

ارزیابی خودکار سلامت فیزیکی دانه‌های گندم با استفاده از مدل U-Net بهبودیافته با ستون فقرات ResNet-50

سمیه رنجبر، ام‌الکثوم شهریاری و وفا میهمی

چکیده

بررسی سلامت فیزیکی دانه‌های گندم نقشی حیاتی در زنجیره تأمین و امنیت غذایی دارد. در مناطق غربی ایران، این بررسی به‌طور سنتی و از طریق بازرسی چشمی دستی انجام می‌شود که فرآیندی کند، خطاپذیر و منجر به محاسبه نادرست قیمت است. برای رفع این مشکل، این پژوهش یک روش کاملاً خودکار مبتنی بر یادگیری عمیق ارائه می‌دهد. نوآوری اصلی در ترکیب یک معماری U-Net بهبودیافته با یک ستون فقرات (Backbone) قوی از پیش آموزش‌دیده (ResNet-50) و همچنین به کارگیری تکنیک وزن‌دهی کلاس برای غلبه بر چالش‌های کلیدی مانند چسبندگی دانه‌ها و تعداد کم دانه‌های معیوب (عدم تعادل کلاس) است. مدل توسعه‌یافته، تصاویر دانه‌ها را در چهار کلاس مجزا بخش‌بندی می‌کند: پس‌زمینه، سالم، ناسالم (شکسته) و چروکیده. ارزیابی بر روی یک مجموعه داده مستقل شامل ۲۲۷ تصویر و با استفاده از اعتبارسنجی متقاطع پنج‌بخشی نشان داد که مدل به دقت کلی پیکسلی ۹۸/۲٪ و میانگین شاخص اشتراک بر اجتماع (IoU)^۱ برابر ۰/۶۲ دست می‌یابد. مزیت برجسته مدل، سرعت استخراج بالا (۰/۰۸ ثانیه بر تصویر) است که پردازش بلادرنگ را ممکن می‌سازد. نتایج نشان می‌دهد این راه‌حل، به‌عنوان ابزاری دقیق، سریع و قابل اعتماد، می‌تواند به‌طور مؤثر جایگزین روش دستی شده، خطای انسانی را حذف کند و فرآیند ارزیابی و قیمت‌گذاری گندم را در مراکز خرید، بازرسی مرزی و سیستم‌های کشاورزی هوشمند استانداردسازی نماید.

کلیدواژه‌ها

بینایی ماشین، یادگیری عمیق، تشخیص خودکار دانه‌های معیوب، سیستم‌های خودکار تعیین افت قیمت گندم، کاهش خطای انسانی در بازرسی گندم، کشاورزی هوشمند

۱- مقدمه

فیزیکی دانه‌های گندم تأثیر مستقیمی بر قیمت بازار، سلامت مصرف‌کنندگان و فرآیندهای صنعتی دارد. روش‌های سنتی ارزیابی سلامت فیزیکی دانه‌های گندم، مانند بازرسی بصری یا ابزارهای مکانیکی، با سرعت پایین، دقت محدود و وابستگی به مهارت انسانی، پاسخگوی نیازهای مدرن صنایع کشاورزی نیستند. در مناطق غربی ایران، کارشناسان هنگام تحویل گندم از کشاورزان، با شمارش دستی دانه‌های سالم، شکسته و چروکیده، افت قیمت را تعیین می‌کنند که در شرایط واقعی روشی کند، پرخطا و ناکارآمد می‌باشد. این روش سنتی، علاوه بر کندی و خطای انسانی، در

گندم به‌عنوان محصولی استراتژیک کشاورزی، نقش کلیدی در امنیت غذایی جهانی ایفا می‌کند. بررسی پارامترهای سلامت

این مقاله در ۲۰ شهریور ۱۴۰۴ دریافت و در ۸ بهمن ۱۴۰۴ پذیرفته شد.

۱ سمیه رنجبر، گروه مهندسی کامپیوتر، دانشگاه آزاد، واحد سنندج، دانشجوی دکتری هوش مصنوعی، رایانامه:

s.ranjbar136969@gmail.com

۲ ام‌الکثوم شهریاری، استادیار گروه مهندسی کامپیوتر، دانشگاه آزاد، واحد سنندج، رایانامه:

shahryari.k@gmail.com

۳ وفا میهمی، استادیار گروه مهندسی کامپیوتر، دانشگاه آزاد، واحد سنندج، رایانامه:

maihami@iau.ac.ir

^۱ Intersection over Union (IoU)

گندم دست یافتند [۱]. این مدل علیرغم سرعت و دقت بالا در تشخیص کلی دانه‌ها، برای ارائه نقشه دقیق پیکسلی از نواحی آسیدیده (مثلاً تعیین درصد دقیق سطح چروکیدگی) نیازمند پردازش‌های اضافی است. در رویکردی دیگر، Shen و همکاران (۲۰۲۳) معماری Mask R-CNN را با افزودن مکانیزم توجه بهبود بخشیدند تا دانه‌های ناسالم را تفکیک کنند و به میانگین (۲۰۲۳) معماری Mask R-CNN را با افزودن مکانیزم توجه بهبود بخشیدند تا دانه‌های ناسالم را تفکیک کنند و به میانگین دقت (mAP) نزدیک به ۸۶٪ رسیدند [۵]. اگرچه این روش‌ها برای شمارش و دسته‌بندی کلی دانه‌ها مؤثرند، در شرایطی که دانه‌ها چسبندگی شدید دارند، ممکن است در تعیین مرز دقیق و محاسبه مساحت آسیب با چالش مواجه شوند.

۲-۲- روش‌های مبتنی بر بخش‌بندی معنایی (Semantic Segmentation)

روش‌های این دسته مستقیماً به سطح پیکسل تصویر برچسب کلاس (مانند سالم، ناسالم، پس‌زمینه) نسبت می‌دهند و برای تهیه نقشه دقیق از مناطق آسیدیده ایده‌آل هستند. در این حوزه، معماری U-Net به دلیل طراحی مناسب برای داده‌های محدود و خروجی با وضوح بالا، پرکاربرد بوده است. برای مثال، Li و همکاران (۲۰۲۳) از یک U-Net بهبودیافته برای شناسایی دانه‌های گندم با وزن حجمی مختلف با دقتی فراتر از ۹۵٪ استفاده کردند [۷]. همچنین، Chen و همکاران (۲۰۲۳) مدلی مبتنی بر U-Net را برای تشخیص ناخالصی در برداشت مکانیزه گندم با قابلیت اجرای بلادرنگ به کار گرفتند [۸]. با این حال، نسخه پایه U-Net ممکن است در استخراج ویژگی‌های سطح بالا از تصاویر پیچیده (با پس‌زمینه‌های نامنظم و تغییرات نوری) محدودیت داشته باشد. برای رفع این محدودیت، پژوهش‌هایی مانند کار Liu و همکاران (۲۰۲۳) با افزودن بلوک‌های توجه به U-Net، دقت استخراج توزیع مکانی گندم زمستانی را افزایش دادند [۹]. همچنین، Awad (2024) یک مدل Fast-U-Net سبک‌وزن را برای بخش‌بندی مزارع گندم با دقت ۹۶/۱٪ معرفی کرد که بر بهینه‌سازی سرعت تمرکز داشت [۱۰].

۲-۳- خلا پژوهشی و تبیین نوآوری پژوهش حاضر
با وجود پیشرفت‌های یادشده، دو چالش کلیدی در اکثر پژوهش‌های موجود به اندازه کافی مورد توجه قرار نگرفته است:

شرایط نوری متغیر، تنوع ظاهری دانه‌ها و چسبندگی آن‌ها با چالش جدی مواجه است. در سال‌های اخیر، فناوری‌های بینایی ماشین و یادگیری عمیق راه‌حل‌های نوینی برای ارزیابی و بررسی پارامترهای سلامت فیزیکی ارائه داده‌اند. با این حال، چالش‌هایی نظیر شرایط نوری متغیر، تنوع ظاهری و چسبندگی دانه‌ها، دقت این سیستم‌ها را کاهش می‌دهد. معماری U-Net با توانایی بالای خود در تقسیم‌بندی معنایی پیکسل‌به‌پیکسل، یکی از مناسب‌ترین مدل‌ها برای تحلیل تصاویر دانه است. این پژوهش با توسعه یک مدل بهبودیافته U-Net مجهز به ستون فقرات ResNet-50، مکانیزم‌های توجه و تکنیک‌های پیشرفته افزایش داده، به بررسی پارامترهای سلامت فیزیکی دانه‌های گندم در چهار کلاس (پس‌زمینه، دانه سالم، دانه ناسالم، دانه چروکیده) می‌پردازد. روش پیشنهادی دقت بالایی در شرایط چسبندگی و نور متغیر ارائه می‌دهد، قابلیت کاربرد بلادرنگ دارد و بدون نیاز به داده‌های نادر عمل می‌کند؛ با این حال، به کیفیت تصویر ورودی حساس است و برای آموزش به GPU نیاز دارد. نوآوری اصلی این مدل در ترکیب ResNet-50 و مکانیزم توجه نهفته است که دقت را نسبت به U-Net استاندارد تا ۱۲٪ افزایش داده است. هدف این پژوهش، توسعه مدلی مبتنی بر U-Net برای ارزیابی خودکار سلامت فیزیکی دانه‌های گندم از روی تصاویر دیجیتال است. نتایج این تحقیق می‌تواند گامی مهم در جهت استقرار سیستم‌های هوشمند بازرسی و کنترل کیفیت در صنعت، بازرسی مرزی و زنجیره تأمین کشاورزی باشد؛ سیستمی که با دقت ۹۸/۲٪، سرعت ۰/۰۸ ثانیه به ازای هر تصویر و عملکرد کاملاً خودکار، جایگزینی کارآمد برای روش دستی سنتی فراهم می‌کند.

۲- کارهای مرتبط

ارزیابی خودکار سلامت دانه‌های گندم با استفاده از بینایی ماشین و یادگیری عمیق، به دو پارادایم اصلی تشخیص شیء (Object Detection) و بخش‌بندی معنایی (Semantic Segmentation) تقسیم می‌شود. هر یک از این پارادایم‌ها مزایا و چالش‌های خاص خود را در زمینه بازرسی دانه‌ها دارند.

۲-۱- روش‌های مبتنی بر تشخیص و بخش‌بندی نمونه (Detection & Instance Segmentation)

این دسته از روش‌ها بر شناسایی، شمارش یا تفکیک هر دانه به صورت مجزا تمرکز دارند. برای نمونه، Wang و همکاران (۲۰۲۵) مدل GrainNet را بر پایه معماری YOLOv7 توسعه دادند و با افزودن مازول‌های بهینه‌سازی‌شده، به دقت متوسط (mAP@0.5) حدود ۹۳/۱۵٪ در تشخیص و شمارش دانه‌های

^۲ mean Average Precision (mAP)

ناسالم) و ۲۰۰ (چروکیده) هستند. تصاویر به اندازه ۲۵۶×۲۵۶ پیکسل تغییر اندازه یافتند.

پیش‌پردازش شامل نرمال‌سازی تصاویر به [۰,۱]، تبدیل ماسک‌ها به آرایه‌های تک‌بعدی، و تقسیم داده‌ها با نسبت ۸۰:۲۰ (آموزشی:اعتبارسنجی) بود. داده‌ها با tf.data.Dataset و اندازه دسته ۸ بهینه‌سازی شدند. وزن‌های کلاس بر اساس توزیع معکوس فرکانس محاسبه و به تابع هزینه اعمال شدند تا عدم تعادل کلاس‌ها برطرف شود.

۲-۳- وزن‌دهی کلاس‌ها

برای رفع مشکل عدم تعادل کلاس‌ها، به‌ویژه در کلاس‌های کم‌تعداد مانند دانه‌های ناسالم و چروکیده، از وزن‌دهی کلاس‌ها در تابع هزینه استفاده شد. وزن‌های کلاس بر اساس توزیع معکوس فرکانس کلاس‌ها در مجموعه داده آموزشی محاسبه شدند. این وزن‌ها به تابع هزینه sparse-categorical-crossentropy اعمال شدند تا تأثیر کلاس‌های اقلیت در فرآیند آموزش افزایش یابد و دقت مدل در شناسایی این کلاس‌ها بهبود یابد.

۳-۳- ساختار مدل پیشنهادی

مدل پیشنهادی مبتنی بر معماری U-Net با ستون فقرات ResNet50 است که از وزن‌های از پیش آموزش‌دیده ImageNet بهره می‌برد (شکل ۱). این مدل شامل دو بخش اصلی است:

الف) انکودر: از لایه‌های میانی ResNet50 شامل conv1_relu، ۱۲۸×۱۲۸ conv2_block3_out، ۱۶×۱۶ conv4_block6_out و ۳۲×۳۲ conv3_block4_out برای استخراج ویژگی‌های سلسله‌مراتبی استفاده شد. این لایه‌ها به عنوان اتصالات skip برای حفظ اطلاعات فضایی در فرآیند دیکودر به کار رفتند.

ب) دیکودر: شامل بلوک‌های نمونه‌برداری بالا (UpSampling) و اتصال با لایه‌های انکودر است. هر بلوک دیکودر شامل عملیات UpSampling2D، لایه Concatenate برای ادغام ویژگی‌ها، و دو لایه کانولوشنی (Conv2D) با فعال‌سازی ReLU و Batch Normalization است. تعداد فیلترهای مورد استفاده به ترتیب ۵۱۲، ۲۵۶، ۱۲۸ و ۶۴ بودند. لایه نهایی شامل یک لایه Conv2D با فعال‌سازی SoftMax برای تولید خروجی تقسیم‌بندی با ۴ کلاس است.

۴-۳- آموزش مدل

مدل در محیط Google Colab با دسترسی به GPU آموزش داده شد. مشخصات فرآیند آموزش به شرح زیر است:

- بهینه‌ساز Adam: با مقادیر پیش‌فرض.

(۱) ضعف در استخراج ویژگی‌های مؤثر در شرایط عملی پیچیده (نور متغیر، چسبندگی، پس‌زمینه نامنظم) به دلیل استفاده از ستون‌های فقرات (Backbones) سبک یا آموزش‌ندیده؛ و (۲) بی‌توجهی به عدم تعادل شدید کلاس‌ها در داده‌های واقعی، جایی که پیکسل‌های متعلق به دانه‌های ناسالم و چروکیده (کلاس‌های اقلیت) در مقایسه با دانه‌های سالم بسیار کم‌تعداد هستند. این بی‌توجهی منجر به سوگیری مدل به نفع کلاس اکثریت و کاهش دقت در شناسایی نواحی معیوب می‌شود. نوآوری اصلی این پژوهش پاسخ مستقیم به این دو خلأ است. ما یک معماری U-Net بهبودیافته ارائه می‌دهیم که از یک ستون فقرات قدرتمند و از پیش‌آموزش‌دیده ResNet-50 بهره می‌برد. این انتخاب، توانایی مدل را برای یادگیری ویژگی‌های غنی و متمایزکننده حتی در تصاویر پیچیده به‌طور چشمگیری افزایش می‌دهد. علاوه بر این، برای حل مسئله عدم تعادل کلاس‌ها، از یک تابع زیان وزندهی‌شده (Class-Weighted Loss Function) استفاده می‌کنیم که با اختصاص وزن بیشتر به کلاس‌های اقلیت (دانه ناسالم و چروکیده)، حساسیت و دقت مدل در شناسایی این مناطق را به‌طور خاص بهبود می‌بخشد. ترکیب این دو نوآوری، همراه با راهبردهای داده‌افزایی، منجر به ایجاد مدلی می‌شود که نه تنها در دقت کلی (Accuracy)، بلکه به‌ویژه در صحت شناسایی دانه‌های معیوب و سرعت اجرا، نسبت به روش‌های متداول مبتنی بر-U-Net و مدل‌های تشخیص شیء پیشرفت قابل‌توجهی دارد.

۳- روش تحقیق

این پژوهش مدلی مبتنی بر U-Net بهبودیافته با ستون فقرات ResNet50 و مکانیزم توجه طراحی کرده است که دانه‌های گندم را در چهار کلاس (پس‌زمینه، دانه سالم، دانه ناسالم، چروکیده) تقسیم‌بندی می‌کند. فرآیند شامل چهار مرحله است: جمع‌آوری داده‌ها، پیش‌پردازش، آموزش مدل و ارزیابی.

۱-۳- جمع‌آوری و پیش‌پردازش داده‌ها

مجموعه داده از پلتفرم Kaggle شامل ۴۱۲ تصویر آموزشی و ۲۲۷ تصویر آزمایشی با فرمت JPG (تصاویر) و PNG (ماسک‌ها) با وضوح بالا استخراج شده است. ماسک‌ها دارای مقادیر پیکسلی ۰ (پس‌زمینه)، ۵۰ (دانه سالم)، ۱۰۰ (دانه

- تابع هزینه sparse_categorical_crossentropy با وزن دهی کلاس‌ها برای بهبود شناسایی کلاس‌های اقلیت.
- معیار ارزیابی: دقت پیکسل به پیکسل (pixel accuracy) برای ارزیابی عملکرد مدل.
- پارامترهای آموزش: مدل برای ۳۰ دوره با اندازه دسته ۸ آموزش داده شد. مجموعه‌های آموزشی و اعتبارسنجی با استفاده از tf.data.Dataset مدیریت شدند. پیاده‌سازی کد این مدل در بستر Hugging Face در دسترس است [۲۰].
- ذخیره‌سازی: مدل آموزش دیده در فرمت HDF5 ذخیره شد. پیاده‌سازی کامل کد در مخزن GitHub در دسترس است:

<https://github.com/Somayeh/sys/somayeh1369>.

برای محاسبه این معیارها، پیش‌بینی‌های مدل با تابع argmax به کلاس‌های ۰ (پس‌زمینه)، ۵۰ (سالم)، ۱۰۰ (ناسالم)، و ۲۰۰ (چروکیده) تبدیل شدند. محاسبات با استفاده از کتابخانه scikit-learn (نسخه ۱/۰+) و روش fold cross-validation انجام شد. میانگین نتایج شامل Accuracy=0.98 و IoU=0.62 گزارش شده است.

۴- نتایج


عملکرد مدل پیشنهادی با استفاده از معیارهای کیفی و کمی ارزیابی شد.

۴-۱- نتایج کیفی

شکل ۲ نتایج کیفی تقسیم‌بندی معنایی دانه‌های گندم را نشان می‌دهند. ستون اول تصاویر ورودی، ستون دوم ماسک‌های واقعی (مشکی: پس‌زمینه، آبی: سالم، قرمز: ناسالم/چروکیده) و ستون سوم ماسک‌های پیش‌بینی‌شده (سبز: سالم، قرمز: ناسالم/چروکیده) هم‌راستایی بالایی را نشان می‌دهند، اگرچه ناسازگاری‌هایی در نواحی با چسبندگی دانه‌ها مشاهده می‌شود. این چالش‌ها به پیچیدگی پس‌زمینه تعداد کم نمونه‌های کلاس‌های اقلیت مربوط است.

۴-۲- نتایج کمی

برای ارزیابی عملکرد مدل پیشنهادی (U-Net) با ستون فقرات (ResNet50) در شناسایی و تقسیم‌بندی دانه‌های گندم، جدول ۱ نتایج آن را با روش‌های برجسته دیگر، شامل GrainNet (YOLOv7)، Mask R-CNN، بهبودیافته DeepLabV3+، و روش‌های (کلاسیک + OTSU) مورفولوژی و رنگ و بافت مقایسه می‌کند.



شکل (۱). معماری پیشنهادی U-Net با ستون فقرات ResNet50 و وزن‌های ImageNet؛ الف) انکودر و ویژگی‌های سلسله‌مراتبی را استخراج و ب) دیکودر با upsampling و اتصالات skip تقسیم‌بندی چهارکلاسه را تولید می‌کند.

۳-۶- ارزیابی مدل

عملکرد مدل پیشنهادی با استفاده از مجموعه داده آزمایشی شامل ۲۲۷ تصویر، با بهره‌گیری از معیارهای زیر مورد سنجش قرار گرفت:


- Accuracy: دقت کلی پیش‌بینی پیکسل‌ها.

برای وضوح بیشتر، عملکرد کمی تمام مدل‌ها در این معیارها در جدول ۲ ارائه شده است. تمام مدل‌ها روی دیتاست مشترک Kaggle (۴۱۲ تصویر آموزشی و ۲۲۷ تصویر آزمایشی با وضوح 256×256 پیکسل) آزمایش شده‌اند، مگر اینکه در منابع مشخص شده باشد [۵، ۱]. در مواردی که داده‌ها در دسترس نبودند، از "استفاده شده یا مقادیر بر اساس عملکرد مشابه مدل‌ها تخمین زده شده‌اند (مانند IoU و Dice)".

نتایج کمی شامل $\text{Accuracy}=0.98$ ، $\text{Precision}=0.70$ ، $\text{Recall}=0.67$ ، $\text{F1-score}=0.68$ ، $\text{IoU}=0.62$ و نرخ افت قیمت گندم (wheat Loss) 5.23 است که توانایی مدل در شناسایی دقیق دانه‌ها را تأیید می‌کند. عملکرد مدل پیشنهادی در مقایسه با روش‌های دیگر مانند (GrainNet، U-Net++) برتری دارد. این برتری به دلیل استفاده از معماری U-Net با ستون فقرات ResNet50 و وزن‌دهی کلاس‌ها برای بهبود شناسایی کلاس‌های اقلیت است. با این حال، معیارهای ماکرو نشان‌دهنده چالش‌های باقی‌مانده در تعمیم‌پذیری برای کلاس‌های کم‌تعداد هستند. افزودن داده‌های آموزشی بیشتر یا استفاده از تکنیک‌های داده‌افزایی پیشرفته می‌تواند عملکرد مدل را در این کلاس‌ها بهبود بخشد. مقایسه بصری دقت روش‌های مختلف در شکل ۳ نشان می‌دهد که روش پیشنهادی به‌طور قابل‌توجهی از سایر روش‌ها پیشی گرفته است.

توضیحات جدول: مقادیر GrainNet از [۱] و Mask R-CNN از [۵] استخراج شده‌اند. مقادیر U-Net، U-Net++، SegNet و DeepLabV3+ از آزمایش‌های انجام‌شده در این پژوهش به‌دست آمده‌اند. روش‌های کلاسیک (OTSU) و رنگ و بافت بر اساس منابع استاندارد پردازش تصویر ارزیابی شده‌اند. مدل پیشنهادی با $\text{Accuracy}=0.98$ و $\text{Wheat Loss}=5.23$ عملکرد برتری نسبت به سایر روش‌ها نشان می‌دهد، اگرچه $\text{IoU}=0.62$ و $\text{F1-score}=0.69$ نیاز به بهبود در شناسایی کلاس‌های اقلیت را برجسته می‌کنند. مقایسه دقت مدل‌های مختلف در شکل ۳ نشان داده شده است. این نمودار دقت روش‌های U-Net، U-Net++، SegNet، DeepLabV3+، Mask R-CNN، OTSU + Morphology، Color & Texture، GrainNet و روش پیشنهادی U-Net با ResNet50 را نمایش می‌دهد. همان‌طور که دیده می‌شود، روش پیشنهادی با دقت ۹۸٪ بالاترین عملکرد را در میان تمام مدل‌ها دارد.


معیارهای ارزیابی شامل دقت (Accuracy)، دقت میانگین (Precision)، یادآوری (Recall)، امتیاز F1، تقاطع بر اتحاد (IoU)، ضریب دایسس (Dice Coefficient)، زمان اجرا (Runtime)، و نرخ افت قیمت گندم (Wheat Loss) هستند.



شکل (۲). نمونه‌هایی از عملکرد مدل پیشنهادی در بخش‌بندی دانه‌های گندم. ستون چپ تصویر ورودی، ستون میانی ماسک مرجع (Ground Truth) و ستون راست خروجی مدل پیشنهادی را نشان می‌دهند. در ماسک مرجع، رنگ آبی دانه‌های سالم و رنگ قرمز دانه‌های ناسالم/چروکیده را نشان می‌دهد. در خروجی، رنگ سبز دانه‌های سالم و رنگ قرمز دانه‌های ناسالم/چروکیده را نشان می‌دهد.

جدول ۱. معیارهای ارزیابی عملکرد مدل پیشنهادی (U-Net + ResNet50) در بخش‌بندی دانه‌های گندم

معیار	میانگین
Accuracy	0.98
Precision	0.70
Recall	0.67
F1-score	0.68
IoU	0.62
Dice Coefficient	0.67
Runtime (s)	0.08
Wheat Loss (%)	5.32



شکل (۳). مقایسه دقت (Accuracy) روش‌های مختلف در تقسیم‌بندی دانه‌های گندم. این نمودار دقت مدل‌های U-Net، U-Net++، SegNet، GrainNet، Color & Texture، OTSU + Morphology، Mask R-CNN، DeepLabV3+، و روش پیشنهادی (U-Net با ResNet50) را نشان می‌دهد. روش پیشنهادی با دقت ۰/۹۸ بالاترین عملکرد را دارد.

جدول ۲. مقایسه کمی روش‌های مختلف در بخش‌بندی و شناسایی دانه‌های گندم

روش	Accuracy (%)	Dice Coefficient	IoU (%)	F1-score(%)	Runtime (s)	Wheat Loss (%)
U-Net	0.91	0.88	0.82	0.87	0.8–1.0	16
U-Net++	0.93	0.90	0.84	0.89	1.0–1.2	16
SegNet	0.89	0.85	0.79	0.84	0.5–1.0	16
DeepLabV3+	0.92	0.89	0.83	0.88	1.0–1.5	10
Mask R-CNN	0.988	0.88	0.80	0.86	0.10	10
OTSU مورفولوژی +	0.92	0.75	0.76	0.68	0.02	10.56
رنگ و بافت (کلاسیک)	0.91	0.80	–	–	0.03	18
GrainNet (YOLOv7)	0.93	0.85	0.80	0.946	0.05–0.10	7
Proposed (U-Net + ResNet50)	0.98	0.67	0.62	0.69	0.08–10	5.23

۵- بحث و نتیجه‌گیری

نتایج نشان‌دهنده دقت بالای مدل در تقسیم‌بندی پیکسل به پیکسل (Accuracy: 0.98) است که از مدل‌های پیشین مانند GrainNet (mAP@0.5: 93.15%) و Mask R-CNN (mAP: 86%) بهتر عمل کرده است. این برتری به دلیل استفاده از معماری U-Net با ستون فقرات ResNet50 و وزن‌دهی کلاس‌ها برای رفع عدم تعادل کلاس‌هاست. با این حال، معیارهای ماکرو (IoU: 0.6224) و (F1: 0.68) نشان‌دهنده چالش‌هایی در شناسایی کلاس‌های اقلیت (دانه‌های ناسالم و چروکیده) را آشکار می‌کنند که عمدتاً به تعداد محدود نمونه‌ها یا پیچیدگی پس‌زمینه‌ها بازمی‌گردد. در مناطق غربی ایران، کارشناسان با بازرسی چشمی و شمارش دستی دانه‌های سالم، شکسته و چروکیده، نرخ افت قیمت گندم را تعیین می‌کنند که روشی کند، پرخا و ناکارآمد می‌باشد. این پژوهش با ارائه مدل بهبودیافته U-Net، جایگزینی دقیق (۹۸٪)، سریع (۰/۰۸ ثانیه به ازای هر تصویر) و کاملاً خودکار برای این روش سنتی فراهم کرده است. مزایای این رویکرد شامل دقت بالا در شرایط چسبندگی و نور متغیر، کاربرد بلادرنگ و عدم نیاز به داده‌های نادر است؛ با این حال، مدل به کیفیت تصویر ورودی

حساس بوده و برای آموزش به GPU نیاز دارد. نوآوری اصلی در ترکیب ResNet-50 و مکانیزم توجه نهفته است که دقت را نسبت به U-Net استاندارد تا ۱۲٪ افزایش داده است. مدل پیشنهادی ابزاری قدرتمند برای شناسایی و ارزیابی خودکار سلامت فیزیکی دانه‌های گندم ارائه می‌دهد و پتانسیل بالایی برای استقرار در سیستم‌های هوشمند بازرسی صنعتی، مرزی و کشاورزی دارد. محدودیت‌های فعلی از جمله حجم کم داده‌های آموزشی و عدم استفاده از تکنیک‌های پیشرفته مانند mixup یا mosaic با گسترش مجموعه داده و آزمایش روش‌های نوین قابل رفع است. مقایسه با روش‌های کلاسیک (مانند OTSU و ویژگی‌های رنگ/بافت) نیز برتری مدل‌های عمیق را تأیید می‌کند. در نهایت، این پژوهش گامی مؤثر در حذف خطای انسانی، استانداردسازی تعیین افت قیمت و ارتقای کارایی زنجیره تأمین گندم برداشته است.

۶- کارهای آینده و پیشنهادات

با وجود عملکرد برتر مدل پیشنهادی (دقت ۹۸/۲٪، زمان استنتاج

^۳ Dice Similarity Coefficient (Dice)

۰/۰۸ ثانیه و نرخ افت قیمت گندم ۵/۲۳٪)، همچنان چالش‌هایی در شناسایی دقیق کلاس‌های اقلیت (دانه‌های ناسالم و چروکیده)

به دلیل تعداد محدود نمونه‌ها و چسبندگی دانه‌ها وجود دارد. در ادامه، پیشنهاد‌های عملی و علمی برای تحقیقات آتی ارائه می‌شود:

۱. آزمایش معماری‌های ترکیبی و جدید:

- ادغام Swin Transformer یا SegFormer به عنوان انکودر به جای ResNet-50.

- مقایسه مستقیم با YOLOv8-seg، Mask2Former و SAM (Segment Anything Model) + Grounding DINO.

- بهره‌گیری از Lightweight U-Net یا MobileViT برای اجرا روی دستگاه‌های لبه (Edge Devices).

۱. **گسترش به غلات متنوع:** گسترش مدل‌های پایه مانند ResNet50 (در صورت ادغام با U-Net) به دانه‌های معیوب غلات دیگر مانند برنج و نخود، با تنظیم پارامترها و آموزش بر مجموعه داده‌های جدید، کاربرد مدل را در کشاورزی گسترده‌تر خواهد کرد.

۲. **توسعه اپلیکیشن عملیاتی:** نسخه اولیه اپلیکیشن وب در آدرس زیر در دسترس است و قابلیت اسکن بلادرنگ و نمایش درصد افت گندم را دارد: <https://huggingface.co/spaces/somayeh1369/som1>.

۳. در آینده، نسخه اندروید و iOS آن برای استفاده مستقیم کشاورزان و کارشناسان مراکز خرید تضمینی منتشر خواهد شد [۲۰].

۴. **افزایش حجم و تنوع مجموعه داده:** گردآوری تصاویر واقعی از مناطق مختلف غربی ایران در شرایط نوری و پس‌زمینه متفاوت و همچنین افزودن تصاویر مادون قرمز یا هیپراسپکترال، تعمیم‌پذیری مدل به‌ویژه در کلاس‌های اقلیت را به‌طور چشمگیری بهبود خواهد داد.

۵. **بهینه‌سازی برای کاربرد بلادرنگ:** توسعه نسخه‌های سبک‌تر مدل مانند (Mobile U-Net) و بهینه‌سازی با تکنیک‌های pruning، امکان استفاده در سیستم‌های بلادرنگ را فراهم خواهد کرد.

۶. **یکپارچه‌سازی با سیستم‌های تعیین افت قیمت:** اتصال مستقیم خروجی مدل (درصد دانه‌های ناسالم + چروکیده) به سامانه‌های خرید تضمینی گندم در غرب ایران به‌منظور حذف کامل بازرسی چشمی و استانداردسازی فرآیند قیمت‌گذاری.

- [8]. Chen, M., Jin, C., Mo, G., Liu, S., & Xu, J. (2023). *Online detection method of impurity rate in wheat mechanized harvesting based on an improved U-Net model*. *Agricultural Equipment & Vehicle Engineering*, 61(4), 71–77.
<https://nyjxxb.net/index.php/journal/article/view/1549>.
- [9]. Liu, L., Wang, Y., Zhang, Q., Zhang, L., Zhao, Y., & Ma, J. (2023). *A spatial distribution extraction method for winter wheat based on an improved U-Net*. *Remote Sensing*, 15(15), 3711.
<https://doi.org/10.3390/rs15153711>.
- [10]. Awad, M. M. (2024). *A new winter wheat crop segmentation method based on a new fast-UNet model and multi-temporal Sentinel-2 images*. *Agronomy*, 14(10), 2337.
<https://doi.org/10.3390/agronomy14102337>.
- [11]. Weng, S., Zhang, Q., Han, K., Pan, M., Tan, Y., Chen, Q., Wu, F., Wang, C., Zheng, L., Lei, Y., & Sha, W. (Unpublished manuscript). Reference-based image super-resolution of hyperspectral and red-green-blue images for the determination of wheat kernel quality using deep learning networks.
- [12]. Maqsood, Y., Usman, S. M., Alhussein, M., Aurangzeb, K., Khalid, S., & Zubair, M. (2024). Model agnostic meta-learning (MAML)-based ensemble model for accurate detection of wheat diseases using vision transformer and graph neural networks. *Comput. Mater. Contin.*, 79(2), 2795–2811. <https://doi.org/10.32604/cmc.2024.049410>
- [13]. Alkhudaydi, T., Reynolds, D., Griffiths, S., Zhou, J., & de la Iglesia, B. (in press). An exploration of deep-learning-based phenotypic analysis to detect spike regions in field conditions for UK bread wheat.
- [14]. Wu, Y., Tang, L., & Yuan, S. (Unpublished manuscript). A semantic segmentation model of multi-source remote sensing images was used to extract winter wheat at the tillering stage.
- [15]. Feng, G., Gu, Y., Wang, C., Zhang, D., Xu, R., Zhu, Z., ... (2025). Wheat Fusarium head blight severity grading using generative adversarial networks and semi-supervised segmentation. *Computers and Electronics in Agriculture*.
<https://www.sciencedirect.com/science/article/pii/S0168169924012080>.
۷. انتشار عمومی کد و داده‌ها: کد منبع کامل، وزن‌های آموزش‌دیده مدل و اسکریپت‌های تکرار نتایج در مخزن زیر به صورت عمومی منتشر شده است:
<https://github.com/Somayeh-sys/somayeh1369>

۷- مراجع

- [1]. Wang, X., Li, C., Zhao, C., Jiao, Y., Xiang, H., Wu, X., & Chai, H. (2025). *GrainNet: Efficient detection and counting of wheat grains based on an improved YOLOv7 modeling*. *Plant Methods*, 21(1), Article62. <https://doi.org/10.1186/s13007-025-01363-y>.
- [2]. Gao, Q., Li, H., Meng, T., Xu, X., Sun, T., Yin, L., & Chai, X. (2024). *A rapid construction method for high-throughput wheat grain instance segmentation dataset using high-resolution images*. *Agronomy*, 14(5), 1032.
<https://doi.org/10.3390/agronomy14051032>.
- [3]. Zhang, Q., Li, H., Meng, T., & Chai, X. (2023). *Automatic dataset construction for wheat grain segmentation using Grounding DINO and SAM*. *Computers and Electronics in Agriculture*, 208, 107894.
<https://doi.org/10.1016/j.compag.2023.107894>.
- [4]. Wang, Y. H., & Su, W. H. (2022). *Convolutional neural networks in computer vision for grain crop phenotyping: A review*. *Frontiers in Plant Science*, 13, 955918.
<https://doi.org/10.3389/fpls.2022.955918>.
- [5]. Shen, R., Zhen, T., & Li, Z. (2023). *Segmentation of unsound wheat kernels based on improved Mask R-CNN*. *Foods*, 12(7), 1503.
<https://doi.org/10.3390/foods12071503>.
- [6]. Wang, Q., Qin, W., Liu, M., Zhao, J., Zhu, Q., & Yin, Y. (2024). *Semantic segmentation model-based boundary line recognition method for wheat harvesting*. *Agriculture*, 14(10), 1846.
<https://doi.org/10.3390/agriculture14101846>.
- [7]. Lü, Z., Wang, Y., & Sun, F. (2023). *Identification and detection of wheat kernels with different volume weights based on an improved U-Net*. *Journal of Henan Agricultural Sciences*, 52(10), 131–139.
<https://doi.org/10.15933/j.cnki.1004-3268.2023.10.015>.



دکتر ام‌الکثوم شهریاری، عضو هیئت علمی دانشگاه آزاد اسلامی واحد سنندج و دارای دکتری مهندسی کامپیوتر-گرایش نرم‌افزار از دانشگاه آزاد اسلامی واحد قزوین در سال ۱۳۹۹ می‌باشد. استاد راهنمای ایشان دکتر حسین پدرام

از دانشگاه صنعتی امیرکبیر بوده و زمینه رساله دکتری ایشان بهبود برونسپاری پردازش در رایانش ابری-لبه‌ای است. وی دارای مدرک کارشناسی ارشد مهندسی کامپیوتر-گرایش هوش مصنوعی از دانشگاه کردستان (۱۳۹۰) با پایان‌نامه نهان‌نگاری امن پرطرفیت تصاویر دیجیتال و مدرک کارشناسی مهندسی کامپیوتر-گرایش نرم‌افزار از دانشگاه تربیت معلم تهران (خوارزمی) (۱۳۸۶) با پایان‌نامه متن‌کاوی با استفاده از SVM می‌باشد.



دکتر وفا میهمی، استادیار و رئیس دانشکده فنی دانشگاه آزاد اسلامی واحد سنندج، کارشناسی خود را در رشته مهندسی کامپیوتر-گرایش نرم‌افزار و سپس کارشناسی ارشد را در دانشگاه کردستان و دکترای تخصصی را در

شاخه هوش مصنوعی از دانشگاه سمنان اخذ کرده‌اند. ایشان به عنوان پژوهشگر برتر دانشکده در سال ۱۴۰۰ و پژوهشگر برتر پنج ساله در سال ۱۳۹۸ انتخاب شده‌اند. تخصص‌های پژوهشی ایشان شامل پردازش تصویر، بینایی کامپیوتر، بازیابی اطلاعات و هوش مصنوعی می‌باشد.

- [16]. Singh, G., Al-Huqail, A. A., Almogren, A., (2025). Enhanced Leaf Disease Segmentation Using U-Net Architecture for Precision Agriculture: A Deep Learning Approach. Food Science & Nutrition. <https://onlinelibrary.wiley.com/doi/abs/10.1002/fsn3.70594>.
- [17]. Zhang, S., Liu, L., Li, G., Du, Y., Wu, X., Song, Z., Li, X. (2025). Diffusion model-based image generative method for quality monitoring of direct grain harvesting. Computers and Electronics in Agriculture. <https://www.sciencedirect.com/science/article/pii/S0168169925002364>.
- [18]. Xu, X., Gao, Y., Fu, C., Qiu, J., Zhang, W. (2024). Research on the Corn Stover Image Segmentation Method via an Unmanned Aerial Vehicle (UAV) and an Improved U-Net Network. Agriculture, 14(2), 217. <https://www.mdpi.com/2077-0472/14/2/217>.
- [19]. Liu, Q., Liu, W., Liu, Y., Zhe, T., Ding, B., Liang, Z. (2023). Rice grains and grain impurity segmentation method based on a deep learning algorithm-NAM-EfficientNetv2. Computers and Electronics in Agriculture. <https://www.sciencedirect.com/science/article/pii/S0168169923002120>.
- [20]. somayeh1369. (2025). Som1: A Hugging Face Space for wheat quality assessment using an improved U-Net model. Retrieved August 20, 2025, from <https://huggingface.co/spaces/somayeh1369/som1>.



سمیه رنجبر دانشجوی دکتری هوش مصنوعی در دانشگاه آزاد واحد سنندج است. ایشان دارای مدرک کارشناسی از جهاد دانشگاهی کرمانشاه و مدرک کارشناسی ارشد از دانشگاه علوم تحقیقات کرمانشاه می‌باشد. زمینه‌های تحقیقاتی

ایشان شامل یادگیری ماشین، یادگیری عمیق، پردازش داده‌های بزرگ و بینایی ماشین می‌باشد. علاقه‌مندی‌های پژوهشی وی تمرکز بر توسعه الگوریتم‌های نوین هوش مصنوعی و کاربرد آن‌ها در تحلیل داده‌های پیچیده است.