



Design and implementation of a deep learning-based intelligent system for automated identification of oak galls in the Zagros forest ecosystems of Iran

Touraj Mokhtarpour^{1*}, Ariya Mokhtarpour², Hamze Ali Shirmardi³ and Seyed Ahmad Musavi Vardanjani⁴

- 1*- Corresponding Author, Researcher, Forests and Rangelands Research Department, Chaharmahal and Bakhtiari Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Shahrekord, Iran, E-mail: mokhtarpour.touraj@gmail.com
- 2- Professional Computer Engineering, Department of Computer Engineering, National Mohajer Skills University, Isfahan, Iran
- 3- Assistant Prof., Forests and Rangelands Research Department, Chaharmahal and Bakhtiari Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Shahrekord, Iran
- 4- MSc, General Department of Natural Resources and Watershed Management of Chaharmahal and Bakhtiari Province, Natural Resources and Watershed Management Organization of Iran, Shahrekord, Iran

Received: 09.05.2025

Revised: 18.02.2026


Accepted: 23.02.2026

Abstract

Background and Objective: Oak galls are abnormal growth structures resulting from complex interactions between plants and gall-inducing agents such as insects, serving as key ecological indicators for assessing forest ecosystem health and biodiversity. The Zagros forests, as one of Iran's most important ecosystems, host dominant oak species and a wide diversity of galls, which, in addition to their ecological roles, have medicinal and industrial applications. However, high morphological diversity, phenotypic similarity among species, and complex environmental conditions pose challenges for manual identification of galls. This study aims to evaluate the YOLOv8n algorithm and develop a deep learning based intelligent system for the automatic identification of 47 oak gall species in the Zagros forests, facilitating access to this knowledge for non-specialist users.

Methodology: A dataset comprising 8,452 images of 47 oak gall species was collected from field sources and public platforms such as iNaturalist. Following preprocessing steps including standard resizing, removal of low-quality images, and data augmentation techniques such as rotation and brightness adjustment the data were converted to the YOLOv8 format and split into 70% training, 20% validation, and 10% testing sets. The YOLOv8n model was trained using transfer learning with pre-trained weights in the Google Colab environment on a Tesla T4 GPU. To prevent overfitting, a dropout rate of 0.3 and early stopping were applied over 50 epochs. Post-training, a graphical user interface (GUI) was developed using Gradio and publicly deployed via Hugging Face Spaces.

Results: The trained model achieved an average precision of 0.83, recall of 0.82, mAP@50 of 0.86, and mAP@50:95 of 0.61. Species such as *Cynips quercusfolii* (precision: 0.944) and *Andricus tomentosus* (precision: 0.940) showed the highest performance, whereas low-sample species like *Andricus malpighii* (precision: 0.583) and *Neuroterus numismalis* (mAP@50:95 = 0.39) performed poorly due to data imbalance. The confusion matrix highlighted misclassifications among morphologically similar species. The developed system is capable of detecting oak galls in field images with complex backgrounds in less



Copyright: © 2024 by the authors. This is an open access, peer-reviewed article published by Research Institute of Forests and Rangelands (<https://ijfrpr.areeo.ac.ir/>) and distributed under the terms of the Creative Commons Attribution License (<https://creativecommons.org/licenses/by/4.0/>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

than 6 milliseconds. The designed GUI enables easy use by foresters, rangers, and enthusiasts, serving as an operational tool for biodiversity monitoring and sustainable forest management. Additionally, the created local database can serve as a reference for future research on gall ecology and climate change effects.

Conclusion: This study demonstrates that lightweight deep learning models such as YOLOv8n can achieve reliable performance even under complex environmental conditions and with imbalanced datasets. The proposed system is not only technically effective but also represents a key step toward integrating artificial intelligence with natural resource conservation in Iran. This approach enhances local capacity for ecosystem monitoring and facilitates broader community participation in biodiversity protection. Furthermore, the developed system can serve as a sustainable digital infrastructure for long-term, citizen-generated data collection and support a distributed monitoring framework across the Zagros forests. Future studies are recommended to employ active learning, high-quality synthetic data generation (e.g., via Diffusion Models or GANs) to target low-sample species, and to evaluate and optimize system performance for real-world field conditions and deployment on mobile or edge devices to increase its applicability in sustainable natural resource management.

Keywords: Deep learning, oak galls, Zagros forests, automatic identification, biodiversity.

طراحی و پیاده‌سازی سیستم هوشمند مبتنی بر یادگیری عمیق برای شناسایی خودکار گال‌های بلوط در اکوسیستم‌های جنگلی زاگرس

تورج مختارپور^{۱*} , آریا مختارپور^۲، حمزه علی شیرمردی^۳ و سید احمد موسوی وردنجانی^۴

*۱- نویسنده مسئول، محقق، بخش تحقیقات جنگل و مرتع، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان چهارمحال و بختیاری، سازمان تحقیقات، آموزش و ترویج کشاورزی، شهرکرد، ایران، پست الکترونیک: mokhtarpour.touraj@gmail.com

۲- کارشناس مهندسی حرفه‌ای کامپیوتر، گروه کامپیوتر، دانشگاه ملی مهارت مهاجر، اصفهان، ایران

۳- استادیار، بخش تحقیقات جنگل و مرتع، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان چهارمحال و بختیاری، سازمان تحقیقات، آموزش و ترویج کشاورزی، شهرکرد، ایران

۴- کارشناس ارشد، اداره کل منابع طبیعی و آبخیزداری استان چهارمحال و بختیاری، سازمان منابع طبیعی و آبخیزداری کشور، شهرکرد، ایران

تاریخ پذیرش: ۱۴۰۴/۱۲/۰۴

تاریخ اصلاح نهایی: ۱۴۰۴/۱۱/۲۹


تاریخ دریافت: ۱۴۰۴/۰۲/۱۹

چکیده

سابقه و هدف: گال‌های بلوط، ساختارهای رشدکرده غیر طبیعی هستند که در نتیجه تعاملات پیچیده بین گیاه و عوامل الفاکاننده (مانند حشرات گال‌زا) پدید می‌آیند و شاخص‌های اکولوژیکی کلیدی برای ارزیابی سلامت اکوسیستم‌های جنگلی و تنوع زیستی به‌شمار می‌روند. جنگل‌های زاگرس به‌عنوان یکی از مهمترین اکوسیستم‌های ایران، میزبان گونه‌های غالب بلوط و تنوع گسترده‌ای از گال‌هاست که علاوه بر نقش اکولوژیکی، دارای کاربردهای دارویی و صنعتی نیز هستند. با این حال، تنوع مورفولوژیکی بالا، شباهت ظاهری بین گونه‌ها و شرایط پیچیده محیطی، شناسایی دستی گال‌ها را با چالش مواجه کرده است. هدف این پژوهش، بررسی قابلیت‌های الگوریتم YOLOv8n همراه با طراحی و پیاده‌سازی یک سیستم هوشمند مبتنی بر یادگیری عمیق برای شناسایی خودکار ۴۷ گونه گال بلوط در جنگل‌های زاگرس و تسهیل دسترسی به این دانش برای کاربران غیرمتخصص است.

مواد و روش‌ها: مجموعه داده‌ای شامل ۸۴۵۲ تصویر از ۴۷ گونه گال بلوط از منابع میدانی و پلتفرم‌های عمومی مانند iNaturalist جمع‌آوری شد. پس از مراحل پیش‌پردازش شامل تغییر اندازه استاندارد، حذف تصاویر کم‌کیفیت و افزایش داده با تکنیک‌هایی مانند چرخش و تغییر روشنایی، داده‌ها به فرمت YOLOv8 تبدیل و با نسبت‌های ۷۰ درصد آموزش، ۲۰ درصد اعتبارسنجی و ۱۰ درصد آزمون تقسیم‌بندی شدند. مدل YOLOv8n با بهره‌گیری از یادگیری انتقالی براساس وزن‌های پیش‌آموزش‌دیده در محیط Google Colab و با GPU Tesla T4 آموزش دید. برای جلوگیری از بیش‌برازش، از Dropout نرخ ۰/۳ و Early Stopping، ۵۰ دوره استفاده شد. پس از آموزش، یک رابط کاربری گرافیکی مبتنی بر Gradio توسعه یافت و از طریق Hugging Face Spaces عمومی منتشر گردید.

نتایج و یافته‌ها: مدل آموزش‌دیده به‌طور میانگین دقت (Precision=0.83)، بازیابی (Recall=0.82)، mAP@50 برابر ۰/۸۶ و mAP@50:95 برابر ۰/۶۱ را کسب کرد. گونه‌هایی مانند *Cynips quercusfoli* دقت: ۰/۹۴۴ و *Andricus tomentosus* بادقت: ۰/۹۴۰ بالاترین عملکرد را نشان دادند، درحالی‌که گونه‌های کم‌نمونه مانند *Andricus malpighii* بادقت: ۰/۵۸۳ و mAP@50:95 = 0.39) *Neuroterus numismalis* به‌دلیل نامتوازن بودن داده‌ها عملکرد ضعیف‌تری داشتند. ماتریس سردرگمی نیز اشتباهات طبقه‌بندی بین گونه‌های مشابه را آشکار کرد. سیستم توسعه‌یافته قادر است در کمتر از ۶ میلی‌ثانیه، گال‌های بلوط را در تصاویر میدانی با پس‌زمینه‌های پیچیده شناسایی کند. رابط کاربری طراحی شده امکان استفاده آسان توسط جنگلبانان، محیط‌بانان و علاقه‌مندان را فراهم می‌کند و به‌عنوان ابزاری عملیاتی برای پایش تنوع زیستی و مدیریت پایدار جنگل‌ها عمل می‌نماید. همچنین، پایگاه داده بومی ایجادشده می‌تواند به‌عنوان مرجعی برای تحقیقات آینده در حوزه اکولوژی



گال‌ها و تغییرات جمعیتی مورد استفاده قرار گیرد.

نتیجه‌گیری: این پژوهش نشان می‌دهد که مدل‌های سبک‌وزن یادگیری عمیق مانند YOLOv8n می‌توانند حتی در شرایط پیچیده محیطی و با داده‌های نامتوازن، عملکردی قابل‌اطمینان داشته باشند. این سیستم نه تنها از نظر فنی مؤثر است، بلکه با همگانی‌سازی دانش زیستی، گامی کلیدی در جهت ادغام فناوری‌های هوش مصنوعی با حفاظت از منابع طبیعی در ایران برداشته است. این رویکرد، ظرفیت‌های محلی را در پایش اکوسیستم‌ها تقویت کرده و امکان مشارکت گسترده‌تر جامعه در حفاظت از تنوع زیستی را فراهم می‌کند. علاوه بر این، سیستم توسعه‌یافته به‌عنوان یک زیرساخت دیجیتال پایدار می‌تواند در بلندمدت به‌عنوان بستر برای جمع‌آوری داده‌های مشاهداتی از سوی کاربران میدانی عمل کند و به ایجاد یک سامانه پایش توزیع‌شده در سطح جنگل‌های زاگرس کمک نماید. بنابراین، پیشنهاد می‌شود در مطالعات آینده از روش‌های یادگیری فعال و تولید داده مصنوعی با کیفیت مانند (Diffusion Models) یا (GANs) برای جمع‌آوری هدفمند داده از گونه‌های کم‌نمونه استفاده شود. همچنین، ارزیابی عملی سیستم در شرایط واقعی میدانی و بهینه‌سازی آن برای اجرا روی دستگاه‌های همراه یا لبه‌ای (Edge Devices)، می‌تواند کاربردی بودن این ابزار را در مدیریت پایدار منابع طبیعی افزایش دهد.

واژه‌های کلیدی: یادگیری عمیق، گال بلوط، جنگل‌های زاگرس، شناسایی خودکار، تنوع زیستی.

مقدمه

گال‌های بلوط، ساختارهای رشدکرده غیر طبیعی در بافت گیاه هستند که در پاسخ به فعالیت‌های فیزیولوژیکی و شیمیایی حشرات، کنه‌ها یا سایر عوامل محرک تشکیل می‌شوند. این ساختارها حاصل تعامل پیچیده‌ای بین گیاه و عامل گال‌زا هستند و معمولاً با تغییر در تقسیم و تمایز سلولی بافت‌های گیاهی همراه هستند. گال‌های بلوط نه تنها به‌عنوان سازوکارهای دفاعی و واکنش‌های فیزیولوژیکی گیاه در برابر عوامل خارجی عمل می‌کنند، بلکه شاخص‌های ارزشمندی برای ارزیابی تنوع زیستی، سلامت اکوسیستم‌های جنگلی و پویایی روابط بین گونه‌های گیاهی و جانوری به‌شمار می‌آیند (Stone & Schönrogge, 2003; Ma et al., 2008; Guo et al., 2012; Ward et al., 2022; Askari et al., 2021). جنگل‌های زاگرس، میزبان گونه‌های غالب بلوط مانند *Quercus brantii* (Lindley, 1840) و *Quercus infectoria* بوده و زیستگاه اصلی این گال‌ها محسوب می‌شوند. این گال‌ها علاوه بر اهمیت اکولوژیکی به دلیل نقششان در زنجیره غذایی و تعاملات گیاه-حشره، با دارا بودن ترکیبات فعال زیستی مانند تانن‌ها، کاربردهای دارویی، صنعتی و سنتی نیز دارند (Tavakoli et al., 2008; Shourmij et al., 2022; Zamani et al., 2020).

(Azizkhani et al., 2007). بااین‌حال، تنوع

مورفولوژیکی بالا از نظر شکل، اندازه، رنگ و محل استقرار روی درخت، شناسایی دستی آنها را فرایندی زمان‌بر و چالش‌برانگیز کرده است (Ward et al., 2022). این پیچیدگی، به‌ویژه در پهنه‌های گسترده‌ای مانند زاگرس، لزوم توسعه ابزارهای نوین و خودکار برای شناسایی دقیق گال‌ها را آشکار می‌کند. هدف اصلی این پژوهش، آموزش الگوریتم (YOLOv8n) برای دستیابی به‌دقت قابل‌قبول و طراحی رابط کاربری گرافیکی برای شناسایی خودکار گال‌های بلوط ایران بر پایه تصاویر است. این سیستم با بهره‌گیری از قابلیت شبکه‌های عصبی پیچشی (CNN) در استخراج ویژگی‌های پیچیده تصویری، امکان تشخیص سریع و دقیق انواع گال‌ها را فراهم می‌کند، که می‌تواند خطاهای انسانی را کاهش داده و پایش اکوسیستم‌های جنگلی را ارتقا دهد. از اهداف فرعی این مطالعه، افزایش آگاهی جنگلبانان، کارشناسان محیط‌زیست، محیط‌بانان و متخصصان منابع طبیعی درباره اهمیت اکولوژیکی کاربردهای عملی گال‌های بلوط است. گال‌ها می‌توانند به‌عنوان شاخص‌های سلامت اکوسیستم عمل کرده و تغییرات در پراکنش آنها نشان‌دهنده تأثیرات اقلیمی یا طغیان آفات می‌باشد (Kot et al., 2019). علاوه بر این، این پژوهش با پیاده‌سازی فناوری یادگیری عمیق

برای اطمینان از کیفیت داده‌ها، تصاویر جمع‌آوری شده توسط کارشناس حشره‌شناسی تأیید شدند تا از صحت برچسب‌گذاری گونه‌ها مطمئن شویم.

پیش‌پردازش تصاویر و حذف تصاویر نامطلوب
پیش‌پردازش تصاویر برای بهبود کیفیت داده‌ها و حذف تصاویر نامطلوب انجام شد. ابتدا، تصاویر با استفاده از نرم‌افزار (OpenCV) بررسی شدند تا مواردی با وضوح پایین، نوردهی نامناسب یا وجود اشیاء مزاحم (مانند برگ‌های اضافی یا حشرات) حذف شوند. تصاویر باقی‌مانده برای یکنواختی به رزولوشن استاندارد 640×640 پیکسل تغییراندازه یافتند و به فرمت (JPEG, PNG, JPG) ذخیره شدند. تکنیک‌های افزایش داده (Data Augmentation) مانند چرخش و تغییر روشنایی اعمال گردید تا تنوع تصاویر افزایش یابد و مدل از بیش‌برازش (Overfitting) جلوگیری کند (Shorten & Khoshgoftaar, 2019). برای حذف نویز و بهبود کنتراست، از فیلترهای نرم‌افزاری مانند (Gaussian Blur) و (Equalization, Histogram) استفاده شد. درنهایت، حدود ۶/۱٪ از تصاویر را به دلیل کیفیت پایین کنار گذاشته و مجموعه داده نهایی انتخاب گردید.

ایجاد فرمت دیتاست به فرمت (YOLOv8) و ساخت فایل (data.yaml)

مجموعه داده به فرمت موردنیاز مدل (YOLOv8)، که یک الگوریتم پیشرفته تشخیص اشیاء است، آماده شد. برای این منظور، هر تصویر با استفاده از ابزار (LabelImg) حاشیه‌نویسی (Annotation) شد و مختصات کادرهای مرزی (Bounding Boxes) برای هر گال همراه با برچسب گونه مربوطه ثبت گردید. این اطلاعات در فایل‌های متنی با فرمت (txt) ذخیره شدند، که شامل مختصات نسبی مرکز کادر، عرض، ارتفاع و کلاس گال بودند. فایل پیکربندی (data.yaml) برای تعریف مسیرهای دایرکتوری‌های داده شامل (test, valid, train)

در حوزه منابع طبیعی، در صدد افزایش بهره‌وری مدیریت جنگل‌ها و هموارسازی مسیر بهره‌برداری پایدار از محصولات فرعی گال‌ها، مانند مواد دارویی و صنعتی است.

ایجاد یک پایگاه داده جامع و بومی از تصاویر گال‌های بلوط ایران از دیگر اهداف این تحقیق است که می‌تواند به‌عنوان مرجعی برای پژوهش‌های آینده و آموزش عمومی مورد استفاده قرار گیرد. این پایگاه، با ثبت ویژگی‌های ظاهری گال‌ها به همراه داده‌های مکانی و زمانی، به شناسایی الگوهای پراکنش و اثرهای محیطی کمک خواهد کرد. همچنین، تلفیق این سامانه با داده‌های اقلیمی و جغرافیایی می‌تواند امکان پیش‌بینی تغییرات توزیع گال‌ها را فراهم کرده و در برنامه‌ریزی‌های حفاظتی مؤثر باشد (Jalaeian et al., 2015). این پژوهش با تلفیق فناوری پیشرفته و دانش اکولوژیکی، گامی نوین در راستای حفاظت از جنگل‌های ایران و بهره‌برداری پایدار از منابع طبیعی برداشته است.

مواد و روش‌ها

جمع‌آوری تصاویر از گال‌های بلوط

در این پژوهش، مجموعه‌ای از ۴۷ گونه گال بلوط، به‌ویژه از گال‌های مربوط به مناطق غربی ایران استفاده گردید (Sadeghi et al., 2009; Sadeghi et al., 2014). نمونه‌ها از گونه‌های غالب بلوط مانند *Q. brantii* و *Q. infectoria* انتخاب شدند، که میزبان گال‌های متنوعی از جمله گال مازوج، *Andricus sternlichti* (Bellido, 2003) و *Aphelonyx persica* (Katilmis & Kiyak, 2008) هستند (Tavakoli et al., 2008). جمع‌آوری عکس نمونه‌ها در سال ۱۴۰۳ انجام شد و تصاویر در شرایط نوری طبیعی و با پس‌زمینه متفاوت از منابع مختلف مانند سایت (Inaturalist) انتخاب شدند تا از ایجاد نویز بصری جلوگیری شود. هرگونه گال حداقل در چندین زاویه مختلف انتخاب شد تا مجموعه داده‌ای جامع ایجاد گردد.

nc: 47

names: ['Andricus_sternlichti',

'Aphelonyx_persica', ...]


این فرایند اطمینان داد که داده‌ها به درستی برای آموزش مدل (YOLOv8n) سازمان‌دهی شده است.

ایجاد و تعداد کلاس‌ها (۴۷ گونه گال) و نام کلاس‌ها مشخص گردید (شکل ۱). این فایل ساختار زیر را دارد.

train: /dataset/train/images

val: /dataset/valid/images

test: /dataset/test/images



شکل ۱- نام و درصد کلاس‌ها در دیتاست

Figure 1. Names and percentages of classes in the dataset

آموزش مدل در محیط (Google Colab) با استفاده از پردازنده گرافیکی (NVIDIA Tesla T4) با حافظه ۱۵۰۹۵ مگابایت انجام شد. استفاده از (GPU) به تسریع قابل توجه فرایند آموزش کمک کرد، به ویژه برای پردازش حجم بالای تصاویر و محاسبات پیچیده شبکه (YOLOv8). محیط (Jupyter Notebook) در (Colab) برای اجرای کدها و مدیریت فرایند آموزش استفاده شد. مدل (YOLOv8n) نسخه نانو برای سرعت بالاتر و کاربرد بیشتر در دستگاه‌های لبه و وب به عنوان پایه انتخاب شد و با استفاده از وزن‌های از پیش آموزش‌دیده (Pre-trained Weights) روی مجموعه داده COCO، فرایند انتقال یادگیری (Transfer Learning) انجام شد. فرایند آموزش شامل نرخ یادگیری ۰/۰۰۱، اندازه دسته (Batch Size) ۱۶ و تعداد دوره‌های آموزش

تقسیم دیتاست به مجموعه‌های آموزشی، اعتبارسنجی و آزمایشی

مجموعه داده به سه بخش تقسیم شد، ۷۰٪ برای آموزش (train)، ۲۰٪ برای اعتبارسنجی (valid) و ۱۰٪ برای آزمایش (test). این تقسیم‌بندی به صورت تصادفی انجام شد تا توزیع متعادلی از گونه‌های مختلف گال در هر بخش حفظ شود. با توجه به تعداد کل ۸۴۵۲ تصویر، حدود ۵۹۱۶ تصویر برای آموزش، ۲۵۳۶ تصویر برای اعتبارسنجی و ۸۴۶ تصویر برای آزمایش تخصیص یافت. این دیتاست به مدل امکان داد تا در مرحله آموزش از داده‌های کافی برای یادگیری استفاده کند، درحالی‌که مجموعه‌های اعتبارسنجی و آزمایشی برای ارزیابی عملکرد و تعمیم‌پذیری مدل به کار رفتند.

محیط محاسباتی و آموزش مدل

۹۰ Epochs) بدست آمد (جدول ۱). برای جلوگیری از بیش‌برازش، تکنیک‌هایی مانند (Early Stopping) و Dropout) اعمال شدند. نرخ Dropout) برابر با ۰/۳ در لایه‌های تمام‌متصل (Fully Connected) تنظیم شد. این مقدار به‌گونه‌ای انتخاب گردید که از حذف بیش‌ازحد نورون‌ها جلوگیری شود و درعین حال بتواند تنوع ویژگی‌ها را در فرایند آموزش حفظ کند. اعمال Dropout) با این نرخ باعث شد مدل از یادگیری الگوهای تصادفی یا نویز در داده‌های آموزشی اجتناب کرده و ویژگی‌های پایدارتر و کلی‌تری از گال‌ها را بیاموزد. از سوی دیگر، سازوکار (Early Stopping) برای جلوگیری از ادامه بی‌فایده فرایند آموزش در صورت عدم بهبود عملکرد اعتبارسنجی استفاده شد. معیار توقف براساس تغییرات (Loss) تابع اعتبارسنجی (Validation

Loss) تعریف گردید، به‌طوری‌که اگر طی ۵۰ دوره متوالی (patience = 50) کاهش معنی‌داری در مقدار Validation Loss) مشاهده نمی‌شد، فرایند آموزش به‌صورت خودکار متوقف می‌گردید. به‌کارگیری این دو روش در کنار هم موجب شد که مدل ضمن حفظ دقت بالا، از بیش‌برازش بر روی داده‌های آموزشی جلوگیری کند و پایداری بیشتری در نتایج نهایی (mAP و Precision/Recall) داشته باشد. (Early Stopping) هرچند در این پژوهش فعال بود اما تا تکرار ۹۰ عمل نکرد، یعنی کاهش یا توقف یادگیری وجود نداشت و الگوریتم در حال یادگیری بوده، علت توقف در تکرار ۹۰ سایر فاکتورهای ارزیابی بوده که به تعادل رسیدند. شکل ۳ و ۴ روند ایجاد تعادل را نمایش می‌دهد.

جدول ۱- محیط محاسباتی و برخی از فرا پارامترها

Table 1- Computational environment and some hyperparameters

Section	Details
Versions and Execution Environment	Ultralytics 8.3.207, Python 3.12.11, PyTorch 2.8.0+cu126, CUDA 12.6
Hardware Configuration	RAM: GB15.1, GPU: Tesla T4,
Model Architecture	YOLOv8n (Nano), 129 layers, approximately 3 million parameters, 8.2 GFLOPs
Number of Classes	nc=47
Layer Structure / Network Layers	Conv, C2f, SPPF, Upsample, Concat, Detect
General Training Parameters	Epochs=90, Batch=16, Image size=640, Auto augment=randaugment, Optimizer=auto
Optimizer Configuration	momentum=0.9 ,lr=0.000196 ,AdamW
Dataset Split	Validation: 1690 ,Train: 5916

پایتون استفاده شد، ازجمله (NumPy) و (Pandas) برای مدیریت و تحلیل داده‌های عددی و جدولی مانند محاسبه

تحلیل و ارزیابی نتایج با کتابخانه‌های پایتون برای تحلیل و ارزیابی عملکرد مدل، از کتابخانه‌های

تشخیص داده شده همراه با درصد اطمینان و زمان پردازش، به صورت همزمان در رابط نمایش داده می‌شود. این رابط به صورت عمومی از طریق پلتفرم (Hugging Face Spaces) در دسترس است (نشانی: <https://huggingface.co/spaces/touraj732/gallery-detector-touraj>).

نتایج

عملکرد مدل YOLOv8 در تشخیص ۴۷ نوع گال بلوط با استفاده از معیارهای دقت (Precision)، فراخوانی (Recall)، (mAP@50) و (mAP@50-95) ارزیابی شد. نتایج نشان داد که گونه *Cynips quercusfoli* (Linneaus, 1758) با دقت = ۰/۹۴۴ و (mAP@50=0.971) و گونه *Andricus grossulariae* (Giraud, 1859) با فراخوانی = ۰/۹۷۲، (mAP@50=0.967) بالاترین عملکرد را در میان معیارهای ارزیابی مهم داشتند. در مقابل، گونه *Andricus malpighii* (Alder, 1881) با دقت = ۰/۵۳، (mAP@50-95=0.309) و گونه *N. numismalis* با فراخوانی = ۰/۶۷۶، (mAP@50-95=0.39) کمترین عملکرد را به ثبت رساندند. در نمودارهای شکل ۲ میانگین کلی دقت (۰/۸۳)، فراخوانی = ۰/۸۲، (mAP@50=0.86) و (mAP@50-95=0.61) برای کل مجموعه داده‌ها بدست آمد، و این مقادارها در کلاس‌های مختلف تغییرات قابل توجهی نشان می‌دهند. در جدول ۲ رتبه‌بندی براساس بالاترین و کمترین ارزیابی‌های انجام شده ارائه گردید. زمان پردازش تصاویر نیز بهینه بود، با میانگین ۰/۳ میلی ثانیه برای پیش پردازش، ۲/۶ میلی ثانیه برای استنتاج و ۱/۳ میلی ثانیه برای پس پردازش در هر تصویر.

معیارهای عملکرد (Matplotlib) و (Seaborn)، برای ترسیم نمودارهای بصری مانند منحنی‌های دقت و تلفات (Precision-Recall Curve) و (Loss Curve) استفاده شد. (Scikit-learn) برای محاسبه معیارهای ارزیابی مانند دقت (Accuracy)، یادآوری (Recall) و ماتریس درهم‌ریختگی (Confusion Matrix)، (Torch) و (Ultralytics) برای مدیریت مدل (YOLOv8) و اجرای پیش‌بینی‌ها، (OpenCV) برای پردازش تصاویر در مرحله ارزیابی و نمایش نتایج. نتایج آموزش و اعتبارسنجی با معیارهای (mAP@50) میانگین دقت متوسط در (IoU=0.5) و (mAP@50:95) بررسی شدند تا دقت تشخیص و تعمیم‌پذیری مدل در شناسایی صحیح گونه‌های گال در تصاویر جدید ارزیابی شود.


توسعه رابط کاربری گرافیکی


برای تسهیل دسترسی به مدل تشخیص گال‌ها و امکان تعامل کاربر با سیستم، یک رابط کاربری گرافیکی (User Interface Graphical) با استفاده از کتابخانه (Gradio نسخه ۴/۲۵/۰) توسعه داده شد. این رابط در قالب یک وب اپلیکیشن (برنامه کاربردی) طراحی گردید که در آن، کاربر قادر است تصویر دیجیتال از گال‌های بلوط را، از طریق مرورگر آپلود نماید. همچنین، یک اسلایدر برای تنظیم آستانه اطمینان (Confidence Threshold) بین ۰ تا ۱ در نظر گرفته شد تا کاربر بتواند حساسیت سیستم تشخیص را کنترل کند. پس از فعال‌سازی دکمه (Upload & Detect)، تصویر ورودی به مدل (YOLOv8) ارسال شده و خروجی شامل تصویر نشان‌دهنده جعبه‌های محدودکننده (Bounding Boxes) حول گال‌های شناسایی شده، فهرستی از گونه‌های

جدول ۲- رتبه‌بندی کلاس‌های گال بلوط براساس معیارهای ارزیابی مدل YOLOv8n

Table 2. Ranking of oak gall classes based on YOLOv8n Evaluation Metrics

Class	Precision	Recall	mAP@50	mAP@50-95	Rank
Highest rankings among evaluation factors in order (out of 47 oak gall types)					
<i>Cynips quercusfoli</i>	0.944	0.851	0.971	0.817	Top1
<i>Andricus tomentosus</i>	0.94	0.923	0.985	0.808	Top 2
<i>Cynips longiventris</i>	0.907	0.947	0.989	0.784	Top 3
<i>Andricus sternlichti</i>	0.895	0.946	0.982	0.847	Top 4
<i>Andricus grossulariae</i>	0.893	0.972	0.967	0.735	Top 5
<i>Andricus infectorius</i>	0.892	1	0.975	0.659	Top 6
Lowest ranks among evaluation factors in order (out of 47 oak gall types)					
<i>Andricus superfetationis</i>	0.746	0.561	0.617	0.444	Low7
<i>Andricus moreae</i>	0.691	0.7	0.606	0.418	Low6
<i>Andricus multiplicatus</i>	0.682	0.846	0.814	0.374	Low5
<i>Aphelonyx persica</i>	0.666	0.577	0.633	0.478	Low4
<i>Andricus curtisii</i>	0.661	0.688	0.746	0.462	Low3
<i>Neuroterus numismalis</i>	0.591	0.676	0.644	0.39	Low2
<i>Andricus malpighii</i>	0.583	0.44	0.584	0.309	Low1





شکل ۲- map@50 , map@50-90 , Recall, Precision برای تمام کلاس‌ها


Figure 2. mAP@50 , mAP@50-95 , Recall, and Precision for all classes

۰/۶ در دوره نودم رسید، که نشان‌دهنده بهبود ۲۱/۵ برای است. همچنین، mAP@50:95 از ۰/۰۲ به ۰/۰۶ در ابتدای آموزش به ۰/۶ در پایان آموزش افزایش یافت. دقت (Precision) و بازیابی (Recall) نیز به ترتیب از ۰/۲۲ و ۰/۱۱ به ۰/۳ و ۰/۸۲

روند بهبود معیارهای ارزیابی و عملکرد کلی مدل در طول ۹۰ دوره آموزشی، مدل (YOLOv8n) به‌طور قابل‌توجهی عملکرد خود را بهبود بخشید. میانگین دقت متوسط (mAP@50) از مقدار اولیه ۰/۰۴ در دوره اول به

تأیید می‌کند، به‌ویژه در شرایطی که تصاویر شامل پس‌زمینه‌های متنوع و تنوع مورفولوژیکی بالایی هستند (شکل ۳).

رسید. این روند صعودی، همگرایی مناسب مدل و عدم بیش‌برازش را نشان می‌دهد، زیرا تمام معیارها در دوره‌های انتهایی به حالت پایداری نزدیک شده‌اند. این نتایج، عملکرد قابل‌قبول مدل در تشخیص ۴۷ گونه مختلف گال بلوط را



شکل ۳- مقایسه روند معیارهای ارزیابی مدل


Figure 3. Comparison of Model Evaluation Metric Trends

تصادفی یا نویز در داده‌های آموزشی اجتناب کرده و ویژگی‌های پایدارتر و کلی‌تری از گال‌ها را بیاموزد. از سوی دیگر، سازوکار (Early Stopping) برای جلوگیری از ادامه بی‌فایده فرایند آموزش در صورت عدم بهبود عملکرد اعتبارسنجی استفاده شد. معیار توقف براساس تغییرات (Loss) تابع اعتبارسنجی (Validation Loss) تعریف گردید، به‌طوری‌که اگر طی ۵۰ دوره متوالی (patience = 50) کاهش معنی‌داری در مقدار (Validation Loss) مشاهده نمی‌شد، فرایند آموزش به‌صورت خودکار متوقف می‌گردید. به‌کارگیری این دو روش در کنار هم موجب شد که مدل ضمن حفظ دقت بالا، از بیش‌برازش بر روی داده‌های آموزشی جلوگیری کند و پایداری بیشتری در نتایج نهایی (mAP و Precision/Recall) داشته باشد. (Stopping Early) هرچند در این پژوهش فعال بود اما تا تکرار ۹۰ عمل نکرد، یعنی کاهش یادگیری و ثبات نداشتیم و الگوریتم در حال یادگیری بوده و علت توقف در تکرار ۹۰ به تعادل رسیدن مقدار دقت،

نتایج تلفات در طول آموزش

تلفات آموزشی و اعتبارسنجی (Box Loss, Cls Loss, DFL Loss) در طول آموزش کاهش یافته‌اند. برای نمونه، تلفات طبقه‌بندی (Cls Loss) در آموزش از ۴/۷۸ در دوره اول به ۰/۹۰ در دوره نودم کاهش یافت، درحالی‌که تلفات اعتبارسنجی آن از ۳/۶ به ۰/۸۴ رسید. این کاهش همزمان و همگرا در تلفات آموزشی و اعتبارسنجی، نشان‌دهنده یادگیری مؤثر و پایدار مدل است (شکل ۴). برای جلوگیری از بیش‌برازش (Overfitting) و بهبود تعمیم‌پذیری مدل (YOLOv8n)، از دو سازوکار (Early Stopping & Dropout) در فرایند آموزش استفاده شد. در این پژوهش، نرخ (Dropout) برابر با ۰/۳ در لایه‌های تمام‌متصل (Fully Connected) تنظیم شد. این مقدار به‌گونه‌ای انتخاب گردید که از حذف بیش‌ازحد نوروها جلوگیری شود و درعین حال بتواند تنوع ویژگی‌ها را در فرایند آموزش حفظ کند. اعمال (Dropout) با این نرخ باعث شد مدل از یادگیری الگوهای

بازیابی و تلفات آموزشی و اعتبارسنجی است.



شکل ۴- مقایسه روند تلفات آموزشی و اعتبارسنجی

Figure 4. Comparison of training and validation loss trends


همچنین، اختلاف قابل توجه بین $mAP@50$ و $mAP@50:95$ نشان می‌دهد که مدل در شناسایی دقیق موقعیت گال‌ها (در IoU بالاتر) با چالش‌هایی مواجه است که می‌تواند به تنوع مورفولوژیکی بالا و نامتوازن بودن داده‌های برخی گونه‌ها نسبت داده شود (شکل ۵).

نتایج تعادل دقت و بازیابی در طول آموزش

رابطه دقت و بازیابی در طول آموزش (Precision vs. Recall) نشان می‌دهد که نقاط در طول آموزش به سمت بالا و راست حرکت کرده‌اند، که نشان‌دهنده بهبود همزمان دقت و بازیابی است. نقاط با رنگ و اندازه بزرگ‌تر (نمایانگر $mAP@50$ بالاتر) عموماً در منطقه بازیابی بالا و دقت متوسط قرار دارند، که بیانگر عملکرد بهتر مدل در شناسایی بیشتر نمونه‌های مثبت است. این الگو، کارایی مدل را در شرایط واقعی جنگل‌های زاگرس، باوجود چالش‌های تنوع مورفولوژیکی و نامتوازن بودن داده‌ها، تأیید می‌کند (شکل ۶).


تغییرات معیارهای ارزیابی عملکرد مدل در طول دوره آموزشی

تحلیل عملکرد مدل در سه مرحله کلیدی آموزش (دوره ۱، ۴۵ و ۹۰) نشان‌دهنده بهبود چشمگیر و پایدار معیارهای ارزیابی است. در دوره اول آموزش، مدل با دقت ۰/۲۲ و بازیابی ۰/۱۱، همچنین $mAP@50=0.04$ و $mAP@50:95=0.02$ عملکرد ضعیفی را نشان می‌دهند که نشان‌دهنده عدم توانایی اولیه در تشخیص صحیح جعبه‌ها و طبقه‌بندی گونه‌هاست. با افزایش دوره‌ها به ۴۵ تکرار، تمام معیارها بهبود قابل توجهی یافته‌اند، دقت به ۰/۷، بازیابی به ۰/۶۶، $mAP@50$ به ۰/۷۲ و $mAP@50:95$ به ۰/۵ رسیدند که نشان‌دهنده یادگیری مؤثر و افزایش دقت تشخیص در شرایط سخت‌تر است. در نهایت، در دوره ۹۰، مدل به بالاترین سطح عملکرد خود دست یافته و مقادیر نهایی به دقت ۰/۸۳، بازیابی ۰/۸۲، $mAP@50=0.86$ و $mAP@50:95=0.6$ رسید. این روند صعودی و همگرا، نشان‌دهنده یادگیری پایدار و عدم بیش‌برازش مدل است.



شکل ۵- تغییرات معیارهای ارزیابی عملکرد مدل در طول سه دوره آموزشی (تکرار ۱، تکرار ۴۵، تکرار ۹۰)

Figure 5. Variations in model performance evaluation metrics across three training epochs: Epoch 1.0, Epoch 45.0, and Epoch 90.0.



شکل ۶- رابطه بین دقت مدل و بازیابی در بین کلاسها

Figure 6. The relationship between precision and recall across different classes.

Andricus confluens (Harris, 1841) و (Bassett, 1881) بالاست، ولی برای کلاس‌هایی مانند *Andricus aries* (Giraud, 1859) و *Andricus caputmedusae* (Hartig, 1843) پایین‌تر است و نشان‌دهنده مشکلات در تشخیص این

ماتریس سردرگمی نرمال شده در شکل ۷، عملکرد مدل را در تشخیص کلاس‌های مختلف نشان می‌دهد. مقادیر روی دیاگونال اصلی نشان‌دهنده دقت طبقه‌بندی برای هر کلاس است که برای کلاس‌هایی مانند *Andricus californicus*

کلاس‌هاست. همچنین، مقادیر خارج از دیاگنال اصلی بیانگر اشتباهات طبقه‌بندی است که نشان می‌دهد برخی کلاس‌ها به‌طور مداوم با یکدیگر اشتباه شناسایی می‌شوند، مانند *A. aries* و *A. californicus* که به راحتی در این ماتریس قابل تشخیص است.

کلاس‌هاست. همچنین، مقادیر خارج از دیاگنال اصلی بیانگر اشتباهات طبقه‌بندی است که نشان می‌دهد برخی کلاس‌ها به‌طور مداوم با یکدیگر اشتباه شناسایی می‌شوند، مانند *A.*




شکل ۷- ماتریس سردرگمی نرمال شده برای تشخیص گونه‌های گال

Figure 7. Normalized confusion matrix for the detection of gall species.

که با استفاده از الگوریتم YOLOv8n با دقت ۹۵٪ شناسایی شدند. الگوریتم توانایی بالایی در تشخیص و تفکیک گال‌های مختلف روی برگ‌ها و شاخه‌ها نشان داد، از جمله شناسایی اشکال، اندازه‌ها و رنگ‌های متنوع گال‌ها، حتی در شرایط پیچیده مانند گال‌های کوچک و متراکم (*N. numismalis*) یا گال‌هایی با ساختار خاص (*A. hystrix*).

مجموعه‌ای از تصاویر گال‌های بلوط که توسط رابط کاربری گرافیکی تشخیص داده شدند (شکل ۸)، شامل پنج نمونه گال از گونه‌های مختلف (*Synophrus politus*) (Hartig, 1843), (*Neuroterus* (Geoffroy, 1785), (*A. Andricus infectarius* (Hartig, 1843), (*numismalis* است *Andricus hystrix* (Kieffer, 1897) و *foecundatrix*




شکل ۸- مجموعه‌ای از تصاویر پردازش‌شده گال‌های بلوط از داده‌های تست

Figure 8. A set of processed images of oak galls from the test dataset.

کاربری امکان آپلود تصویر، تنظیم آستانه اطمینان و دریافت نتایج لحظه‌ای را فراهم می‌کند. در شکل ۹ سیستم موقعیت گال‌ها را با جعبه‌های سبز رنگ مشخص کرده و نام علمی گونه همراه با درصد اطمینان را ارائه می‌دهد. این ویژگی‌ها، ابزار را برای کاربردهای میدانی توسط جنگل‌داران، محققان و دانشجویان بسیار کاربردی کرده است. این پلتفرم می‌تواند به‌عنوان پایه‌ای برای پایش هوشمند تنوع زیستی و مدیریت پایدار منابع طبیعی در مناطق جنگلی مورد استفاده قرار گیرد.

معماری و پیاده‌سازی رابط کاربری گرافیکی یک سیستم هوشمند مبتنی بر یادگیری عمیق برای تشخیص خودکار گال‌های جنگلی برگ بلوط توسعه داده شد. این سیستم با استفاده از معماری (YOLOv8) قادر است ۴۷ گونه مختلف گال بلوط (مانند *Andricus* و *Cynips*) را در تصاویر روزمره شناسایی و طبقه‌بندی کند. مدل با استفاده از مجموعه داده‌ای متشکل از تصاویر برچسب‌دار آموزش‌دیده و در محیط تعاملی (Gradio) پیاده‌سازی شده است. این رابط



شکل ۹- نمایی از صفحه ورودی وب اپلیکشن (تصویر چپ) و صفحه پردازش (تصویر راست)

Figure 9. Interface of the web application's entry page (left) and the image processing module (right)

بحث

این پژوهش با به‌کارگیری مدل سبک YOLOv8n برای شناسایی خودکار گال‌های بلوط در جنگل‌های زاگرس، گامی مؤثر در جهت تلفیق فناوری‌های هوش مصنوعی با پایش تنوع زیستی در محیط‌های طبیعی و پیچیده برداشته است. نتایج به‌دست‌آمده، با $mAP@50 = 0.84$ و $mAP@50:95 = 0.60$ ، همراه با دقت و بازیابی به‌ترتیب 0.83 و 0.82 ، نشان‌دهنده عملکرد قابل‌قبول مدل، در شرایطی است که از نظر بصری و اکولوژیکی بسیار چالش‌برانگیز است. این عملکرد زمانی ارزشمندتر می‌شود که در نظر گرفته شود که تصاویر مورد استفاده در این پژوهش عمدتاً از محیط‌های میدانی با پس‌زمینه‌های پیچیده، نورپردازی غیریکنواخت و تنوع بالای مورفولوژیکی جمع‌آوری شده‌اند. در مقایسه با سایر پژوهش‌های مبتنی بر YOLOv8 در حوزه‌های کشاورزی و گیاه‌پزشکی، نتایج این پژوهش از نظر عددی در محدوده‌ای قابل‌مقایسه قرار دارد. برای نمونه، Zhang و همکاران (۲۰۲۵) در شناسایی آفات در مزرعه با YOLOv8 به دقت 0.85 دست یافتند، در حالی که Zhang و Li (۲۰۲۵) با مدل RSS-YOLOv8n برای شناسایی آفات پنبه دقتی در حدود 0.80 گزارش کردند. این ارقام نشان می‌دهد که این پژوهش با وجود پیچیدگی ذاتی داده‌های جنگلی، عملکردی مشابه با مطالعات انجام‌شده در شرایط کنترل‌شده‌تر داشته است. با این حال، تفاوت بنیادینی بین این پژوهش و مطالعات مشابه در طبیعت داده‌ها و هدف کاربردی آن است. در حالی که بسیاری از تحقیقات مانند Ren و همکاران، (۲۰۲۵) با $mAP@50 = 98.9$ از تصاویر آزمایشگاهی با پس‌زمینه‌های خنثی و بدون نویز برای اسپورهای قارچ بیماری‌زای ذرت استفاده کرده‌اند. داده‌های این پژوهش شامل ۴۷ گونه مختلف گال بلوط با تنوع رشدی، زوایای دید متفاوت و پس‌زمینه‌های پویای جنگلی است که به‌طور ذاتی دقت مدل را کاهش می‌دهد.

علاوه بر این، عملکرد متغیر مدل در شناسایی گونه‌های مختلف از دقت بالای 0.94 برای گونه‌هایی مانند *C. quercusfoli* و *A. tomentosus* تا دقت پایین‌تر برای *N.*

numismalis و *A. malpighii* همسو با یافته‌های جهانی در زمینه داده‌های نامتوازن برخوردار است. این پدیده در تحقیقاتی مانند Peng و Yu (۲۰۲۱) و Tong و همکاران (۲۰۲۳) نیز گزارش شده است، که با وجود استفاده از معماری‌های پیشرفته‌تر مانند EIoU و Wise-IoU همچنان با کاهش عملکرد در کلاس‌های کم‌نمونه مواجه بوده‌اند. این موضوع تأکید می‌کند که چالش اصلی در کاربردهای بیولوژیکی هوش مصنوعی، نه ضعف الگوریتم‌ها، بلکه کمبود داده‌های متعادل و باکیفیت است. نکته مهم دیگر، تمرکز بر کاربرد عملیاتی برای کاربران غیرمتخصص است. در حالی که بسیاری از پژوهش‌های مشابه مانند Khalid و همکاران (۲۰۲۳) فقط به توسعه مدل یا پیاده‌سازی در اپلیکیشن‌های تخصصی محدود به کاربرد آفات مزارع کوچک می‌شود. این پروژه با طراحی یک رابط کاربری گرافیکی ساده و انتشار مدل از طریق پلتفرم Hugging Face، زمینه را برای استفاده گسترده‌تر توسط جنگلبانان، محیط‌بانان و علاقه‌مندان فراهم کرده است. این رویکرد، پژوهش را از حوزه فقط دانشگاهی خارج کرده و آن را به یک ابزار عملیاتی برای مدیریت منابع طبیعی تبدیل می‌کند. این موضوع، همسو با جهت‌گیری جهانی، هوش مصنوعی برای حفاظت از طبیعت (AI for Conservation) است، که بر لزوم دسترسی‌پذیری و کاربرپسندی فناوری‌های پایش زیستی تأکید دارد.

با وجود این، این پژوهش نیز از محدودیت‌های ذاتی این حوزه مستثنی نیست. نامتوازن بودن داده‌ها، کمبود تصاویر از برخی گونه‌های نادر و عدم ارزیابی عملکرد مدل در شرایط بلادرنگ میدانی از جمله چالش‌هایی هستند که به‌درستی مطرح شده‌اند. راهکارهایی مانند استفاده از تکنیک‌های یادگیری فعال (Active Learning) برای جمع‌آوری هدفمند تصاویر مشکل‌دار و بهینه‌سازی مدل برای دستگاه‌های لبه (Edge Devices) می‌تواند گام‌های مؤثری در جهت رفع این محدودیت‌ها باشد. در مجموع، نتایج این پژوهش نه تنها از نظر فنی، عملکردی رقابتی با سایر مطالعات جهانی دارد، بلکه از منظر کاربردی بودن، دسترسی‌پذیری و تطبیق با شرایط واقعی محیط‌های طبیعی، گامی فراتر از بسیاری از پژوهش‌های

پایش تنوع زیستی جنگل‌های ایران، نقشی کلیدی، نه به‌عنوان جایگزین متخصصان، بلکه به‌عنوان تسهیل‌گر توزیع گسترده دانش زیستی و تقویت ظرفیت‌های محلی در حفاظت از منابع طبیعی ایفا کنند.

مشابه برداشته است. این پروژه نشان می‌دهد که مدل‌های سبک‌وزن مانند YOLOv8n، با وجود محدودیت‌های ذاتی، می‌توانند در حوزه‌های پیچیده‌ای مانند

References

- Askari, Y., Jahanbazi, H., and Pourhashemi, M., 2021. Evaluation of oak leaf gall in healthy and declined forest oak (*Quercus brantii* Lindl.) stands of Kohgiluyeh and Boyer-Ahmad province, Iran. *Iranian Journal of Forest and Poplar Research*, 30(1): 27-38 (In Persian). <https://doi.org/10.22092/ijfpr.2022.356577.2025>
- Azizkhani, E., Sadeghi, S. E., Rasoulzadeh, G. R., Tavakoli, M., Omid, R., Moniri, V. R. and Yarmand, H. 2007. Survey of gall wasps of the family Cynipidae associated with two oak species, *Quercus brantii* and *Q. infectoria* in Lorestan province of Iran. *Iranian Journal of Forest and Range Protection Research*, 5(1): 66-79 (In Persian).
- Guo, R., Wang, Y.P. and Wu, H., 2012. The diversity of insects galls and relationships between insects galls and their host plants and environment. *Journal of Environmental Entomology*, 34(3): 370-376.
- Jalaieian, M., Jafari, A., Ghasemi, R., 2015. Collection of gall (*Aphelonyx persica*) in Kohgiluyeh and Boyer-Ahmad province and determination of its density and distribution areas. *Civilica* (In Persian). <https://civilica.com/doc/1056638>
- Khalid, S., Oqaibi, H. M., Aqib, M., and Hafeez, Y., 2023. Small pests detection in field crops using deep learning object detection. *Sustainability*, 15(8): 6815. <https://doi.org/10.3390/su15086815>
- Kot, I., Sempruch, C., Rubinowska, K., and Michałek, W., 2019. Effect of *Neuroterus quercusbaccarum* (L.) galls on physiological and biochemical response of *Quercus robur* leaves. *Bulletin of Entomological Research*, 109(6): 792-800. <https://doi.org/10.1017/S0007485319000133>
- Ma, S.M., Yu, H., Li, C.C. and Yang, M.Z. 2008. Plant gall biology. *Chinese Bulletin of Entomology*, 45(2): 330-335.
- Peng, H., and Yu, S., 2021. A systematic IoU-related method: Beyond simplified regression for better localization. *IEEE Transactions on Image Processing*, 30: 5032-5044. <https://doi.org/10.1109/TIP.2021.3077144>
- Ren, Y., Xu, Y., Tian, H., Zhang, Q., Yang, M., Zhu, R., Xin, D., Chen, Q., Wei, Q., and Song, S., 2025. Detection of Maize Pathogenic Fungal Spores Based on Deep Learning. *Agriculture*, 15(15): 1689. <https://doi.org/10.3390/agriculture15151689>
- Sadeghi, S. E., Asareh, M. H., and Tavakoli, M., 2009. Oak gall wasps of Iran. Tehran: Research Institute of Forests and Rangelands Press. 304p (In Persian).
- Sadeghi, S.E., Melika, G., Stone, G., Tavakoli, M., Barimani, H. and Zeinali, S., 2014. A review of oak gall wasps of Iran, distribution, host plants and introducing a managing program for their's protection. *Journal of Plant Research*, 27(3): 450464 (In Persian).
- Shorten, C., and Khoshgoftaar, T. M., 2019. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1): 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Shourmij, M., Khalili Fard, J., Najafizadeh, P. and Mousavi, Z., 2022. Safety assessment of the *Quercus brantii* gall hydroalcoholic extract: Single and repeated oral dose toxicity studies. *Iranian Journal of Basic Medical Sciences*, 25(11): 1389-1395. <https://doi.org/10.22038/ijbms.2022.65488.14418>.
- Stone, G.N. and Schönrogge, K., 2003. The adaptive significance of insect gall morphology. *Trends in Ecology and Evolution*, 18(10): 512-514.
- Tavakoli, M., Hosseinzadeh, J. and Padasht, F., 2008. Study of morphological structure of Mazouj gall and its causative wasp in western Iran oak forests. *International Journal of Forest and Range Protection Research*, 5(2): 45-52. http://ijfprp.areeo.ac.ir/article_106309.html
- Tong, Z., Chen, Y., Xu, Z., and Yu, R., 2023. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism. *arXiv preprint arXiv: 2301.10051*. <https://doi.org/10.48550/arXiv.2301.10051>
- Ward A., Busbee R., Chen R., Davis C., Driscoll A., Egan S., Goldberg B., Hood G., Jones D., Kranz A., Meadely-Dunphy S., Milks A., Ott J., Prior K., Sheikh S., Shzu S., Weinersmith K., Zhang L., Zhang Y. and Forbes A., 2022. The arthropod associates of 155 North American cynipid oak galls. *Zoological Studies*, 61:57. <https://doi.org/10.6620/ZS.2022.61-57>
- Zamani, S.M. and Sadeghi, S.E. 2020. Evaluation antifungal properties of aqueous, acetone and alcohol extracts of *Quercus brantii* Lindl. var. *persica* (Jaub and Spach) Zohary. *Iranian Journal of Forest and Range Protection Research*, 17(2): 161-172 (In Persian). <https://doi.org/10.22092/ijfprp.2019.125323.1371>
- Zhang, X., and Li, Y., 2025. Cotton Pest Detection

Method based on Improved YOLOv8. *Frontiers in Computing and Intelligent Systems*, 12(1): 104-109. <https://doi.org/10.54097/mz27vb83>
– Zhang, X., Qiao, H., Xi, L., et al., 2025. Detecting small

objects for field crop pests using improved YOLOv8J. *Transactions of the Chinese Society of Agricultural Engineering*, 41(13): 225-233. <https://doi.org/10.11975/j.issn.1002-6819.202502116>