

Stress Field Prediction Using Conditional Generative Adversarial Networks and Image Processing in a Perforated Plate under Static Loading

Behnam Anbarlooie*^{id}, Melika Maleki Rad

Faculty of New Technologies and Aerospace Engineering, Shahid Beheshti University, Tehran, Iran

ARTICLE INFO

Article Type

Original Research

Article History

Received: August 18, 2025

Revised: November 30, 2025

Accepted: November 30, 2025

ePublished: December 09, 2025

ABSTRACT

The study of the mechanical properties and behavior of materials, as well as stress and strain fields, has been carried out using methods such as experiments, numerical methods, and precise mathematical solutions over the decades. In recent years, machine learning, and especially deep learning, have become one of the most commonly used methods in various engineering fields. One of its important applications is the prediction of material behavior in numerous structures. These methods have drawn significant attention due to their rapid execution, apposite accuracy, and implementation convenience, and are used as an alternative or supplementary tool for traditional analysis methods. Using the machine learning method, in case the problems are properly characterized, they can provide a much more powerful tool in a machine learning process compared to other tools. The purpose of this paper is to predict the stress field and maximum stress on a perforated plate under static loading using a deep learning method based on a conditional adversarial generative network (CGANs) and to quantify the results using an image processing method. Also, at the end, the numerical results obtained from this model are extracted and compared with the results attained from finite element analysis to evaluate the accuracy of the proposed model.

Keywords: Stress Field, Machine Learning, Image Processing, Finite Element Method

How to cite this article

Anbarlooie B, Maleki Rad M, Stress Field Prediction Using Conditional Generative Adversarial Networks and Image Processing in a Perforated Plate under Static Loading. Modares Mechanical Engineering; 2025;25(12):801-818.

*Corresponding author's email: b_anbarloei@sbu.ac.ir

*Corresponding ORCID ID: 0000-0002-0945-0548



Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.



شاپا: ۷۹۰۹-۲۴۷۷؛ مهندسی مکانیک مدرس. ۸۱۸-۸۰۱:۱۲(۱۴):۱۴۰۴

مهندسی مکانیک مدرس

DOI: 10.48311/mme.2025.96917.0

صفحه اصلی مجله: mme.modares.ac.ir



پیش‌بینی میدان تنش با استفاده از شبکه مولد تخصصی شرطی و پردازش تصویر در یک صفحه سوراخ‌دار تحت بارگذاری استاتیکی

بهنام انبارلویی*^{ID}، ملیکا ملکی راد

دانشگاه شهید بهشتی، دانشکده فناوری های نوین و مهندسی هوافضا

چکیده

بررسی خواص و رفتار مکانیکی مواد و میدان‌های تنش و کرنش از روش‌هایی مانند آزمایش‌های تجربی، شبیه‌سازی‌های عددی و حل دقیق ریاضی صورت می‌پذیرد. در سال‌های اخیر، یادگیری ماشین و به‌ویژه یادگیری عمیق به یکی از روش‌های پرکاربرد در حوزه‌های مختلف مهندسی تبدیل شده‌اند. یکی از کاربردهای مهم آن، پیش‌بینی رفتار مواد در سازه‌های مختلف است. این روش‌ها به دلیل سرعت بالا، دقت مناسب و سهولت در پیاده‌سازی، توجه ویژه‌ای را به خود جلب کرده‌اند و به‌عنوان جایگزین یا ابزار کمکی برای روش‌های سنتی تحلیل مورد استفاده قرار می‌گیرند و با استفاده از فرایند یادگیری ماشین در صورت مشخصه‌سازی صحیح مسائل می‌توانند در یک فرایند یادگیری ماشین‌ایزاری به‌مراتب قوی‌تر از ابزارهای پیشین فراهم سازند. هدف از این مقاله، پیش‌بینی میدان تنش و حداکثر تنش وارده بر یک صفحه سوراخ‌دار تحت بارگذاری استاتیکی با استفاده از روش یادگیری عمیق مبتنی بر شبکه مولد تخصصی شرطی و کمی‌سازی نتایج با استفاده از روش پردازش تصویر است. همچنین در پایان، نتایج عددی به‌دست‌آمده از این مدل استخراج شده و با نتایج حاصل از تحلیل اجزاء محدود مقایسه می‌گردد تا میزان دقت مدل پیشنهادی مورد ارزیابی قرار گیرد.

اطلاعات مقاله

نوع مقاله

مقاله پژوهشی

تاریخچه مقاله

دریافت: ۱۴۰۴/۰۵/۲۷

بازنگری: ۱۴۰۴/۰۹/۰۹

پذیرش: ۱۴۰۴/۰۹/۰۹

ارائه آنلاین: ۱۴۰۴/۰۹/۱۸

کلیدواژه‌ها: میدان تنش - یادگیری ماشین - پردازش تصویر - روش اجزای محدود

نحوه ارجاع به این مقاله

انبارلویی بهنام، ملکی راد ملیکا، پیش‌بینی میدان تنش با استفاده از شبکه مولد تخصصی شرطی و پردازش تصویر در یک صفحه سوراخ‌دار تحت بارگذاری استاتیکی، مهندسی مکانیک مدرس. ۸۱۸-۸۰۱:۱۲(۱۴):۱۴۰۴.

*پست الکترونیکی نویسنده عهده‌دار مکاتبات: b_anbarloei@sbu.ac.ir

*شناسه اراکید نویسنده عهده‌دار مکاتبات: ۰۰۰۰-۰۰۰۲-۰۹۴۵-۰۵۴۸



Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.

۱- مقدمه

شبکه مولد تخصصی^۱، یکی از روش‌های یادگیری عمیق بدون نظارت است که برای اولین بار توسط یان گودفلو و همکاران [۱] معرفی شد. ایده اولیه آن، بر مبنای نمایش داده‌های اولیه توسط کاربر برای مدل، و تولید داده توسط مدل بر اساس پراکندگی داده‌های ورودی شکل گرفته است. به عنوان مثال، پس از نمایش تصاویر تعدادی ساختمان به مدل، بتواند تصویر یک ساختمان جدید غیرتکراری و واقع‌گرایانه برای ما تولید کند. استفاده عملی از شبکه‌های مولد تخصصی از سال ۲۰۱۷ آغاز شد که از این فناوری برای ارتقای کیفیت تصاویر چهره انسان‌ها به کار گرفته شد و توانست با افزایش وضوح و جزئیات، تصاویری طبیعی‌تر و با کیفیتی بالاتر ارائه دهد [۲]. کارکرد این مدل را می‌توان به شکل دو شبکه تفسیر کرد که وظیفه یکی از آن‌ها، جعل تصویر (مولد)^۲، و دیگری تشخیص‌دهندگی (متمايزگر)^۳ است. [۳]

در زمینه تحلیل رفتار مکانیکی مواد، رونه‌برگه^۴ و همکارانش [۴] با معرفی معماری یونت^۵ نقش مهمی در گسترش استفاده از شبکه‌های کانولوشنی در پردازش تصویر ایفا کردند. به علت توانایی بالای این معماری در استخراج ویژگی‌های محلی و حفظ جزئیات تصویر، عملکرد مناسبی در بازسازی میدان‌های تنش و کرنش دارد. ترکیب مولد با شبکه‌های مولد تخصصی به بازسازی دقیق‌تر این میدان‌ها کمک می‌کند و آن را به ابزاری موثر در این کار تبدیل کرده است.

نی و همکاران [۱۳] در پژوهشی دیگر، رویکردی مبتنی بر یادگیری عمیق را برای پیش‌بینی میدان تنش در تغییر شکل الاستیک مواد جامد معرفی کردند. هدف اصلی آنها توسعه یک مدل کارآمد و دقیق با استفاده از شبکه‌های عصبی پیچشی برای جایگزینی یا تکمیل روش‌های محاسباتی سنتی مانند روش اجزا محدود بود. ژائو و همکارانش [۱۴] با هدف پیش‌بینی میدان کرنش و ارزیابی خطر شکست سازه‌ای، یک رویکرد یادگیری عمیق مبتنی بر شبکه‌های مولد تخصصی بهبود یافته را برای اتصالات دال پل پیش‌ساخته پیشنهاد کردند. این کار در راستای گسترش کاربرد روش‌های یادگیری عمیق در پیش‌بینی میدان‌های تنش و کرنش سازه‌ها، به ویژه برای شرایطی است که داده‌های آموزشی کافی یا کامل برای آن‌ها موجود نیست. شبانگ و همکاران [۱۵] برای پیش‌بینی میدانی رفتار مکانیکی فرا مواد مکانیکی ساختاریافته، یک مدل جایگزین مبتنی بر شبکه مولد تخصصی پیشنهاد کردند. ساهو و همکارانش [۱۶] باهدف تسریع طراحی کامپوزیت‌های جدید با عملکرد بالا و کاهش نیاز به آزمایش‌های پرهزینه و


شبیه‌سازی‌های پیچیده، یک مدل یادگیری عمیق به نام شبکه مولد تخصصی گرافی را معرفی کردند که با استفاده از دانش علم مواد، برای پیش‌بینی میدان‌های تغییر شکل از طرح‌های جدید کامپوزیتی توسعه یافته است. لیو و همکاران [۱۷] یک چارچوب یادگیری عمیق جدید را برای پیش‌بینی میدان‌های تنش با دقت بالا در مفاصل پیچی کامپوزیتی معرفی کردند. همچنین هوی و همکاران [۱۸] به بررسی یک مدل یادگیری عمیق مبتنی بر شبکه مولد تخصصی شرطی را برای ارزیابی و پیش‌بینی سریع تنش پسماند ناشی از پخت در کامپوزیت‌ها پرداخته‌اند. آمیگمن و همکاران [۱۹] هم یک الگوریتم نوین مولد تخصصی را برای تشخیص ترک، ترسیم دقیق ظاهر ترک و پیش‌بینی الگوهای رشد ترک در کامپوزیت‌های سیمانی مهندسی شده معرفی کردند. افزون بر این موارد جیانگ و همکارانش [۲۰] نیز برای مقابله با چالش‌های پیش‌بینی عمر خستگی فولاد زنگ‌زن آستنیتی ۳۱۶ در شرایط سخت (زیر آب با دما و فشار بالا) یک مدل ارائه کرده‌اند که بر مبنای یک ساختار یادگیری عمیق است و از شبکه‌های مولد تخصصی شرطی استفاده می‌کند.

در پژوهشی که توسط یانگ و همکارانش [۵] انجام شد، از یک مدل شبکه مولد تخصصی برای پیش‌بینی میدان‌های تنش و کرنش در مواد کامپوزیتی بهره برده شد. در این مدل فقط با داشتن اطلاعات مربوط به هندسه ماده، بدون نیاز به دانستن شرایط مرزی یا بارگذاری، توزیع تنش و کرنش مورد پیش‌بینی انجام می‌گرفت. در طراحی این مدل، از معماری یونت برای تولید تصویر میدان تنش استفاده شد و برای ارزیابی دقت پیش‌بینی نیز ساختار پیچ‌گن^۶ به کار رفت. نتایج کلی نشان داد که مدل در بازسازی میدان تنش دقت نسبتاً بالایی دارد؛ به‌طوری‌که ضریب تعیین^۷ بین پیش‌بینی مدل و خروجی تحلیل اجزای محدود حدود ۰/۹۶ گزارش شده است. همچنین، مدل در شناسایی نواحی حساس و نقاطی که احتمال تمرکز تنش در آن‌ها بیشتر است، عملکرد قابل قبولی داشت.

در این پژوهش، از مدلی با رویکرد و ساختار متفاوتی در تحلیل مسئله استفاده شده است. ابتدا با توسعه کد و برنامه‌نویسی در نرم‌افزار انسیس^۸، پایگاه‌داده برای هر هندسه‌ای و میدان تنش متناظر آن و حداکثر تنش وارد شده بر جسم به‌دست آمده و سپس جفت تصاویری از هندسه و میدان تنش ساخته شده و مدل شبکه مولد تخصصی شرطی تحت آموزش قرار می‌گیرد تا آموزش ماشین برای ارتباط بین این دو ایجاد شود.

ایده اصلی روش بازسازی میدان تنش مبتنی بر شبکه مولد تخصصی شرطی این است که شبیه‌سازی میدان تنش به‌عنوان یک مسئله تولید تصویر در نظر گرفته شود [۶]. یعنی به جای استفاده

به‌روزرسانی در متمایزگر بر اساس سیستم صفر و یک انجام می‌شود؛ مثلاً به تمامی تصاویر واقعی، عدد یک و به تصاویر جعل شده، عدد صفر اختصاص داده می‌شود. هر بار که یک تصویر جعلی، واقعی و یا تصویر واقعی، جعلی تشخیص داده شود، یک خطا محسوب می‌شود. همچنین به‌روزرسانی مولد بر اساس تعداد دفعاتی که متمایزگر واقعی نبودن تصویر تولید شده را متوجه شود، انجام می‌گیرد تا بتواند متمایزگر را فریب دهد. شکل ۱، روندنمای فرایند آموزش شبکه مولد تخصصی را نشان می‌دهد که تولید نمونه‌ها توسط مولد، ارزیابی آن‌ها توسط متمایزگر و به‌روزرسانی هر دو مدل را شامل می‌شود.



شکل ۱ روندنمای فرایند آموزش شبکه مولد تخصصی: تولید نمونه‌ها توسط مولد، ارزیابی آن‌ها توسط متمایزگر، و به‌روزرسانی متقابل مدل‌ها

Fig.1 Flowchart of the training process of a Generative Adversarial Network (GAN): sample generation by the generator, evaluation by the discriminator, and mutual updating of both models

۲-۲- شبکه مولد تخصصی شرطی

همان‌طور که گفته شد، شبکه مولد تخصصی، یک روش یادگیری عمیق بدون نظارت محسوب می‌شود. این نوع شبکه، هیچ کنترلی بر داده‌های تولید شده ندارد، اما یک شبکه مولد تخصصی شرطی، شرط اضافی برای مدیریت فرایند تولید داده ارائه می‌کند. اگر برچسب‌هایی به‌عنوان محدودیت در مدل گنجانده شوند، یک زیرگروه از شبکه‌های مولد تخصصی به نام شبکه مولد تخصصی شرطی خواهیم داشت. در شبکه‌های مولد تخصصی شرطی یک پارامتر اضافی برای تولید داده‌های مربوطه به مولد اضافه شده، برچسب‌ها به‌عنوان ورودی به متمایزگر تغذیه می‌شوند تا به تشخیص داده‌های واقعی از داده‌های جعلی تولید شده کمک کنند. مزیت نوع شرطی این است که شبکه‌های مولد تخصصی در مرحله آموزش بی‌ثبات هستند، اما شبکه‌های مولد تخصصی شرطی به علت وجود محدودیت برای برچسب‌های ورودی، نسبتاً پایدارتر هستند. همان‌گونه که در شکل ۲ (روندنمای فرایند آموزش شبکه مولد تخصصی شرطی) مشاهده می‌شود، در مدل مولد تخصصی شرطی علاوه بر بردار ورودی تصادفی، یک شرط یا برچسب به مولد وارد می‌شود و پس از تولید نمونه، این نمونه‌ها به همراه نمونه‌های

از روش‌های سنتی برای محاسبه تنش‌ها، از یک مدل هوش مصنوعی استفاده می‌شود که چگونگی جزئیات محلی و پیچیده تنش‌ها را شناسایی و بازسازی کرده و در این باب یادگیری ماشین رقم می‌خورد، به‌طوری که خروجی آن به میدان واقعی تنش شبیه باشد و کیفیت بالایی داشته باشد.

تفاوت اصلی این پروژه با کار انجام شده توسط یانگ و همکارانش [۵] در ایجاد عامل تمرکز تنش، هندسه مدل، رفتار مادی و شیوه ارزیابی نتایج است. در پژوهش یانگ، مقایسه به‌صورت تصویری در یک صفحه با هندسه مربعی انجام شده و تمرکز بیشتر روی شباهت کلی بین میدان تنش پیش‌بینی شده و خروجی نرم‌افزار اجزا محدود بود؛ اما در این پروژه، علاوه بر ایجاد مجموعه داده مستقل و مقایسه تصویری و کیفی در یک صفحه سوراخ‌دار به‌منظور بررسی عامل تمرکز تنش، مقدار عددی بیشینه تنش با استفاده از روش پردازش تصویر از خروجی مدل استخراج شده و به‌صورت کمی با مقدار متناظر در تحلیل اجزا محدود مقایسه شده است. این نوع ارزیابی، امکان بررسی نتایج را به‌صورت کمی و با استفاده از ابزار یادگیری ماشین و از دیدگاه مهندسی فراهم کرده و درک فیزیکی بهتری از عملکرد مدل ارائه می‌دهد. به‌طورکلی، این پروژه ضمن استفاده از مدل شبکه مولد تخصصی با ساختاری ساده‌تر، توجه بیشتری به تحلیل عددی و ارزیابی ملموس‌تر نتایج داشته است. بالاین‌حال، یکی دیگر از اهداف نهایی این مطالعه، پیش‌بینی میدان تنش بدون نیاز به استفاده از تحلیل اجزا محدود و مبتنی بر روش یادگیری ماشین است.

۲- روش شناسی

۲-۱- شبکه مولد تخصصی

کارکرد شبکه مولد تخصصی را می‌توان به شکل دو شبکه تفسیر کرد که وظیفه یکی از آن‌ها، جعل تصویر (مولد)، و دیگری تشخیص‌دهندگی (متمایزگر) است. یکی از شبکه‌ها سعی در جعل و دیگری سعی در تشخیص تصویر جعل شده از تصویر واقعی دارد و برای ساخت تصویر، این دو شبکه باید با یکدیگر رقابت کنند [7]. با هر بار انجام رقابت، هم شبکه مولد و هم شبکه متمایزگر دچار بهبود و پیشرفت عملکردی می‌شوند. در حالت کلی، ابتدا یک ورودی تصادفی (مثلاً با استفاده از نویز) به مدل داده می‌شود. سپس یک تصویر با ابعاد مشابه تصویر واقعی توسط مولد تولید می‌شود و به متمایزگر داده می‌شود. در این مرحله، متمایزگر تصاویر خروجی مولد را با تصاویر واقعی مقایسه کرده و در صورتی که تصویر تولید شده توسط متمایزگر تایید نشود، متمایزگر بازخوردی به مولد ارسال کرده و این موضوع را اعلام می‌کند. مولد هم پس از دریافت بازخورد سعی می‌کند با تکرار این روند، تصاویری شبیه‌تر به تصویر واقعی تولید کند. متمایزگر نیز در هر تکرار سعی می‌کند قدرت خود در تشخیص تصویر واقعی از تصویر جعلی را افزایش دهد. مدل با هر بار انجام مقایسه، یک بار به‌روزرسانی می‌شود. این

جزئیات و سوق‌دادن مدل به سمت یادگیری ساختارهای با بسامد بالا، متمایزگر شبکه مولد تخصصی محدود می‌شود تا تنها بر روی ساختارهای محلی تصویر تمرکز کند. این امر به وسیله تعریف بردارهای کوچک محلی از تصویر، به نام پیچ^۳ انجام می‌گیرد که هر کدام به صورت یک ناحیه مربعی کوچک تعریف می‌شوند و براین اساس، معماری متمایزگری به نام پیچ‌گن معرفی می‌شود که وظیفه تشخیص واقعی یا جعلی بودن هر پیچ از تصویر را بر عهده دارد. این متمایزگر به صورت پیچشی در سراسر تصویر اعمال شده و خروجی نهایی آن از طریق میانگین‌گیری پاسخ‌های مربوط به تمامی پیچ‌ها حاصل می‌گردد. همچنین ابعاد پیچ به ابعاد تصویر ورودی وابسته است [۱۲].

روند انجام کار به این صورت است که ابتدا تصاویر هندسی (برچسب‌ها یا محدودیت‌ها) به دودسته آموزشی و آزمایشی تقسیم شده و به مولد وارد می‌شوند. متمایزگر، تصاویر تولید شده توسط مولد را با تصاویر واقعی به دست آمده از نرم‌افزار اجزا محدود، مقایسه و ارزیابی می‌کند. سپس همان‌طور که توضیح داده شد، یادگیری مدل انجام می‌شود. این عمل تا جایی ادامه داد که متمایزگر و مولد به تعادل برسند و نتیجه نهایی نمایش داده شود.

۳- نتایج و یافته‌ها

در این پژوهش، با استفاده از کتابخانه تنسورفلو، یک مدل یادگیری عمیق در یک شبکه مولد تخصصی شرطی پیاده‌سازی شده است و دو مجموعه داده متشکل از تصاویر جفت شده به عنوان محدودیت برای شبکه قرار داده می‌شود. این مجموعه داده، به شکل تصاویری جفت شده از هندسه جسم مورد آزمایش و میدان تنش متناظر آن هندسه تشکیل شده است.


۳-۱- رویکرد یادگیری عمیق

این مدل با استفاده از یک کارت گرافیک رادئون با ۳۲۰ مگابایت حافظه اختصاصی و تا ۱۶ گیگابایت حافظه اشتراکی آموزش داده شده است. تعداد دوره‌های آموزشی ۵۰ و اندازه دسته برابر با ۱ است. تعداد دوره آموزشی به شکلی تنظیم شده تا مدل به اندازه کافی آموزش ببیند و همچنین دچار بیش‌برازش نشود. برای تعیین تعداد مناسب دوره‌های آموزشی، آموزش مدل چند بار با دوره‌های آموزشی متفاوت به شکل صعودی تکرار شده و تا رسیدن به نتایج قابل قبول بصری ادامه پیدا کرد. انکدر و دیکدر مولد هر کدام ۹ لایه (شامل لایه ورودی و خروجی) دارند. تعداد کل پارامترهای قابل آموزش مولد حدود ۵۴ میلیون است.

تابع هزینه مولد به صورت زیر تعریف شده است:

$$\text{هزینه ال} = 1 \times \lambda + \text{هزینه گن} = \text{هزینه کل مولد}$$

واقعی به مدل متمایزگر ارائه می‌گردند و هر دو مدل تا همگرایی به روزرسانی می‌شوند.



شکل ۲ روند فرایند آموزش شبکه مولد تخصصی شرطی: بردار ورودی تصادفی و برچسب شرطی به مولد؛ تولید نمونه؛ ارائه نمونه‌های تولیدی همراه با داده‌های واقعی به متمایزگر؛ ارزیابی و به روزرسانی متقابل تا همگرایی

Fig.2 Flowchart of the training process of a Conditional Generative Adversarial Network (cGAN): random input vector and conditional label to the generator, sample generation, generated samples combined with real samples provided to the discriminator, evaluation by the discriminator, and mutual updating of both models


۲-۳- تنسورفلو

تنسورفلو^۴ یک کتابخانه منبع باز [۸] برای یادگیری ماشین است که قابلیت آموزش داده و اجرا بدون نیاز به بازنویسی کد بر روی واحدهای پردازش گرافیکی، واحدهای پردازش مرکزی و واحدهای پردازش تنسور در پلتفرم‌های مختلف، از دستگاه‌های قابل حمل گرفته تا رایانه‌ها و سرورهای پیشرفته را دارد. این سیستم که در ابتدا توسط تیم گوگل به منظور انجام تحقیقات یادگیری ماشینی و شبکه‌های عصبی عمیق توسعه یافته بود، در طیف گسترده‌ای از حوزه‌های دیگر نیز قابل استفاده است. از تنسورفلو می‌توان برای توسعه مدل‌هایی برای کارهای مختلف از جمله پردازش زبان طبیعی، تشخیص تصویر، تشخیص دست‌خط و شبیه‌سازی‌های مختلف مبتنی بر محاسباتی مانند معادلات دیفرانسیل جزئی استفاده کرد.

در حالت کلی، این مدل، دو جزء کلیدی دارد:

مولد یونت^۱: یک مدل شبکه عصبی عمیق است که در زمینه‌های مختلفی مانند دسته‌بندی تصاویر پزشکی، ماهواره‌ای و هوایی و بینایی ماشین در رباتیک کاربرد دارد [۹-۱۱]. مولد یونت از دو بخش انکدر و دیکدر با اتصالات جهشی بین لایه‌های متقارن تشکیل شده است.

متمایزگر پیچ‌گن^۱: در بسیاری از مسائلی که در آن‌ها به دنبال تولید تصویر هستیم، استفاده از توابع زبان سنتی منجر به تولید تصاویر تار و فاقد جزئیات دقیق می‌شود، زیرا این توابع قادر به تشویق وضوح و جزئیات بسامد بالا نیستند. به منظور بهبود کیفیت



شکل ۳ شبیه‌سازی صفحات سوراخ‌دار دوبعدی با شرایط بارگذاری یکسان: (a) نقشه رنگ سفارشی پلازما شامل ۱۲۸ رنگ، (b) نقشه رنگ پیش‌فرض نرم‌افزار شامل ۸ رنگ

Fig.3 Simulation of two-dimensional perforated plates under identical loading conditions: (a) default ANSYS APDL colormap with 8 discrete colors, (b) customized plasma colormap with 128 colors

برای تهیه این تصاویر، ابتدا مجموعه‌ای از صفحات سوراخ‌دار دوبعدی با هندسه‌های متفاوت در یکی از نرم‌افزارهای اجزا محدود، یک بار با نقشه رنگ پیش‌فرض نرم‌افزار متشکل از ۸ رنگ (Error! Reference source not found. و بار دیگر با یک نقشه رنگ سفارشی بر اساس طیف رنگی پلازما که حاوی ۱۲۸ رنگ است شبیه‌سازی شده (Error! Reference source not found. و سپس تحت بارگذاری در شرایط یکسانی قرار می‌گیرند تا میدان تنش اعمالی بر روی آن‌ها به‌عنوان خروجی ذخیره شوند. در نهایت، ۲۲۵۰ تصویر تولید شده برای مجموعه داده اول و و در نهایت ۱۵۱۶ تصویر برای مجموعه داده دوم به شکل تصاویر جفت شده آماده‌سازی می‌شوند و به شکل جداگانه به‌عنوان مجموعه‌داده در اختیار برنامه یادگیری عمیق قرار می‌گیرند. از مجموعه‌داده اول، نتایج کیفی و مجموعه‌داده دوم، نتایج کمی استخراج می‌شود.

۳-۱- نتایج کیفی

این نتایج با استفاده از مجموعه‌داده تهیه شده توسط نقشه رنگ پیش‌فرض نرم‌افزار حاصل می‌شوند به‌طوری که مجموعه‌داده مربوطه (مجموعه‌داده اول) در اختیار برنامه یادگیری عمیق قرار می‌گیرد.

در اینجا، هزینه گن به معنای تابع خطای متقاطع سیگموئید است که بین تصاویر تولیدشده توسط مدل و یک آرایه‌ای از عدد یک محاسبه می‌شود. این تابع خطا نشان می‌دهد که مدل چقدر در فریب‌دادن متمایزگر موفق بوده است. زیرا آرایه‌ای از عدد یک به این معناست که مدل می‌خواهد تصاویر تولیدی‌اش به‌قدری واقعی به نظر برسند که تمایزدهنده آن‌ها را به‌عنوان تصاویر واقعی تشخیص دهد.

هزینه ال ۱ به معنای میانگین قدرمطلق اختلاف بین تصویر تولید شده و تصویر هدف است. این معیار کمک می‌کند تا مدل، تصاویر تولیدی را از نظر شباهت پیکسلی به تصاویر واقعی نزدیک‌تر کند. همچنین λ یک ضریب وزنی است که برابر با مقدار استاندارد ۱۰۰ در نظر گرفته شده است [۸]. این ضریب مشخص می‌کند که میزان اهمیت هزینه ال ۱ نسبت به هزینه گن چقدر است. به عبارت دیگر، λ تعیین می‌کند که مدل تا چه اندازه باید روی شباهت پیکسلی با تصویر واقعی تمرکز کند. متمایزگر پیچ‌گن شامل ۵ لایه است و حدود ۳۴ میلیون پارامتر قابل آموزش دارد. این متمایزگر تصویر را به پیچ‌های 30×30 پیکسلی تقسیم کرده و هر پیچ را به طور مستقل به‌عنوان واقعی یا جعلی طبقه‌بندی می‌کند. تابع هزینه متمایزگر به‌صورت زیر است:

$$\text{هزینه جعلی} + \text{هزینه واقعی} = \text{هزینه کل مولد}$$

در اینجا، هزینه واقعی به معنای تابع خطای متقاطع سیگموئید بین تصاویر واقعی و آرایه‌ای از عدد یک است. این یعنی مدل متمایزگر باید تصاویر واقعی را به‌درستی به‌عنوان واقعی تشخیص دهد، چون برچسب هدف برای تصاویر واقعی، عدد یک است. از طرف دیگر، هزینه جعلی نیز یک تابع خطای متقاطع سیگموئید است که بین تصاویر تولیدشده توسط مولد و آرایه‌ای از عدد صفر محاسبه می‌شود. این یعنی تمایزدهنده باید تصاویر تولیدی را به‌درستی به‌عنوان "جعلی" یا "غیرواقعی" تشخیص دهد، چون برچسب هدف برای آن‌ها صفر است. بهینه‌سازی هر دو شبکه مولد و متمایزگر با استفاده از الگوریتم آدام و با نرخ یادگیری ثابت 2×10^{-4} و پارامتر $\beta_1 = 0.5$ انجام شد که مطابق با تنظیمات استاندارد [۸] است.

3- ساخت مجموعه‌داده

این مجموعه‌داده، به شکل تصاویری جفت شده از هندسه جسم مورد آزمایش و میدان تنش متناظر آن هندسه و با استفاده از نرم‌افزار تجاری انسیس تولید شده است. در این پژوهش، میدان‌های تنش که توسط روش اجزای محدود تولید شده‌اند، به‌عنوان داده مرجع برای مقایسه با نتایج مدل یادگیری ماشین در نظر گرفته می‌شوند. تمام شبیه‌سازی‌ها در فضای دوبعدی انجام شده‌اند.

این کد در نرم‌افزار، برای تمامی این حالت‌ها، تصویر هندسه و میدان تنش متناظر ذخیره می‌شود. سپس با استفاده از کد پایتون، این تصاویر در ابعاد 512×512 پیکسل برش داده شده و با در کنار هم قرار دادن تصویر هر میدان تنش به هندسه متناظر آن، مجموعه داده‌ای از تصاویر جفت شده خواهیم داشت.


Error! Reference source not found. یک نمونه تصویر جفت‌شده از مجموعه داده با نقشه رنگ پیش‌فرض نرم‌افزار را نشان می‌دهد. باید توجه شود که مدل‌هایی با سوراخ خیلی نزدیک به مرزهای کناری، به علت رفتار غیریکنواخت از مجموعه داده حذف می‌شوند و در نهایت تعداد ۲۰۱۶ تصویر هندسه و میدان تنش با نقشه رنگی پیش‌فرض نرم‌افزار به صورت جداگانه با نسبت ۸۰:۲۰ به دودسته آموزش و آزمون دسته‌بندی شده و ۱۶۱۲ تصویر در پوشه آموزش و ۴۰۴ تصویر در پوشه آزمون قرار می‌گیرد.

این تصاویر به عنوان ورودی به کد وارد می‌شوند. پس از اتمام مراحل آموزش و آزمون، یک هندسه دیگر را برای انجام پیش‌بینی به کد وارد می‌کنیم و برنامه توسعه داده شده، بر اساس نمونه‌های پایگاه داده، میدان تنش را برای هندسه‌های موردنظر پیش‌بینی می‌کند. همان‌طور که در **Error! Reference source not found.** مشاهده می‌شود، میدان تنش پیش‌بینی شده با یادگیری عمیق انطباق قابل قبولی با نتایج تحلیل اجزا محدود دارد. ۷- نتایج کمی

۱-۷- ساخت مجموعه داده و آموزش مدل

در این بخش، از مجموعه داده اول با نقشه رنگ سفارشی با طیف رنگی پلاسم استفاده می‌شود. هدف از این کار، استخراج نتایج عددی با استفاده از پردازش تصویر، از میدان تنش پیش‌بینی شده توسط روش یادگیری ماشین و مقایسه آن با نتایج به دست آمده از روش اجزا محدود و بررسی درصد خطای نتایج است.

مشابه روند طی شده برای مشاهده نتایج به صورت کیفی، در این بخش هم برای تهیه تصاویر ابتدا یک صفحه دوبعدی به ابعاد واحد با سوراخ دایروی به شعاع ۳۵ میلی‌متر از یک ماده ایزوتروپیک با خاصیت الاستیک خطی، با مدول الاستیسیته $E_x = 200 \text{ GP}$ و ضریب پواسون ۰/۳ در نرم‌افزار انسیس مدل‌سازی شده و سپس حرکت این یک صفحه از ضلع پایینی با یک تکیه‌گاه گیردار محدود می‌شود و به ضلع بالایی، یک جابجایی قائم به اندازه ۰/۰۵ متر اعمال و سپس با انجام مش‌زنی و حل مسئله، تصویر میدان تنش ذخیره می‌شود. در **Error! Reference source not found.** دو خروجی مربوط به تحلیل هر هندسه قابل مشاهده است.




شکل ۳ شرایط مرزی و بارگذاری صفحه سوراخ‌دار دوبعدی در محیط نرم‌افزار انسیس: تکیه‌گاه گیردار در ضلع پایینی و جابجایی قائم به اندازه ۰/۰۵ متر در ضلع بالایی

Fig.4 Boundary conditions and loading of a two-dimensional perforated plate in ANSYS: fixed support at the bottom edge and vertical displacement of 0.05 m at the top edge


برای تهیه تصاویر مجموعه داده اول، در ابتدا یک صفحه دوبعدی با ابعاد 1000×1000 میلی‌متر با سوراخ دایروی به شعاع ۳۵ میلی‌متر از یک ماده ایزوتروپیک با خاصیت الاستیک خطی، با مدول الاستیسیته ۲۰۰ گیگاپاسکال و ضریب پواسون ۰/۳ در نرم‌افزار انسیس با استفاده از زبان برنامه‌نویسی مدل‌سازی می‌شود. پلین ۱۸۳ مان بندی می‌شود و تعداد المان‌ها در مدل‌های مختلف بین ۸۴۰۰ تا ۱۰۹۰۰ عدد متغیر است. در نهایت با حل مسئله، تصویر هندسه قابل مشاهده است. تنش ذخیره می‌شود. در **Error! Reference source not found.** سه خروجی مربوط به تحلیل هر هندسه قابل مشاهده است. در مرحله بعد کار، نتایج حاصل از مدل‌سازی با نقشه رنگ پیش‌فرض نرم‌افزار به شکل میدان تنش، مش و هندسه بدون بارگذاری نشان داده شده است.

سپس حرکت این یک صفحه از ضلع پایینی با یک تکیه‌گاه گیردار محدود شده و به ضلع بالایی، یک جابجایی قائم به اندازه ۰/۰۵ متر اعمال می‌شود (**شکل ۳**). سپس با استفاده از المان دوبعدی در مرحله بعد، به منظور ایجاد پایگاه داده با استفاده از قابلیت برنامه‌نویسی در نرم‌افزار انسیس، مختصات مرکز سوراخ با نوشتن دو حلقه برای طول و عرض مرکز سوراخ، ابتدا در یک ردیف و در هر بار به اندازه ۲۰ میلی‌متر از سمت چپ به راست تا جایی جابه‌جا می‌شود تا سوراخ بدون خروج از صفحه، به سمت راست آن برسد. سپس با حرکت مرکز سوراخ به اندازه ۲۰ میلی‌متر به سمت بالا، در ردیف جدید مجدداً سوراخ با گام‌های ۲۰ میلی‌متری تا سمت راست صفحه حرکت می‌کند و این روند تا جایی ادامه پیدا می‌کند که صفحه جاروب شده و ۲۲۵۰ حالت مختلف را در بر بگیرد. با اجرای



شکل ۶ یک نمونه تصویر جفت‌شده با نقشه رنگ پیش‌فرض نرم‌افزار برای ایجاد پایگاه‌داده: قرار گرفتن تصویر هندسه در کنار میدان تنش متناظر آن




Fig.6 Example of a paired image generated using the default colormap in ANSYS for dataset construction: geometry image combined with the corresponding stress field



شکل ۷ (الف) میدان تنش پیش‌بینی شده توسط یادگیری عمیق، (ب) میدان تنش نتیجه شده از تحلیل نرم‌افزار انسیس، (ج) هندسه بدون بارگذاری با نقشه رنگ پیش‌فرض نرم‌افزار


Fig.7 Comparison of predicted and simulated results: (a) stress field predicted by the deep learning model, (b) stress field obtained from ANSYS analysis, (c) initial geometry without loading using the default colormap

در مرحله بعد، با تهیه و تنظیم نقشه رنگ سفارشی و اضافه‌کردن دستور مربوط به اعمال آن در برنامه قبلی، مجدداً مختصات مرکز سوراخ را با نوشتن دو حلقه برای x و y هر بار به اندازه ۲۰ میلی‌متر تا جایی جابه‌جا می‌شود تا کل صفحه جاروب شده و مدل‌هایی با سوراخ خیلی نزدیک به مرزهای کناری، به علت رفتار غیریکنواخت از مجموعه‌داده حذف می‌شوند و در نهایت ۱۵۱۶ تصویر هندسه و میدان تنش با نقشه رنگی سفارشی با نسبت ۸۰:۲۰ به دودسته آموزش و آزمون دسته‌بندی شده و ۱۲۱۲ تصویر در پوشه آموزش و ۳۰۴ تصویر در پوشه آزمون قرار می‌گیرد. شکل یک نمونه تصویر جفت‌شده از مجموعه‌داده با نقشه رنگ سفارشی را نشان می‌دهد.



شکل ۴ تصاویر خروجی با نقشه رنگ پیش‌فرض نرم‌افزار در محیط نرم‌افزار انسیس شامل: (الف) میدان تنش حاصل از تحلیل، (ب) مش‌زنی مدل، (ج) هندسه بدون بارگذاری

Fig.5 Outputs of ANSYS APDL using the default colormap: (a) stress field obtained from the analysis, (b) meshed model, (c) initial geometry without loading



شکل ۱۰ (a) میدان تنش پیش‌بینی شده توسط یادگیری عمیق، (b) میدان تنش نتیجه شده از تحلیل نرم‌افزار انسیس، (c) هندسه بدون بارگذاری با نقشه رنگ سفارشی

Fig.10 Comparison of predicted and simulated results: (a) stress field predicted by the deep learning model, (b) stress field obtained from ANSYS analysis, (c) initial geometry without loading using the customized colormap

۸- معیارهای ارزیابی دقت تصاویر خروجی از مدل

این بخش به ارزیابی دقت عملکرد مدل در پیش‌بینی میدان تنش از تصاویر سه‌کاناله‌ای رنگی اختصاص دارد. برای این منظور، معیارهای خطای کلیدی شامل میانگین مربعات خطا، ریشه میانگین مربعات خطا، میانگین خطای مطلق، معیار ال ۲ و خطای نسبی به‌صورت هم‌زمان بر روی هر سه کانال رنگی محاسبه شده‌اند. هدف این تحلیل، تعیین دقیق ثبات، دقت و گستره‌ی خطای مدل در بازتولید ساختار میدان تنش است. نمودارهای توزیع و عملکرد نیز در ادامه، روند و تراکم این خطاها را نشان خواهند داد.

۱-۸- معیار ال ۲

معیار ال ۲ میزان خطای نقطه‌به‌نقطه بین تصویر پیش‌بینی شده و تصویر مرجع را اندازه‌گیری می‌کند در این تحلیل، محاسبات بر روی سه کانال رنگی قرمز، سبز و آبی انجام می‌شود؛ به این معنا که مقادیر شدت هر سه کانال از ۰ تا ۲۵۵ برای تعیین مقدار متناظر هر نقطه به کار می‌روند. با داشتن دو تصویر ۱ و ۲، معیار ال ۲ بین آن‌ها به‌صورت زیر تعریف می‌شود:


۱-۱-۸- معیار خطای کلی ال ۲

خطای ال ۲ کلی که خطای تجمعی کل تصویر را نشان می‌دهد، به‌صورت فاصله اقلیدسی بر روی تمام پیکسل‌ها و هر سه کانال رنگی محاسبه می‌شود:


خطای کلی ال ۲

$$= \sqrt{\sum_{\text{تمام پیکسل‌ها}} \sum_{\{آبی, سبز, قرمز\} \in \text{کانال}} (\text{مقدار واقعی کانال} - \text{مقدار پیش‌بینی})^2}$$

معیار ال ۲ میزان خطای نقطه‌به‌نقطه بین تصویر پیش‌بینی شده و تصویر مرجع را اندازه‌گیری می‌کند. برای محاسبه این معیار ابتدا فایل لاگ حاوی اطلاعات پردازش تصاویر خوانده می‌شود و نام تصاویر واقعی و پیش‌بینی شده استخراج می‌گردد تا جفت‌های متناظر مشخص شوند، سپس اختلاف مقدار هر یک از سه کانال رنگی پیکسل‌ها در دو تصویر گرفته شده و مربع این اختلافات محاسبه می‌شود. مجموع این مقادیر بیانگر بزرگی خطای کل تصویر است؛ یعنی هرچه مقدار ال ۲ کوچک‌تر باشد، انطباق تصویر پیش‌بینی شده با تصویر واقعی بیشتر است. این معیار نسبت به




شکل ۸ تصاویر خروجی با نقشه رنگ سفارشی در محیط نرم‌افزار انسیس شامل: (الف) میدان تنش حاصل از تحلیل، (ب) مش‌زنی مدل
Fig.8 Outputs of ANSYS APDL using the customized plasma colormap: (a) stress field obtained from the analysis, (b) meshed model



شکل ۹ یک نمونه تصویر جفت‌شده با نقشه رنگ سفارشی پلاسما برای ایجاد پایگاه‌داده: قرار گرفتن تصویر هندسه در کنار میدان تنش متناظر آن
Fig.9 Example of a paired image generated using the customized plasma colormap for dataset construction: geometry image combined with the corresponding stress field

تصاویر آموزش هم به‌عنوان ورودی به کد وارد شده و پس از آموزش مدل، هندسه‌های جدید و متنوع از نظر محل قرارگیری سوراخ به کد وارد می‌شود تا میدان تنش متناظر با آن پیش‌بینی شود. شکل ۱۰ میدان تنش پیش‌بینی شده توسط یادگیری عمیق را در کنار میدان تنش نتیجه شده از تحلیل نرم‌افزار انسیس و هندسه بدون بارگذاری با نقشه رنگ سفارشی را برای یکی از هندسه‌های جدید نشان می‌دهد.

خطاهای بزرگ حساس‌تر است، زیرا اختلافات بزرگ پس از توان دوم وزن بیشتری پیدا می‌کنند.



شکل ۱۱ معیار خطای تجمعی ال ۲ برای مدل در پیش‌بینی میدان تنش سه‌کاناله‌ی بر حسب شماره تصویر

Fig. 11 Distribution of the L2 Norm of the model's prediction of the three-channel stress field (RGB) versus the sample index

در شکل ۱۱، توزیع این خطای تجمعی بر روی هر سه کانال رنگی بر حسب شماره تصویر نشان داده شده است. نمودار نشان می‌دهد که نوسانات خطای مدل حول یک مقدار متوسط پایدار است و هیچ روند صعودی یا نزولی قابل توجهی در طول ۳۰۴ نمونه مشاهده نمی‌شود، که نشان‌دهنده ثبات عملکردی مدل در طول فرآیند ارزیابی است. بیشتر خطاهای کلی مدل در یک محدوده متمرکز بین ۶۵۰۰ تا ۷۵۰۰ نوسان می‌کنند. با این حال، نمودار چندین نقطه پرت و قله‌های خطا را نیز مشخص می‌کند که بالاترین میزان خطا در آن‌ها به حدود ۸۲۰۰ می‌رسد. این قله‌های خطا نشان‌دهنده نمونه‌هایی هستند که مدل در پیش‌بینی دقیق ساختار میدان تنش در آن‌ها، بیشترین مشکل را داشته است.

در مجموع، با توجه به اینکه بیشترین ال ۲ ممکن برای یک تصویر ۵۱۲ × ۵۱۲ سه‌کاناله بیش از ۲۲۶۰۰۰ است، مقادیر ثبت شده در این محدوده نشان‌دهنده یک عملکرد قوی و خطای متوسط بسیار پایین برای مدل است.

۱-۱-۸- معیار خطای محلی ال ۲

علاوه بر محاسبه خطای کلی ال ۲ برای کل تصویر، برای انجام تحلیل دقیق‌تر و محلی، نقشه خطای محلی بر اساس پیکسل‌ها تهیه می‌شود. در این روش، به جای بررسی کل تصویر به صورت یکجا، نقشه به قطعات کوچک مستطیل‌شکل یا مربعی، مانند پیکسل‌های ۴ × ۴ تقسیم می‌شود. خطای ال ۲ به صورت مجزا برای هر پیک محاسبه می‌شود و سپس یک نقشه حرارتی ایجاد می‌گردد. خطای محلی ال ۲ به صورت فاصله اقلیدسی بر روی پیکسل‌های پیک و هر سه کانال رنگی محاسبه می‌شود:

خطای ال ۲ پیک

$$= \sqrt{\sum_{\text{پیکسل‌های پیک}} \sum_{\{\text{آبی، سبز، قرمز}\} \in \text{کانال}} \left(\text{مقدار پیش‌بینی} - \text{مقدار واقعی} \right)^2}$$

استفاده از پیک‌ها این امکان را می‌دهد تا نقاطی که خطا به صورت موضعی در یک ناحیه کوچک متمرکز شده (مثل خطاهای ناشی از اثرات مرزی یا عیوب محلی در مدل‌سازی)، شناسایی کند و مشخص شود که خطاها دقیقاً در کجای میدان تنش رخ داده‌اند. در شکل ۱۲، نقشه بصری خطای محلی ال ۲ که بر اساس خطای محاسبه‌شده در پیک‌های ۴ × ۴ ایجاد شده است، توزیع مکانی عدم تطابق یا خطا را نمایش می‌دهد.

همان‌طور که از نوار رنگی در سمت راست مشخص است، مقادیر خطا در یک طیف رنگی از سیاه (خطای نزدیک به صفر) تا زرد روشن (خطای حداکثر، تا حدود) عددگذاری شده‌اند. این نقشه نشان می‌دهد که خطاهای موضعی مدل، عمدتاً در نواحی مرزی تصویر مانند گوشه‌ها و لبه‌ها متمرکز شده‌اند. این نقاط با خطای بالا می‌توانند ناشی از اثرات مرزی مدل‌سازی باشند.

۲-۸- معیار میانگین مربع خطا

معیار میانگین مربع خطا میانگین مجذور اختلاف‌ها بین تصویر پیش‌بینی‌شده و تصویر مرجع را اندازه‌گیری می‌کند. این معیار میزان خطای نقطه‌به‌نقطه بین تصویر پیش‌بینی‌شده و تصویر مرجع را اندازه‌گیری می‌کند. در این تحلیل، محاسبات بر روی سه کانال رنگی قرمز، سبز و آبی انجام می‌شود؛ به این معنی که مقادیر شدت هر سه کانال از ۰ تا ۲۵۵ برای تعیین مقدار متناظر هر نقطه به کار می‌روند. این معیار خطای متوسط کل تصویر را نشان می‌دهد و به صورت میانگین مجذور اختلاف‌ها بر روی تمام پیکسل‌ها و هر سه کانال رنگی محاسبه می‌شود. با داشتن دو تصویر واقعی و پیش‌بینی‌شده با تعداد کل مقادیر مشخص (شامل پیکسل‌ها و کانال‌ها)، معیار میانگین مربع خطا بین آن‌ها به صورت زیر تعریف می‌شود:

معیار میانگین مربع خطا

$$= \frac{1}{\sum_{\text{نقطه}} \text{تعداد کل}} \left(\sum_{\text{نقطه}} \left(\text{مقدار پیش‌بینی} - \text{مقدار واقعی} \right)^2 \right)$$

برای محاسبه این معیار، همانند معیار ال ۲ ابتدا فایل لاگ حاوی اطلاعات پردازش تصاویر خوانده می‌شود و نام تصاویر واقعی و پیش‌بینی‌شده استخراج می‌گردد تا جفت‌های متناظر مشخص شوند. سپس اختلاف مقدار هر یک از سه کانال رنگی پیکسل‌ها در دو تصویر گرفته شده و مربع این اختلافات محاسبه می‌شود.

میانگین این مقادیر بیانگر بزرگی خطای متوسط تصویر است؛ یعنی هرچه مقدار آن کوچک‌تر باشد، انطباق تصویر پیش‌بینی‌شده با تصویر واقعی بیشتر است. این معیار نسبت به خطاهای بزرگ بسیار حساس‌تر است، زیرا اختلافات بزرگ پس از توان دوم وزن بیشتری پیدا می‌کنند.


۳-۸- معیار ریشه میانگین مربع خطا

این معیار، با محاسبه ریشه دوم معیار میانگین مربع خطا به دست می‌آید:

معیار میانگین مربع خطا

$$= \sqrt{\frac{1}{\sum_{\text{نقطه}}^{\text{تعداد کل}} (\text{مقدار واقعی} - \text{مقدار پیش‌بینی})^2}$$

در شکل ۱۴، توزیع ریشه میانگین مربعات خطا بر حسب شماره تصویر نمایش داده شده است. نمودار نشان می‌دهد که خطا در طول ۳۰۴ نمونه ارزیابی شده در یک محدوده نسبتاً باریک و بدون روند صعودی یا نزولی نوسان می‌کند. تمرکز مقادیر حول میانگین پایین (زیر ۸) نشان‌دهنده دقت خوب مدل است.



شکل ۱۴ توزیع ریشه میانگین مربع خطای مدل بر حسب شماره تصویر

Fig.14 Distribution of the Root Mean Square Error (RMSE) of the model versus sample index


۴-۸- معیار میانگین خطای مطلق

این معیار، خطای مطلق متوسط کل تصویر را نشان می‌دهد و به صورت میانگین اختلاف مطلق‌ها بر روی تمام پیکسل‌ها و هر سه کانال رنگی محاسبه می‌شود:

معیار میانگین خطای مطلق


$$= \frac{1}{\sum_{\text{نقطه}}^{\text{تعداد کل}} |\text{مقدار پیش‌بینی} - \text{مقدار واقعی}|}$$

برخلاف دو معیار قبل که اختلافات را مربع می‌کنند، این معیار از قدرمطلق استفاده می‌کند و در نتیجه کمتر تحت تأثیر خطاهای بزرگ ناگهانی قرار می‌گیرد.




شکل ۱۵ توزیع میانگین خطای مطلق بر حسب شماره تصویر

Fig.10 Distribution of the Mean Absolute Error (MAE) of the model versus sample index



شکل ۱۲ نقشه خطای محلی برای یک نمونه‌ی منتخب. این نقشه توزیع مکانی خطای مطلق را بر اساس معیار محلی ال ۲ نشان می‌دهد و تمرکز خطا را در اطراف محل تغییرات ناگهانی تنش (مانند مرزها و سوراخ مرکزی) برجسته می‌سازد.

Fig.12 Local Error Map for a selected sample. The map illustrates the spatial distribution of the absolute error based on local L2 norm, highlighting error concentration around areas of abrupt stress change (such as boundaries and the central hole).



شکل ۱۳ توزیع میانگین مربع خطای مدل بر حسب شماره تصویر

Fig.13 Distribution of the Mean Squared Error (MSE) of the model versus sample index

در شکل ۱۳، توزیع میانگین مربع خطا بر حسب شماره تصویر نمایش داده شده است. نمودار نشان می‌دهد که نوسانات خطای مدل حول یک مقدار متوسط پایدار در طول ۳۰۴ نمونه مشاهده می‌شود. عدم وجود یک روند صعودی یا نزولی قابل توجه در طول فرآیند ارزیابی، نشان‌دهنده ثبات عملکردی مدل است به طوری که عملکرد مدل در برابر داده‌های ورودی مختلف از تفاوت‌های جزئی نمونه‌ها تأثیرپذیری زیادی ندارد. بیشتر خطاها در یک محدوده متمرکز بین ۵۰ تا ۷۵ نوسان می‌کنند. این محدوده‌ی نوسان نشان‌دهنده دقت نسبتاً بالای مدل در بخش عمده‌ی نمونه‌هاست. با این حال، نمودار چندین نقطه پرت و قله‌های خطا را نیز مشخص می‌کند که بالاترین میزان خطا در آن‌ها به حدود ۸۵ (در نزدیکی شاخص‌های ۹۵ و ۲۰۵) می‌رسد. این قله‌های خطا نشان‌دهنده نمونه‌هایی هستند که مدل در پیش‌بینی مقادیر شدت پیکسلی میدان تنش در آن‌ها، بیشترین انحراف را از مقادیر واقعی داشته است.

به طور کلی، باتوجه به اینکه حداکثر مقدار ممکن برای این معیار در صورتی که مقادیر رنگ پیکسل از ۰ تا ۲۵۵ متغیر باشند، برای یک پیکسل $255^2 \approx 65000$ است، مقادیر ثبت شده در این محدوده (میانگین حدود ۶۰) نشان‌دهنده یک عملکرد قوی و خطای متوسط بسیار پایین برای مدل است.

مقایسه مقادیر فاصله‌ها انجام می‌شود و نقطه‌ای که کمترین فاصله را با پیکسل داشته باشد، به‌عنوان نزدیک‌ترین نقطه انتخاب می‌شود.

پس از اینکه نزدیک‌ترین نقطه در مسیر رنگی شناسایی شد، موقعیت نسبی پیکسل در مسیر رنگی پلاسما به‌صورت درصد محاسبه می‌شود. این درصد نشان‌دهنده موقعیت نسبی پیکسل در مسیر رنگی است و مقدار آن بین ۰ و ۱ خواهد بود که صورت زیر محاسبه می‌شود:

$$1 - \frac{\text{اندیس نزدیک‌ترین نقطه}}{\text{تعداد نقاط در مسیر رنگی پلاسما}} = \text{درصد مکانی}$$

این رابطه تضمین می‌کند که اولین رنگ مسیر (بنفش تیره، معادل حداقل تنش) دقیقاً مقدار ۰ و آخرین رنگ مسیر (زرد روشن، معادل حداکثر تنش) دقیقاً مقدار ۱ دریافت کند. تقسیم اندیس نزدیک‌ترین نقطه بر تعداد نقاط در مسیر رنگی پلاسما باعث می‌شود نگاشت در تمام طول مسیر کاملاً خطی و یکنواخت باشد و هیچ انحرافی در ابتدا یا انتهای بازه تنش رخ ندهد.

برای تبدیل درصد موقعیت به مقادیر فیزیکی، باید یک بازه مشخص از مقادیر فیزیکی تعریف شود. این بازه فیزیکی در اصل همان مقدار حداقل و حداکثر تعریف شده در نقشه رنگ سفارشی پلاسما است که نمایانگر حداقل و حداکثر تنش تعریف شده در میدان تنش هستند. در نقشه رنگی که در نرم‌افزار انسیس از آن استفاده شده، حد پایین تنش معادل با رنگ بنفش و مقدار عددی 5×10^8 پاسکال و حد بالای تنش، با رنگ زرد و مقدار عددی 5×10^{10} پاسکال مشخص شده است.

پس از تعیین بازه مقادیر فیزیکی، درصد موقعیت پیکسل به طور خطی به این بازه نگاشت می‌شود. این نگاشت با استفاده از یک رابطه خطی انجام می‌شود که درصد موقعیت پیکسل را به مقادیر فیزیکی متناظر آن در بازه موردنظر تبدیل می‌کند که این فرمول به‌صورت زیر است:

$$\left(\text{حد پایین تنش} - \text{حد بالای تنش} \right) \times (\text{درصد مکانی}) + \text{حد پایین تنش} = \text{مقدار نگاشت شده}$$

این مقادیر نگاشت شده در اصل مقدار تنش است که هر پیکسل از تصویر پیش‌بینی شده نماینده آن است. سپس از بین تمامی مقادیر نگاشت شده، حداکثر مقدار استخراج شده و به‌عنوان حداکثر تنش پیش‌بینی شده در یک فایل اکسل ذخیره شدند. این فایل شامل اطلاعات دقیق در مورد نام هر تصویر، مقادیر حداکثر آرجی‌بی و مقدار حداکثر تنش مرتبط با هر تصویر بود

بر روی نوار رنگی Error! Reference source not found.، نقاط نگاشت شده از تصاویر بر روی طیف رنگی پلاسما مرجع و همچنین حداکثر تنش محاسبه شده قابل مشاهده است.

در شکل ۱۵، توزیع میانگین خطای مطلق بر حسب شماره تصویر نمایش داده شده است. همانند دیگر معیارهای ارزیابی، نمودار خطی میانگین خطای مطلق نیز ثبات عملکرد مدل را نشان می‌دهد. نوسانات خطا حول مقدار تقریباً $3/7$ (که مقدار پایینی است) متمرکز شده و بیشتر خطاها در محدوده ۳ تا $4/5$ نوسان می‌کنند. قله‌های خطا تا حدود ۵ نیز دیده می‌شوند که نشان‌دهنده نمونه‌های دارای بیشترین خطای مطلق هستند. با این حال، با توجه به مقیاس عددی رنگ پیکسل‌ها (۲۵۵-۰)، میانگین خطای مطلق در حدود ۳.۷، نشان‌دهنده یک عملکرد بسیار خوب و کم‌خطا برای مدل است، زیرا به معنای آن است که میانگین انحراف هر پیکسل، نسبت به مقیاس کل، مقدار ناچیزی است.

۹- استخراج مقدار عددی حداکثر تنش

در جهت کمی‌سازی رنگ پیکسل‌های تصاویر تولید شده، روشی مبتنی بر نگاشت رنگ هر پیکسل بر روی یک مسیر رنگی مرجع پلاسما در فضای سه‌بعدی مدل رنگی آرجی‌بی توسعه داده شد. این مسیر، متشکل از ۱۲۸ رنگ تعریف شده در نقشه رنگ سفارشی پلاسما است که به‌عنوان مبنای تحلیل انتخاب شدند. برای تبدیل مسیر رنگی پلاسما به یک مسیر پیوسته و هموار، از روش درون‌یابی اسپلاین استفاده شد. ابتدا این نقشه رنگ به‌صورت یک منحنی پیوسته و نرم با ۱۲۸ نقطه در فضای سه‌بعدی آرجی‌بی تعریف شد، یعنی نقاط رنگی که به‌صورت دستی در یک آرایه ذخیره شدند را به یک منحنی پیوسته تبدیل کرده و امکان انجام نگاشت دقیق‌تر رنگ‌ها به مقادیر فیزیکی را فراهم می‌کند و سپس منحنی به‌دست‌آمده پس از اعمال اسپلاین برای تحلیل و نگاشت رنگ‌ها به مقادیر فیزیکی مورد استفاده قرار می‌گیرد. پس از تعریف مسیر رنگی پلاسما، تصاویر ورودی خوانده شده و به فضای رنگی آرجی‌بی تبدیل شدند. تصاویر به‌منظور پردازش سریع‌تر، به ابعاد 1250×1250 تغییر اندازه یافتند. در مرحله بعد، پیکسل‌های تصویر به‌صورت یک آرایه یک‌بعدی از مقادیر رنگی آرجی‌بی استخراج شدند که به‌عنوان ورودی برای فرایند نگاشت استفاده شدند.

باهدف این‌که که موقعیت هر پیکسل در مسیر رنگی پلاسما تعیین شود، ابتدا باید فاصله هر پیکسل از هر یک از نقاط رنگی موجود در مسیر پلاسما محاسبه شود. برای این منظور از فاصله اقلیدسی استفاده می‌شود که یکی از رایج‌ترین روش‌ها برای اندازه‌گیری تفاوت بین دونقطه در فضای چندبعدی (در اینجا، فضای سه‌بعدی رنگ‌ها) است.

رابطه فاصله اقلیدسی برای دونقطه به‌صورت زیر است:

$$d = \sqrt{(R_1 - R_2)^2 + (G_1 - G_2)^2 + (B_1 - B_2)^2}$$

در اینجا G_2, B_2, R_2 نمایانگر مقادیر رنگ قرمز، آبی و سبز پیکسل‌ها و G_1, B_1, R_1 نقاط مسیر رنگی پلاسما هستند.


پس از محاسبه فاصله‌ها بین رنگ هر پیکسل و تمامی نقاط مسیر پلاسما، باید نزدیک‌ترین نقطه به پیکسل را انتخاب کرد. این کار با

توسط نرم‌افزار انسیس مقایسه می‌شوند و درصد خطای با فرمول زیر محاسبه می‌شود:

درصد خطا

$$= \frac{|\text{حداکثر تنش اندازه‌گیری شده} - \text{حداکثر تنش تحلیل انسیس}|}{\text{حداکثر تنش تحلیل انسیس}} \times 100$$


برای بررسی دقت مدل در نقاط مختلف صفحه، نمودار درصد خطای محاسبه شده بر اساس مختصات مرکز سوراخ ترسیم شد (Error! Reference source not found). نتایج نشان می‌دهند که مدل در بیشتر نواحی هندسه عملکرد یکنواختی داشته و میزان خطا در محدوده قابل‌قبولی باقی مانده است و تنها در تعداد معدودی از نقاط، افزایش غیرعادی در خطا دیده شده که نشان‌دهنده اشکالاتی در تخمین دقیق تنش‌ها در مرحله استخراج مقادیر عددی از تصویر است.



شکل ۱۸ نمودار درصد خطا بر حسب مختصات مرکز سوراخ؛ یکنواختی عملکرد مدل در بیشتر نواحی هندسه و مشاهده افزایش خطا در تعداد محدودی از نقاط

Fig.18 Error percentage versus hole center coordinates: uniform model performance in most regions of the geometry with increased error observed at a limited number of points

برای بررسی توزیع مقادیر خطای مدل در تمامی تصاویر پیش‌بینی شده، هیستوگرام درصد خطا در تمامی پیکسل‌ها رسم شد. همان‌طور که در شکل ۱۹ مشاهده می‌شود، بیشترین تراکم در خطاهای محاسبه شده در بازه خطای ۰ تا ۲ درصد هستند. همچنین توزیع خطا دارای فراوانی کمی در سمت راست نمودار است که نشان می‌دهد تنها درصد کمی از پیکسل‌ها دچار خطای بیش از ۱۰٪ شده‌اند. این تحلیل آماری نشان‌دهنده عملکرد خوب مدل در پیش‌بینی عددی مقدار حداکثر تنش است. همچنین با استفاده از معیارهای خطای مطلق، میانگین مربع خطا و ریشه میانگین مربع خطا همانند بخش ارزیابی دقت تصاویر خروجی از مدل، دقت داده‌های عددی بررسی شد، با این تفاوت که به‌جای مقادیر مربوط به شدت رنگ، از اعداد استخراج شده برای حداکثر تنش و حداکثر تنش اعلام شده توسط نرم‌افزار اجزا محدود استفاده می‌شود.




شکل ۱۶ پیکسل‌های نگاشت‌شده روی طیف رنگی پلاسمای مرجع و حداکثر تنش محاسبه‌شده: نمایش نقاط نگاشت‌شده بر روی مسیر رنگی و استخراج بیشینه تنش از تصاویر پیش‌بینی‌شده

Fig.16 Mapped pixels on the reference plasma colormap and the calculated maximum stress: representation of mapped points along the color path and extraction of maximum stress from predicted images

این خروجی در واقع کالیبراسیون در یک شبیه‌سازی عددی تنش است؛ یعنی هر رنگ در طیف پلاسمای به یک مقدار تنش کاملاً مشخص و یکتا نگاشت شده است. به این ترتیب، وقتی پیکسلی در تصویر خروجی شبکه به رنگ زرد روشن نزدیک باشد، مقدار تنش محاسبه‌شده برای آن به‌درستی در نزدیکی 5×10^8 پاسکال قرار می‌گیرد و بالعکس، رنگ‌های بنفش تیره به مقادیر نزدیک به 5×10^8 پاسکال منجر می‌شوند.

برای بررسی میزان تطابق نتیجه مدل با طیف رنگی مرجع، مسیر طیف رنگ پلاسمای در فضای سه‌بعدی آر‌جی‌بی ترسیم و پیکسل‌های تصویر پیش‌بینی‌شده در شکل مشخص شده‌اند. همان‌طور که در این شکل مشاهده می‌شود، مسیر نقشه رنگ به شکل یک منحنی به‌خوبی نمایش‌داده شده و نقاط مربوط به پیکسل‌های خروجی مدل تا حد قابل‌قبولی بر روی همین مسیر قرار گرفته‌اند.




شکل ۱۷ مسیر طیف رنگ پلاسمای در فضای سه‌بعدی آر‌جی‌بی و پیکسل‌های تصویر پیش‌بینی‌شده: نمایش منحنی حاصل از اسپلاین و قرارگیری نقاط تصویر بر روی مسیر رنگی

Fig.17 Plasma colormap trajectory in three-dimensional RGB space and the pixels of the predicted image: spline-based curve representation and placement of image pixels along the color path

۱۰- معیارهای ارزیابی دقت مقدار عددی حداکثر تنش

در مرحله بعد برای بررسی خطای مدل، مقادیر حداکثر تنش محاسبه شده توسط این روش با مقادیر حداکثر تنش اعلام شده


غالب مقادیر این معیار در محدوده‌ای بسیار پایین‌تر از قله‌ها و در زیر خط میانگین قرار دارد.



شکل ۲۱ توزیع ریشه میانگین مربع خطای حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر

Fig.21 Distribution of the Root Mean Square Error (RMSE) of the predicted maximum stress values versus sample index

در شکل ۲۲، توزیع میانگین خطای مطلق بر حسب شماره نمونه نمایش داده شده است. مانند نمودارهای قبلی، در این نمودار نیز هیچ روند صعودی یا نزولی در طول ۳۰۴ نمونه مشاهده نمی‌شود، که نشان‌دهنده پایداری عملکرد مدل است. در این معیار هم یک قله خطای بالا در تصویر شماره ۴۰ وجود دارد. با وجود آن پیک، تمرکز غالب مقادیر خطا در زیر خط میانگین قرار دارد. این نشان می‌دهد که در بخش عمده نمونه‌ها، خطای مطلق مدل پایین‌تر از میانگین کلی بوده و عملکرد مدل در بیشتر داده‌ها مناسب است.




شکل ۲۲ توزیع میانگین خطای مطلق حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر

Fig.22 Distribution of the Mean Absolute Error (MAE) of the predicted maximum stress values versus sample index

۱۱- تحلیل منابع خطا و عدم قطعیت

در این بخش، ما به دنبال ارزیابی و مقایسه پایداری دو مرحله تولید تصویر با مدل یادگیری ماشین و روش پیشنهادی مبتنی بر پردازش تصویر هستیم. این تحلیل بر تأثیر انباشت عدم قطعیت‌ها در هر مرحله بر خطای نهایی پیش‌بینی تنش تمرکز دارد.

در روش پیشنهادی پژوهش، پیش‌بینی تنش، یک روند چندمرحله‌ای دارد؛ ابتدا مدل، تصویر میدان تنش را تولید می‌کند و سپس عملیات پس‌پردازش مانند نگاشت پلاسم و استخراج مقدار بیشینه تنش انجام می‌شود؛ بنابراین خطای نهایی این روش، ترکیبی است از: خطای ذاتی مدل تولید تصویر و عدم قطعیت‌های اضافه‌شده در مراحل پس‌پردازش (مانند نویز تصویر، خطای کمی‌سازی رنگ‌ها و برازش منحنی بر نقشه رنگ). هدف اصلی تحلیل این است که به‌صورت کمی و آماری مشخص شود که آیا این زنجیره عدم قطعیت‌ها باعث افزایش چشمگیر خطا می‌شود و



شکل ۱۹ هیستوگرام درصد خطا: بیشترین تراکم خطا در بازه ۰ تا ۲ درصد و تعداد کمی از پیکسل‌ها با خطای بیش از ۱۵ درصد

Fig.19 Histogram of error percentage: highest density of errors in the 0–2% range with a small number of pixels exceeding 15% error




شکل ۲۰ توزیع میانگین مربع خطای حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر

Fig.20 Distribution of the Mean Squared Error (MSE) of the predicted maximum stress values versus sample index


در شکل ۲۰، توزیع میانگین مربعات خطا بر حسب شماره تصویر نمایش داده شده است. نمودار نشان می‌دهد که مقادیر خطا در بیش از ۳۰۰ نمونه ارزیابی‌شده، در یک محدوده نسبتاً باریک، حول میانگین $10^{19} \times 1/33$ نوسان می‌کند. مقادیر خطا عموماً در سطح پایینی (نزدیک به خط میانگین نمایش داده شده) قرار دارند، که نشان‌دهنده عملکرد خوب مدل است. هیچ روند صعودی یا نزولی مشخصی در طول نمونه‌ها مشاهده نمی‌شود، که پایداری نسبی عملکرد مدل در داده‌های ارزیابی را نشان می‌دهد. با این حال، چند قله خطای بالا (نقاط پرت) وجود دارد. این نقاط پرت نشان‌دهنده مواردی هستند که پردازش تصویر عملکرد ضعیف و خطای زیادی داشته است. اگرچه چند نمونه دارای خطای بالا هستند، اما تمرکز غالب مقادیر خطا در محدوده‌ای بسیار پایین‌تر از این پیک‌ها و در نزدیکی یا پایین‌تر از خط میانگین قرار دارد. این تمرکز پایین، در حالت کلی، نشان‌دهنده دقت قابل‌قبول مدل در بیشتر نمونه‌های ارزیابی است.

در شکل ۲۱، توزیع ریشه میانگین مربعات خطا بر حسب شماره تصویر نمایش داده شده است. این نمودار، ریشه مقادیر میانگین مربع خطا را نشان می‌دهد. همانند نمودار میانگین مربعات خطا، در این نمودار نیز هیچ روند صعودی یا نزولی پایداری در طول نمونه‌ها مشاهده نمی‌شود. این امر نشان‌دهنده پایداری عملکرد مدل در کل مجموعه داده ارزیابی است. ویژگی مشترک هر دو نمودار، وجود یک خطای بالا در تصویر شماره ۴۰ که نشان می‌دهد همان نمونه، بزرگترین خطا را در هر دو معیار ایجاد کرده است. با وجود نوسانات و وجود آن نقطه پرت، تمرکز




شکل ۲۴ توزیع میانگین مربع خطا برای حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر با مشخص شدن نقاط پرت

Fig.24 Distribution of the Mean Squared Error (MSE) of the predicted maximum stress values versus sample index, with highlighted outliers




شکل ۲۵ توزیع ریشه میانگین مربع خطا برای حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر با مشخص شدن نقاط پرت

Fig.25 Distribution of the Distribution of the Root Mean Square Error (RMSE) of the predicted maximum stress values for the Scalar Model versus sample index, with highlighted outliers



شکل ۲۶ توزیع ریشه میانگین مربع خطا برای حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر با مشخص شدن نقاط پرت

Fig.26 Distribution of the Root Mean Square Error (RMSE) of the predicted maximum stress values versus sample index, with highlighted outliers



شکل ۲۷ توزیع میانگین خطای مطلق مدل بر حسب شماره تصویر با مشخص شدن نقاط پرت

Fig.27 Distribution of the Mean Absolute Error (MAE) the model versus sample index, with highlighted outliers

اگر افزایش ایجاد می‌کند، آیا از دید مهندسی قابل قبول و قابل مدیریت می باشد.

برای مقایسه دقیق عملکرد دو مدل، توزیع خطای نمونه‌ها با استفاده از معیارهایی که قبلاً بررسی شده بود، یعنی میانگین مربعات خطا، ریشه میانگین مربعات خطا و میانگین خطای مطلق انجام می‌شود. تفاوت نمودارهای این تحلیل با بخش‌های قبلی این است که برای تشخیص نمونه‌هایی که خطای آن‌ها به دلیل تأثیر تجمیعی عدم قطعیت‌ها به طور غیرعادی زیاد شده است، از روش دامنه بین چارکی استفاده شده است بدین ترتیب که ابتدا موقعیت چارک موردنظر در توزیع خطاهای مرتب شده (به ترتیب صعودی) با استفاده از رابطه زیر محاسبه می‌شود:

$$\text{موقعیت چارک} = \frac{(1 + \text{تعداد نمونه‌ها})}{4} \times \text{شماره چارک}$$

دامنه بین چارکی، فاصله بین چارک سوم و چارک اول است و معیار پراکندگی مرکزی داده‌ها را نشان می‌دهد:

$$\text{چارک اول} - \text{چارک سوم} = \text{دامنه بین چارکی}$$

بر اساس این روش، یک مقدار خطا، زمانی نقطه پرت تلقی می‌شود که خارج از محدوده تعریف شده توسط چارک اول و چارک سوم قرار بگیرد:


$$\text{دامنه بین چارکی} \times \frac{1}{10} + \text{چارک سوم} > \text{مقدار خطا}$$

یا

$$\text{دامنه بین چارکی} \times \frac{1}{10} - \text{چارک اول} < \text{مقدار خطا}$$


همان‌طور که در شکل ۲۳ مشاهده می‌شود، مدل در طول بیش از ۳۰۰ نمونه، تنها ۲ نقطه پرت را در معیار میانگین مربع خطا نشان می‌دهد. در مقابل، شکل ۲۴، ۲۹ نقطه پرت را نشان می‌دهد. این افزایش در تعداد نقاط پرت، مستقیماً ناشی از تأثیر انباشت عدم قطعیت‌ها در فرآیند متوالی مدل است.

در شکل ۲۵ مشخص است که در معیار ریشه میانگین مربع خطا، مدل سطح بسیار بالایی از پایداری را داراست و تنها یک نقطه پرت را در طول بیش از ۳۰۰ نمونه ارزیابی شده ثبت کرده است اما شکل ۲۶، در مجموع ۹ نقطه پرت را نشان می‌دهد.



شکل ۲۳ توزیع میانگین مربع خطای مدل بر حسب شماره تصویر با مشخص شدن نقاط پرت

Fig.23 Distribution of the Mean Squared Error (MSE) of the model versus sample index, with highlighted outliers



شکل ۲۸ توزیع میانگین خطای مطلق برای حداکثر تنش پیش‌بینی شده بر حسب شماره تصویر با مشخص شدن نقاط پرت

Fig.28 Distribution of the Mean Absolute Error (MAE) of the predicted maximum stress values versus sample index, with highlighted outliers

شکل ۲۷ (مربوط به معیار میانگین خطای مطلق) نشان می‌دهد که مدل هیچ نقطه پرتی ندارد و در مقابل، شکل ۲۷ در مجموع ۹ نقطه پرت را نشان می‌دهد.

افزایش چشمگیر نقاط پرت در روش پیشنهادی، به‌ویژه ۲۸ مورد در معیار میانگین مربع خطا، ناشی از انباشت عدم قطعیت در مراحل متوالی فرایند استخراج حداکثر تنش است. این عدم قطعیت‌ها نه از خود مدل تولید تصویر، بلکه از سازوکارهای پس‌پردازش (نگاشت رنگ و استخراج بیشینه) ناشی می‌شوند که شامل موارد زیر هستند:

۱. حساسیت تابع استخراج حداکثر به نویز پیکسل: این موضوع روش نهایی استخراج بر مبنای جستجوی حداکثر مقدار در میان تمامی مقادیر نگاشت شده است. اگر فقط یک پیکسل تولید شده توسط مدل دارای رنگی باشد که اندکی خارج از مسیر مرجع پلاسما قرار گیرد (نویز پیکسل) یا رنگ آن به‌طور غیرواقعی به سمت نواحی انتهایی طیف (زرد) کشیده شود، مقدار استخراج شده بلافاصله به‌طور چشمگیری بالا می‌رود.

۲. خطای کمی‌سازی و گسستگی طیف رنگ پلاسما: مسیر رنگی مرجع پلاسما از ۱۲۸ رنگ تعریف شده تشکیل شده است. باوجود استفاده از درون‌یابی اسپلاین برای ایجاد یک مسیر پیوسته، به علت استفاده از یک نقشه رنگ غیرخطی، فاصله بین دو گره رنگی مجاور یکسان نیست. پس یک انحراف کوچک در رنگ پیکسل پیش‌بینی‌شده در برخی نواحی، منجر به خطا در محاسبه فاصله اقلیدسی می‌شود و در نهایت به اشتباه در تشخیص مقدار فیزیکی تنش منجر می‌گردد. این خطا، ذاتاً یک خطای کمی‌سازی است.

۳. نقص‌های مربوط به نقشه رنگ پلاسما و درون‌یابی اسپلاین: همان‌طور که در شکل ۱۷ مشاهده می‌شود، مسیر نگاشت رنگی مرجع پلاسما در فضای سه‌بعدی آر‌جی‌بی، یک مسیر منحنی و پیچیده است. این پیچیدگی، به‌ویژه در ناحیه انتهایی طیف رنگی نزدیک به رنگ زرد (که متناظر با مقادیر حداکثر تنش است که سعی در محاسبه آن شده است و از نظر مهندسی بحرانی‌ترین نقطه است)، عاملی اساسی در ایجاد خطاهای زیاد و نقاط پرت در روش پیشنهادی به شمار می‌رود. پیچش مسیر در ناحیه زرد رنگ یک

مشکل جدی ایجاد می‌کند، پیچش‌های محلی در مسیر، باعث می‌شوند که نقاطی از منحنی پلاسما که از لحاظ مقدار فیزیکی تنش، از هم دور هستند، در فضای سه‌بعدی به لحاظ هندسی به یکدیگر نزدیک شوند. در این شرایط اگر یک پیکسل تولید شده توسط مدل، به دلیل نویز جزئی مدل، رنگی تولید کند که در محل این پیچش‌ها قرار گیرد، ممکن است به‌جای اینکه به نقطه اصلی روی مسیر نگاشت شود، به اشتباه به نقطه‌ای دیگر در انتهای پیچش (نزدیک‌ترین نقطه غلط) نگاشت شود. این تشخیص اشتباه نزدیک‌ترین نقطه، به اختلاف رنگ جزئی ناشی از مدل اجازه می‌دهد که به یک جهش ناگهانی و بزرگ در مقدار تنش تبدیل شده و خطای فاحش ایجاد کند. از طرفی ناحیه رنگ زرد متناظر با مقادیر بسیار بالای تنش در فضای فیزیکی است. در این منطقه، حتی تغییرات کوچک در مقادیر رنگ، به تغییرات بسیار بزرگ و غیرخطی در مقدار نهایی تنش تبدیل می‌شود.

این تحلیل نشان می‌دهد که داده‌های پرت اضافه شده نتیجه چالش فنی نگاشت رنگ در بحرانی‌ترین ناحیه تنش است که به دلیل هندسه پیچیده مسیر پلاسما و نویز جزئی مدل، تشدید می‌شود.

در جهت حذف خطاهای ذکر شده می‌توان از راهکارهای زیر بهره برد:

۱. افزایش دقت تصاویر خروجی مدل در جهت جلوگیری از تولید رنگ‌هایی خارج از مسیر نقشه رنگ
۲. افزایش تعداد گرهِ‌های طیف رنگی مرجع پلاسما (مثلاً از ۱۲۸ به ۲۵۶ یا ۵۱۲) در جهت کاهش فاصله فیزیکی بین گرهِها باهدف کاهش خطای ناشی از نگاشت منحنی و تغییر نرم‌افزار اجزا محدود از انسیس به نرم‌افزار مشابهی که قابلیت تعریف بیشتر از ۱۲۸ رنگ داشته باشد.
۳. از ابتدا از یک نقشه رنگ کاملاً خطی و غیرپیچیده استفاده شود تا مشکل پیچش در مسیر رنگ رفع شود.

۱۲- نتیجه‌گیری

در این پروژه، از یک مدل یادگیری عمیق به نام شبکه مولد تخصصی شرطی برای پیش‌بینی میدان تنش در یک صفحه دوبعدی دارای سوراخ استفاده شد. برای تولید داده‌های آموزشی، ابتدا با استفاده از زبان برنامه‌نویسی نرم‌افزار انسیس، تصاویر هندسه و میدان تنش تهیه شد. سپس این تصاویر به‌صورت جفت شده به مدل داده شدند تا مدل بتواند با یادگیری از آن‌ها، میدان تنش مربوط به هندسه‌های جدید را پیش‌بینی کند.

به‌منظور ارزیابی عملکرد مدل، از یک روش عددی استفاده شد که در آن رنگ هر پیکسل از تصویر خروجی به مقدار فیزیکی تنش تبدیل گردید. در ادامه، تنش‌های پیش‌بینی‌شده با نتایج حاصل از تحلیل اجزای محدود مقایسه شدند. نتایج به‌دست‌آمده نشان داد که مدل در بیشتر نمونه‌ها توانسته میدان تنش را با دقت خوبی بازسازی کند، به‌طوری که درصد خطای آن در اکثر موارد کمتر از ۲ درصد گزارش شده است. همچنین، تحلیل هیستوگرام خطا نشان داد که بیشتر پیکسل‌ها دارای خطای کم هستند و فقط در موارد

- [3] P. Isola, et al., "Image-to-image translation with conditional adversarial networks," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017. doi:10.1109/CVPR.2017.632
- [4] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015. Springer. doi:10.1007/978-3-319-24574-4_28
- [5] Z. Yang, C. H. Yu, and M. J. Buehler, "Deep learning model to predict complex stress and strain fields in hierarchical composites," Science Advances, vol. 7, no. 15, 2021. doi:10.1126/sciadv.abd7416
- [6] C. Xu, et al., "Conditional Generative Adversarial Network Enabled Localized Stress Recovery of Periodic Composites," Computer Modeling in Engineering & Sciences (CMES), vol. 140, no. 1, 2024. doi:10.32604/cmcs.2024.047327
- [7] V. L. T. De Souza, et al., "A review on generative adversarial networks for image generation," Computers & Graphics, vol. 114, pp. 13–25, 2023. doi:10.1016/j.cag.2023.05.010
- [8] Tensorflow, "Pix2Pix tutorial." Available: <https://www.tensorflow.org/tutorials/generative/pix2pix>. doi:10.5281/zenodo.4724125
- [9] P. Ulmas and I. Liiv, "Segmentation of satellite imagery using U-net models for land cover classification," arXiv preprint arXiv:2003.02899, 2020. doi: 10.48550/arXiv.2003.02899
- [10] J. Zhao, et al., "Firefighting Robot Extinguishment Decision-Making Based on Visual Guidance: A Novel Attention and Scale U-Net Model and Genetic Algorithm," Journal of Field Robotics, vol. 42, no. 4, pp. 1103–1124, 2025. doi: 10.1002/rob.22438
- [11] G. Du, et al., "Medical image segmentation based on U-net: A review," Journal of Imaging Science & Technology, vol. 64, no. 2, 2020. doi:10.2352/J.ImagingSci.Technol.2020.64.2.020508
- [12] Y. Gündüç, "Vit-gan: Image-to-image translation with vision transformers and conditional gans," arXiv preprint arXiv:2110.09305, 2021. doi: 10.48550/arXiv.2110.09305
- [13] Nie, Z., Jiang, H. and Kara, L.B., 2018. Deep learning for stress field prediction using convolutional neural networks. arXiv preprint arXiv:1808.08914.
- [14] Zhao, Q., Sun, B., Zhao, W., Watanabe, T., Usui, T. and Takeda, H., 2024. Improved GAN-based deep learning approach for strain field prediction and failure analysis of precast bridge slab joints. Engineering Structures, 321, p.119023. doi:10.1016/j.engstruct.2024.119023
- [15] Xiang, Y., Hou, J., Chen, X., Pidaparti, R., Song, K., Tang, K. and Wang, X., 2024. A GAN-based stepwise full-field mechanical prediction model for architected metamaterials. International Journal of Mechanical Sciences, 284, p.109771. doi:10.1016/j.ijmecsci.2024.109771
- [16] Sahu, R., Gupta, A., Mittal, D., Chatterjee, P. and Jha, S.K., 2025. Unsupervised Graph-GAN model for stress-strain field prediction in a composite. Journal of

محدودی مقدار خطا افزایش یافته است. مقایسه مقادیر تنش استخراج شده با نتایج واقعی به دست آمده از نرم افزار انسیس نشان داد که روش پیشنهادی در اکثر نقاط هندسه عملکرد مناسبی دارد و خطاهای آن عمدتاً کمتر از ۲ درصد بوده و تنها بخش بسیار کوچکی از پیکسل‌ها خطای بزرگ‌تر از ۱۵ درصد را نشان می‌دهند. تحلیل شاخص‌های میانگین مربعات خطا ریشه میانگین مربعات خطا و میانگین خطای مطلق نیز بیانگر پایداری مناسب روش در میان بیش از ۳۰۰ نمونه بوده و توزیع خطاها حول مقادیر میانگین، رفتار منظم و غیرنوسانی مدل را تأیید کرد. با این حال، تحلیل عمیق‌تر منابع خطا نشان داد که مرحله پس‌پردازش یعنی نگاشت رنگ و استخراج بیشینه تنش، منبع اصلی افزایش نقاط پرت است. مقایسه خطای مدل تولید تصویر با خطای مرحله استخراج عددی تنش نشان داد که روش پردازش، افزایش نقاط پرت را نشان می‌دهد. این اختلاف ناشی از انباشت عدم قطعیت‌ها در موارد زیر است:

۱. حساسیت شدید مقدار بیشینه تنش به نویز رنگی حتی در یک پیکسل
۲. گسستگی و غیرخطی بودن مسیر رنگی پلاسما و تأثیر آن بر انتخاب نقطه نزدیک
۳. پیچش هندسی مسیر رنگ در ناحیه رنگ زرد (ناحیه متناظر با بیشینه تنش) که باعث می‌شود انحراف‌های کوچک رنگی مدل به جهش‌های بزرگ در مقدار تنش تبدیل شود.

این نتایج نشان می‌دهد که مدل پیش‌بینی تصویر عملکردی پایدار و دقیق دارد، اما پیچیدگی هندسی دامنه رنگ پلاسما، به‌ویژه در ناحیه بحرانی بیشینه تنش، منجر به خطاهای بزرگ و نقاط پرت در مرحله استخراج مقدار عددی می‌شود. در مجموع، می‌توان نتیجه گرفت که استفاده از مدل‌های مبتنی بر شبکه مولد تخصصی، به‌ویژه شبکه مولد تخصصی شرطی، می‌تواند روشی سریع و قابل اعتماد برای پیش‌بینی رفتار مکانیکی در سازه‌های ساده باشد. البته نتایج به دست آمده نشان می‌دهند که کیفیت تصاویر آموزشی و روش استخراج مقادیر عددی از خروجی مدل، نقش مهمی در دقت نهایی پیش‌بینی دارند.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیرایرانی منتشر نشده است.

تعارض منافع: هیچ تعارض منافعی برای اظهار وجود ندارد.

منابع

- [1] I. J. Goodfellow, et al., "Generative adversarial nets," Advances in Neural Information Processing Systems, vol. 27, 2014. doi:10.48550/arXiv.1406.2646
- [2] A. Aggarwal, M. Mittal, and G. Battineni, "Generative adversarial network: An overview of theory and applications," International Journal of Information Management Data Insights, vol. 1, no. 1, p. 100004, 2021. doi: 10.1016/j.jjime.2020.100004

Materials Science, pp.1-20. doi:10.1007/s10853-025-10772-2

[17] Liu, Y., Lin, Q., Pan, W., Yu, W., Ren, Y. and Zhao, Y., 2024. SR-M- GAN: A generative model for high-fidelity stress fields prediction of the composite bolted joints. Advanced Engineering Informatics, 61, p.102537. doi:10.1016/j.aei.2024.102537

[18] Hui, X., Xu, Y., Niu, J. and Zhang, W., 2024. Rapid evaluation and prediction of cure-induced residual stress of composites based on cGAN deep learning model. Composite Structures, 330, p.117827. doi:10.1016/j.compstruct.2023.117827

[19] Amieghemen, G.E., Ramezani, M. and Sherif, M.M., 2025. Residual Pyramidal GAN (RP-GAN) for crack detection and prediction of crack growth in engineered cementitious composites. Measurement, 242, p.115769. doi:10.1016/j.measurement.2024.115769

[20] Jiang, L., Hu, Y., Li, H., Shao, X., Zhang, X., Kan, Q. and Kang, G., 2025. A cGAN-based fatigue life prediction of 316 austenitic stainless steel in high-temperature and high-pressure water environments. International Journal of Fatigue, 190, p.108633. doi:10.1016/j.ijfatigue.2024.108633