



Implementation of Transfer Learning to Classify Pictures of Some Weeds

Iman Ahmadi^{1*}, Fateme Tavassoli²

¹ Assistant Professor, Department of Genetics and Plant Production Engineering, Institute of Agriculture, Water, Food and Nutraceuticals, Isf. C., Islamic Azad University, Isfahan, Iran.

² Msc of Applied Mathematics, University of Yazd, Yazd, Iran.

* Corresponding Author's Email: imanahmadi1358@iau.ac.ir
(Received: July. 3, 2025 – Accepted: September. 17, 2025)

ABSTRACT

Objective: Computer vision is a branch of artificial intelligence that deals with object recognition in images or image classification. In this article, transfer learning was used to classify weed images into eighteen categories. With the help of transfer learning models, image processing using deep learning algorithms can be implemented on computers with standard hardware capabilities. The trade-off is reduced model accuracy compared to using deep learning from scratch.

Material and methods: First, images from each of the eighteen weed categories were collected. These were split into a training set (695 images) and a test set (260 images). The training dataset was then augmented using computer-based image enhancement, increasing its size tenfold to 6,950 images. These images served as the raw input data for building the computer vision model. Image preprocessing was carried out using functions available in the PyTorch library. Then, a transfer learning model was developed using the training images and evaluated using the test images. The main evaluation metric in this study was the confusion matrix, through which other metrics—sensitivity, specificity, precision, F1-score, and accuracy—were calculated and presented.

Results: According to the results, the values of sensitivity, specificity, precision, F1-score, and accuracy were 84%, 99%, 83%, 84%, and 84%, respectively.

Conclusion: These results indicate that the classifier performed acceptably well despite being trained without a GPU-equipped computer.

Keywords: Classification, EfficientNet model, Test accuracy, Transfer learning, Weed

Cite this article: Ahmadi, I., Tavassoli, F. 2025. Implementation of Transfer Learning to Classify Pictures of Some Weeds. *Journal of Sustainable Agricultural Science Research*. 5(2): 1-15.

DOI: <https://doi.org/10.71667/sarj.2025.1211044>



© The Author(s).

DOI: <https://doi.org/10.71667/sarj.2025.1211044>

Publisher: Islamic Azad University of Kerman Branch Press.

پیاده‌سازی یک مدل یادگیری انتقالی برای دسته‌بندی تصاویر تعدادی از علف‌های هرز

ایمان احمدی^{۱*}، فاطمه توسلی^۲

۱- استادیار گروه مهندسی تولید و ژنتیک گیاهی، دانشکده کشاورزی، آب، غذا و فراسودمندها، واحد خوراسگان، دانشگاه آزاد اسلامی، اصفهان، ایران

۲- دانش آموخته کارشناسی ارشد ریاضی کاربردی، دانشگاه یزد، یزد، ایران

* ایمیل نویسنده مسئول: imanahmadi1358@iau.ac.ir

(تاریخ دریافت: ۱۴۰۴/۴/۱۲ - تاریخ پذیرش: ۱۴۰۴/۶/۲۶)

چکیده

هدف: ماشین بینایی شاخه‌ای از هوش مصنوعی است که با تشخیص اشیاء موجود در یک تصویر و یا دسته‌بندی تصاویر سر و کار دارد. در این مقاله برای دسته‌بندی تصاویر علفهای هرز در هجده دسته از روش یادگیری انتقالی استفاده شده است. با استفاده از مدل‌های یادگیری انتقالی، پیاده‌سازی پردازش تصویر به کمک الگوریتم‌های یادگیری عمیق روی رایانه‌های دارای امکانات سخت‌افزاری معمولی امکان‌پذیر می‌شود. هزینه انجام این کار کم شدن صحت مدل بر مبنای یادگیری انتقالی نسبت به مدل یادگیری عمیق است.

مواد و روش‌ها: ابتدا تصاویری از هر یک از هجده دسته علف‌های هرز جمع‌آوری شد و این تصاویر به دو دسته آموزش، شامل ۶۹۵ تصویر، و آزمون، شامل ۲۶۰ تصویر، تقسیم شدند. سپس تعداد تصاویر پایگاه داده‌ای آموزش با فرآیند افزایش رایانه‌ای تصاویر ده برابر شد و تعداد تصاویر پایگاه داده‌ای آموزش به ۶۹۵۰ تصویر رسید. این تصاویر به عنوان داده‌های خام اولیه برای ایجاد مدل ماشین بینایی مورد استفاده قرار گرفت. عملیات پیش‌پردازش تصاویر به کمک توابع موجود در کتابخانه PyTorch انجام شد، سپس مدل یادگیری انتقالی با استفاده از تصاویر پایگاه داده‌ای آموزش توسعه یافت و روی تصاویر پایگاه داده‌ای آزمون، ارزیابی شد. معیار اصلی ارزیابی مدل، ماتریس در هم ریختگی بود که به وسیله آن سایر معیارهای ارزیابی یعنی حساسیت، اختصاصیت، دقت، نمره F1 و صحت محاسبه و نتایج آن ارائه شد.

یافته‌ها: بر طبق نتایج به دست آمده مقادیر معیارهای حساسیت، اختصاصیت، دقت، نمره F1 و صحت به دست آمده در این پژوهش به ترتیب برابر با ۸۴، ۹۹، ۸۳ و ۸۴ درصد بودند.

نتیجه‌گیری: این نتایج از قابل قبول بودن عملکرد دسته بند با وجود عدم استفاده از رایانه مجهز به GPU در فرآیند آموزش حکایت دارد.

واژه‌های کلیدی: دسته‌بندی، صحت آزمون، علف هرز، مدل EfficientNet، یادگیری انتقالی

استناد:

Ahmadi, I., Tavassoli, F. 2025. Implementation of Transfer Learning to Classify Pictures of Some Weeds. *Journal of Sustainable Agricultural Science Research*. 5(2). 1-15.

DOI: <https://doi.org/10.71667/sarj.2025.1211044>



© The Author(s).

ناشر: انتشارات دانشگاه آزاد اسلامی واحد کرمان

DOI: <https://doi.org/10.71667/sarj.2025.1211044>

مقدمه

ماشین بینایی شاخه‌ای از هوش مصنوعی است که با تشخیص اشیاء در یک تصویر و یا دسته‌بندی تصاویر بر طبق آنچه که در طول فرآیند آموزش یادگرفته است سر و کار دارد.

امروزه با استفاده از GPUهای چند هسته‌ای، تقریباً تمام کارهای مرتبط با دید ماشین با به کارگیری الگوریتم‌های یادگیری عمیق پیاده‌سازی می‌شوند، به ویژه از الگوریتم‌های شبکه‌های عصبی کانولوشنال به وفور در این زمینه به کار گرفته می‌شوند. یک شبکه عصبی کانولوشنال در صدد یافتن الگو در یک تصویر است. هر چه تعداد لایه‌های شبکه بیشتر باشد، الگوهای بیشتری گرفته خواهد شد و پیش‌بینی‌های صحیح‌تری از شبکه حاصل خواهد شد. اصول کاری یک شبکه عصبی کانولوشنال به صورت زیر است: یک فیلتر متحرک کوچک (با اندازه به عنوان مثال 3×3 و یا 5×5 پیکسل) حرکت خود را از گوشه بالا-چپ یک تصویر دارای اندازه بزرگ (به عنوان مثال 200×200 پیکسل) شروع کرده و با گام‌های یک پیکسلی به سمت راست حرکت می‌کند. در هر موقعیتی که فیلتر شکلی شبیه الگوش تشخیص دهد، آن شکل را در موقعیت متناظر از تصویر خروجی انعکاس می‌دهد. بعد از اینکه لایه بالایی از تصویر جارو شد، فیلتر به لبه سمت چپ لایه بعد منتقل شده و شروع به حرکت به سمت راست به منظور پیدا کردن الگوها در این لایه می‌کند. این فرآیند آنقدر تکرار می‌شود تا فیلتر به موقعیت پائین و سمت راست تصویر برسد. تصویر خروجی از این فرآیند، تکرارهایی از الگوی فیلتر است که در مکان‌های متناسب با تصویر اصلی که آن الگو موجود بوده، ثبت شده است. بنابراین، اگر از فیلترهای مختلفی در این فرآیند استفاده شود، بسیاری از الگوهای تصویر داده شده تشخیص داده خواهد شد و این الگوها در فرآیند دسته‌بندی تصاویر مورد استفاده قرار خواهند گرفت. هزینه افزودن بر تعداد فیلترها، زمان و منابع سخت افزاری بیشتری است که برای کامل شدن کل فرآیند مورد نیاز است. بنابراین، شبکه‌های عصبی کانولوشنال خیلی عمیق برای اجرا به سخت افزار GPU چند

هسته‌ای نیاز دارند و بدون آن فرآیند آموزش شبکه خیلی طول می‌کشد. در اینجاست که مفهوم یادگیری انتقالی وارد عمل می‌شود.

در مدل یادگیری انتقالی، ضرایب یک شبکه خیلی عمیق به شبکه دیگری که وظیفه مشابهی با شبکه اول دارد اما روی تصاویر دیگری عمل می‌کند، انتقال داده می‌شود. ضرایب منتقل شده برای جلوگیری از تغییر در طول فرآیند آموزش مدل، ثابت در نظر گرفته می‌شوند. با استفاده از این روش، شبکه در زمان منطقی قابل آموزش بوده و قادر است کلاس‌های تصاویر داده شده را تشخیص دهد. بنابراین، شبکه‌های عصبی کانولوشنال خیلی عمیق روی رایانه معمولی دارای CPU با استفاده از روش یادگیری انتقالی قابل پیاده‌سازی است. برخی از پژوهشگران از ایده یادگیری انتقالی برای پردازش تصاویر استفاده کرده‌اند، به عنوان مثال (Chen et al., 2020) و (Ouhami et al., 2020) از یادگیری انتقالی برای تشخیص بیماری‌های گیاهی از روی تصاویر گیاه استفاده کردند. در پژوهش دیگری برای دسته‌بندی آفات گیاهی از شبکه عصبی پیچشی عمیق و یادگیری انتقالی استفاده شده است (Thenmozhi & Srinivasulu Reddy, 2019).

همانطور که پژوهش‌های اخیر از سوی نویسندگان مختلف نشان می‌دهد، حوزه شناسایی علف‌های هرز نیز به‌طور چشمگیری تحت تأثیر فناوری‌های یادگیری عمیق قرار گرفته است. (Li & Chen, 2025) به چالش اساسی شناسایی علف‌های هرز در محیط‌های پیچیده‌ای که محصولات و علف‌های هرز به‌صورت درهم‌تنیده رشد می‌کنند پرداخته‌اند و پیشنهاد کردند که راهکار مؤثر، پاشش دقیق علف‌کش بر روی علف‌های هرز در حالی است که از آسیب به محصولات جلوگیری شود. رویکرد فنی آنان بر طبقه‌بندی، شناسایی و مکان‌یابی علف‌ها و محصولات متمرکز بود و اذعان کردند که ویژگی‌های پیچیده ناشی از رشد درهم‌تنیده، از عوامل اصلی مؤثر بر استخراج ویژگی‌های علف‌های هرز هستند.

(AWRC-DLMLO) توسعه داده‌اند. این تکنیک با استفاده از فیلترگذاری گاوسی در مرحله پیش‌پردازش تصاویر برای حذف نویز ناخواسته آغاز می‌شود، سپس بخش‌بندی گیاهان با بهره‌گیری از Residual Attention U-Net انجام می‌گیرد و برای استخراج بردار ویژگی از روش ShuffleNetV2 استفاده می‌شود. افزون بر این، الگوریتم بهینه‌سازی لمورها برای تنظیم ابرپارامترها و بهبود کارایی مدل به کار گرفته شده است. در این پژوهش از روش یادگیری انتقالی بر مبنای مدل از پیش آموزش دیده EfficientNet برای دسته‌بندی تصاویر علف هرز در هجده دسته استفاده شده است. دلیل این انتخاب به عدم دسترسی به رایانه مجهز به GPU برای پیاده‌سازی شبکه عصبی پیچشی عمیق بر می‌گردد. همچنین از آنجا که استفاده از روشهای یادگیری ماشین سنتی مثل ماشین بردار پشتیبان (SVM) برای کاربردهای پردازش تصویر پس از سال ۲۰۱۲ و با معرفی شبکه‌های عصبی پیچشی منسوخ شده است، استفاده از روش یادگیری انتقالی تنها گزینه موجود برای انجام این پژوهش بود. از سوی دیگر مدل EfficientNet به دلیل ساختار شبکه کارآمد و مکانیزم‌های هوشمندانه‌اش به عنوان یک مدل برتر برای وظایف طبقه‌بندی تصاویر ظاهر می‌شود. این مدل با بارگذاری پارامترهای از پیش آموزش داده شده، تسریع همگرایی و کاهش زمان آموزش در یادگیری انتقالی را به همراه دارد. این مشخصات، EfficientNet را به یک انتخاب قدرتمند برای وظایف طبقه‌بندی تصویر تبدیل می‌کند که از دیگر مدل‌ها در دقت و کارایی پیشی می‌گیرد (Huang et al., 2023).

مواد و روش‌ها

۱- آماده‌سازی تصاویر خام

هدف از این پژوهش تشخیص هجده نوع از علف‌های هرز موجود در مزارع است. نام‌های علمی و فارسی این هجده نوع علف هرز در جدول ۱ آورده شده است. در این پژوهش از نام علمی این علف‌های هرز به عنوان نام گروه‌های دسته‌بند استفاده شد.

(Pai et al., 2024) چشم‌اندازی جامع از چگونگی تحول کامل کشاورزی توسط روش‌های یادگیری عمیق ارائه دادند؛ رویکردی که امکان مکان‌یابی سریع اشیاء و شناسایی آن‌ها را فراهم می‌سازد. با این حال، آنان تأکید می‌کنند که شناسایی و طبقه‌بندی علف‌های هرز می‌تواند دشوار باشد، زیرا علف‌های هرز و محصولات شباهت زیادی در رنگ، شکل و بافت دارند. مرور ادبیات آنها نشان‌دهنده وجود پتانسیل در روش‌های مختلف یادگیری عمیق برای شناسایی، مکان‌یابی و طبقه‌بندی علف‌ها و محصولات بود و بیان کردند که عمده پژوهش‌ها از راهبردهای یادگیری نظارت‌شده بهره گرفته و مدل‌های از پیش آموزش‌دیده را بر مجموعه‌داده‌های بزرگ و برچسب‌خورده بازآموزی کرده‌اند تا به دقت بالا دست یابند.

(Hasan et al., 2022) پژوهش‌های تجربی گسترده‌ای بر روی پنج شبکه عصبی عمیق پیشرفته شامل VGG16، ResNet-50، Inception-V3، Inception-ResNet-v2 و MobileNetV2 انجام داده و کارایی آن‌ها را در شناسایی علف‌های هرز ارزیابی کردند. آنها یادآور شدند که شناسایی علف‌های هرز به دلیل شباهت رنگ، بافت و شکل میان محصولات و علف‌ها کاری چالش‌برانگیز است و این موضوع می‌تواند به واسطه شرایط تصویربرداری، موقعیت جغرافیایی یا شرایط آب‌وهوایی در هنگام ثبت تصاویر پیچیده‌تر شود. پژوهش آنان با ترکیب چند مجموعه‌داده کوچک‌تر، یک پایگاه داده بزرگ از علف‌ها و محصولات ایجاد کرده و با استفاده از روش افزایش داده، عدم‌توازن کلاسی را کاهش داده و این پایگاه داده را برای ارزیابی شبکه‌های عصبی به کار برده است. یافته کلیدی آن‌ها نشان داد که VGG16 بر روی مجموعه‌داده‌های کوچک عملکرد بهتری داشته، در حالی که ResNet-50 در پایگاه داده ترکیبی بزرگ عملکرد بهتری نسبت به سایر مدل‌ها ارائه کرده است.

(Gopalakrishnan et al., 2025) رویکردی پیشرفته‌تر ارائه کرده و سامانه‌ای خودکار برای شناسایی و طبقه‌بندی علف‌های هرز مبتنی بر مدل یادگیری عمیق همراه با بهینه‌سازی "لمورها

جدول ۱- نام‌های علمی و فارسی علف‌های هرز مورد استفاده در این پژوهش (نام‌های علمی علف‌های هرز به عنوان نام‌های گروه‌های دسته‌بند در این

پژوهش مورد استفاده قرار گرفت)

نام علمی	نام فارسی
Bromus danthoniae Trin	برموس
Capsella bursa pastoris (L.)	کیسه کشیش
Cardaria draba (L.) Desv	ازمک
Cirsium arvense (L.) Scop	کنگر صحرائی
Convolvulus arvensis L	پیچک صحرائی
Galium tricomutum	شیر پنیر
Glycyrrhiza glabra	شیرین بیان
Lactuca spp	کاهوک وحشی
Matricaria chamomilla	بابونه
Melilotus officinalis	یونجه زرد
Polygonum persicaria L	هفت بند
Scorpiurus muricatus L.	دم عقربی
Silybum marianum (L.) Gaertn	خار مریم
Sinapis arvensis	خردل وحشی
Sorghum halepense (L.) Pers	قیاق
Tragopogon major	شنگ
Vaccaria hispanica	جفجفک
Vicia hycanica	ماشک گل زرد

"Iran_Weeds" منتقل شدند. این پوشه در مسیر کاری زبان برنامه‌نویسی Python به منظور توسعه مدل کپی شد. تعداد کل تصاویر نهایی قرار گرفته در پوشه‌های "train" و "test" بترتیب برابر با ۶۹۵۰ و ۲۶۰ تصویر بود. تصاویر موجود در پوشه "train" برای آموزش مدل استفاده شد (منظور از آموزش مدل، تغییر وزن‌های مدل در جهتی است که پیش‌بینی‌های مدل روی تصاویر "train" با واقعیت انطباق یابد)، در حالی که تصاویر موجود در پوشه "test" برای آزمایش خوب بودن وزن‌های به دست آمده برای تشخیص علف‌های هرز موجود در تصاویر دیده نشده پوشه "test" به کار برده شد.

۲- روند توسعه مدل

توسعه مدل با کد نوشته شده در محیط برنامه‌نویسی PyCharm با استفاده از کتابخانه PyTorch زبان برنامه‌نویسی Python انجام شد. در کتابخانه PyTorch توابعی وجود دارد که این کتابخانه را برای ایجاد مدل‌های بر مبنای مفهوم یادگیری انتقالی

از تعدادی تصویر متعلق به هر یک از گروه‌های دسته بند برای توسعه مدل استفاده شد. کل تصاویر مورد استفاده در این پژوهش برابر با ۹۵۵ تصویر از علف‌های هرز بود. ابتدا تصاویر هر یک از گروه‌های دسته‌بند به صورت تصادفی و با نسبت تقریبی ۳ به ۱ به دو زیر گروه تقسیم شدند. سپس به ازاء هر کلاس از علف‌های هرز هجده گانه، تصاویر زیر گروه بزرگتر به یک پوشه دارای نام یکسان با نام دسته‌بند متناظر منتقل شدند و همه این پوشه‌ها در پوشه دیگری تحت عنوان "train" کپی شدند (کل تصاویر اولیه پوشه train برابر با ۶۹۵ تصویر بود). روند مشابهی برای هر یک از زیر گروه‌های کوچکتر انجام شد، با این تفاوت که تمام پوشه‌های به دست آمده در پوشه دیگری تحت عنوان "test" کپی شدند (کل تصاویر اولیه پوشه test برابر با ۲۶۰ تصویر بود). همچنین برای افزایش تعداد تصاویر آموزشی به کمک رایانه از روش image augmentation در این پژوهش استفاده گردید و تعداد تصاویر آموزشی ۱۰ برابر شد. سپس پوشه‌های "train" و "test" به پوشه نهایی تحت عنوان

مناسب می‌کند. معماری مدل بر مبنای یادگیری انتقالی (TL) نظر در این پژوهش بر مبنای مدل از پیش آموزش دیده تحت برای دسته‌بندی هجده نوع از علف‌های هرز در جدول ۲ نشان عنوان EfficientNet توسعه یافته است. داده شده است. شایان ذکر است که مدل یادگیری انتقالی مورد

جدول ۲- معماری مدل یادگیری انتقالی (TL) استوار بر مدل از پیش آموزش دیده EfficientNet

Layer (type (var_name))	Input Shape	Output Shape	Param #	Trainable
EfficientNet (EfficientNet)	[32, 3, 224, 224]	[32, 18]	--	Partial
Sequential (features)	[32, 3, 224, 224]	[32, 1280, 7, 7]	--	False
└Conv2dNormActivation(0)	[32, 3, 224, 224]	[32, 32, 112, 112]	--	False
└Conv2d (0)	[32, 3, 224, 224]	[32, 32, 112, 112]	(864)	False
└BatchNorm2d (1)	[32, 32, 112, 112]	[32, 32, 112, 112]	(64)	False
└SiLU (2)	[32, 32, 112, 112]	[32, 32, 112, 112]	--	--
└Sequential (1)	[32, 32, 112, 112]	[32, 16, 112, 112]	--	False
└MBConv (0)	[32, 32, 112, 112]	[32, 16, 112, 112]	(1,448)	False
└Sequential (2)	[32, 16, 112, 112]	[32, 24, 56, 56]	--	False
└MBConv (0)	[32, 16, 112, 112]	[32, 24, 56, 56]	(6,004)	False
└MBConv (1)	[32, 24, 56, 56]	[32, 24, 56, 56]	(10,710)	False
└Sequential (3)	[32, 24, 56, 56]	[32, 40, 28, 28]	--	False
└MBConv (0)	[32, 24, 56, 56]	[32, 40, 28, 28]	(15,350)	False
└MBConv (1)	[32, 40, 28, 28]	[32, 40, 28, 28]	(31,290)	False
└Sequential (4)	[32, 40, 28, 28]	[32, 80, 14, 14]	--	False
└MBConv (0)	[32, 40, 28, 28]	[32, 80, 14, 14]	(37,130)	False
└MBConv (1)	[32, 80, 14, 14]	[32, 80, 14, 14]	(102,900)	False
└MBConv (2)	[32, 80, 14, 14]	[32, 80, 14, 14]	(102,900)	False
└Sequential (5)	[32, 80, 14, 14]	[32, 112, 14, 14]	--	False
└MBConv (0)	[32, 80, 14, 14]	[32, 112, 14, 14]	(126,004)	False
└MBConv (1)	[32, 112, 14, 14]	[32, 112, 14, 14]	(208,572)	False
└MBConv (2)	[32, 112, 14, 14]	[32, 112, 14, 14]	(208,572)	False
└Sequential (6)	[32, 112, 14, 14]	[32, 192, 7, 7]	--	False
└MBConv (0)	[32, 112, 14, 14]	[32, 192, 7, 7]	(262,492)	False
└MBConv (1)	[32, 192, 7, 7]	[32, 192, 7, 7]	(587,952)	False
└MBConv (2)	[32, 192, 7, 7]	[32, 192, 7, 7]	(587,952)	False
└MBConv (3)	[32, 192, 7, 7]	[32, 192, 7, 7]	(587,952)	False
└Sequential (7)	[32, 192, 7, 7]	[32, 320, 7, 7]	--	False
└MBConv (0)	[32, 192, 7, 7]	[32, 320, 7, 7]	(717,232)	False
└Conv2dNormActivation(8)	[32, 320, 7, 7]	[32, 1280, 7, 7]	--	False
└Conv2d (0)	[32, 320, 7, 7]	[32, 1280, 7, 7]	(409,600)	False
└BatchNorm2d (1)	[32, 1280, 7, 7]	[32, 1280, 7, 7]	(2,560)	False
└SiLU (2)	[32, 1280, 7, 7]	[32, 1280, 7, 7]	--	--
└AdaptiveAvgPool2d (avgpool)	[32, 1280, 7, 7]	[32, 1280, 1, 1]	--	--
└Sequential (classifier)	[32, 1280]	[32, 18]	--	True
└Dropout (0)	[32, 1280]	[32, 1280]	--	--
└Linear (1)	[32, 1280]	[32, 18]	23,058	True

=====
 Total params: 4,030,606
 Trainable params: 23,058
 Non-trainable params: 4,007,548
 Total mult-adds (Units.GIGABYTES): 12.31
 =====
 Input size (MB): 19.27
 Forward/backward pass size (MB): 3452.10
 Params size (MB): 16.12
 Estimated Total Size (MB): 3487.49
 =====

در بخش دسته‌بند [Sequential (classifier)] قابل تغییر هستند. این کار باعث کاهش قابل توجه در زمان مورد نیاز برای آموزش مدل می‌شود. از نظر عددی، تعداد پارامترهای قابل آموزش از ۴۰۳۰۶۰۶ پارامتر مربوط به مدل EfficientNet به ۲۳۰۵۸ پارامتر مربوط به مدل بر مبنای مفهوم یادگیری انتقالی (TL)

همانطور که مشاهده می‌شود، پارامترهای قرار گرفته در بخش استخراج ویژگی‌ها [Sequential (features)] در طول فرآیند آموزش مدل امکان تغییر ندارند و به اصطلاح این پارامترها freeze شده‌اند (قابلیت آموزش پارامترهای بخش استخراج ویژگی‌ها False لحاظ شده است)، و فقط پارامترهای قرار گرفته

کاهش یافته است. این ویژگی مدل TL باعث می‌شود که امکان اجرای این مدل روی رایانه مجهز به CPU معمولی در زمان منطقی ایجاد شود.

مقادیر پارامترهای مدل TL که توسط کاربر باید مقدار آن تنظیم شود در جدول ۳ آورده شده است:

جدول ۳- مقادیر پارامترهای تعیین شده برای مدل TL

مقدار	نام فارسی	نام انگلیسی
۲۵	تعداد دوره‌های آموزش	Training epoch
۳۲	تعداد تصاویر مربوط به گروه‌های تصویری استفاده شده در آموزش	Batch size
Adam	تابع بهینه‌ساز	optimizer
0/001	نرخ یادگیری	Learning rate
CrossEntropy	تابع هزینه	Loss function

متعلق به یک دسته خاص علف هرز است که مدل آن‌ها را به اشتباه متعلق به دسته‌های دیگر پیش بینی کرده است. در واقع مخرج کسر تعداد تصاویری که به طور واقعی متعلق به آن دسته خاص علف هرز هستند را می‌رساند و صورت کسر تعداد تصاویر درست پیش بینی شده متعلق به آن دسته خاص از علف هرز را مشخص می‌کند.

۳-۳- اختصاصیت Specificity

این معیار قابلیت مدل در شناسایی نمونه‌های منفی صحیح هر گروه دسته‌بند را می‌رساند. به زبان ریاضی اختصاصیت با استفاده از فرمول $Specificity = \frac{TN}{TN+FP} \times 100$ محاسبه می‌شود، جاییکه TN تعداد نمونه‌هایی است که به طور صحیح، منفی پیش بینی شده‌اند و FP تعداد نمونه‌هایی است که به اشتباه، مثبت پیش بینی شده‌اند.

به بیان دیگر اگر دسته خاصی از علف‌های هرز در نظر گرفته شود، TN تعداد تصاویر متعلق به سایر دسته‌های علف هرز است که مدل هم آن‌ها را متعلق به آن دسته خاص پیش بینی نکرده است و FP تعداد تصاویر متعلق به سایر دسته‌های علف

۳-۳- معیارهای ارزیابی مدل

۳-۱- زمان آموزش مدل

به طور کلی مدل دارای زمان آموزش کم از مدل دارای زمان آموزش زیاد بهتر است. بنابراین زمان آموزش به عنوان یکی از معیارهای ارزیابی لحاظ شد. اهمیت مقدار زمان آموزش در مدل‌های یادگیری عمیق در حال اجرا روی رایانه‌های مجهز به CPU معمولی به جای GPU بالاتر می‌رود.

۳-۲- حساسیت (Recall) Sensitivity

این معیار توانایی مدل در شناسایی نمونه‌های مثبت صحیح را می‌رساند. به زبان ریاضی حساسیت با استفاده از فرمول زیر محاسبه می‌شود:

$$Sensitivity (Recall) = \frac{TP}{TP+FN} \times 100$$

جایی که TP تعداد نمونه‌هایی است که به طور صحیح، مثبت پیش بینی شده‌اند و FN تعداد نمونه‌هایی است که به اشتباه، منفی پیش بینی شده‌اند. به بیان دیگر TP تعداد تصاویر متعلق به یک دسته خاص علف هرز است که مدل هم آن‌ها را متعلق به آن دسته خاص پیش بینی کرده است و FN تعداد تصاویر

صحت محاسبه شده برحسب عدد دوره رسم می‌شوند. نمودار به‌دست آمده برای اطمینان یافتن از کفایت تعداد دوره‌های آموزشی به کار می‌رود.

۳-۷- ماتریس در هم ریختگی Confusion matrix

برای به‌دست آمدن شناخت کاملی از تعداد پیش‌بینی‌های غلط مدل و اینکه گروه صحیح با کدام گروه‌ها قاتی شده‌است، از ماتریس در هم ریختگی استفاده می‌شود. در این مطالعه یک ماتریس در هم ریختگی 18×18 برای مشخص شدن مکان پیش‌بینی‌های غلط هجده نوع علف هرز مورد مطالعه در این پژوهش توسعه یافته است. در یک ماتریس در هم ریختگی، هر چه تمرکز مقادیر بزرگ روی قطر اصلی ماتریس بیشتر باشد (یعنی مقادیر صفر و کوچک بیشتری در سایر سلول‌های ماتریس باشد) بهتر است (Vidyarthi et al., (2021)).

نتایج و بحث

۱- زمان آموزش مدل:

زمان کل مصرف شده برای آموزش مدل 24440 ثانیه (حدود 7 ساعت) شد. از آنجا که مدل روی رایانه‌ای که مجهز به CPU معمولی بود آموزش داده شده است، این مقدار زمان هر چند زیاد است اما منطقی بوده و در صورت استفاده از رایانه مجهز به GPU برای آموزش مدل، این زمان به مقدار قابل توجهی کاهش می‌یابد.

۲- صحت مدل برحسب شماره دوره:

شکل ۱ مقادیر صحت و تابع هزینه به دست آمده در طول فرآیندهای آموزش و آزمون مدل برحسب شماره دوره را نشان می‌دهد:

هرز است که مدل آن‌ها را به اشتباه متعلق به آن دسته خاص پیش‌بینی کرده است. در واقع مخرج کسر تعداد تصاویری که به طور واقعی متعلق به آن دسته خاص علف هرز نیستند را می‌رساند و صورت کسر تعداد تصاویری را نشان می‌دهد که عدم تعلق آن‌ها به آن دسته خاص علف هرز به طور صحیح پیش‌بینی شده است.

۳-۴- دقت Precision


این معیار نسبت تعداد نمونه‌هایی که به طور صحیح مثبت پیش‌بینی شده‌اند به تعداد کل نمونه‌هایی که مثبت پیش‌بینی شده‌اند را مشخص می‌کند. به زبان ریاضی دقت با استفاده از فرمول زیر محاسبه می‌شود: $Precision = \frac{TP}{TP+FP} \times 100$.

۳-۵- نمره F1 یا F1 score

میانگین هارمونیک حساسیت و دقت به محاسبه نمره F1 می‌انجامد. به بیان ریاضی داریم: $F1\ score = \frac{2 \times Precision \times Recall}{Precision+Recall} \times 100$. هر گاه یکی از مقادیر حساسیت و یا دقت صفر باشند، نمره F1 صفر می‌شود که بد بودن مدل را به خوبی نشان می‌دهد، درحالی‌که میانگین حسابی این دو پارامتر عددی بزرگتر از صفر خواهد شد.

۳-۶- صحت Accuracy

این معیار با محاسبه نسبت تعداد نمونه‌های به طور صحیح پیش‌بینی شده توسط مدل به تعداد کل پیش‌بینی‌ها به‌دست می‌آید. به بیان ریاضی داریم: $Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100$. در طول فرآیند آموزش، این پارامتر پس از هر دوره آموزش (epoch) محاسبه می‌شود (در این مطالعه تعداد دوره‌های آموزش 25 دوره در نظر گرفته شد)، سپس مقادیر



شکل ۱- مقادیر صحت و تابع هزینه فرآیندهای آموزش و آزمون بر حسب شماره دوره

فاصله بین صحت‌های بخش آموزش و آزمون در شماره دوره‌های بالای ۱۵ کم شده، در نتیجه برای مدل وضعیت بیش برآزشی و کم برآزشی پیش نیامده است.
۳- ماتریس درهم ریختگی برای نمونه‌های آزمون:
شکل ۲ ماتریس درهم ریختگی به دست آمده از ۲۶۰ تصویر متعلق به مجموعه داده‌ای آزمون را نشان می‌دهد:

اولین نکته‌ای که از شکل ۱ به دست می‌آید این است که در شماره دوره بیش از ۱۵، نوسان‌های مقادیر صحت و تابع هزینه در حد ۱۰٪ بوده و صحت مدل در بخش آزمون به بیش از ۸۰٪ رسیده است، در نتیجه مدل خوب آموزش دیده است و افزایش شماره دوره به بیش از ۲۵ باعث افزایش چشمگیر صحت بخش آزمون نخواهد شد. از طرف دیگر از آنجا که

True Class \ Predicted Class	Bromus_danthoniae_Trin	Capsella_bursa_pastoris_(L)	Cardaria_draba_(L)_Desv	Cirsium_arvense_(L)_Scop	Convolvulus_arvensis_L	Galium_tricomutum	Glycyrrhiza_glabra	Lactuca_spp	Matricaria_chamomilla	Melilotus_officinalis	Polygonum_persicaria_L	Scorpiurus_muricatus_L	Silybum_marianum_(L)_Gaertn	Sinapis_arvensis	Sorghum_halepense_(L)_Pers	Tragopogon_major	Vaccaria_hispanica	Vicia_hyrcanica
Bromus_danthoniae_Trin	13	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0
Capsella_bursa_pastoris_(L)	0	4	1	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0
Cardaria_draba_(L)_Desv	0	0	7	0	0	0	0	0	0	2	0	1	0	0	0	0	0	0
Cirsium_arvense_(L)_Scop	0	0	0	6	1	0	0	0	0	0	0	0	0	0	0	0	0	0
Convolvulus_arvensis_L	0	0	0	0	10	0	1	1	0	0	0	0	0	0	0	0	0	0
Galium_tricomutum	0	0	0	0	0	1	0	6	0	0	1	0	0	0	0	0	0	0
Glycyrrhiza_glabra	0	0	0	0	0	0	0	0	10	0	0	0	1	0	1	0	0	0
Lactuca_spp	0	1	0	0	0	0	0	0	0	4	0	0	0	0	0	0	1	0
Matricaria_chamomilla	0	0	0	0	0	0	0	0	0	0	15	0	0	0	0	0	0	0
Melilotus_officinalis	0	0	1	0	0	0	0	0	0	0	0	14	0	0	0	1	0	0
Polygonum_persicaria_L	0	2	0	0	0	0	0	0	0	0	0	0	15	0	0	0	0	0
Scorpiurus_muricatus_L	0	0	0	0	0	0	0	0	0	0	0	0	0	15	0	0	1	0
Silybum_marianum_(L)_Gaertn	0	0	0	0	0	1	0	0	0	0	0	0	0	0	20	0	0	0
Sinapis_arvensis	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	24	0	1
Sorghum_halepense_(L)_Pers	3	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	16	0
Tragopogon_major	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	17	0
Vaccaria_hispanica	0	0	0	0	0	1	0	0	0	0	1	0	0	0	1	0	0	13
Vicia_hyrcanica	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	2	14

شکل ۲- ماتریس درهم ریختگی به دست آمده در این مطالعه

نیز به راحتی به کمک این ماتریس قابل محاسبه است. در هر ردیف از ماتریس، مجموع اعداد سلول‌ها به جز سلول قرار گرفته در قطر اصلی ماتریس، تعداد تصاویر FN متعلق به گروه دسته‌بند متناظر را نشان می‌دهد. همچنین در هر ستون از ماتریس، مجموع اعداد سلول‌ها به جز سلول قرار گرفته در قطر اصلی ماتریس، تعداد تصاویر FP متعلق به گروه دسته‌بند متناظر را نشان می‌دهد و در نهایت تعداد تصاویر TN مربوط به هر گروه از گروه‌های دسته‌بند از رابطه زیر محاسبه می‌شود:

$$TN = 260 - (TP + FN + FP)$$

جدول ۴ مقادیر TP، TN، FP و FN هر گروه از گروه‌های دسته‌بند علف‌های هرز مورد توجه در این پژوهش را نشان می‌دهد:

در این شکل ماتریس برچسب‌های واقعی در برابر برچسب‌های پیش‌بینی شده توسط مدل برای تصاویر آزمون نشان داده شده است و اعداد موجود در سلول‌های ماتریس بیانگر تعداد تصاویر متعلق به هر ترکیب از برچسب‌هاست. همانطور که مشاهده می‌شود اعداد ثبت شده در سلول‌های قرار گرفته در قطر اصلی این ماتریس بزرگتر از اعداد ثبت شده در سایر سلول‌های ماتریس است. اعداد موجود در سلول‌های قطر اصلی ماتریس، تعداد تصاویر متعلق به مجموعه داده‌ای آزمون مربوط به هر یک از گروه‌های دسته‌بند را نشان می‌دهد که مدل، برچسب آن‌ها را به درستی مثبت پیش‌بینی کرده است. به بیان دیگر این مقادیر تعداد تصاویر TP مربوط به هر گروه از گروه‌های هجده گانه علف‌های هرز را نشان می‌دهد. تعداد تصاویر FP و FN و TN متعلق به هر یک از گروه‌های دسته‌بند

جدول ۴- اطلاعات مفیدی که از ماتریس درهم ریختگی قابل استخراج است

نام گروه دسته بند	TN	FP	FN	TP
برموس	۲۴۱	۴	۲	۱۳
کیسه کشیش	۲۵۰	۳	۳	۴
ازمک	۲۴۸	۲	۳	۷
کنگر صحرايي	۲۵۱	۲	۱	۶
پیچک صحرايي	۲۴۶	۲	۲	۱۰
شیر پنیر	۲۴۸	۴	۲	۶
شیرین بیان	۲۴۶	۱	۳	۱۰
کاهوک وحشی	۲۵۳	۱	۲	۴
بابونه	۲۴۴	۳	۰	۱۳
یونجه زرد	۲۴۱	۳	۲	۱۴
هفت بند	۲۴۰	۳	۲	۱۵
دم عقربی	۲۴۲	۱	۲	۱۵
خار مریم	۲۳۸	۱	۱	۲۰
خردل وحشی	۲۳۲	۴	۳	۲۱
قیاق	۲۳۵	۵	۴	۱۶
شنگ	۲۳۹	۰	۴	۱۷
جغجغک	۲۴۱	۳	۳	۱۳
ماشک گل زرد	۲۴۳	۰	۳	۱۴

۴- محاسبه حساسیت، اختصاصیت، دقت، نمره F1 و صحت یافته در این پژوهش استفاده شد. جدول ۵ مقادیر معیارهای مدل: ذکر شده برای هر یک از گروه‌های دسته‌بند را نشان می‌دهد:

مقادیر نشان داده شده در جدول ۴ برای محاسبه معیارهای حساسیت، اختصاصیت، دقت، نمره F1 و صحت مدل توسعه

جدول ۵- مقادیر حساسیت، اختصاصیت، دقت و نمره F1 محاسبه شده برای گروه‌های دسته‌بند (درصد)

گروه دسته بند	حساسیت	اختصاصیت	دقت	نمره F1
برموس	۸۷	۹۸	۷۶	۸۱
کیسه کشیش	۵۷	۹۹	۵۷	۵۷
ازمک	۷۰	۹۹	۷۸	۷۴
کنگر صحرایی	۸۶	۹۹	۷۵	۸۰
پیچک صحرایی	۸۳	۹۹	۸۳	۸۳
شیر پنیر	۷۵	۹۸	۶۰	۶۷
شیرین بیان	۷۷	۱۰۰	۹۱	۸۳
کاهوک وحشی	۶۷	۱۰۰	۸۰	۷۳
بابونه	۱۰۰	۹۹	۸۱	۹۰
یونجه زرد	۸۸	۹۹	۸۲	۸۵
هفت بند	۸۸	۹۹	۸۳	۸۶
دم عقربی	۸۸	۱۰۰	۹۴	۹۱
خار مریم	۹۵	۱۰۰	۹۵	۹۵
خردل وحشی	۸۸	۹۸	۸۴	۸۶
قیاق	۸۰	۹۸	۷۶	۷۸
شنگ	۸۱	۱۰۰	۱۰۰	۸۹
جفجفک	۸۱	۹۹	۸۱	۸۱
ماشک گل	۱۰۰	۱۰۰	۹۰	۸۲
زرد				

مقادیر معیارهای نشان داده شده در جدول ۵ برای هر کدام از ۱۸ گروه علف‌های هرز غالب ایران محاسبه شده است. برای محاسبه معیارهای نظیر مربوط به مدل، می‌توان از میانگین‌گیری معمولی و یا وزن دار استفاده کرد. جدول ۶ مقادیر معیارهای

جدول ۶- مقادیر معیارهای ارزیابی محاسبه شده برای مدل با میانگین‌گیری معمولی و وزن‌دار

روش محاسبه	حساسیت	اختصاصیت	دقت	نمره F1
معمولی	۸۱	۹۹	۸۲	۸۱
وزن‌دار	۸۴	۹۹	۸۴	۸۳

$$\text{accuracy} = \frac{\sum_{i=1}^{10} (TP_i)}{\sum_{i=1}^{10} (TP_i + FP_i)} = \frac{218}{260} = 84$$

صحت مدل با استفاده از فرمول زیر به دست آمد:

احمدی و توسلی: پیاده‌سازی یک مدل یادگیری انتقالی برای دسته‌بندی تصاویر..... ۱۰

برای ارزیابی عملکرد مدل به صورت دیداری، پیش‌بینی‌های روی ۲۷ تصویر انتخاب شده به صورت تصادفی از مجموعه مدل روی تعدادی از تصاویر علف‌های هرز گروه‌های مختلف دسته‌بند مورد توجه قرار گرفت. شکل ۳ پیش‌بینی‌های مدل

Pred: Bromus_danthoniae_Trin | Prob: 0.942 |
RPD: data\iran_weeds\test\Bromus_danthoniae_Trin



Pred: Bromus_danthoniae_Trin | Prob: 0.960 |
RPD: data\iran_weeds\test\Bromus_danthoniae_Trin



Pred: Convolvulus_arvensis_L | Prob: 0.723 |
RPD: data\iran_weeds\test\Convolvulus_arvensis_L



Pred: Vicia_hircanica | Prob: 0.453 |
RPD: data\iran_weeds\test\Convolvulus_arvensis_L



Pred: Capsella_bursa_pastoris_(L.) | Prob: 0.994 |
RPD: data\iran_weeds\test\Galium_tricornutum



Pred: Galium_tricornutum | Prob: 0.746 |
RPD: data\iran_weeds\test\Galium_tricornutum



Pred: Glycyrrhiza_glabra | Prob: 0.611 |
RPD: data\iran_weeds\test\Glycyrrhiza_glabra



Pred: Glycyrrhiza_glabra | Prob: 0.997 |
RPD: data\iran_weeds\test\Glycyrrhiza_glabra



Pred: Polygonum_persicaria_L | Prob: 0.494 |
RPD: data\iran_weeds\test\Lactuca_spp



Pred: *Lactuca_spp* | Prob: 0.206 |
RPD: data\iran_weeds\test\Lactuca_spp



Pred: *Matricaria_chamomilla* | Prob: 0.999 |
RPD: data\iran_weeds\test\Matricaria_chamomilla



Pred: *Matricaria_chamomilla* | Prob: 0.999 |
RPD: data\iran_weeds\test\Matricaria_chamomilla



Pred: *Melilotus_officinalis* | Prob: 0.999 |
RPD: data\iran_weeds\test\Melilotus_officinalis



Pred: *Sinapis_arvensis* | Prob: 0.740 |
RPD: data\iran_weeds\test\Melilotus_officinalis



Pred: *Polygonum_persicaria_L* | Prob: 0.976 |
RPD: data\iran_weeds\test\Polygonum_persicaria_L



Pred: *Glycyrrhiza_glabra* | Prob: 0.707 |
RPD: data\iran_weeds\test\Polygonum_persicaria_L



Pred: *Scorpiurus_muricatus_L* | Prob: 0.855 |
RPD: data\iran_weeds\test\Scorpiurus_muricatus_L



Pred: *Scorpiurus_muricatus_L* | Prob: 1.000 |
RPD: data\iran_weeds\test\Scorpiurus_muricatus_L



Pred: *Scorpiurus_muricatus_L* | Prob: 0.336 |
RPD: data\iran_weeds\test\Sinapis_arvensis



Pred: *Sinapis_arvensis* | Prob: 0.958 |
RPD: data\iran_weeds\test\Sinapis_arvensis



Pred: *Tragopogon_major* | Prob: 0.929 |
RPD: data\iran_weeds\test\Tragopogon_major



احمدی و توسلی: پیاده‌سازی یک مدل یادگیری انتقالی برای دسته‌بندی تصاویر..... ۱۲

Pred: *Tragopogon major* | Prob: 0.995 |
RPD: data\iran_weeds\test\Tragopogon_major



Pred: *Cirsium arvense* (L.) Scop | Prob: 0.724 |
RPD: data\iran_weeds\test\Vaccaria_hispanica



Pred: *Vaccaria hispanica* | Prob: 0.949 |
RPD: data\iran_weeds\test\Vaccaria_hispanica



Pred: *Vicia hircanica* | Prob: 0.997 |
RPD: data\iran_weeds\test\Vicia_hircanica



Pred: *Vicia hircanica* | Prob: 0.981 |
RPD: data\iran_weeds\test\Vicia_hircanica



Pred: *Melilotus officinalis* | Prob: 0.440 |
RPD: data\iran_weeds\test\Vicia_hircanica



شکل ۳- پیش‌بینی‌های مدل روی تعدادی از تصاویر علف‌های هرز گرفته شده از مجموعه داده‌ای آزمون

تصاویری است که به مزرعه خاصی تعلق ندارند، متفاوت است.

از طرف دیگر (Li & Chen, 2025) برای تشخیص علفهای هرز از الگوریتم YoloV3 و (Pai et al., 2024) از الگوریتم YoloV5 استفاده کرده‌اند که هر دو در زمره الگوریتمهای R-CNN قرار دارند که با روش یادگیری انتقالی به کار رفته در این پژوهش که استوار بر الگوریتم CNN است، متفاوت است. دلیل به کارگیری روش یادگیری انتقالی در این پژوهش نیز به عدم دسترسی به منابع سخت‌افزاری بروز (رایانه مجهز به GPU) برمی‌گردد. طبیعی است که استفاده از نرم‌افزارهای بروز قابل نصب روی رایانه مجهز به GPU، بالا رفتن صحت مدل در تشخیص علفهای هرز را به دنبال خواهد داشت.

از سوی دیگر در پژوهش (Gopalakrishnan et al., 2025) تعداد تصاویر به کار رفته در آموزش مدل ۷۸۸۳ تصویر بوده است که به مراتب بیشتر از ۹۵۵ تصویر به کار رفته در این پژوهش است که با روش افزایش نرم‌افزاری تصاویر (image augmentation) تعداد آنها به ۶۹۵۰ تصویر رسانده شد. (Hasan et al., 2023) نیز به عنوان یک نتیجه‌گیری از پژوهش خود به ایجاد یک پایگاه داده‌ای مرجع قوی برای انجام پژوهشهای تشخیص و دسته‌بندی علفهای هرز تأکید داشته‌اند.

شاید دلیل کم بودن مقدار معیارهای ارزیابی به دست آمده در مورد گیاهان شیرینیر و کیسه کشیش که بترتیب نمره F1 برابر با ۰.۵۷ و ۰.۶۷ داشته‌اند هم به کم بودن تعداد تصاویر متعلق به این دو دسته علف هرز برگردد که در مورد پایگاه داده‌ای آزمون بترتیب فقط دارای ۸ و ۷ تصویر بوده‌اند. اگر تعداد تصاویر بیشتری در توسعه مدل در اختیار بود، شاید مقدار

سه واژه مخفف در بالای هر تصویر وجود دارد که عبارتند از Pred، Prob، RPD. مخفف Prediction است و گروه پیش‌بینی شده مربوط به آن تصویر را نشان می‌دهد. RPD مخفف Real Parent Directory است و دسته صحیحی که آن تصویر به آن متعلق است را مشخص می‌کند. Prob مخفف Probability است و مقدار احتمالی را نشان می‌دهد که با آن احتمال، تصویر مورد نظر به گروه پیش‌بینی شده نسبت داده می‌شود. به بیان دیگر، الگوریتم دسته‌بند هجده احتمال را برای هر تصویر محاسبه می‌کند که این احتمالات تعلق آن تصویر به هر کدام از هجده دسته از علفهای هرز را نشان می‌دهد و دسته دارای بزرگترین احتمال را به عنوان دسته پیش‌بینی شده برای آن تصویر بر می‌گرداند.

همانطور که دیده می‌شود ۸ تصویر از ۲۷ تصویر موجود در شکل ۳ به طور اشتباه پیش‌بینی شده است، در نتیجه نرخ خطا ۲۹٪ (یعنی نرخ صحت ۷۱٪) است. با در نظر گرفتن همه ۲۶۰ تصویر پایگاه داده‌ای آزمون، صحت مدل همان مقدار به دست آمده یعنی ۸۴٪ خواهد شد.

در مقام مقایسه، صحت‌های به دست آمده در پژوهش‌های (Li & Chen, 2025) و (Pai et al., 2024) بترتیب برابر با ۹۷/۷٪ و ۹۶/۱٪ بوده است که نسبت به صحت به دست آمده در پژوهش حاضر یعنی ۸۴٪ برتری قابل ملاحظه دارد. دلیل این تفاوت ممکن است وابسته به علل زیر باشد:

در پژوهش (Li & Chen, 2025) تشخیص علفهای هرز از مزارع فلفل دلمه‌ای و در پژوهش (Pai et al., 2024) تشخیص علفهای هرز در مزارع سویا هدف‌گذاری شده بود که با پژوهش حاضر که هدف آن اصل دسته‌بندی ۱۸ نوع علف هرز با توجه به

یادگیری انتقالی برای طبقه‌بندی برخی از تصاویر علف‌های هرز در هجده گروه علف‌های هرز استفاده شد. عملکرد مدل با استفاده از برخی معیارهای استاندارد یادگیری عمیق و همچنین ارائه پیش‌بینی‌های مدل بر روی برخی از تصاویر انتخاب شده به‌طور تصادفی از پایگاه داده‌ای آزمون ارزیابی شد. به عنوان نتیجه‌گیری می‌توان گفت در این مطالعه یک مدل یادگیری انتقالی سبک از نظر محاسباتی که روی یک مجموعه تصویری کم حجم دارای ۹۵۵ تصویر از تصاویر علف‌های هرز آموزش دیده است، برای دسته‌بندی تصاویر در هجده گروه استفاده شد. بر طبق نتایج به‌دست آمده هر چند عملکرد مدل عالی نبود، اما به‌طور نسبی قابل قبول بوده است.

نمره F1 به‌دست آمده برای این دو گیاه هم از مقدار فعلی بیشتر می‌شد.

نتیجه‌گیری

مدلی که مبتنی بر مفهوم یادگیری انتقالی است، از ضرایب یک شبکه عصبی پیچیده بسیار عمیق استفاده می‌کند، اما ضرایب بخش انتخاب ویژگی مدل را در طول فرآیند آموزش منجمد می‌کند. بنابراین، این مدل می‌تواند دقتی شبیه یک شبکه عصبی کانولوشنی بسیار عمیق را به دست آورد و در عین حال زمان آموزش مدل را به میزان قابل توجهی کاهش دهد. مدلی که مبتنی بر مفهوم یادگیری انتقالی است می‌تواند برای شناسایی و طبقه‌بندی اشیاء از تصاویر ورودی استفاده شود. در این تحقیق از مفهوم

REFERENCES

- Chen, J., Zhang, D., Sun, Y., & Nanekaran, Y. A. 2020. Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture*, 173, 105393. Available from <https://doi.org/10.1016/j.compag.2020.105393>.
- Gopalakrishnan, K., Sivaraj, R., & Vijayakumar, M. 2025. Automated weed and crop recognition and classification model using deep transfer learning with optimization algorithm. *Scientific Reports*, 15, Article 15275. <https://www.nature.com/articles/s41598-025-15275-3>
- Hasan, A. S. M. M., Laga, H., Jones, M. G. K., & Sohel, F. 2022. Weed recognition using deep learning techniques on class-imbalanced imagery. *Crop and Pasture Science*, 74(6), 628–644. <https://www.publish.csiro.au/CP/pdf/CP21626>
- Huang, Z., Su, L., Wu, J., Chen, Y. 2023. Rock Image Classification Based on EfficientNet and Triplet Attention Mechanism. *Appl. Sci.* 2023, 13, 3180. <https://doi.org/10.3390/app13053180>
- Li, X., & Chen, Z. 2025. Research on weed identification based on deep learning. *Proceedings of the 2025 ACM International Conference on Artificial Intelligence and Agriculture*, 3728820. <https://dl.acm.org/doi/epdf/10.1145/3728725.3728820>
- Ouhami, M., Es-Saady, Y., Hajji, M. E., Hafiane, A., Canals, R., & Yassa, M. E. 2020. Deep transfer learning models for tomato disease detection. In: *ICISP 2020. LNCS* (Vol. 12119, pp. 65_73).
- Pai, D. G., Kamat, R., & Balachandra, M. 2024. Deep learning techniques for weed detection in agricultural environments: A comprehensive review. *IEEE Access*, 12, 113193–113214. <https://doi.org/10.1109/ACCESS.2024.3418454>

Thenmozhi, K., & Srinivasulu Reddy, U. 2019. Crop pest classification based on deep convolutional neural network and transfer learning. *Computers and Electronics in Agriculture*, 164, 104906. Available from <https://doi.org/10.1016/j.compag.2019.104906>.

Vidyarthi, S. K., Singh, S. K., Xiao, H. W., & Tiwari, R. 2021. Deep learnt grading of almond kernels. *Journal of Food Process Engineering*, 44(4), p.e13662.