

## **Classification of High Dimensional Imbalanced Dataset via Game Theory-based Generative Adversarial Networks**

S. Mirabedini, M. R. Kangavari\*, J. Mohammadzadeh

\*Iran University of Science and Technology

(Received: 30/07/2020, Accepted: 11/01/2021)

### **ABSTRACT**

*Game theory uses mathematical models to analyze the methods of cooperation or competition of intelligent beings. Game theory attempts to model the mathematical behavior of strategic interactions among rational decision-makers. The ultimate goal in this field of knowledge is to find the optimal strategy for the players. One of the newest ideas in the application of Game theory in the field of artificial intelligence and machine learning has led to generative adversarial networks (GANs). GANs which consist of two parts, use the Game theory and compete with each other, making unsupervised or semi-supervised learning possible. In addition to data generation, these networks are used for malicious software identification, software security, machine translation, and natural language processing, and also to build a three-dimensional model of an image. However, GANs have a very long training time due to the high number of epochs and input parameters. In this paper, in order to solve the problem of long training time of these networks in the classification of imbalanced high-dimensional datasets, a solution is presented in which, GAN-based minority classes are first oversampled. Then in order to improve the efficiency of the designed GAN, the mentioned network is parallelized and ensemble classification is done. The results of classifying a diabetic retinopathy dataset by the proposed method show that whilst maintaining the classification accuracy of 87%, the training time is reduced by 74%, thus demonstrating a higher accuracy in comparison to the latest scientific achievements.*

**Keywords:** Generative Adversarial Networks, Deep Neural Networks, Image Classification, Imbalanced Dataset, Game Theory, Machine Learning

---

\* Corresponding Author Email: kangavari@iust.ac.ir

## نشریه علمی "پدافند الکترونیکی و سایبری"

سال نهم، شماره ۲، تابستان ۱۴۰۰، ص ۷۴-۶۳

## علمی-پژوهشی

## رده‌بندی مجموعه داده نامتوازن با ابعاد بالا از طریق شبکه‌های رقابتی مولد عمیق مبتنی بر نظریه بازی

شیرین میرعبدی‌نی<sup>۱</sup>، محمدرضا کنگاوری<sup>۲\*</sup>، جواد محمدزاده<sup>۳</sup>

۱- دانشجوی دکتری گروه مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد کرج، ۲- دانشیار دانشگاه علم و صنعت ایران،

۳- استادیار گروه مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد کرج

(دریافت: ۱۳۹۹/۰۵/۰۹، پذیرش: ۱۳۹۹/۱۰/۲۲)

**چکیده**

نظریه بازی با استفاده از مدل‌های ریاضی به تحلیل روش‌های همکاری یا رقابت موجودات منطقی و هوشمند می‌پردازد. نظریه بازی تلاش می‌کند تا رفتار ریاضی حاکم بر یک موقعیت تضارب منافع را مدل‌سازی کند. هدف نهایی این دانش، یافتن راهبرد بهینه برای بازیکنان است. یکی از جدیدترین ایده‌ها در کاربرد نظریه بازی درزمینه<sup>۰</sup> هوش مصنوعی و یادگیری ماشین، شبکه‌های رقابتی مولد عمیق هستند. این شبکه‌ها که از دو بخش تشکیل می‌شوند با استفاده از نظریه بازی و با رقابت با یکدیگر موجب می‌شوند امکان یادگیری بهصورت بدون نظارت و یا نیمه ناظارتی فراهم گردد. از این شبکه‌ها علاوه بر تولید داده، در شناسایی نرم‌افزارهای مخرب و امنیت نرم‌افزار، ترجمه ماشینی و پردازش زبان طبیعی و ساخت مدل سه‌بعدی از یک تصویر نیز استفاده می‌شود. اما این نوع مدل‌ها به علت تعداد بالای تکرار و مؤلفه‌های ورودی، زمان آموزش بسیار طولانی دارند. در این مقاله در راستای حل مسئله زمان آموزش طولانی این شبکه‌ها در موضوع رده‌بندی مجموعه داده‌های با ابعاد بالای نامتوازن، راهکاری ارائه می‌شود که ابتدا داده‌های کم تعداد مربوط به کلاس‌های مجموعه داده‌ها، مبتنی بر شبکه رقابتی مولد، بیش‌نمونه‌برداری شده، سپس جهت بهبود کارایی شبکه‌های رقابتی مولد، موازی‌سازی شبکه مذکور انجام گرفته و با تمرکز بر افزایش کارایی، با رده‌بندی تجمیعی نتایج حاصله در حالات مختلف مورد بررسی و ارزیابی قرار می‌گیرد. نتایج به عمل آمده روی رده‌بندی مجموعه داده رتینوپاتی دیابتی با روش مذکور نشان داد با حفظ دقت رده‌بندی ۸۷٪، زمان آموزش ۷۴٪ کاهش می‌یابد که نتایج حاصله نسبت به آخرین پیشرفت‌های علمی نیز دقت بالاتری را نشان می‌دهد.

**کلیدواژه‌ها:** شبکه‌های رقابتی مولد، شبکه‌های عصبی عمیق، رده‌بندی تصاویر، مجموعه داده نامتوازن، نظریه بازی، یادگیری ماشین

روش‌های یادگیری عمیق با فرض این که داده ورودی یک تصویر باشد پیکسل‌های خام تصویر را از طریق یک مدل چندلایه و بهصورت سلسه مراتبی به مجموعه‌ای از ویژگی‌ها تبدیل می‌کند که این ویژگی‌ها در نهایت برای رده‌بندی، به رده‌بند داده می‌شود. روش‌های یادگیری عمیق در قالب معماری‌های مختلفی پیاده‌سازی شده است [۴-۲]. از جمله شبکه‌های عصبی پیچشی عمیق، روی مجموعه داده‌های تصاویر، یکی از موفق‌ترین معماری‌ها در میان معماری‌های یادگیری عمیق محسوب می‌گردد. شبکه‌های پیچشی، مدل‌های یادگیری عمیقی هستند که از داده‌های خام، برداشت‌های سطح میانی و سطح بالا به دست می‌آورند. یکی از مزیت‌های مهم شبکه‌های پیچشی این است که این دسته از شبکه‌ها، ویژگی‌ها را به طور مستقیم از داده ورودی استخراج می‌کنند و دیگر به طراحی یک استخراج کننده

**۱- مقدمه**

هم‌زمان با دسترسی به حجم عظیم داده‌ها، استفاده از برخی فناوری‌ها جهت تجزیه و تحلیل مجموعه داده‌ها ضروری شده است [۱]. مسئله رده‌بندی مجموعه داده‌ها، فنی جهت معنا بخشیدن به داده‌های در دسترس است که بهصورت با نظارت، بدون نظارت و نیمه ناظارتی قابل انجام است. در روش‌های سنتی رده‌بندی، مرحله استخراج ویژگی، با کمک فرد خبره صورت می‌پذیرد، اما با استفاده از شبکه‌های عصبی عمیق، امکان استخراج ویژگی‌های مجموعه داده‌ها درمسائل رده‌بندی، بدون نیاز به دانش قبلی و فرد خبره نیز میسر است.

\* رایانه‌نامه نویسنده مسئول: Kangavari@iust.ac.ir

تصمیم‌گیری‌های مهم بود [۱۰]. سال‌ها بعد، جان نش نابغه و ریاضیدان بزرگ، نظریه خود را چنین مطرح کرد "بهترین نتایج زمانی حاصل می‌شوند که هر کس آنچه را که برای خود و گروه بهترین است انجام دهد"؛ او مساله همکاری را در نظریه بازی گسترش داد و نشان داد که اگر افراد همکاری کنند و نفع گروه را نیز در نظر داشته باشند به بیشترین منافع برای خود و گروه دست می‌یابند. کار مهمی که جان نش انجام داد، یعنی آن چیزی که این نظریه آن را کم داشت، مساله تعادل بود و اینکه هر بازی در نهایت یک تعادل دارد [۱۱، ۱۲]. یکی از کاربردهای چشمگیر نظریه بازی و تعادل نش در طراحی شبکه‌های رقابتی مولد عمیق می‌باشد که در این مقاله برای رفع چالش داده‌های نامتوازن از این نوع شبکه استفاده شده است.

اما در انجام آزمایش‌ها مشخص شد آموزش شبکه رقابتی مولد عمیق در مرحله بیش نمونه‌برداری، به دلیل پیچیدگی بالای این نوع شبکه و ویژگی‌های بزرگ داده‌های با ابعاد بالا، فرایندی بسیار زمان بر است. لذا با پیوند داده‌های بزرگ و روش‌های یادگیری عمیق، به موازی‌سازی این مدل اقدام شد و به این ترتیب با به کارگیری شبکه‌های رقابتی مولد چندگانه، زمان آموزش این شبکه نیز کاهش قابل توجهی یافت. لازم به ذکر است در مرحله ردبندی، با توزیع داده‌ها بین ماشین‌ها، از آنچه که دقت مدل‌های عمیق با تعداد کمتر داده‌ها کاهش می‌یابد، در نهایت برای رفع مشکل کاهش دقت در اثر توزیع داده‌ها، از چارچوب یادگیری تجمعی که دارای مزیت پایداری و استحکام بیشتری نسبت به روش‌های تکردبند هستند از چندین ردبند استفاده شد.

مجموعه داده‌های منتخب در این پژوهش، تصاویر رتینوپاتی دیابتی است که با مشکل عدم توازن داده‌ها روبروست و تصاویر مذکور با ابعاد و ویژگی‌های بزرگ است. در این مقاله، مدلی پیشنهاد می‌گردد که علاوه بر ارائه راه حلی برای رویارویی با چالش عدم توازن مجموعه داده‌های مذکور، با روش‌های بیش نمونه‌برداری مبتنی بر شبکه‌های رقابتی مولد، بستری مناسب نیز برای موازی ساختن شبکه‌های مذکور فراهم آورده است.

در بخش‌های بعدی به معرفی اجزاء مختلف شبکه‌های رقابتی مولد و نحوه عملکرد این شبکه‌ها بر اساس نظریه بازی پرداخته می‌شود. سپس مدل پیشنهادی مبتنی بر این نوع شبکه جهت ردبندی مجموعه داده با ابعاد بالا و نامتوازن ارائه می‌گردد و نتایج حاصل از آزمایش‌ها متعدد انجام گرفته به صورت موازی و با استفاده از تعداد مختلف GPU نیز مورد بررسی و ارزیابی قرار می‌گیرد.

ویژگی مستقل و فرد خبره نیاز ندارند [۵-۷].

در موضوع ردبندی، مسئله داده‌های نامتوازن از جمله مسائلی است که طی سالیان اخیر از ابعاد مختلف مورد بررسی قرار گرفته است. این روش‌ها به سه صورت روش‌های سطح داده<sup>۱</sup>، روش‌های سطح الگوریتم<sup>۲</sup> و روش‌های ترکیبی از سطح داده و الگوریتم<sup>۳</sup> انجام شده است [۸]. تحقیقات نشان داده که در ردبندی با شبکه‌های عصبی عمیق، روش‌های سطح داده-بیش نمونه‌برداری<sup>۴</sup>-عملکرد بهتری دارد [۹]. همچنین بیش نمونه‌برداری نیز به دو صورت سنتی و مبتنی بر شبکه‌های مولد عمیق مطرح بوده است. شبکه‌های مولد عمیق به دو گونه شبکه‌های رقابتی مولد عمیق<sup>۵</sup> و شبکه خودمزگذار متغیر<sup>۶</sup> موجود است که شبکه‌های رقابتی مولد عمیق، آموزش سخت‌تر و نمونه‌های تولیدشده با کیفیت بهتر دارند و شبکه‌های خودمزگذار متغیر، آموزش آسان‌تر داشته، اما نمونه‌های با کیفیت پایین‌تر تولید می‌کنند.

ماهیت شبکه‌های عصبی عمیق به گونه‌ای است که با دریافت داده‌های بیشتر هنگام آموزش، مدل بهتری ایجاد می‌کنند. اما ویژگی داده‌های بزرگ، یادگیری عمیق را با چالش‌هایی روبرو ساخته است. یکی از بزرگ‌ترین چالش‌ها، به حجم و ابعاد بالای داده‌ها و تعداد ویژگی‌های داده موردن یادگیری مربوط می‌شود که به صورت مستقیم بر زمان آموزش تأثیر می‌گذارد. راهکار موجود برای غلبه بر این چالش، عملیات موازی‌سازی است که تاکنون نیز در راستای توزیعی نمودن الگوریتم‌های یادگیری عمیق گام‌هایی برداشته شده است.

در این پژوهش، به منظور رفع چالش نامتوازن بودن مجموعه داده‌ها در عملیات ردبندی، از روش بیش نمونه‌برداری مبتنی بر شبکه‌های رقابتی مولد عمیق، در تولید داده‌های با ابعاد بالا استفاده شده است. این شبکه‌ها نوعی از شبکه‌های عصبی عمیق و زیرمجموعه موضوع یادگیری ماشین هستند که مبتنی بر نظریه بازی و تعادل نش برای تولید داده‌ها، به خوبی عمل کرده‌اند. در سال ۱۹۹۴ جان نش<sup>۷</sup> و همکاران به خاطر مطالعات خلاقانه در زمینه<sup>۸</sup> نظریه بازی، برنده جایزه نوبل شدند. سال‌ها پیش پدر علم اقتصاد مدرن (آدام اسمیت) مطرح کرد که در رقابت، انگیزه‌های فردی به اهداف مشترک کمک می‌کند و بهترین نتایج زمانی پیدید می‌آید که هر کسی در گروه، کاری را که برای خودش بهترین است انجام دهد و سال‌ها این تفکر اساس

<sup>1</sup> Data level approaches

<sup>2</sup> Algorithm level approaches

<sup>3</sup> Cost-sensitive learning framework

<sup>4</sup> Over-Sampling

<sup>5</sup> Generative Adversarial Networks

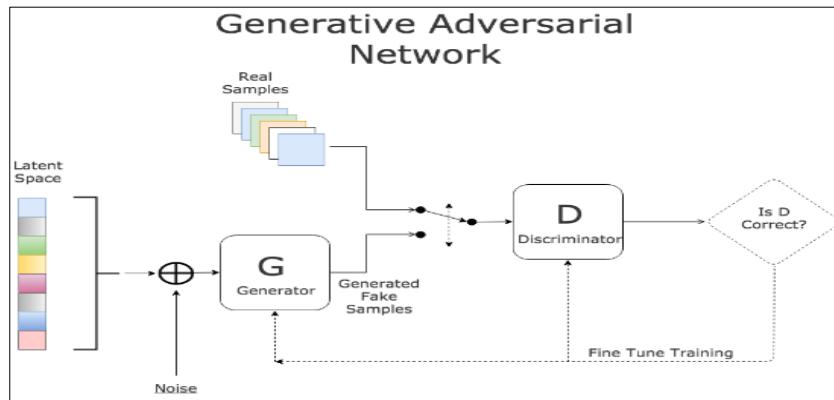
<sup>6</sup> variational autoencoder

<sup>7</sup> John Nash

عمیق غالباً از نوع پیچشی طراحی می‌گردد [۱۳]؛ ساختار کلی این شبکه‌ها در شکل (۱) قابل مشاهده است.

## ۲- شبکه‌های رقابتی مولد عمیق (GANs)

شبکه‌های رقابتی مولد عمیق از دو بخش اصلی مولد<sup>۱</sup> و متمایزگر<sup>۲</sup> تشکیل شده است که هر یک به صورت شبکه‌های



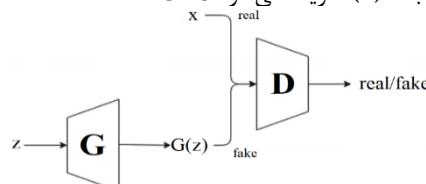
شکل (۱): ساختار کلی شبکه‌های رقابتی مولد

کاربرد در قالب رابطه (۱) قابل نمایش است:

$$\min_G \max_D f(D, G) = E_{x \sim p_{data}(x)} \log D(x) + E_{z \sim p_z(z)} \log(1 - D(G(z))) \quad (1)$$

مطابق رابطه (۱) و شکل (۲) هر دو طرف بازی توسط دوتابع معروفی می‌شوند که با توجه به تفاوت ورودی و پارامترها، دوتابع تعريف شده نیز متفاوت هستند؛ تابع متمایزگر D با ورودی  $x$  و تابع مولد G با ورودی  $z$  که یک نویز تولیدشده از  $x$  است و تابع احتمالی گاووسی است را دریافت می‌کند و  $G(z)$  یک نمونه تولیدشده توسط تابع G است. هدف بازی مینیماکس در اینجا کم کردن فاصله داده تولیدشده با داده واقعی است. اگر داده‌های واقعی به عنوان ورودی متمایزگر D ارائه شود، انتظار می‌رود خروجی این تابع عدد یک باشد. اما اگر ورودی متمایزگر، داده تولیدشده توسط مولد G باشد حاصل خروجی می‌باشد. بنابراین، تابع بهینه‌سازی شبکه مولد رقابتی به صفر میل کند.

به صورت رابطه (۱) تعریف می‌شود [۱۵].



شکل (۲): شماتیک شبکه‌های رقابتی مولد.

در حین فرآیند، بر اساس معادله نش نظریه بازی، شبکه مولد سعی می‌کند پارامترهای مربوط به خود را اصلاح کند و نتایج خود را تا حد مطلوبی دقیق کند که شبکه متمایزگر آن داده را به عنوان یک داده واقعی تشخیص دهد، در حالی که شبکه

زیرشبکه مولد جهت ایجاد تصاویر جدید غیرواقعی و زیرشبکه متمایزگر مسئول تمایز تصاویر ساختگی از تصاویر واقعی می‌باشد. در این ساختار که بر اساس نظریه بازی بنیان‌گذاری شده، تعادل نش<sup>۳</sup> با بهینه‌سازی عملکرد هر دو بخش منطبق شده است، به این معنی که عملکرد بهینه کل سیستم در گروه عملکرد بهینه هر دو بخش مذکور است یعنی مولد تلاش می‌کند تا تصاویر ساختگی نزدیک به واقع تولید نماید و متمایزگر تلاش می‌کند تا تشخیص تصاویر ساختگی را به درستی انجام دهد، لذا این دور و تسلسل ادامه پیدا می‌کند تا این که تصاویر تولیدشده توسط مولد به علت شباهت بیش از حد به تصاویر واقعی قابل تشخیص توسط متمایزگر نباشد و در این نقطه بهترین تصاویر ساختگی تولید می‌گردد و تعادل نش نظریه بازی نیز در همین نقطه محقق می‌شود [۱۴].

## ۲- نحوه کار شبکه‌های رقابتی مولد از دیدگاه نظریه بازی

همان‌طور که بیان شد شبکه‌های رقابتی مولد شامل دو زیرشبکه مولد و متمایزگر بوده که شبکه مولد، مسئول ایجاد داده معتبر از داده‌های ورودی و شبکه متمایزگر، مسئول تجزیه و تحلیل داده‌ها و تعیین واقعی یا ساختگی بودن داده است. طرز کار این شبکه شبیه بازی مینیماکس<sup>۴</sup> است که دو زیرشبکه مولد و متمایزگر، شرکت‌کنندگان اصلی آن هستند. مینیماکس یک قانون تصمیم‌گیری است که در نظریه بازی و آمار برای مینیمم کردن احتمال شکست و ضرر در بدترین حالت که بیشترین احتمال ضرر را دارد از آن استفاده می‌شود [۱۵]. این قانون برای این

<sup>1</sup> Generator

<sup>2</sup> Discriminator

<sup>3</sup> Nash Equilibrium

<sup>4</sup> minimax

برداری بهمنظور رفع مشکل عدم توازن داده‌ها در ردهبندی استفاده شده است. در این مرحله، از آنجا که مجموعه داده‌ای مورد استفاده، با ابعاد بالا بوده و مؤلفه‌های شبکه رقابتی مولد عمیق طراحی شده جهت تولید تصاویر کم تعداد، بسیار بزرگ می‌باشد به این منظور از روش‌های موازی‌سازی جهت کاهش زمان آموزش شبکه استفاده گردیده است.

پس از مرحله بیش نمونه‌برداری، تصاویر تولید شده و تصاویر اصلی مجموعه داده‌ها به شبکه پیچشی عمیق طراحی شده، جهت ردهبندی ارسال می‌شود. در مرحله ردهبندی نیز، برای بهبود دقت از چارچوب یادگیری تجمیعی استفاده شده و با استفاده از چندین ردهبند و درنهایت با اعمال یک ساز و کار رأی گیری، تصاویر برچسب‌گذاری می‌شوند.

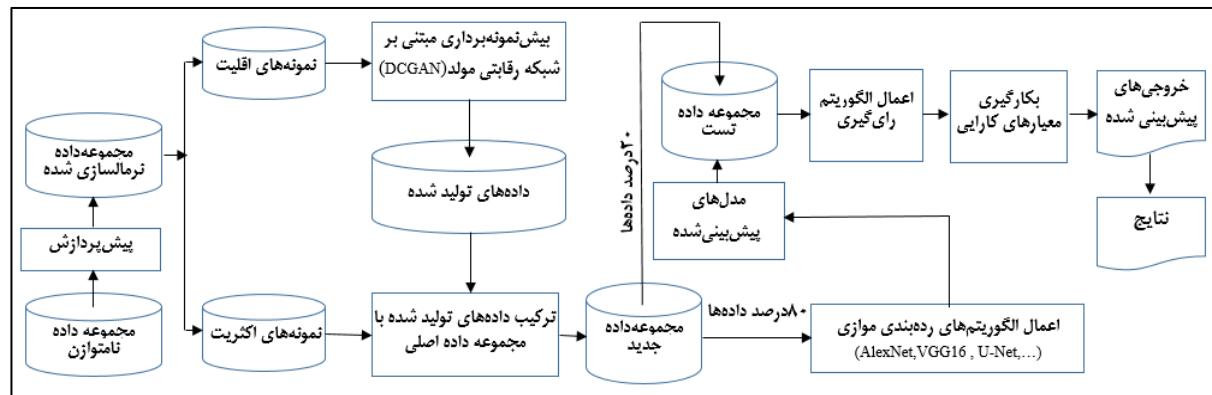
مراحل کلی انجام ردهبندی مجموعه داده‌های نامتوازن و با ابعاد بالا در روش پیشنهادی، به شرح شکل (۳) می‌باشد.

متمازیزگر، پارامترهای خودش را اصلاح می‌کند تا تفاوت بین داده واقعی و داده تولیدشده توسط مولد را تشخیص دهد.

معماری‌های مختلف و متنوعی از شبکه‌های رقابتی مولد بر اساس نیاز و کاربرد معین، توسط محققین این حوزه ارائه گردیده، از جمله شبکه‌های رقابتی مولد تماماً متصل [۱۳]، شبکه‌های رقابتی مولد پیچشی [۱۶]، شبکه‌های رقابتی مولد شرطی [۱۷]، که در این مقاله، معماری شبکه رقابتی مولد پیچشی، در ردهبندی مجموعه داده نامتوازن به کار گرفته شده است. در قسمت بعد به ارائه راه کار پیشنهادی پرداخته می‌شود.

### ۳- کلیات روش پیشنهادی

از آنجا که در شبکه‌های عصبی عمیق، رویکرد بیش نمونه‌برداری<sup>۱</sup> در سطح داده‌ها نسبت به دیگر روش‌ها بهینه‌تر عمل کرده است [۹] در این پژوهش، از شبکه رقابتی مولد، جهت بیش نمونه-



شکل (۳): راه حل پیشنهادی ردهبندی مجموعه داده نامتوازن

رقابتی مولد عمیق، تصاویری از کلاس‌های اقلیت به تعداد کلاس اکثربیت تولید می‌گردد.

در مرحله بعد تصاویر اصلی مجموعه داده‌ها به همراه تصاویر بیش نمونه‌برداری شده، به دو قسمت داده‌های تست و داده‌های آموزش به نسبت ۲۰ به ۸۰ تقسیم شده (که ۲۰ درصد داده‌های آموزش نیز جهت اعتبارسنجی<sup>۲</sup> به کار می‌رود) و داده‌های آموزش به عنوان ورودی به صورت موازی به چندین مدل عمیق پیچشی، جهت آموزش مدل‌ها و استخراج ویژگی‌ها ارائه می‌شود. در این مرحله نیز از موازی‌سازی شبکه‌های مربوط به هر ردهبند استفاده شده است. پس از آموزش شبکه‌های مذکور، مدل‌های پیش‌بینی‌کننده، خروجی این مرحله است. طبق چارچوب یادگیری تجمیعی، داده‌های تست روی این مدل‌ها اعمال شده و سپس با استفاده از یک ساز و کار رأی گیری روی نتایج حاصله از ردهبندهای آموزش دیده، رده تصویر تعیین

مطابق شکل (۳) ابتدا روی کل مجموعه داده‌های نامتوازن پیش‌پردازش صورت می‌گیرد، سپس مجموعه داده‌های نرمال‌سازی شده، به دو دسته نمونه‌های اقلیت و نمونه‌های اکثربیت تقسیم شده و از روش الگوریتم‌های سطح داده-بیش نمونه‌برداری- به تولید داده‌های کم تعداد و اقلیت از مجموعه آموزشی اقدام می‌شود که این مرحله از آزمایش با استفاده از شبکه رقابتی مولد پیچشی (DCGAN) انجام می‌گردد. لازم به ذکر است که به علت بزرگ بودن ویژگی‌های تصاویر و مؤلفه‌های شبکه رقابتی مولد در مرحله بیش نمونه‌برداری، زمان آموزش مدل، طولانی است. به همین جهت برای کاهش زمان آموزش مدل، طولانی است. به همین جهت برای کاهش استفاده شده است، به این ترتیب که نمونه‌های مرتبط با هر کلاس روی یک ماشین و با شبکه رقابتی مولد مشخص و مرتبط آموزش دیده و تولید می‌شود. پس از آموزش شبکه‌های

<sup>2</sup> validation

<sup>1</sup> Over-Sampling

تصاویر در هر کلاس میسر می‌گردد. پس از آن که مولدها آموزش داده شدند، با تولید نمونه‌های کم تعداد می‌توان بر چالش داده‌های نامتوازن غلبه کرد و بین کلاس‌های مجموعه داده‌ها توازن برقرار کرد.

### ۳-۳- مرحله رده‌بندی

در این مرحله نیز از شبکه‌های عصبی پیچشی، برای رده‌بندی استفاده شده است. به این صورت که با توزیع داده‌ها روی چندین ماشین از یک خوشه، عملیات آموزش مدل‌های رده‌بندی، بهصورت موازی انجام می‌گردد. از آنجا که دقت مدل‌های عمیق به تعداد داده‌های ورودی مرتبط است هرچه تعداد داده‌های ورودی بیشتر باشد، دقت بیشتر حاصل می‌شود و در صورتی که داده‌ها روی ماشین‌ها پخش شود از دقت رده‌بندها کاسته می‌شود. در این قسمت جهت جبران و بهبود دقت مرحله رده‌بندی، از چارچوب یادگیری تجمیعی<sup>۲</sup> با چندین رده‌بند استفاده شده است [۲۱]. هر رده‌بند از طریق یادگیری انتقالی<sup>۳</sup> [۲۲] و بهصورت توزیعی آموزش داده می‌شوند. رده‌بندهای مذکور شامل AlexNet، VGG16، U-Net [۲۵-۲۳] با بهینه‌سازهای<sup>۴</sup> متفاوت بوده و این در حالی است که تعداد رده‌بندها به اندازه تعداد ماشین‌های موجود در خوشه، قابلیت گسترش دارند.

### ۴-۳- موازی‌سازی عملیات

در این پژوهش، با توجه به ابعاد بالای داده و ویژگی‌های مربوطه، با رویکرد بهبود کارایی<sup>۵</sup>، به جهت کاهش زمان آموزش مدل و افزایش دقت در دو مرحله بیش نمونه‌برداری و همچنین رده‌بندی، عملیات موازی‌سازی صورت گرفته است.

در مرحله بیش نمونه‌برداری مبتنی بر شبکه رقابتی مولد، برای آموزش مدل مولد پیشنهادی، بهمنظور کاهش زمان کلی آموزش، نیاز به توزیع مدل روی ماشین‌های مختلف می‌باشد. توزیع مدل مولد مذکور، بهصورت ترکیبی از ایده موازی‌سازی داده و موازی‌سازی مدل انجام شده است.

مدل پیشنهادی برای موازی‌سازی، یک خوش شامل چند ماشین می‌باشد. در روش پیشنهادی، عملیات آموزش روی بخش مشخصی از داده در قالب یک وظیفه<sup>۶</sup> تعریف می‌شود. وظایف تعریف شده به ماشین پسرو<sup>۷</sup> مورد نظر ارسال شده، هر یک از ماشین‌های پسرو، پس از اجرای وظیفه دریافتی از سامانه سوی

می‌شود. نتایج از نظر دقت مرحله رده‌بندی و زمان آموزش مرحله بیش نمونه‌برداری بررسی شده و نتایج حاصل از تجمیع رده‌بندها روی دقت، با معیار آزمون تی زوجی مورد ارزیابی قرار می‌گیرد.

در قسمت بعد جزئیات بیشتری از مراحل روش پیشنهادی ارائه می‌گردد.

### ۱-۳- مرحله پیش‌پردازش

جهت پیش‌پردازش، از آنجا که مجموعه داده‌های تصویری در شرایط مختلف تهیه شده‌اند، بنابراین، این تصاویر از لحاظ نور، ساختار، ابعاد و دیگر شرایط با یکدیگر متفاوت هستند. لذا ضرورت دارد تا حد امکان تصاویر یکپارچه گشته، تأثیر منفی روی اجرای عملیات نگذارد.

در انجام این پژوهش برای انجام عملیات پیش‌پردازش و نرم‌السازی تصاویر، از کتابخانه OpenCV<sup>۸</sup> استفاده شد. با این عمل علاوه بر این که تصاویر یکپارچه گشته و از وضوح کافی برخوردار شدن، حجم آن‌ها نیز کاهش یافت.

### ۲-۳- مرحله بیش نمونه‌برداری مبتنی بر شبکه مولد

در حال حاضر در حوزه یادگیری عمیق، علاوه بر شبکه‌های رقابتی مولد، شبکه خودرنگار متغیر نیز قابلیت تولید داده‌ها را دارند [۱۸]. لازم بهذکر است گرچه آموزش شبکه‌های خودرنگار متغیر سهل‌تر است اما تصاویر تولید شده توسط آنها کیفیت مطلوب را ندارد [۲۰، ۱۹]؛ این در حالی است که آموزش شبکه‌های رقابتی مولد عمیق، نیاز به زمان و کار بیشتر داشته اما تصاویر با کیفیت بالاتری تولید می‌کنند. لذا در این تحقیق، شبکه‌های رقابتی مولد، برای مرحله بیش نمونه‌برداری گزیده شد.

اما به علت اینکه شبکه‌های رقابتی مولد، عملیات آموزش را بهطور کلی در مدت زمان نسبتاً طولانی انجام می‌دهند و اجرای این عملیات توسط سامانه‌های دارای واحد پردازنده گرافیکی پرقدرت، ساعتها زمان می‌برد و سامانه‌های معمولی، قدرت اجرای این عملیات را ندارند، لذا برای حل این موضوع از روش‌های موازی‌سازی استفاده شده است که در قسمت بعد به تشریح آن اقدام خواهد شد.

لازم به ذکر است معماری شبکه‌های رقابتی مولد با توجه به ورودی‌های متفاوت انتخاب می‌شود. لذا از آنجایی که داده‌های ورودی این تحقیق از نوع تصویر با ابعاد بالا هستند از معماری شبکه عصبی پیچشی در ساختار مولد و متمایزگر استفاده شده است. شبکه مولد طراحی شده در این پژوهش، با دقت بالا روی کلاس‌های کم تعداد آموزش می‌بیند و به این ترتیب قابلیت تولید

<sup>2</sup> Ensemble learning

<sup>3</sup> Transfer Learning

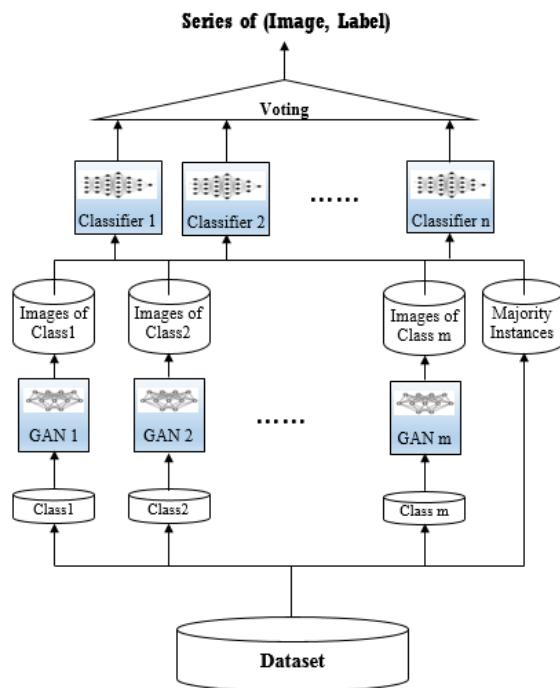
<sup>4</sup> optimizer

<sup>5</sup> Efficiency

<sup>6</sup> Task

<sup>7</sup> Slave

<sup>8</sup> <https://opencv.org/>



شکل (۴): معماری مدل پیشنهادی با توزیع شبکه‌های رقابتی مولد و تجمعی رده‌بندها.

چنانکه در شکل (۴) مشاهده می‌شود کلاس‌های کم تعداد، هر کدام به یک ماشین در خوشة تخصیص می‌یابد و به صورت موازی، آموزش مدل‌های مولد صورت می‌پذیرد. در نهایت مدل‌های آموزش دیده جهت تولید تصاویر، به کار گرفته می‌شود. سپس در فاز دوم این تحقیق رده‌بندی صورت می‌گیرد.

در اینجا لازم به ذکر است که با توزیع داده‌ها بین ماشین‌ها، داده‌های تخصیص یافته به هر رده‌بند کاهش یافته و با توجه به وابسته بودن دقت مدل‌های عمیق به تعداد داده‌ها، با کاهش داده‌ها، کاهش دقت به وجود می‌آید. برای رفع این نقص رده‌بندهای مختلف به صورت موازی در ماشین‌های چندگانه آموزش دیده شوند و در نهایت در زمان تست، با استفاده از چارچوب یادگیری تجمعی با چندین رده‌بند آموزش دیده شده و سپس اعمال یک سازوکار رأی‌گیری، خروجی‌های حاصل از رده‌بندها تجمعی می‌شود. در این الگوریتم رده‌ای که بیشتر از همه تکرار شده است، به عنوان رده تصویر انتخاب می‌شود.

الگوریتم‌های متفاوتی برای رأی‌گیری معرفی شده‌اند. از میان این الگوریتم‌ها، الگوریتم رأی‌گیری اکثریت بویر-مور<sup>۲</sup> سریع‌تر از سایر الگوریتم‌ها عمل می‌نماید. پیچیدگی زمانی این الگوریتم  $O(n)$  است. به همین دلیل در این قسمت از این الگوریتم استفاده شده است. این الگوریتم در هر لیست، عنصری که نسبت به عناصر دیگر بیشتر تکرار شده است را می‌یابد. روند عملیات

ماشین پیشرو<sup>۱</sup>، خروجی خود را به ماشین پیشرو ارسال می‌نمایند. شبکه کد ارائه شده در الگوریتم (۱)، روند آموزش این شبکه رقابتی مولد را ت Shan می‌دهد.

#### Algorithm 1: Distributed DCGAN Algorithm

```

1: FOR each machine  $i \in 1, \dots, v$  in parallel do
2:   FOR number of training iterations do
3:     FOR  $k$  steps do
4:       Sample minibatch of  $m$  noise samples  $z_i^{(1)}, z_i^{(2)}, \dots, z_i^{(m)}$  from noise prior  $p_g(z)$ 
5:       Sample minibatch of  $m$  examples  $x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)}$  from data generating distribution  $P_{\text{data}}$ 
6:       Update the discriminator by ascending its stochastic gradient:
7:        $\tau_{D_i} = -\frac{1}{M} \sum_{m=1}^M [\log D(x_i^{(m)}) + \log (1 - D(G(z_i^{(m)})))]$ 
8:     End for
9:     Sample minibatch of  $m$  noise samples  $z_i^{(1)}, z_i^{(2)}, \dots, z_i^{(m)}$  from noise prior  $p_g(z)$ .
10:    Update the generator by descending its stochastic gradient:
11:     $\tau_{G_i} = \frac{1}{M} \sum_{m=1}^M \log (1 - D(G(z_i^{(m)})))$ 
12:  End for
13: RETURN  $\tau_{D_i}, \tau_{G_i}$ 
14: END FOR
  
```

الگوریتم (۱): شبکه کد توزیع مدل مولد طراحی شده در خوشة.

در روش‌های موازی‌سازی داده در حین آموزش، ماشین‌های پس‌رو با ارسال مؤلفه‌های خود به ماشین پیشرو عملیات همگام‌سازی را انجام می‌دهند. اما در روش پیشنهادی با حذف تعاملات در حین آموزش، سرعت عملیات افزایش می‌یابد.

لازم به ذکر است در این آزمایش‌ها ابرمولفه دوره به جهت آموزش شبکه‌های رقابتی مولد به کاررفته ۲۰۰۰۰ است. در هر دوره با توجه به تعداد داده و تعداد دسته، تکرار و به روزرسانی مؤلفه‌ها انجام می‌شود. بنابراین، هر دوره شامل چندین تکرار است که لازم است مؤلفه‌ها با راه‌ها توسط شبکه ارسال و دریافت شوند تا به نحو درست آموزش بیینند. در این پژوهش به منظور کاهش زمان آموزش، حتی الامکان ارتباط‌های غیرضروری حذف شده است. معماری مورد استفاده جهت توزیع مدل در قالب شکل (۴) تجسم داده شده است.

<sup>2</sup>Boyer-More

<sup>1</sup> Master

بودن و با ابعاد و ویژگی بزرگ بودن را دارا باشد. لذا مجموعه داده‌های تصویری رتینوپاتی دیابتی، به علت داشتن این دو ویژگی، مناسب با موضوع این تحقیق انتخاب شد. مجموعه داده‌های مذکور، تصاویر رنگی شبکیه چشم مربوط به بیمارستانی در کشور انگلستان می‌باشد که به صورت سراسری از سایت کاگل به آدرس <https://www.kaggle.com/c/diabetic-retinopathy-detection/> که در سال ۲۰۱۵ به عنوان یک مسابقه ارائه شد شامل حدود ۸۰ گیگابایت تصاویر شبکیه است. این تصاویر، رنگی و با ابعاد بالا حدود ۴۰۰۰\*۳۹۰۰ پیکسل بوده و همچنین ویژگی‌های تصاویر، بزرگ می‌باشد. بنابراین، خصوصیت تصاویر با ابعاد بالا و ویژگی‌های بزرگ را دارد.

جدول (۲): اطلاعات مجموعه داده‌های رتینوپاتی دیابتی کاگل.

کلاس	تعداد تصاویر در کلاس	درصد نسبت به کل
.	۲۵۸۱۰	۷۳/۴۸٪
۱	۲۴۴۳	۶/۹۶٪
۲	۵۲۹۲	۱۵/۰۷٪
۳	۸۷۳	۲/۴۸٪
۴	۷۰۸	۲/۰۱٪

این مجموعه داده‌ها به شرح جدول (۲) تعداد ۳۵۱۲۶ تصویر شامل پنج کلاس است که کلاس ۰ (افراد سالم) بسیار پر تعداد در حدود ۷۳٪ کل داده‌های و کلاس‌های با درجه دیابت نوع ۱ تا ۴ درصد پایینی از کل داده‌ها را شامل می‌شوند. در این مجموعه تصاویر کلاس‌های ۰ و ۱ و ۲ و ۳ کلاس‌های غیرپرولیفراتیو یا NPDR بوده و کلاس ۴ از نوع پرولیفراتیو یا PDR می‌باشد. چنانی که در جدول مذکور مشاهده می‌شود کلاس PDR حدود ۰.۲٪ کل مجموعه داده‌ها را شامل می‌شود، لذا مجموعه داده‌های مذکور علاوه بر بزرگ بودن ابعاد، ویژگی نامتوازن بودن را نیز دارد.

#### ۲-۴- مجموعه داده تست و ارزیابی

آموزش شبکه‌های عصبی عمیق مستلزم داشتن مجموعه داده‌های به اندازه کافی بزرگ و مناسب است؛ همچنین برای ارزیابی روش پیشنهادی به مجموعه داده‌ای از همان نوع و با تعداد مناسب نیاز می‌باشد. از این‌رو، از ۲۰ درصد مجموعه داده‌های انتخابی برای تست و ۲۰ درصد نیز برای ارزیابی استفاده شد.

#### ۳-۴- معیارهای ارزیابی شبکه رقابتی مولد

رویکرد یادگیری ماشین از تعداد زیادی مؤلفه تشکیل شده است که این مؤلفه‌ها در حین روند آموزش مقادیر متغیری به خود می‌گیرند تا با رسیدن به نقطه تعادل به بهترین مقدار خود

رای گیری در الگوریتم (۲) نمایش داده شده است.

#### Algorithm 2: Voting

```

1: initialize an element m and a counter i with i = 0
2: FOR each element x of the input sequence:
3:   IF i = 0
4:     Assign m = x and i = 1
5:   ELSE IF m = x
6:     assign i = i + 1
7:   ELSE
8:     assign i = i - 1
9:   Return m
9: END FOR

```

الگوریتم (۲): شبکه گرد رای گیری بویر-مور.

#### ۴- آزمایش‌ها

برای پیاده‌سازی روش پیشنهادی، مشخصات نرم‌افزاری و سخت‌افزاری محیط آزمایش مطابق جدول (۱) در نظر گرفته و جهت پیاده‌سازی مدل‌های عمیق، از کتابخانه سطح بالای یادگیری عمیق Keras [۲۶] با زبان پایتون استفاده شده است. این کتابخانه مجموعه‌ای مفید از توابع و API‌ها برای ساخت انواع مختلف شبکه‌های عصبی را در اختیار قرار می‌دهد؛ اما، برای اجرا نیاز به یک چارچوب سطح پایین دارد که در اینجا Tensorflow [۲۷] انتخاب شده است. همچنین یک ابزار به نام Tensorboard دارد که از آن می‌توان برای متصورسازی گراف‌های محاسبات و نیز مشاهده نمودارهای خط و دقت در فرایندهای آموزش و آزمون استفاده کرد.

جدول (۱): مشخصات محیط آزمایش

API	Python
OS	Ubuntu
CPU	Intel Core i7
GPU	NVidia GTX 1050 Ti
	NVidia GTX 1080
	NVidia GTX 1080 Ti
RAM	16 GB
	20 GB
	20 GB
Disk	2 TB
	250 GB
	250 GB

#### ۱-۴- مجموعه داده انتخابی

از آنجا که هدف این تحقیق، رده‌بندی داده‌های نامتوازن و بزرگ است لذا مجموعه داده انتخابی می‌بایست دو ویژگی نامتوازن

طراحی شده‌اند که تأثیر ابرمُؤلفه‌های مذکور در زمان و دقت و تعیین‌پذیری مدل به خوبی نشان داده می‌شوند.

## ۵- نتایج و بحث

با توجه به این که رده‌بندی تصاویر رتینوپاتی دیابتی با استفاده از مدل رقابتی مولد تجمیعی با رویکرد افزایش کارایی تاکنون انجام نشده است، جهت بررسی کلاری، مدل مولد توزیع شده با مدل غیرتوزیعی مقایسه می‌گردد و تأثیر موازی‌سازی و تجمیع در زمان آموزش در دو حالت مذکور و با ابرمُؤلفه‌های مختلف مورد بحث و بررسی قرار می‌گیرد. همچنین در حالت توزیعی، با توجه به تعداد مختلف ماشین‌های درون خوشة، نتایج متفاوتی تولید می‌شود که مورد بررسی قرار می‌گیرد. ضمناً نتایج حاصل از این روش به لحاظ دقت، با روش‌های یادگیری عمیق انجام‌شده روی مجموعه داده منتخب این پژوهش، مورد مقایسه قرار می‌گیرد.

### ۱- بررسی تأثیر تعداد دوره در مدت زمان آموزش و دقت رده‌بندی

در انجام این آزمایش‌ها برای انتخاب تعداد دوره، در مدل شبکه عمیق طراحی شده روی مجموعه داده رتینوپاتی دیابتی کاگل، برای رسیدن به بهترین تعداد دوره، از ۱۰۰۰۰ دوره آغاز و با ۵۰۰۰۰ تعداد دوره افزایش داده شد.

پس از رسیدن به دقت مطلوب اندازه گام را کاهش داده و نقاط پیرامون نقطه مطلوب مورد بررسی قرار گرفت تا بهترین انتخاب حاصل شود. در نمودار شکل (۷) زمان و دقت بهازای بهترین تعداد دوره و تعداد دوره‌های قبل و بعد از آن نمایش داده شده است. طبق نتایج حاصل شده، از تعداد دوره ۲۰۰۰۰۰، مدل به ثبات می‌رسد. بنابراین، تعداد دوره ۲۰۰۰۰۰ برای شبکه طراحی شده انتخاب شد.

در نمودار شکل (۷) زمان مرحله بیش نمونه‌برداری و دقت مرحله رده‌بندی به ازای بهترین تعداد دوره و یک دوره قبل و بعد از آن نمایش داده شده است. نتایج حاصل شده روی داده‌های رتینوپاتی دیابتی کاگل نشان می‌دهد، دقت رده‌بندی در ۲۰۰۰۰۰ دوره آموزش به طور میانگین حدود ۱/۱ درصد از ۱۵۰۰۰۰ دوره بیشتر است و در مقایسه با ۲۵۰۰۰۰ دوره در دقت رده‌بندی، تفاوت چشم‌گیری حاصل نشده است؛ طبق نمودار، تنها زمان به طور میانگین ۱۵ ساعت افزایش داشته است. لذا تعداد دوره ۲۰۰۰۰۰ برای انجام آزمایش‌ها انتخاب شده است. ضمناً همان‌گونه که در شکل مشاهده می‌شود کاهش قابل توجه زمان به نسبت بزرگ‌تر شدن تعداد ماشین‌ها (حدود ۷۴ درصد) حاصل می‌شود.

بررسی از مؤلفه‌ها قبل از آغاز روند آموزش تنظیم می‌شوند. به این مؤلفه‌ها، ابرمُؤلفه گفته می‌شود. قانون و قاعده معینی برای تنظیم صحیح این ابرمُؤلفه‌ها وجود ندارد. بنابراین، راه حل موجود، به کارگیری مقادیر مختلف و بررسی تأثیر آن در نتیجه روند آموزش است. این ابرمُؤلفه‌ها در زمان آموزش و دقت خروجی بسیار تأثیرگذار هستند. ابرمُؤلفه‌های بررسی شده عبارت‌اند از:

- دوره<sup>۱</sup>: تعداد دفعاتی که عملیات آموزش روی تمامی داده‌های آموزش انجام می‌شود. از آنجایی که شبکه‌های عصبی برای بهینه‌سازی مؤلفه‌ها و وزن‌ها از گرادیان کاهشی تصادفی<sup>۲</sup> استفاده می‌کنند، با اجرای عملیات آموزش در یک دوره، مقدار بهینه برای مؤلفه‌ها حاصل نمی‌شود، در این شرایط گفته می‌شود که شبکه دچار کم‌برازش<sup>۳</sup> شده است. به عبارتی شبکه، یک مدل کلی از مجموعه آموزش ایجاد می‌کند که حتی روی داده‌های آموزش نیز دارای خطای بالا خواهد بود [۲۸]. با افزایش تعداد دوره، مدل تولیدشده نیز بهبود می‌یابد. عملیات به قدری تکرار می‌شود تا مدل بهینه تولید گردد. البته لازم به ذکر است که اگر تعداد دوره بالا باشد نیز مدل دچار بیش‌برازش<sup>۴</sup> می‌شود. در این حالت، مدل تنها روی داده‌های آموزش به خوبی عمل کرده و اگر داده‌ای از داده‌های آموزش فاصله داشته باشد به درستی نمی‌تواند عمل نماید.

- اندازه دسته<sup>۵</sup>: این مقدار مشخص کننده تعداد دفعاتی است که در هر دوره، خطای شبکه محاسبه شده و مؤلفه‌ها به روزرسانی می‌شوند. به عنوان مثال اگر اندازه دسته ۳۲ در نظر گرفته شود بهزاری انجام عملیات آموزش روی ۳۲ داده، خطای شبکه محاسبه شده و به روزرسانی انجام می‌شود. هر چه اندازه دسته بزرگ‌تر در نظر گرفته شود فضای اشغالی حافظه نیز افزایش می‌یابد اما از آنجایی که تعداد دفعات به روزرسانی کاهش می‌یابد، زمان آموزش نیز کم می‌شود. لازم به ذکر است بررسی‌های صورت گرفته نشان داده است که با افزایش اندازه دسته، پایداری شبکه کاهش می‌یابد [۳۰، ۳۱]. هدف دستیابی به بهترین عملکرد هم‌زمان با کاهش زمان محاسبات است.

در قسمت بعد به بررسی تأثیر تعداد دوره و اندازه دسته در زمان آموزش و تأثیر آن در دقت رده‌بندی اقدام می‌شود. هدف آن است با انتخاب درست، نه تنها از زمان آموزش کاسته شود بلکه دقت نیز محفوظ بماند. در این ارزیابی، آزمایش‌ها به گونه‌ای

<sup>1</sup> epoch

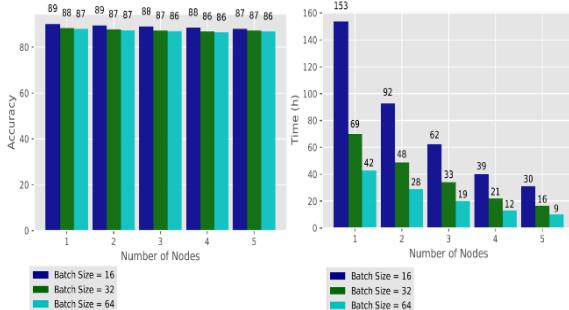
<sup>2</sup> Stochastic gradient descent

<sup>3</sup> underfitting

<sup>4</sup> overfitting

<sup>5</sup> batch size

می‌نماید و از طرفی در سامانه‌های با ظرفیت حافظه کمتر نیز قابل اجرا است.

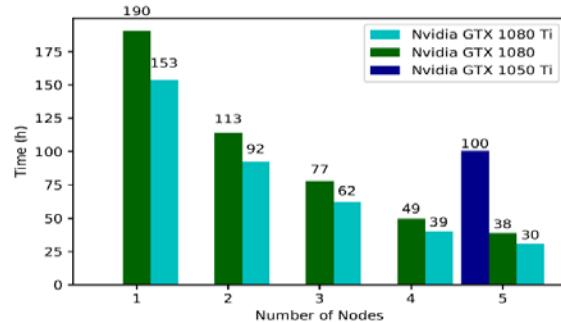


شکل (۸): نمودار تغییرات زمان بیش نمونه‌برداری و دقت رده‌بندی به ازای مقادیر مختلف اندازه دسته و تعداد ماشین

### ۳-۵- بررسی زمان آموزش با سامانه‌های مختلف

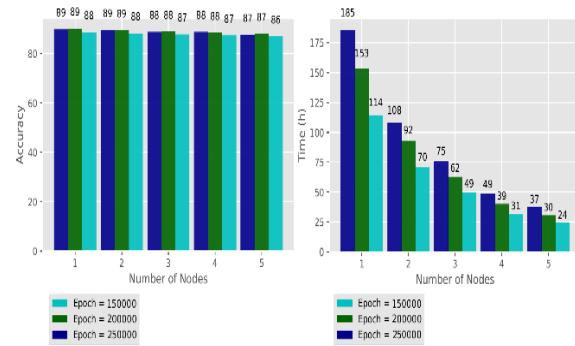
هدف اصلی از اعمال عملیات توزیع، افزایش کارایی و کاهش زمان است. با توجه به نتایج بدست‌آمده با افزایش تعداد ماشین‌های درون خوشه، زمان آموزش به طرز چشم‌گیری کاهش می‌یابد. این عمل در سامانه‌های فیزیکی با پردازنده گرافیکی معمولی تأثیر بیشتری دارد، زیرا عملیات آموزش بسیار کنتر از سامانه‌های فیزیکی قدرتمند است.

از دیگر اهداف توزیع، امکان استفاده از سامانه‌های معمولی است که یا امکان اجرای عملیات روی آنها وجود ندارد و یا در صورت امکان‌پذیر بودن بسیار سنگین و زمان‌بر هستند. این میزان از تأثیرگذاری برای مدل‌های پیچیده نمایان‌تر است. نمودار شکل (۹) نشان‌دهنده تأثیر توزیع مدل پیشنهادی بر روی مجموعه داده انتخابی در زمان آموزش روی سامانه‌های فیزیکی با قدرت متفاوت است.



شکل (۹): مقایسه زمان آموزش مدل مولد طراحی شده روی سامانه‌های متفاوت.

طبق نمودار شکل (۹) امکان اجرای مدل ارائه‌شده برای مجموعه داده رتینوپاتی دیابتی به صورت غیرتوزیعی به دلیل پیچیدگی بالای زیاد و حجم بالای داده‌ها در حالت غیرتوزیعی روی سیستم با پردازنده گرافیکی Nvidia GTX 1050 Ti



شکل (۷): نمودار تغییرات زمان مرحله بیش نمونه‌برداری و دقت رده‌بندی به ازای مقادیر مختلف تعداد دوره و تعداد ماشین

### ۲-۵- بررسی تأثیر اندازه دسته در مدت زمان و دقت رده‌بندی

پس از انتخاب تعداد دوره، مطالعه و بررسی روی اندازه دسته انجام گرفت. لازم به ذکر است اندازه دسته به سه طریق انتخاب می‌شود، این سه طریق عبارت‌اند از:

(۱) انتخاب اندازه ۱ برای اندازه دسته، که در این حالت به ازای هر تصویر میزان خطای محاسبه شده و مؤلفه‌ها به روزسانی می‌شود که این انتخاب به دلیل بار محاسباتی بالا مطلوب نیست.

(۲) انتخاب اندازه کل مجموعه داده آموزش برای اندازه دسته، که در این حالت به ازای کل مجموعه داده تنها یکبار خطای محاسبه شده و به روزسانی انجام می‌شود؛ که این امر زمانی که مجموعه داده، از نوع داده‌های بزرگ باشد، امکان‌پذیر نیست.

(۳) انتخاب تعداد بین ۱ تا تعداد کل داده‌های مجموعه داده مورد نظر، به عنوان اندازه دسته، که مطلوب‌ترین راه مطرح شده است.

از میان اعداد درون بازه مذکور هر چه عدد انتخابی بزرگ‌تر باشد، تعیین‌پذیری مدل کاهش می‌یابد و به حافظه بیشتری هم نیاز است [۳۱]. طبق بررسی‌های انجام شده از میان اعداد درون بازه مذکور، اندازه ۱۶، ۳۲ و ۶۴ بهترین انتخاب‌ها بوده و ۳۲ را به عنوان پیش‌فرض معرفی نموده‌اند [۲۹، ۳۲]، اما نمی‌توان با قطعیت این عدد را به عنوان اندازه دسته انتخاب نمود. بنابراین، لازم است ارزیابی روی هر سه اندازه انجام شود تا بهترین اندازه برای مدل پیشنهادی انتخاب شود.

طبق نمودار شکل (۸) مدل پیشنهادی برای مجموعه داده انتخابی، روی تعداد ۱۶، ۳۲ و ۶۴ دسته مورد ارزیابی و بررسی قرار داده شد تا بهترین تعداد دسته معین شود. با وجود زمان طولانی‌تر آموزش به ازای تعداد دسته ۱۶، همین عدد برای مدل پیشنهادی انتخاب گردید چراکه دقت بالاتری در رده‌بندی ایجاد

و حالت چند ردهبند با اعمال الگوریتم رأی‌گیری نشان می‌دهد. از آنجایی که برای انجام رأی‌گیری حداقل به سه داده نیاز است، برای اجرای این الگوریتم حداقل به ۳ ردهبند و ماشین درون خوش نیاز است. بهمنظور ارزیابی، آزمون تی دو نمونه‌ای، روی ۳ تا ۵ مدل ردهبند به صورت مجزا بررسی صورت گرفت. نتیجه این ارزیابی برای دو حالت ارائه شده در جدول (۴) نشان داده شده است.

**جدول (۳):** میزان دقت ردهبندی در حالت تک ردهبند و حالت چند ردهبند با اعمال سازوکار رأی‌گیری.

تعداد بندهای دردون خوش	ردهبندها	میانگین دقت ردهبندی پس از در حالت تجمیع و رأی‌گیری	دقت ردهبندی
۳	AlexNet(Adam), VGG16(Adam), UNet	۸۸/۶۲	۸۹/۷۷
۴	AlexNet(Adam), VGG16(Adam), UNet, AlexNet(RMSprop)	۸۷/۷۸	۸۹/۰۸
۵	AlexNet(Adam), VGG16(Adam), UNet, AlexNet(RMSprop), VGG16(RMSprop)	۸۷/۱۹	۸۸/۶۸

**جدول (۴):** محاسبات آزمون تی دو نمونه‌ای بر روی ۳ وضعیت آزمایش روی مدل پیشنهادی.

تعداد ردهبندهای دردون خوش	T	$\bar{d}$	P-value
۳	۱۲۲/۵۷	۱/۱۴	4.067e-16
۴	۱۲۲/۸۷	۱/۳۰	3.978e-16
۵	۱۸۳/۳۴	۱/۴۹	2.2e-16

### ۵- مقایسه دقت روش پیشنهادی با روش‌های مشابه

روش پیشنهادی علاوه بر تمرکز روی افزایش کارایی و بهبود زمان آموزش مدل رقابتی مولد عمیق که در بخش قبل به آن اشاره شد، دقت ردهبندی را نیز نسبت به روش‌های مشابه افزایش داده است. لازم به ذکر است ردهبندی دیتاست مذکور در سال ۲۰۱۵ توسط کاگل ارائه شد و نفرات برتر این مسابقه در بین ۶۰ گروه شرکت‌کننده به دقت حدود ۸۰ درصد دست یافتند [۳۴، ۳۳]. سپس Prat و همکاران در سال ۲۰۱۶ و Qummar و همکاران در سال ۲۰۱۹ با روش‌های یادگیری عمیق، روی همین مجموعه داده‌ها ردهبندی انجام دادند که در جدول (۵) و شکل (۱۰)، مقایسه این روش‌ها و درنهایت دقت ردهبندی‌ها در هر روش نمایش داده شده است.

امکان‌پذیر نیست و برای اجرای توزیعی نیز به حداقل ۵ ماشین با قدرت مشابه نیاز است. این مدل روی پردازنده نسبتاً قدرتمند Nvidia GTX 1080 Ti در حالت غیر توزیعی به مدت ۶ روز زمان می‌برد که با اعمال عملیات توزیع، می‌توان آن را تا حداقل حدود ۷۴ درصد کاهش داد.

همان‌گونه که از نمودارهای فوق مشهود است با افزایش تعداد ماشین‌ها، زمان آموزش، کاهش قابل توجه دارد اما دقت مرحله ردهبندی کاهش می‌یابد. برای رفع این نقص با استفاده از چارچوب یادگیری تجمیعی، از ردهبندهای چندگانه استفاده شده است که در بخش بعدی، اثر تجمیع ردهبندها و اعمال ساز و کار رأی‌گیری در رفع این نقص نمایش داده می‌شود.

### ۴- بررسی تأثیر الگوریتم رأی‌گیری در دقت ردهبندی

در این آزمایش الگوریتم ردهبندی در وضعیت‌های متفاوت توزیعی و غیرتوزیعی، روی یک الی پنج پردازنده گرافیکی بررسی شد. هر چه تعداد ماشین‌ها افزایش یافت به علت کم شدن تعداد داده‌ها به هر ماشین، دقت کاهش پیدا کرد. برای رفع مشکل کاهش دقت، بر اساس یادگیری انتقالی، مدل‌های پیچشی عمیق در AlexNet، VGG16 و UNet با بهینه‌سازهای مختلف آموزش داده شدند. سپس در سه وضعیت متفاوت با ماشین‌های چندگانه، اثر تجمیع ردهبندها و اعمال ساز و کار رأی‌گیری بر روی دقت ردهبندی، مورد بررسی قرار گرفت.

طبق بررسی‌های انجام شده، در مرحله ردهبندی، هر چه تعداد ردهبندها روی ماشین‌های دردون خوش افزایش داده شد، چون تعداد آرا بیشتر می‌شود میزان بهبود دقت ردهبندی با استفاده از الگوریتم رأی‌گیری بیشتر از زمانی است که عمل ردهبندی تنها با استفاده از یک ردهبند انجام می‌شود.

در اینجا برای ارزیابی عملکرد چارچوب یادگیری تجمیعی و ردهبند چندگانه و اعمال الگوریتم رأی‌گیری مذکور از آزمون تی دو نمونه‌ای<sup>۱</sup> استفاده شده است. این آزمون پاسخی برای سؤال آیا اختلاف بین دو میانگین تفاوت معنی‌داری با صفر دارد؟ است. منظور از دو میانگین، میانگین دقت ردهبندی با یک ردهبند واحد و میانگین دقت ردهبندی با چندین ردهبند و اعمال ساز و کار رأی‌گیری است.

نتیجه آزمون تی دو نمونه‌ای در این مرحله از آزمایش‌ها به شرح زیر است:

**جدول (۳)،** دقت ردهبندی را در حالت استفاده از یک ردهبند

<sup>1</sup> paired sample T Test

جدول (۵): مقایسه روش پیشنهادی با [۳۵] و [۳۶]

روش	تعداد تصاویر / مجموعه داده	روش نمونه‌برداری	نوع ردهبند	کتابخانه/ زبان پیاده‌سازی	دقت
[۳۶] Prat et al.2016	80000 D.R. Kaggle Dataset	Normal Data Augmentation	CNN	Keras/Python	۷۵٪.
Qummar et al.2019 [۳۵]	35126 D.R. Kaggle Dataset	Data Augmentation	CNN, Transfer Learining	Keras/Python	۸۰/۸٪.
Our Method	35126 D.R. Kaggle Dataset	GAN	CNN, Transfer Learining	Keras/Python	۸۷/۸۶٪.

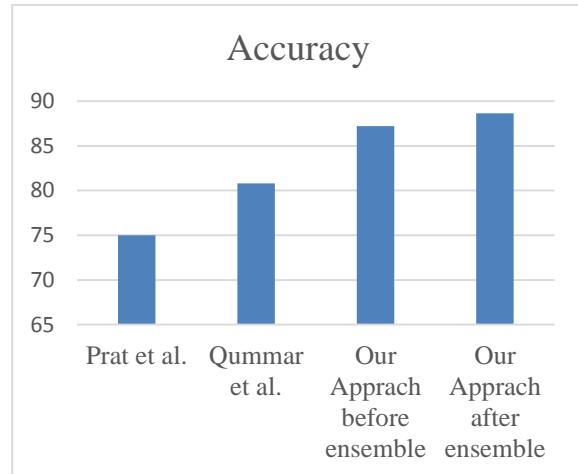
آموزش و دقت ردهبندی تأثیرگذار هستند مورد ارزیابی قرار گرفت و بهترین مقدار ممکن برای مدل‌های مذکور برگزیده شد. سپس تأثیر توزیع در زمان آموزش شبکه رقبایی مولد طراحی شده در مرحله بیش‌نمونه‌برداری و دقت ردهبندی موردنبررسی قرار گرفت. مشاهدات نشان داد که با توزیع شبکه، میان ماشین‌های درون خوشه، علاوه بر بهینه‌سازی کارایی و کاهش زمان ۷۴ درصدی آموزش، دقت ردهبندی نیز نسبت به موارد مشابه قبلی بهبود یافت. همچنین از دیگر نتایج جانبی حاصل از این ارزیابی می‌توان به امکان جایگزین کردن چند سیستم فیزیکی با قدرت محدود به جای سامانه‌های قادرمند نیز اشاره کرد.

لازم به ذکر است مشاهدات در مرحله ردهبندی توزیعی نشان داد که با افزایش تعداد ماشین‌های درون خوشه، به دلیل کاهش تعداد داده آموزشی در هر یک از ماشین‌ها، دقت ردهبندی کمی کاهش می‌یابد، لذا با استفاده از چندین ردهبند و تجمعی نتایج حاصله از طریق ساز و کار رأی‌گیری، این مشکل کاهش دقت نیز مرتفع گردید.

در این پژوهش برای حل مسئله ردهبندی داده‌های نامتوازن با ابعاد بالا با رویکرد بهینه‌سازی کارایی و استفاده از ساز و کار موازی‌سازی شبکه‌های رقبایی مولد مبتنی بر نظریه بازی و همچنین تجمعی ردهبندها چارچوبی ارائه شد که می‌تواند برای کلیه مجموعه داده‌های با ابعاد بالا و نامتوازن مورد استفاده قرار گیرد.

## ۷- مراجع

- [1] M. R. K. H. Saberi and M. R. Hasani Ahangar, "Providing an Agent-Based Architecture for Semantic Mining From Large-Scale Data in Distributed Environments," Journal of Electronical & Cyber Defence, vol. 8, no. 3, 2020.
- [2] S. Krig, "Feature learning and deep learning architecture survey," in Computer Vision Metrics: Springer, pp. 375-514. 2016.
- [3] I. Goodfellow, Y. Bengio, and A. Courville, Deep learning, MIT press, 2016.



شکل (۱۰): مقایسه دقت مدل پیشنهادی با [۳۵] و [۳۶]

چنانکه در نمودار مشاهده می‌شود علاوه بر بهبود کارایی در ردهبندی مجموعه داده نامتوازن، دقت نیز در روش پیشنهادی حدود ۷ درصد نسبت به روش‌های قبلی افزایش نشان می‌دهد.

## ۶- نتیجه‌گیری

در این مقاله، کاربردی از شبکه رقبایی مولد که بر اساس نظریه بازی طراحی شده است در حل چالش ردهبندی داده‌های نامتوازن، طراحی و مورد آزمایش قرار گرفت. با توجه به تمرکز این پژوهش بر روی بهینه‌سازی کارایی و رفع مشکل طولانی بودن زمان آموزش شبکه‌های رقبایی مولد، در مرحله بیش نمونه‌برداری موازی‌سازی و در مرحله ردهبندی تجمعی صورت گرفت.

لذا عملیات ردهبندی بر روی مجموعه داده نامتوازن و با ابعاد و ویژگی‌های بزرگ رتینوپاتی دیابتی کاگل علاوه بر اجرای معمولی، در حالت اجرای موازی شبکه نیز مورد آزمایش قرار گرفت.

در نخستین گام، ابرمُؤلفه‌های شبکه‌های عصبی عمیق از جمله تعداد دوره و اندازه دسته که روی افزایش کارایی و زمان

- [21] T. G. Dietterich, "Ensemble learning," *The handbook of brain theory and neural networks*, vol. 2, pp. 110-125, 2002.
- [22] L. Torrey and J. Shavlik, "Transfer learning," in *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*: IGI global, pp. 242-264, 2010.
- [23] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size," arXiv preprint arXiv:1602.07360, 2016.
- [24] 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*, Springer, pp. 234-241, 2015.
- [25] H. Qassim, A. Verma, and D. Feinziper, "Compressed residual-VGG16 CNN model for big data places image recognition," in *2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)*, IEEE, pp. 169-175, 2018.
- [26] F.C. e. al., "Keras" <https://keras.io> (accessed).
- [27] M. Abadi et al., "Tensorflow: Large-scale machine learning on heterogeneous distributed systems," arXiv preprint arXiv:1603.04467, 2016.
- [28] L. ZeBlemoyer. "Linear Regression Bias / Variance Tradeoff ".<https://courses.cs.washington.edu/courses/cse546/> (accessed 2018).
- [29] Y. Bengio, "Practical recommendations for gradient-based training of deep architectures," in *Neural networks: Tricks of the trade*, Springer, pp. 437-478, 2012.
- [30] J. Hermans, "On Scalable Deep Learning and Parallelizing Gradient Descent," Master, Maastricht, 2017. [Online]. Available: <http://cds.cern.ch/record/2276711>.
- [31] D. Masters and C. Luschi, "Revisiting Small Batch Training for Deep Neural Networks. arXiv 2018," arXiv preprint arXiv:1804.07612.
- [32] N. S. Keskar, D. Mudigere, J. Nocedal, M. Smelyanskiy, and P. T. P. Tang, "On large-batch training for deep learning: Generalization gap and sharp minima," arXiv preprint arXiv:1609.04836, 2016. [Online]. Available: <http://arxiv.org/abs/1609.04836>.
- [33] B. Graham, "Kaggle diabetic retinopathy detection competition report," University of Warwick, 2015.
- [34] M. Antony and S. Brüggemann, "Kaggle Diabetic Retinopathy Detection; Team o\_O solution," ed: Competition Report Github. url :[https://github.com/sveitser/kaggle\\_diabetic](https://github.com/sveitser/kaggle_diabetic) ..., 2015.
- [35] S. Qummar et al., "A deep learning ensemble approach for diabetic retinopathy detection," *IEEE Access*, vol. 7, pp. 150530-150539, 2019.
- [36] H. Pratt, F. Coenen, D. M. Broadbent, S. P. Harding, and Y. Zheng, "Convolutional neural networks for diabetic retinopathy," *Procedia Computer Science*, vol. 90, pp. 200-205, 2016.
- [4] S. P. M. Zakeri Nasrabadi1, "Automatic Test Data Generation in File Format Fuzzers," *Journal of Electronical & Cyber Defence*, vol. 8, no. 29, 2020.
- [5] D. C. Ciresan, U. Meier, J. Masci, L. M. Gambardella, and J. Schmidhuber, "Flexible, high performance convolutional neural networks for image classification," in *Twenty-Second International Joint Conference on Artificial Intelligence*, 2011.
- [6] C. C. Chatterjee, "Basics of the Classic CNN," <https://towardsdatascience.com/basics-of-the-classic-cnn-a3dce1225add> (accessed may/11/2019).
- [7] "Convolutional Neural Networks (CNNs / ConvNets)," <https://cs231n.github.io/convolutional-networks/> (accessed).
- [8] Y. Sun, A. K. Wong, and M. S. Kamel, "Classification of imbalanced data: A review," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 23, no. 04, pp. 687-719, 2009.
- [9] M. Buda, A. Maki, and M. A. Mazurowski, "A systematic study of the class imbalance problem in convolutional neural networks," *Neural Networks*, vol. 106, pp. 249-259, 2018.
- [10] J. v. Neumann, "Zur theorie der gesellschaftsspiele," *Mathematische annalen*, vol. 100, no. 1, pp. 295-320, 1928.
- [11] A. W. Tucker and R. D. Luce, *Contributions to the Theory of Games* (no. 40), Princeton University Press, 1959.
- [12] A. A. M. Forooghy and M. Bagheri, "A Decision-Making Model in a Cyber Conflicts Acted Upon Vulnerability, Based on Game Theoretic Analysis," *Journal of Electronical & Cyber Defence*, vol. 6, no. 22, 2018.
- [13] I. Goodfellow et al., "Generative adversarial nets," in *Advances in neural information processing systems*, pp. 2672-2680, 2014.
- [14] E. L. Denton, S. Chintala, and R. Fergus, "Deep generative image models using a laplacian pyramid of adversarial networks," in *Advances in neural information processing systems*, pp. 1486-1494, 2015.
- [15] I. Goodfellow, "NIPS 2016 tutorial: Generative adversarial networks," arXiv preprint arXiv:1701.00160, 2016. [Online]. Available: <http://arxiv.org/abs/1701.00160>.
- [16] A. Radford, L. Metz, and S. Chintala, "Unsupervised representation learning with deep convolutional generative adversarial networks," arXiv preprint arXiv:1511.06434, 2015.
- [17] M. Mirza and S. Osindero, "Conditional generative adversarial nets," arXiv preprint arXiv:1411.1784, 2014.
- [18] J. An and S. Cho, "Variational autoencoder based anomaly detection using reconstruction probability," *pecial Lecture on IE*, vol. 2, no. 1, 2015.
- [19] S. Nowozin, B. Cseke, and R. Tomioka, "f-gan: Training generative neural samplers using variational divergence minimization," in *Advances in neural information processing systems*, pp. 271-279, 2016.
- [20] A. Kadurin, S. Nikolenko, K. Khrabrov, A. Aliper, and A. Zhavoronkov, "drugGAN: an advanced generative adversarial autoencoder model for de novo generation of new molecules with desired molecular properties in silico," *Molecular pharmaceutics*, vol. 14, no. 9, pp. 3098-3104, 2017.