر دقت و قابلیت تعمیم‌پذیری<sup>۴</sup> روش‌های یادگیری ماشین تأثیر منفی بگذارد.

در این مطالعه، به دنبال یافتن راه‌حلی مؤثر برای تشخیص بیماری‌های برگ سیب با دقت بالا هستیم. برای این منظور، روش یادگیری انتقالی<sup>۵</sup> معرفی می‌شود. یادگیری انتقالی روشی قدرتمند است که به ما امکان می‌دهد دانش و الگوهای آموخته از یک مسئله مرتبط را به مسئله‌ای دیگر تعمیم دهیم و از آن‌ها در فرآیند تشخیص بیماری‌های برگ سیب استفاده کنیم. با استفاده از این روش، تلاش بر آن است که با کمترین نیاز به داده‌های آموزشی، دقت و عملکرد سامانه‌های تشخیص بیماری را بهبود بخشیم.

بیماری‌های درختان سالیانه باعث از بین رفتن ۲۰ تا ۴۰ درصد

1. Machine Learning

2. Deep Learning

3. Object Detection

4. Generalizability

5. Transfer Learning

6. Wang

7. Convolutional Neural Network (CNN)

8. Agarwal

برای کاهش شاخص‌های الگو<sup>۱۶</sup> و افزایش میزان همگرایی<sup>۱۷</sup> و دقت بیشتر از این دو روش استفاده شده بود. این شبکه توانست این چهار بیماری سیب را با دقت ۹۷/۶۲ درصد درست تشخیص دهد.

وانگ<sup>۱۸</sup> و همکاران (۲۰۱۷) از یادگیری انتقالی و تنظیم دقیق<sup>۱۹</sup> معماری‌های همه‌منظوره برای طبقه‌بندی شدت بیماری ریزدانه در مجموعه داده تصاویر پوسیدگی سیاه سیب استفاده کردند. آن‌ها با استفاده از VGG16 به دقت ۹۰/۱۶ درصد دست یافتند. چائو<sup>۲۰</sup> و همکاران (۲۰۲۰) در پژوهش خود با ترکیب الگوهای پیش‌آمورخته DenseNet و Xception در یک مجموعه داده سفارشی، از رویکرد یادگیری انتقالی برای طبقه‌بندی تصاویر بیماری‌های سیب به پنج طبقه استفاده کردند. دقت این الگوی طبقه‌بندی ۹۸/۸۲ درصد برآورد شد.

شکل ۱ مراحل شناسایی بیماری برگ درخت سیب در این پژوهش را نشان می‌دهد:

سیب استفاده کردند. آن‌ها از مجموعه داده «دهکده گیاه»<sup>۱</sup> بهره بردند که بر روی الگوهای پیش‌آمورخته درهم‌پیچیده معروف یعنی VGG16 و Inception-V3 اجرا می‌شوند. این الگوی پیشنهادی به دقت ۹۹ درصد دست یافت.

ضیاء<sup>۲</sup> و همکاران از یک چارچوب موازی برای شناسایی و طبقه‌بندی بیماری برگ سیب در زمان واقعی<sup>۳</sup> استفاده کردند. برای استخراج ویژگی‌ها<sup>۴</sup>، از تصاویر بهبودیافته برای آموزش الگوی درهم‌پیچیده پیش‌آمورخته استفاده شد. در این روش از مجموعه داده دهکده گیاه برای فرآیند آزمایش استفاده شد. آن‌ها توانستند به دقت ۹۶/۶ درصد دست یابند (ضیاء و همکاران، ۲۰۱۹). بارانوال<sup>۵</sup> و همکاران (۲۰۱۹) نیز از شبکه‌های عصبی درهم‌پیچیده برای شناسایی و تشخیص خودکار بیماری سیب استفاده کردند. برای تأیید نتایج، از مجموعه داده‌های دهکده گیاه استفاده شد که در آن انواع مختلف تصاویر برگ‌های سالم و نیز بیمار سیب موجود است. از پالایش تصویر<sup>۶</sup>، فشرده‌سازی تصویر<sup>۷</sup>، و روش‌های تولید تصویر<sup>۸</sup> برای تهیه مجموعه بزرگی از تصاویر و تنظیم کامل سامانه استفاده شد. در همه طبقه‌های مجموعه داده، الگوی پیش‌آمورخته به دقت ۹۸/۵۴ درصد دست یافت.

گودرزی و همکاران (۱۳۹۳) با استفاده از پردازش تصویر<sup>۹</sup> و خوشه‌بندی<sup>۱۰</sup> با استفاده از الگوریتم آستانه‌گذاری<sup>۱۱</sup> و شبکه عصبی، آفات گیاهان را بررسی کرده و توانستند در شناسایی و طبقه‌بندی بیماری به دقتی بیش از ۹۰ درصد دست یابند. قاسمی ورجانی<sup>۱۲</sup> و همکاران (۲۰۱۸) در پژوهشی برای تشخیص سه بیماری برگ درخت سیب از روی تصویر برگ آن‌ها، از یک الگوی ترکیبی شبکه عصبی استفاده کردند. در این پژوهش برای آموزش شبکه از دو الگوریتم بهینه‌سازی ازدحام ذرات<sup>۱۳</sup> و الگوریتم لون برگ مارکوارت<sup>۱۴</sup> استفاده شده است. دقت این سامانه در تشخیص این سه بیماری ۹۹ درصد بود. لئو<sup>۱۵</sup> و همکاران (۲۰۱۸) برای تشخیص چهار بیماری درخت سیب از روش‌های یادگیری عمیق و شبکه AlexNet استفاده کردند.

1. PlantVillage
2. Zia
3. Real-Time
4. Feature Extraction
5. Baranwal
6. Image Filtering
7. Image Compression
8. Image Generation
9. Image Processing
10. Clustering
11. Threshold
12. Ghasemi Varjani
13. Particle Swarm Optimization (PSO)
14. Levenberg-Marquardt (LM)
15. Liu
16. Model Parameters
17. Convergence Rate
18. Wang
19. Fine-Tuning
20. Chao



شکل ۱. مراحل شناسایی بیماری برگ درخت سیب در این پژوهش

## دستاورد

همان‌طور که در شکل ۱ نشان داده شده است، تشخیص بیماری‌های برگ درخت سیب از گام‌های مختلفی تشکیل شده است که مجموعه داده در گام نخست قرار دارد. در این مطالعه از مجموعه داده دهکده گیاه بهره گرفته شد که شامل تصاویری از بیماری گیاهان مختلف از جمله سیب، گوجه‌فرنگی و سیب‌زمینی و غیره است. در این مطالعه از تصاویر مربوط به بیماری برگ درخت سیب استفاده شد. در گام دوم، داده‌ها پیش‌پردازش شدند. پس از عملیات پیش‌پردازش، عملیات استخراج ویژگی از تصاویر انجام شد و در نهایت هر تصویر، به یک طبقه تعلق گرفت. در ادامه هر یک از این مراحل به تفصیل بررسی می‌شوند:

## دریافت تصاویر

در این مطالعه برای تشخیص بیماری برگ درخت سیب از مجموعه داده دهکده گیاه که دارای چهار دسته، یک دسته سالم و ۳ دسته بیماری است، استفاده شد. سه بیماری شایع برگ سیب یعنی زخم سیب<sup>۲</sup>، پوسیدگی سیاه<sup>۳</sup>، و زنگ سیب و سدر<sup>۴</sup> بررسی شده است. در شکل ۲ نمونه‌هایی از این تصاویر ارائه شده است. در مجموعه داده دهکده گیاه، ۳۹ طبقه از برگ گیاهان مختلف و تصاویر پس‌زمینه آن‌ها موجود است. مجموعه داده شامل ۶۱۴۸۶ تصویر است و از شش روش تقویت داده مختلف برای افزایش تعداد تصاویر مجموعه داده استفاده شده

است. این روش‌ها عبارت‌اند از چرخش تصویر<sup>۵</sup>، تصحیح گاما<sup>۶</sup>، افزودن نویز به تصویر<sup>۷</sup>، افزایش رنگ PCA<sup>۸</sup>، چرخش<sup>۹</sup> و مقیاس‌گذاری<sup>۱۰</sup>. در ادامه درباره هر یک از این روش‌ها توضیح مختصری ارائه می‌شود.

چرخش تصویر. این روش شامل چرخاندن تصاویر برگ به زاویه‌های مختلف است تا به الگو کمک کند تا بیماری‌ها را در جهت‌های مختلف بشناسد.

تصحیح گاما. تصحیح گاما به تنظیم روشنایی و میزان سفیدی و سیاهی تصاویر کمک می‌کند. این روش می‌تواند به الگو کمک کند تا در شرایط نوری متفاوت به خوبی عمل کند.

افزودن نویز به تصویر. افزودن نویز (مانند نویز گوسی<sup>۱۱</sup>) به تصاویر می‌تواند به الگو کمک کند تا در برابر اختلالات و ناپایداری‌های احتمالی مقاوم‌تر شود.

1. Pre-Processing
2. Apple Scab
3. Black Rot
4. Cedar Apple Rust
5. Image Rotation
6. Gamma Correction
7. Noise Addition
8. PCA Color Augmentation
9. Rotation
10. Scaling
11. Gaussian Noise

چرخش و مقیاس‌گذاری. چرخش مشابه با چرخش تصویر به ایجاد نمونه‌های مختلف از یک تصویر با چرخاندن آن کمک می‌کند، همچنین تغییر اندازه تصویر می‌تواند به الگو کمک کند تا اندازه‌های مختلف بیماری‌ها و ویژگی‌های برگ را تشخیص دهد.

**افزایش رنگ PCA.** روش افزایش رنگ PCA، یک روش آماری است که برای کاهش بُعد داده‌ها استفاده می‌شود و می‌تواند در تقویت داده برای تغییر رنگ‌های تصویر بدون تغییر ساختار اصلی آن به کار رود.




شکل ۲. نمایی از تصاویر مجموعه داده دهکده گیاه

### پیش‌پردازش تصاویر

با بررسی‌های انجام‌شده بر روی مجموعه داده دهکده گیاه مشخص شد که بیشتر تصاویر این مجموعه دارای حاشیه و پس‌زمینه اضافی زیادی هستند که همین امر باعث افزایش پردازش سامانه و در نتیجه پایین آمدن سرعت یادگیری الگو و همچنین در مواردی باعث ایجاد خطا در یادگیری می‌شوند.

این مجموعه داده شامل تصاویر سالم و بیمار از ۱۵ محصول در نظر گرفته شده است که عبارت‌اند از سیب، بلوبری، گیلان، ذرت، انگور، پرتقال، هلو، فلفل، سیب‌زمینی، تمشک، سویا، کدو، توت‌فرنگی و گوجه‌فرنگی و نیز یک طبقه پس‌زمینه بدون وجود برگ‌ها که برای بالا بردن دقت سامانه استفاده می‌شود. در این مطالعه ما از تصاویر برگ درخت سیب استفاده کردیم.



شکل ۳. عملیات پیش‌پردازش انجام‌شده برای بهبود داده‌ها

### تقویت داده<sup>۱</sup>

برای افزایش تنوع مجموعه داده و کاهش احتمال بیش‌برازش<sup>۲</sup> در الگوهای عصبی عمیق، از روش‌های تقویت داده استفاده شده است. این رویکرد، تعمیم‌پذیری الگو بر روی داده‌های دیده

همان‌طور که در شکل ۳ نشان داده شده است، برای حل این مشکل، با استفاده از الگوریتم خوشه‌بندی K-Means، بخش‌های مختلف تصویر را جدا کرده، شیء در تصویر را یافته، آن را برش داده و پس‌زمینه‌های اضافی آن حذف شده است.

1. Data Augmentation

2. Overfitting

### شاخص‌های شبکه

شاخص‌های الگو شبکه عصبی براساس جدول ۱ تنظیم شده است. این شاخص‌ها در همه شبکه‌ها یکسان هستند.

جدول ۱. شاخص‌های الگو شبکه عصبی

مقدار	شاخص
۱۵	MiniBatchSize
۱۰	MaxEpochs
۰,۰۰۰۱	InitialLearningRate
۳	Validation Frequency
بیش‌تر	زمان

در این مطالعه، دقت ده شبکه عصبی پیشرفته که پیش‌تر برای شناسایی و تشخیص تصاویر در چالش‌های بزرگ داده‌ها آموزش دیده‌اند را برای کاربرد خاص تشخیص بیماری‌های برگ درخت سیب ارزیابی کردیم. نتایج نشان می‌دهند که تقریباً همه الگوهای بررسی شده دقت بالایی دارند. باین حال، تفاوت‌های اندکی بین عملکرد آن‌ها مشاهده می‌شود. در ادامه ابتدا مشخصات محیط شبیه‌سازی، شاخص‌های ارزیابی، تقسیم‌بندی داده‌ها و طرح پژوهش برای ارزیابی روش پیشنهادی بیان شده و پس از بیان مفروضات موردنظر، نتایج عملکرد آزمایش‌ها ارائه شده است.

### محیط شبیه‌سازی

در این مطالعه برای پیاده‌سازی از محیط برنامه‌نویسی و شبیه‌سازی نرم‌افزار Matlab2022b و یک رایانه همراه با ۱۶ گیگابایت حافظه رم<sup>۲</sup>، پردازنده گرافیکی الگو NVIDIA GeForce GTX1050 و پردازنده مرکزی الگو Core™ i7700-7HQ CPU @ 3.80GHz 3.99 GH Intel® استفاده شد.

نشده را بهبود بخشیده و دقت تشخیص بیماری‌های برگ درخت سیب را افزایش می‌دهد.

در این مطالعه، تقویت داده به شکلی پویا و به موازات آموزش الگو انجام شد. با استفاده از چرخش‌های تصادفی در بازه  $[0, 360]$ ، بزرگنمایی با نرخ‌های متفاوت بین  $[0.8, 1.2]$ ، تغییرات تصادفی در شدت نور و کنتراست و نیز برش‌های افقی و عمودی<sup>۱</sup>، تصاویر ورودی تقویت شدند. همه این تغییرات به روشی اعمال شدند که ویژگی‌های بنیادین بیماری‌ها حفظ شوند و الگو محرک‌های متنوع‌تری برای یادگیری دریافت کند. همچنین برای اجتناب از اعمال تغییرات شدید که می‌تواند باعث از دست رفتن اطلاعات مهم شوند، شاخص‌های تقویت به دقت تنظیم شد. علاوه بر این، با استفاده از یک رویکرد تصادفی، هر تصویر ورودی به صورت منحصر به فرد تقویت شد تا از یکنواختی داده‌ها جلوگیری شده و اطمینان حاصل شود که الگو می‌تواند بر تنوع حقیقی شرایط زمینه‌ای موجود در داده‌های دنیای واقعی تعمیم یابد.

### استخراج ویژگی و طبقه‌بندی

در این مطالعه، ابتدا با استفاده از ۱۰ شبکه یادگیری عمیق پیش‌آمورخته، که نام آن‌ها در ادامه ارائه شده است، تشخیص بیماری برگ درخت سیب بررسی شد. نتایج دقیق این آزمایش‌ها در بخش نتایج و بحث توضیح داده شده است. شبکه‌هایی که با استفاده از آن‌ها ویژگی‌های بیماری‌های برگ درخت سیب را استخراج و سپس تصاویر آن‌ها را طبقه‌بندی کرده‌ایم به شرح زیر است:

- AlexNet
- DarkNet-53
- DensNet-201
- GoogleNet
- Inception-v3
- MobileNet-v2
- NasNet-Larg
- ResNet-101
- VGG-16
- Xception

1. Flip

2. RAM

## شاخص‌های ارزیابی

در این مطالعه برای ارزیابی روش پیشنهادی از معیار طبقه‌بندی صحت<sup>۱</sup> و حساسیت<sup>۲</sup> استفاده شد. در زیر فرمول این معیار نشان داده شده است.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (2)$$

در رابطه (۱) و (۲)، TP بیانگر تعداد نمونه‌هایی است که طبقه واقعی آن‌ها مثبت بوده و روش پیشنهادی نیز طبقه آن‌ها را به درستی مثبت تشخیص داده است. منظور از مثبت بودن یعنی آن تصویر نمونه، تصویر یک برگ بیمار بوده است و منظور از منفی بودن یعنی تصویر یک برگ سالم است. FP بیانگر تعداد نمونه‌هایی است که طبقه واقعی آن‌ها منفی بوده ولی روش پیشنهادی به اشتباه طبقه آن را مثبت تشخیص داده است. FN

بیانگر تعداد نمونه‌هایی است که طبقه واقعی آن‌ها مثبت بوده ولی روش پیشنهادی به اشتباه طبقه آن‌ها را منفی تشخیص داده است. TN بیانگر تعداد نمونه‌هایی است که طبقه واقعی آن‌ها منفی بوده و روش پیشنهادی نیز به درستی طبقه آن را منفی تشخیص داده است.

## تقسیم‌بندی داده‌ها

در این مطالعه برای تقسیم‌بندی داده‌ها به دسته‌های آموزش و آزمایش از روش تصادفی استفاده شده و به ترتیب با نسبت ۷۰ به ۳۰ تقسیم‌بندی شدند.

## نتایج آزمایش‌ها

در جدول ۲ نتایج حاصل از آزمایش شبکه‌های یادگیری انتقال مختلف مشاهده می‌شود. در این آزمایش‌ها صحت و حساسیت هر الگو بررسی شده است.

جدول ۲. صحت و حساسیت شبکه‌های مختلف یادگیری انتقالی در تشخیص بیماری درخت سیب

حساسیت	صحت	نام شبکه
۹۹٫۵۰	۹۹٫۷۱	AlexNet
۹۹٫۶۰	۹۹٫۷۸	53-DarkNet
۹۹٫۶۵	۹۹٫۷۸	201-DensNet
۹۸٫۱۰	۹۸٫۲۸	GoogleNet
۹۸٫۰۶	۹۸٫۸۵	Inception-v3
۹۹٫۲۰	۹۹٫۳۵	MobileNet-v2
۹۹٫۷۰	۹۹٫۷۸	NasNet-Larg
۱۰۰	۹۹٫۷۸	101-ResNet
۹۹٫۵۰	۹۹٫۷۱	16-VGG
۹۷٫۶۰	۹۷٫۸۵	Xception

## عملکرد شبکه‌های عصبی

شبکه‌های 53-DarkNet، 201-DensNet، NasNet-Large و 101-ResNet با کسب صحتی معادل ۹۹/۷۸ درصد، عملکردی قابل توجه از خود نشان دادند (نمودارهای ۱ و ۲). همچنین، همان‌طور که مشاهده می‌شود، شبکه 101-ResNet با

کسب حساسیت ۱۰۰ درصد بهترین عملکرد را در زمینه تشخیص بیماری‌های برگ درخت سیب دارد. این موضوع بیانگر قدرت بالای این الگو در استخراج ویژگی‌های کلیدی مرتبط با بیماری‌های برگ است. این شبکه‌ها با بهره‌گیری از لایه‌های

1. Accuracy  
2. Sensitivity

میدانی، که به الگوهای سبک وزن نیاز دارند، بسیار با اهمیت باشد. معماری این الگو به گونه‌ای است که مصرف منابع را بهینه می‌کند و امکان می‌دهد که در دستگاه‌هایی با توان پردازشی محدود نیز قابل استفاده باشد.

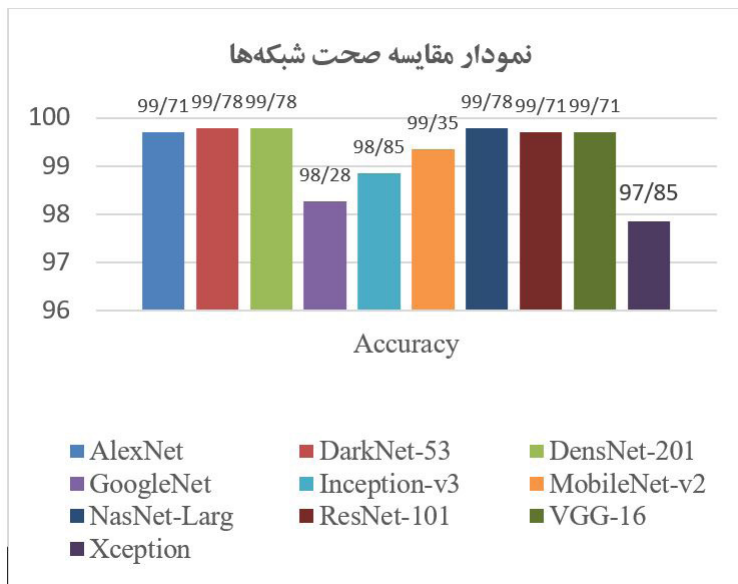
**مقایسه شبکه‌های مختلف**

عمیق تر و سازوکارهای پیچیده تر، توانسته‌اند الگوهای پیچیده مورد نیاز برای تشخیص دقیق بیماری‌ها را به خوبی یاد بگیرند.

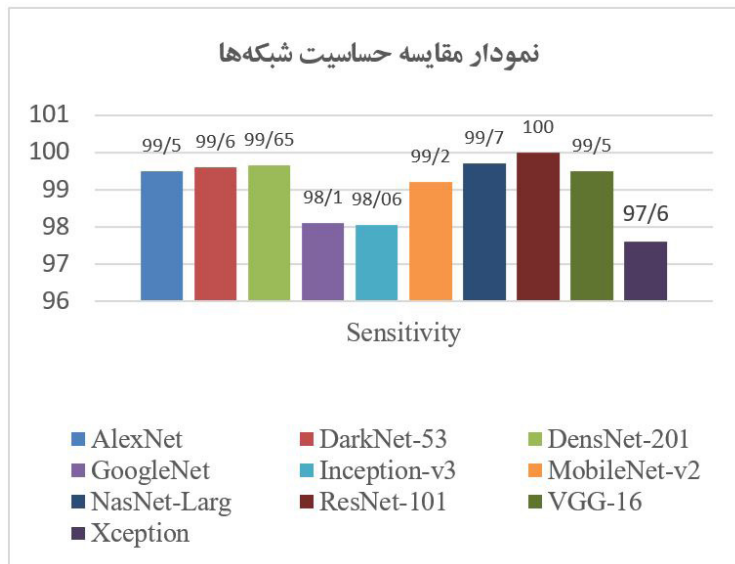
**اهمیت کاربردی MobileNet-v2**

MobileNet-v2 با صحت ۹۹/۳۵ درصد، عملکردی متمایز

را از خود نشان می‌دهد که این امر می‌تواند برای کاربردهای



نمودار ۱. مقایسه مقدار صحت‌های الگوهای مختلف



نمودار ۲. مقایسه مقدار حساسیت الگوهای مختلف



و صحت آن‌ها برجسته‌تر است. این نتایج نویدبخش، راه را برای توسعه بیشتر سامانه‌های هوشمند کمک‌رسان به کشاورزان برای مدیریت بهتر بیماری‌های گیاهی هموار می‌سازد. همچنین، این روش قابل توسعه و تطبیق با سایر بیماری‌ها و گیاهان است و می‌تواند در عملکرد و بهره‌وری سامانه‌های تشخیص بیماری برگ سیب بهبود قابل توجهی به ارمغان آورد.

بر اساس نتایج به دست آمده، پیشنهاد می‌شود که در پژوهش‌های آتی بر بهینه‌سازی الگوهای موجود و توسعه الگوهای جدیدی تأکید شود که بتوانند با داده‌های محدودتر به نتایج دقیق‌تر دست یابند. همچنین، بررسی چگونگی پردازش ویژگی‌ها در لایه‌های مختلف الگوها و تأثیر آن‌ها بر صحت نهایی، می‌تواند از دلایل عملکرد متفاوت شبکه‌ها درک بهتری به دست دهد.

### منابع

- راد، رؤیا، موسوی، محمد و وردی، فاطمه (۱۳۹۹). استفاده از یادگیری عمیق در تشخیص خودکار بیماری گیاهان براساس پردازش تصویر برگ. *تحقیقات سامانه‌ها و مکانیزاسیون کشاورزی*، جلد ۲۱، شماره ۷۶. ص. ۴۹-۶۸.
- گودرزی، ع.، صادقی‌فر، ص.، علی کرمی، ح. و پرهون، ح. (۱۳۹۳). خوشه‌بندی به روش threshold و شبکه‌های عصبی برای خوشه‌بندی و طبقه‌بندی آفات گیاهان. دومین همایش سراسری کشاورزی و منابع طبیعی پایدار، تهران، مؤسسه آموزش عالی مهر اروند، گروه ترویجی دوستاناران محیط‌زیست و انجمن حمایت از طبیعت ایران.
- Agarwal, M., Gupta, S.K. and Biswas, K.K., 2020. Development of Efficient CNN model for Tomato crop disease identification. *Sustainable Computing: Informatics and Systems*, 28, p.100407.
- Baranwal, S., Khandelwal, S. and Arora, A., 2019, February. Deep learning convolutional neural network for apple leaves disease detection. *In Proceedings of international conference on sustainable computing in science, technology and management (SUSCOM)*, Amity University Rajasthan, Jaipur-India..
- Chao X, Sun G, Zhao H, Li M, He D (2020) *Identification of apple tree leaf diseases based on deep learning models. Symmetry*

در حالی که AlexNet و VGG-16 هر دو ۹۹/۷۱ درصد صحت را نشان می‌دهند، این الگوها که در نسل‌های اولیه شبکه‌های عمیق قرار می‌گیرند، هنوز هم عملکردی رقابتی دارند. با این حال، نسبت به شبکه‌های بروزتر، تفاوت‌های جزئی در عملکرد مشاهده می‌شود که ممکن است حاصل تفاوت‌هایی باشد که در تعداد لایه‌ها، پیچیدگی الگو و قدرت استخراج آن‌ها وجود دارد.

### تحلیل عملکرد Xception

الگوی Xception کمترین صحت و حساسیت را در میان همه شبکه‌های مورد آزمایش کسب کرده است که این امر می‌تواند مؤید این واقعیت باشد که این الگو ممکن است به تنظیمات دقیق‌تری نیاز داشته باشد یا شاید این شبکه به دلیل معماری خاص خود به داده‌های آموزشی بیشتر یا تنوع بیشتر در داده‌ها نیاز دارد تا بتواند عملکرد بهتری را ارائه دهد.

### توصیه‌ها

در این مطالعه، تشخیص صحیح بیماری‌های برگ سیب با استفاده از روش یادگیری انتقالی بررسی شد. اهمیت این موضوع در باغبانی و تولیدات مرتبط با برگ سیب امری مشهود است، زیرا این بیماری‌ها می‌توانند عملکرد و کیفیت محصولات را کاهش دهند. در مجموع، نتایج این مطالعه اهمیت انتخاب الگوی مناسب برای کاربردهای خاص و نیز نیاز به تنظیم دقیق شاخص‌ها و امکان بهره‌برداری از الگوهای پیش‌آمخته در محیط‌های داده‌ای محدود را نمایان می‌سازد. این تحقیق گامی برای بهینه‌سازی تشخیص بیماری‌های درخت سیب با استفاده از یادگیری عمیق است و دورنمایی را برای پیشرفت‌های آینده در این حوزه فراهم می‌آورد. روش تشخیص بیماری‌های برگ سیب با استفاده از یادگیری انتقالی که در این مقاله بررسی شده است، ابزاری مؤثر و کارآمد برای تشخیص بیماری‌های برگ سیب است.

نتایج نشان داد که شبکه‌های عمیق مورد استفاده، نه تنها در تشخیص و طبقه‌بندی بیماری‌های درخت سیب توانایی قابل توجهی دارند، بلکه در مقایسه با روش‌های مرسوم دیگر، سرعت تشخیص

12(7):1065

Ghasemi Varjani, Z., Mohtesabi, S. S., Ghasemi, H., & Omrani, I. (2018). *Development of a new hybrid system to detect apple tree leaf diseases*. Iranian Biosystems Engineering, 49(2), 215-225. (in Persian)

Roustaei, M., & Giveki, D. (2023). *Diagnosis of COVID-19 Disease in X-ray Images Based on Deep Learning Methods and Combining Classifiers*. Journal of Health and Biomedical

Informatics, 10(2), 111-124.

Wang, G., Sun, Y., & Wang, J. (2017). *Automatic image-based plant disease severity estimation using deep learning*. *Computational Intelligence and Neuroscience*, 2017.

## Analysis of Transfer Learning Methods in Optimizing Apple Tree Disease Detection

Mohammad Roustaei<sup>1</sup>, Mohsen Nourozi<sup>2</sup>

1. Master Student of Imam Hossein Comprehensive University, Tehran, Iran. (Corresponding author). Email: M.Roustaei@ihu.ac.ir

2. Researcher at Faculty of Computer, Network and Communication, Imam Hossein Comprehensive University, Tehran, Iran Email: M.Nourozi@ihu.ac.ir

### Abstract

Accurate detection of apple leaf diseases is essential to prevent the reduction in both the quantity and quality of crop yield. With advancements in deep learning methods, the diagnosis of these diseases is improving, but data limitations remain a significant barrier. This research evaluates pretrained deep learning models with precise settings and demonstrates that high accuracy in disease detection is possible even with limited data. The selected models perform better than conventional methods and introduce transfer learning as an effective strategy to combat limited data and the diversity of diseases. These models aid farmers and horticulture specialists in identifying and managing apple leaf diseases more efficiently and rapidly. Additionally, these models are not only beneficial for farmers but also for agricultural consultants, students of agricultural sciences, and researchers in this field. Moreover, these methods are adaptable to other diseases and plants, promising advancements in plant disease detection systems in the future. The present study has the potential to revolutionize horticultural processes through optimization and automation, leading to a transformation in plant disease management.

**Keywords:** Plant Disease Detection, Classification, Smart Agriculture, Transfer Learning, Deep Learning.