



Computational Intelligence in Electrical Engineering  
Vol. 13, No. 3, 2022  
Research Paper

## Variational Generative Adversarial Networks for Preventing Mode Collapse

Mehdi Jamaseb Kholari<sup>1</sup>, Vali Derhami<sup>2</sup>, Mahdi Yazdian-Dehkordi<sup>3</sup>

1 Computer Engineering Department, Yazd University, Yazd, Iran

2 Computer Engineering Department, Yazd University, Yazd, Iran

3 Computer Engineering Department, Yazd University, Yazd, Iran

### Abstract:

Generative models try to obtain a probability distribution that is similar to that of observed data. Two different solutions have been proposed in this regard in recent years: one is to minimize the divergence (distance) between the two distributions by maximizing the variational lower bound, and the other is to implicitly reduce the distance between the two distributions through adversarial processes. One of the problems in generative adversarial networks (GANs) is the mode collapse. Mode collapse is a phenomenon in which, for various inputs, the generative model generates low variety or similar images. This paper tries to provide a solution to the mode collapse problem proposing a novel method called variational generative adversarial networks (VGANs). This method exploits variational autoencoders to initialize GANs. In other words, in addition to maximizing the variational lower bound, it also implicitly reduces the distance between the two distributions. Experimental results show that this method can deal with the mode collapse problem better than the state-of-the-art. Moreover, in the qualitative analysis, according to a survey of 136 people on the authenticity of the generated images, the proposed method can generate images more similar to real ones.

**Keywords:** Deep Learning, Generative Adversarial Networks, Machine Learning, Variational Inference, Mode Collapse.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<http://dx.doi.org/10.22108/isee.2021.129742.1495>

## شبکه‌های تخصصی مولد تغییراتی برای جلوگیری از فروافتادگی حالت

مهدی جاماسب خلاری<sup>۱</sup>، ولی درهمی<sup>۲\*</sup>، مهدی یزدیان دهکردی<sup>۳</sup>

۱- دانشجوی دکتری، دانشکده مهندسی کامپیوتر- دانشگاه یزد- یزد- ایران

jamasb@yazd.ac.ir

۲- استاد، دانشکده مهندسی کامپیوتر- دانشگاه یزد - یزد- ایران

vderhami@yazd.ac.ir

۳- استادیار، دانشکده مهندسی کامپیوتر- دانشگاه یزد - یزد- ایران

yazdian@yazd.ac.ir

**چکیده:** مدل‌های مولد سعی می‌کنند توزیع احتمالی که مشابه با توزیع داده‌های دیده شده باشد را به دست آورند. برای این کار دو راه‌حل در سال‌های اخیر ارائه شده است؛ یکی کمینه‌کردن واگرایی (فاصله) بین دو توزیع از طریق بیشینه‌کردن باند پایین تغییراتی و دیگری کاهش ضمنی فاصله بین دو توزیع از طریق فرآیندهای تخصصی. یکی از مشکلات موجود در شبکه‌های تخصصی مولد، فروافتادگی حالت است. فروافتادگی حالت به موضوعی گفته می‌شود که مدل مولد به‌ازای مقادیر ورودی متفاوت و پراکنده، نمونه‌های با پراکندگی کم یا حتی نمونه‌های مشابه به هم تولید می‌کند. این مقاله با ارائه روشی با عنوان شبکه‌های مولد تخصصی تغییراتی سعی در مقابله با فروافتادگی حالت و همچنین، تولید داده‌های طبیعی‌تر دارد. این روش با استفاده از خودرمزگذارهای تغییراتی، شبکه‌های تخصصی مولد را مقداردهی اولیه می‌کند. به بیان دیگر، علاوه بر اینکه باند پایین تغییراتی را بیشینه می‌کند، فاصله بین دو توزیع را به‌صورت ضمنی کاهش می‌دهد. نتایج تجربی نشان می‌دهند این روش توانسته است بهتر از روش‌های موجود با مشکل فروافتادگی حالت مقابله کند. همچنین، در تحلیل کیفی براساس نظرسنجی از ۱۳۶ فرد در رابطه با واقعی بودن تصاویر تولیدشده نشان داده شد روش پیشنهادی تصاویر مشابه‌تری به واقعیت نسبت به روش پایه تولید کرده است.

**واژه‌های کلیدی:** استنباط تغییراتی، شبکه‌های تخصصی مولد، فروافتادگی حالت، یادگیری ماشینی، یادگیری عمیق

## ۱- مقدمه

استفاده شده است [4]-[1]. به‌تازگی گونه‌ی خاصی از شبکه‌های یادگیری عمیق با عنوان شبکه‌های تخصصی مولد<sup>۱</sup> یا به‌اختصار GANs معرفی شده است [6], [5]. شبکه‌های تخصصی مولد درحقیقت یک چارچوب هستند که مدل‌های مولد را براساس یک فرآیند تخصصی می‌سازند. در این چارچوب دو مدل هم‌زمان آموزش داده می‌شود. یک مدل مولد<sup>۲</sup> G که توزیع داده‌ها را به دست می‌آورد و یک مدل متمایزکننده<sup>۳</sup> D که احتمال اینکه نمونه از داده‌های آموزشی آمده باشد یا از مدل G را تخمین می‌زند. پروسه آموزش G این است که احتمال اینکه D اشتباه کند را بیشینه کند. درحقیقت این چارچوب مانند یک بازی دونفره بازی کمینه - بیشینه<sup>۴</sup> است. نمای کلی شبکه‌های تخصصی

از سال ۲۰۰۶ یادگیری عمیق به‌عنوان یک حوزه جدید در تحقیقات یادگیری ماشینی شناخته شده است. تکنیک‌های مربوط به آن در سال‌های اخیر توسعه پیدا کرده و در کاربردهای مختلفی از پردازش اطلاعات و پردازش سیگنال

<sup>۱</sup> تاریخ ارسال مقاله: ۱۴۰۰/۰۵/۰۷

تاریخ پذیرش مقاله: ۱۴۰۰/۰۶/۱۳

نام نویسنده مسئول: ولی درهمی

نشانی نویسنده مسئول: ایران - یزد - دانشگاه یزد - دانشکده مهندسی کامپیوتر

مشخص می‌شود درحقیقت شبکه‌های  $\frac{pdata(x)}{pdata(x)+pg(x)}$  تخصصی مولد فاصله جنسن‌شانون را کمینه می‌کند [5]. پس تابع هدف مولد همان کمینه‌کردن فاصله جنسن‌شانون است. همچنین، می‌توان این تابع هدف را از هر فاصله، یا به عبارت صحیح‌تر، هر واگرایی  $f$  تعریف و کمینه کرد [7].

با اینکه شبکه‌های تخصصی مولد نتایج شگفت‌انگیزی از خود بروز داده‌اند، در مقاله‌های مختلف به دو مشکل اساسی در شبکه‌های تخصصی مولد اشاره شده است - [8] [11]. مشکل اولی این است که به دلیل اینکه حقیقت شبکه‌های تخصصی مولد یک بازی مجموع صفر<sup>۱۱</sup> است، هر مدل (مولد و متمایزکننده) باید تابع هدفی را بهینه کند که فقط بر پارامترهای خود کنترل دارد و نمی‌تواند پارامترهای رقیب را تغییر دهد. پس تلاش بیشتری برای آموزش و یافتن بهینه که عمدتاً هم‌محلی است، وجود خواهد داشت که به یک بهینه سراسری منجر نمی‌شود و آموزش را سخت می‌کند.


مشکل دیگر با عنوان «فروپاشی حالت»<sup>۱۲</sup> یا «سناریو هلویتیکا» وجود دارد. این مشکل به حالتی اطلاق می‌شود که مدل مولد تابعی را یاد می‌گیرد که تعداد زیادی از ورودی‌های متفاوت (مقادیر  $Z$  که از تابع توزیع ساده می‌آیند) را به یک نقطه مشابه خروجی نگاشت می‌کند. در عمل این به صورت جزئی اتفاق می‌افتد که تعداد زیادی ورودی متفاوت به تعداد خیلی کمی خروجی متفاوت نگاشت می‌شود.

در این بخش، مقدمه‌ای از شبکه‌های تخصصی مولد و همچنین، مشکلات آن گفته شد. در ادامه، کارهای مرتبط برای رفع مشکل فروافتادگی حالت در سال‌های اخیر بررسی می‌شوند و در ادامه، اصول روش‌های مولد بر پایه استنباط تغییراتی بیان می‌شوند. سپس روش پیشنهادی با عنوان «شبکه تخصصی مولد تغییراتی»<sup>۱۳</sup> ارائه می‌شود. پس از آن، نتایج تجربی کیفی و کمی به‌دست آمده، بررسی و نتیجه‌گیری می‌شوند.

## ۲- کارهای مرتبط

ایان گودفلو و همکارانش شبکه‌های تخصصی مولد را

مولد در شکل (۱) نشان داده شده است. در صورتی که  $G$  و  $D$  به صورت یک شبکه پرسپترون چندلایه تعریف شده باشند، کل سیستم می‌تواند به صورت پس‌انتشار<sup>۱۴</sup> خطا آموزش داده شود. در این روش، مدل مولد با استفاده از شبکه عصبی نویزهای تصادفی را به نمونه تبدیل می‌کند. همچنین، با استفاده از شبکه‌های عصبی یک مدل متمایزکننده، آموزش داده می‌شود. با استفاده از این روش هیچ نیازی به تخمین استنتاج<sup>۱۵</sup> و زنجیره مارکوف نیست [5].



شکل (۱): نحوه عملکرد شبکه‌های تخصصی مولد

برای یادگیری توزیع مولد  $p_g$  از داده  $x$ ، یک احتمال پیشین<sup>۱۶</sup> بر متغیر نویز تصادفی ورودی  $p_z(z)$  تعریف می‌شود. پس از آن، نگاشتی<sup>۱۷</sup> به فضای داده<sup>۱۸</sup> با عنوان  $G(z; \theta_g)$  ارائه می‌شود که  $G$  یک تابع مشخص<sup>۱۹</sup> است که به وسیله یک پرسپترون چندلایه با پارامترهای  $\theta_g$  بیان می‌شود. همچنین، پرسپترون چندلایه دوم  $D(x; \theta_d)$  تعریف می‌شود که یک خروجی اسکالر دارد. این خروجی احتمال اینکه  $x$  از داده‌ها آمده باشد در مقابل  $p_g$  را تخمین می‌زند. شبکه  $D$  احتمال انتساب برچسب درست - که  $x$  از داده است - را در مقابل داده از  $p_g$  را بیشینه می‌کند. هم‌زمان با آن،  $G$  برای کمینه‌کردن  $\log(1-D(G(z)))$  آموزش داده می‌شود. درحقیقت،  $D$  و  $G$  بازی کمینه - بیشینه دونفره زیر را با تابع مقدار  $V(G, D)$  بازی می‌کنند [5].

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim pdata(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

با بازنویسی رابطه فوق در صورتی که تابع هدف  $D$  به صورت بیشینه‌یابی log-likelihood برای تخمین احتمال شرطی  $P(Y=y|x)$  ترجمه شود و در نظر گرفتن این موضوع که برای  $G$  بهترین  $D$  برابر است با  $D_G^*(x)$

(10) مقیاس پذیر نمی‌شود.

راه حل دیگر برای مقابله با مشکل فروپاشی حالت، اضافه کردن ترم پنالته به تابع هدف شبکه‌های تخصصی مولد (رابطه (۱)) به شکلی است که فاصله بین نمونه‌های تولید شده از مدل مولد افزایش یابد. ترم‌های متعددی برای این کار ارائه شده‌اند [20]-[18] که برخی از آنها به صورت ضمنی و برخی به صورت صریح، ترم رگلاتوری را به تابع هدف اضافه می‌کنند. یکی از معایب این روش‌ها سخت‌تر شدن آموزش کل شبکه است. همان‌طور که گفته شد شبکه‌های تخصصی مولد از سختی آموزش و عدم همگرایی رنج می‌برند که با اضافه کردن ترم‌های پنالته نامناسب مسئله را بغرنج‌تر می‌کنند.

استفاده از چندین شبکه مولد به صورتی که هر کدام بتوانند چندین مد را پوشش دهند نیز یکی از راه‌حل‌های مقابله با فروافتادگی حالت بیان شده است [25]-[21] در این راه‌حل‌ها با استفاده از چندین شبکه مولد یا چندین شبکه متمایزکننده قصد دارند مجموعه‌ای از شبکه‌ها را آموزش دهند که هر کدام از شبکه‌ها مختص یک یا چند حالت باشند و مجموعه این شبکه‌ها بتوانند تمام حالت‌های مسئله را پوشش دهند. یکی از معایب عمده این کار، هزینه زیاد آموزش مدل است.

نقش اساسی وزن‌دهی اولیه برای مقابله با فروافتادگی حالت در شبکه‌های مولد تخصصی در مقاله‌های [26]، [27] تأکید شده است. این نشان‌دهنده این است که می‌توان با وزن‌دهی اولیه مناسب، مسئله فروافتادگی حالت را تا حد زیادی کنترل کرد.

نتیجه به‌دست آمده از این پژوهش می‌تواند در بهبود عملکرد مدل‌های مولد تأثیر بسزایی داشته باشد که بر اساس آن، می‌توان نمونه داده‌های بسیار مشابه به واقعیت را تولید کرد. این نمونه‌ها می‌توانند مانند این پژوهش، تصویر واقعی یا متن [28]، نقاشی [12]، ویدئو [29] یا هر اثر هنری [30] باشد.

### ۳- استنباط تغییراتی

استنباط تغییراتی یکی از روش‌های استنباط در

در سال ۲۰۱۴ معرفی کردند [5]. با توجه به موفقیت‌های این روش در تولید داده‌ها تحقیقات وسیعی در این حوزه شکل گرفت. همان‌طور که اشاره شد این نوع از شبکه‌ها دارای دو ضعف مهم‌اند. بیشتر تحقیقات بر سختی آموزش این نوع شبکه برای کاربردهای واقعی معطوف بوده است [15]-[12] از میان کارهای انجام شده در حوزه مقابله با فروافتادگی حالت، به راهکار ارائه شده در مقاله اشاره می‌شود. در این کار به جای استفاده از یک شبکه برای مولد و یک شبکه برای متمایزکننده، به صورت محلی از چندین شبکه برای تولید داده‌ها و از چندین شبکه برای تمایز داده‌ها استفاده می‌کنند. در راهکار دیگری [16] از شبکه‌های کانولوشنالی و ضد کانولوشنالی [13] برای مدل متمایزکننده و مدل مولد استفاده کرده است. همچنین، از خودرمزگذارها استفاده شده است تا بتوانند بر مشکل سختی آموزش غلبه کنند [14].

راه‌حل ارائه شده در [17] راهکاری با عنوان «ویژگی‌های دسته کوچک» است که در آن به متمایزکننده اجازه داده می‌شود یک نمونه را با یک دسته کوچک داده‌های تولید شده از مولد و یک دسته کوچک از داده‌های واقعی مقایسه شود. با اندازه‌گیری فاصله با دیگر نمونه‌ها می‌تواند بفهمد یک نمونه با دیگر نمونه‌های تولید شده مشابه است یا خیر. این کار نتایج مناسبی داشته است. این روش تا حدی مشکل فروپاشی حالت را حل می‌کند؛ اما مشکلات دیگری نظیر مشکل شمارش، پرسپکتیو در تصویر و ساختارهای کلی را بهبود نمی‌دهد.

راه‌حل بعدی ارائه شده، استفاده از روشی به نام «شبکه‌های تخصصی مولد باز شده» است [8]. این روش بر این مسئله اصرار دارد که باید ابتدا متمایزکننده بهینه پیدا شود و بر اساس آن، مولد آموزش ببیند. برای این کار به‌ازای هر دسته کوچک داده، چندین بار مدل متمایزکننده آموزش داده می‌شود؛ در حالی که فقط یکبار مدل مولد آموزش داده می‌شود. این کار نسبت به روش «ویژگی‌های دسته کوچک» مشکل «فروپاشی حالت» را نمی‌تواند برطرف کند؛ اما مشکلات دیگر را نیز تا حدی بهبود می‌دهد. مشکل این روش این است که به دلیل افزایش بسیار زیاد پیچیدگی، برای داده‌های واقعی بزرگ (مانند مجموعه داده CFAR

شبکه‌های تخصصی مولد تغییراتی برای جلوگیری از فروافتادگی حالت

مدل‌های گرافیکی<sup>۱۴</sup> است.

$$\begin{aligned} KL(p(x) \parallel q(x)) &= \int p(x) \log \frac{p(x)}{q(x)} dx \\ &= - \int p(x) \log \frac{q(x)}{p(x)} dx \end{aligned} \quad (۳)$$



شکل (۲): مدل گرافیکی استنباط تغییراتی

در رابطه فوق،  $p$  و  $q$  دو توزیع متفاوت اند که واگرایی بین آنها سنجیده می‌شود. به این ترتیب، برای اینکه دو توزیع به هم نزدیک شود، باید رابطه زیر کمینه شود:

$$\begin{aligned} KL(q(z) \parallel p(z|x)) &= - \int q(z) \log \frac{p(z|x)}{q(z)} dz \end{aligned} \quad (۴)$$

در صورت جایگذاری رابطه (۲) به جای  $p(z|x)$  و ساده‌سازی به صورت زیر است:

$$\begin{aligned} & - \int q(z) \log \frac{p(x,z)}{q(z)} dz \\ &= - \int q(z) \log \frac{p(x,z)}{q(z)} \cdot \frac{1}{p(x)} dz \\ &= - \int q(z) \left[ \log \frac{p(x,z)}{q(z)} - \log p(x) \right] dz \\ &= - \int q(z) \log \frac{p(x,z)}{q(z)} dz + \int q(z) \log p(x) dz \\ &= - \int q(z) \log \frac{p(x,z)}{q(z)} dz + \log p(x) \end{aligned} \quad (۵)$$

با توجه به رابطه (۴) و بازنویسی آن رابطه زیر پدید می‌آید:

$$\begin{aligned} \log p(x) &= KL(q(z) \parallel p(z|x)) \\ &+ \int q(z) \log \frac{p(x,z)}{q(z)} dz \end{aligned} \quad (۶)$$

با توجه به معلوم بودن  $\log p(x)$  مقدری ثابت خواهد شد. در استنباط تغییراتی به جای کمینه کردن واگرایی کولبک - لیبلر ترم  $\int q(z) \log \frac{p(x,z)}{q(z)} dz$  را بیشینه می‌کنند که با عنوان «باند پایین حاشیه‌ای» شناخته می‌شود. برای بیشینه کردن این ترم به صورت زیر عمل می‌شود:

$$\begin{aligned} & \int q(z) \log \frac{p(x,z)}{q(z)} dz \\ &= \int q(z) \log \frac{p(x|z)p(z)}{q(z)} dz \\ &= \int q(z) \log p(x|z) dz + \int q(z) \log \frac{p(z)}{q(z)} dz \end{aligned} \quad (۷)$$

در صورتی که در مدل گرافیکی شکل فوق  $X$  مشاهده‌ها<sup>۱۵</sup> و  $Z$  متغیر پنهان<sup>۱۶</sup> باشد، هدف، محاسبه احتمال پسین  $P(Z|X)$  است که با استفاده از قضیه بیز به صورت زیر محاسبه می‌شود.

$$p(z|x) = \frac{p(x|z)p(z)}{p(x)} = \frac{p(x,z)}{p(x)} \quad (۲)$$

در رابطه فوق،  $p(x)$  یک توزیع حاشیه‌ای<sup>۱۷</sup> است که از رابطه  $p(x) = \int p(x|z)p(z) dz$  محاسبه می‌شود. این انتگرال در بسیاری از موارد رام‌شدنی<sup>۱۸</sup> است و نمی‌توان آن را محاسبه کرد و هنگامی که  $z$  از ابعاد بالا باشد، به دلیل اینکه انتگرال چندگانه خواهد شد، مهارناپذیر است. در حوزه آمار و احتمال دو روش برخورد با این مشکل وجود دارد؛ یکی استفاده از روش مونت‌کارلو است که با نمونه‌گیری، انتگرال را حل می‌کند و روش دیگر، استنباط تغییراتی است. در روش استنباط تغییراتی،  $p(z|x)$  را با توزیع دیگری نظیر  $q(z)$  تقریب می‌زنند. اگر  $q(z)$  یک توزیع رام‌شدنی باشد، می‌توان با تغییر پارامترهای آن به شکلی مشابه  $p(z|x)$  این تقریب را انجام داد. برای اینکه  $q(z)$  یک توزیع رام‌شدنی باشد، می‌توان آن را از خانواده توزیع‌های مشهور مانند گاوسی و نمایی انتخاب کرد. پس نیاز است فاصله بین  $q(z)$  و  $p(z|x)$  کمینه شود. برای این کار می‌توان از معیارهای واگرایی و فاصله استفاده کرد. یکی از واگرایی‌های معروف، واگرایی کولبک - لیبلر<sup>۱۹</sup> است که جنسن‌شانون نیز از آن بهره می‌گیرد و به صورت زیر تعریف می‌شود [۳۱]:

تابع هزینه این خودرمزگذار از رابطه (۸) برداشت می‌شود که شامل دو ترم  $KL(q(z) \parallel p(z))$  و  $\mathbb{E}_{q(z)}[\log p(x|z)]$  است. ترم  $KL(q(z) \parallel p(z))$  بیان می‌کند توزیع  $z$  که خروجی کدگذار است، مشابه هر توزیع دلخواه و رام‌شدنی مانند گاوسی است. ترم  $\mathbb{E}_{q(z)}[\log p(x|z)]$  به صورت مفهومی همان خطای بازسازی<sup>۲۲</sup> است. پس تابع هزینه خودرمزگذار تغییراتی به صورت زیر دانسته می‌شود [32].

$$\begin{aligned} & \max \left( \frac{\mathbb{E}_{q(z)}[\log p(x|z)]}{\log_{\text{like}}} - \frac{KL(q(z) \parallel p(z))}{KL_{\text{dist}}} \right) \\ & = \min \left( \frac{|x - \hat{x}|^2}{\text{reconstruction\_erro}} + \frac{KL(q(z|x) \parallel p(x))}{KL_{\text{dist}}} \right) \end{aligned} \quad (9)$$

در رابطه فوق، به عبارتی به جای بیشینه کردن رابطه (۸) از کمینه کردن خطای بازسازی و واگرایی کولبک - لیبلر استفاده می‌شود. باید توجه داشت کاهش خطای بازسازی معادل افزایش تابع راست‌نمایی در نظر گرفته می‌شود [33]. روش پیشنهادی، با بهره‌گیری از شبکه خودرمزگذار تغییراتی و تغییر در ساختار تابع هدف و فرآیند یادگیری شبکه تخصصی مولد، مدلی ارائه می‌کند که از قابلیت هر دو شبکه مولد تخصصی و خودرمزگذارهای تغییراتی در فرآیند ساخت مدل مولد استفاده می‌کند. در رابطه (۵) دو ترم واگرایی کولبک - لیبلر و باندپایین حاشیه‌ای وجود دارد. در روش‌های استنباط تغییراتی از جمله خودرمزگذار تغییراتی فقط باند پایین حاشیه‌ای را بیشینه می‌کنند و در شبکه‌های تخصصی واگرایی (درحقیقت فاصله جنسن شانون) را کمینه می‌کنند؛ اما راه‌حل بینابینی - که این مقاله به آن پرداخته است - نیز وجود دارد که هر دو را به صورت نوبه‌ای بهینه می‌کند.

در مقاله [7] نشان داده شده است از هر واگرایی  $f$  می‌توان به جای فاصله شانون در شبکه‌های تخصصی مولد استفاده کرد. در خودرمزگذارهای تغییراتی نیز از انواع دیگر واگرایی به عنوان ترم تنظیم<sup>۲۳</sup> استفاده می‌شود. پس می‌توان پس از اینکه باند پایین حاشیه‌ای را با استفاده از خودرمزگذار تغییراتی بیشینه کرد، با استفاده از شبکه‌های تخصصی مولد، ترم واگرایی بین دو توزیع را کاهش داد. با این کار برعکس خودرمزگذارهای تخصصی [34] که قصد


نتیجه این خواهد بود که باند پایین حاشیه‌ای شامل دو ترم می‌شود که یکی از آنها واگرایی کولبک - لیبلر بین  $p(z)$  و  $q(z)$  است و دیگری امید ریاضی  $\log p(x/z)$  با توجه به  $q(z)$  است. به این ترتیب، رابطه (۷) به صورت زیر نوشته می‌شود:

$$\begin{aligned} & \int q(z) \log \frac{p(x,z)}{q(z)} dz \\ & = \mathbb{E}_{q(z)}[\log p(x|z)] \\ & \quad - KL(q(z) \parallel p(z)) \\ & = \text{Log\_Llik} - \text{KL\_dist} \end{aligned} \quad (8)$$

این رابطه نشان می‌دهد به جای کاهش فاصله بین توزیع  $q(z)$  و  $p(z/x)$  (رابطه (۸))، از رابطه (۸) استفاده می‌شود و فاصله  $q(z)$  با  $p(z)$  یعنی  $KL_{\text{dist}}$  که مستقل از مشاهده  $x$  است، کاهش و لگاریتم راست‌نمایی<sup>۲۰</sup> یعنی  $\log_{\text{like}}$  افزایش می‌یابد. روش‌های استنباط تغییراتی با استفاده از بیشینه کردن راست‌نمایی سعی در افزایش شباهت بین دو توزیع دارند. یکی از رویکردهای متداول برای این منظور، استفاده از شبکه‌های خودرمزگذار تغییراتی<sup>۲۱</sup> است که در ادامه بررسی می‌شوند.

## ۴- روش پیشنهادی

در این مقاله یک روش مبتنی بر شبکه خودرمزگذار تغییراتی، برای بهبود چالش فروافتادگی حالت و افزایش کیفیت داده‌های تولیدی در شبکه‌های تخصصی پیشنهاد شده است. در قسمت قبل نشان داده شد با کم کردن فاصله (واگرایی) بین یک توزیع رام‌شدنی دلخواه  $q(z)$  و توزیع  $p(z/x)$  در حین افزایش لگاریتم راست‌نمایی، می‌توان  $p(x/z)$  را تقریب زد. با استفاده از رمزگذارها این بهینه‌سازی انجام می‌شود. خودرمزگذار تغییراتی مدنظر در شکل (۳) نشان داده شده است.



شکل (۳): خودرمزگذار تغییراتی

هدف، کاستن مشکل فروپاشی حالت بوده است؛ بنابراین، می‌توان از راه‌حل‌های به‌کاررفته در مقاله‌های [7], [17], [35]–[37] برای ارزیابی مدل استفاده کرد؛ اما در این مقاله از ارزیابی کیفی نیز استفاده شده است؛ بنابراین، در دو بخش آینده، روش پیشنهادی به‌صورت مجزا ارزیابی کمی و کیفی می‌شوند. بخشی از پیاده‌سازی روش پیشنهادی در دسترس است<sup>۲۴</sup>. مجموعه داده‌های بررسی شده، مجموعه داده مشهور MNIST [۳۸] و CIFAR [۳۹] است. نمونه‌هایی از تصاویر تولیدشده برای دو مجموعه داده در شکل (۸) نشان داده شده‌اند. در این شکل چند نمونه به‌صورت خاص با دایره قرمز مشخص شده‌اند. این تصاویر برتری کیفیت روش شبکه تخصصی مولد تغییراتی را نسبت به روش DC-GAN به‌صورت بصری نشان می‌دهد.

### ۵-۱- ارزیابی کمی

معیارهای محدودی برای ارزیابی مدل‌های مولد ارائه شده‌اند که یکی از پراستفاده‌ترین آنها استفاده از معیار لگاریتم راست‌نمایی بر توزیع داده‌های تولیدشده در کنار توزیع داده‌های آزمایشی استخراج‌شده از پنجره پارزن است. این روش در مقاله [40] ارائه شده و برای ارزیابی روش‌های مولد در بیشتر کارهای انجام‌شده در حوزه شبکه‌های تخصصی مولد از آن استفاده شده است. در جدول زیر مقادیر به‌دست‌آمده از روش پیشنهادی این مقاله (VGAN) و روش‌های پیشین ارائه شده‌اند.

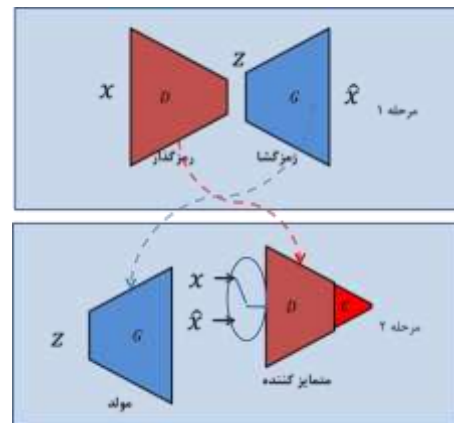
جدول (۱): میانگین و انحراف استاندارد لگاریتم راست‌نمایی پنجره پارزن در دو مجموعه داده با روش‌های مختلف

Method	MNIST	CIFAR
DBN[41]	138±2	569±4.1
DC-GAN[42]	131±1.2	555±3.9
Conditional-GANs[35]	132±1.8	598±3.8
Improved Wasserstein GAN[36]	148±1.3	608±3.0
VGAN	163±1.3	611±3.6

با توجه به جدول، در هر دو مجموعه داده، روش ارائه‌شده در این مقاله نسبت به سایر روش‌ها نتیجه بهتری کسب کرده است.

در وضعیت فروافتادگی حالت، پراکندگی تخمین کلاس

دارند با استفاده از مکانیسم تخصصی خودرمزگذارهای تغییراتی را بهبود دهند، سعی در بهبود شبکه‌های تخصصی با استفاده از خودرمزگذارهای تغییراتی دارد. دیاگرام عملکرد سیستم پیشنهادی به‌صورت شماتیک در شکل (۴) نشان داده شده است.



شکل (۴): شبکه تخصصی مولد تغییراتی

شبکه تخصصی تغییراتی، دو مرحله برای آموزش دارد؛ در مرحله نخست، شبکه با عنوان یک خودرمزگذار تغییراتی آموزش داده می‌شود تا توزیع  $z$  تعیین شود و پس از آن در مرحله دوم با تبدیل کدگشا به شبکه مولد  $G$  و تبدیل کدگذار به شبکه متمایزکننده  $D$  و اضافه‌کردن یک تبدیل‌کننده  $C$  که وظیفه کلاسه‌بندی را دارد، یک شبکه مولد تخصصی تشکیل می‌شود که وظیفه کمینه‌کردن فاصله بین توزیع داده‌ها و نمونه‌های تولیدشده را دارد.

به بیان دیگر، روش پیشنهادی یک پیش‌آموزش برای شبکه‌های مولد تخصصی است که در این پیش‌آموزش از خودرمزگذارهای تغییراتی استفاده می‌شود. در ادامه، نتایج تجربی به‌دست‌آمده از این روش بیان می‌شوند [35].

### ۵- نتایج تجربی

یکی از چالش‌های اساسی در مدل‌های مولد به‌خصوص شبکه‌های تخصصی، مولد یافتن معیاری برای ارزیابی مدل ارائه‌شده است. در این بین راه‌حلی ارائه شده‌اند؛ اما در تمامی موارد، محققان اذعان دارند نتایج با این معیارها به‌صورت صحیح ارزیابی نمی‌شوند. همچنین، در این مقاله

در روش DC-GAN (میله‌های آبی) واضح است بخش زیادی از داده‌ها در کلاس ۳ و سپس ۷ تجمع شده‌اند که با توزیع واقعی (میله‌های قرمز) تفاوت محسوسی دارند؛ اما در روش پیشنهادی VGAN داده‌ها به صورت مناسب‌تری در بین کلاس‌ها پخش شده‌اند.

## ۵-۲- ارزیابی کیفی

برای ارزیابی بهتر روش پیشنهادی، در این بخش از معیارهای کیفی استفاده شده که از روی نظرات تعداد زیادی از کاربران انسانی به دست آمده است. برای نظرسنجی از کاربران، در یک سامانه تحت وب ۱۰۰۰۰ تصویر واقعی از مجموعه داده MNIST به همراه ۱۰۰۰۰ تصویر تولیدشده از روش DC-GAN و همچنین، ۱۰۰۰۰ تصویر تولیدشده از روش پیشنهادی (VGAN) وجود دارد. این تصاویر به صورت تصادفی به کاربران نشان داده شده و از کاربران خواسته شده است مشخص کنند کدام تصویر واقعی و کدام تصویر تولیدشده از ماشین است<sup>۲۵</sup>. درخور ذکر است در نظرسنجی به کاربران هیچ پیش فرضی داده نشده و از نظرسنجی احتمالی توسط بات‌ها با به‌کارگیری کپچای گوگل جلوگیری شده است. شکل (۷) عکسی از صفحه نظرسنجی را نشان می‌دهد.



شکل (۷): تصویر صفحه نظرسنجی

به سمت یک فضای خاص سوق می‌یابد. در صورتی که بتوان از این فروافتادگی حالت جلوگیری کرد، پراکندگی مناسب در فضای توزیع داده‌های تولیدشده برقرار خواهد شد. برای سنجش این خصوصیت از شاخص پراکندگی تخمین کلاس داده‌ها استفاده شده است. در این شاخص، پراکندگی کل داده‌ها بر حسب مجموعه داده مدنظر، محاسبه و به صورت زیر معرفی می‌شود:

$$D(x) = \frac{1}{c} \sum_{i=1}^c |I(c_i = i) - I(y_i = i)| \quad (10)$$

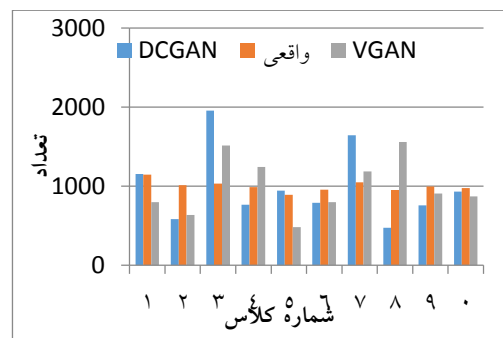
در رابطه فوق،  $I(c_i = i)$  تعداد نمونه‌های کلاس  $i$  م در مجموعه داده آزمایشی و  $I(y_i = i)$  تعداد نمونه‌های کلاس  $i$  بند شده در کلاس  $i$  با استفاده از کلاس‌بند مناسب هر مجموعه داده است. هرچه این معیار کمتر باشد، بهتر است و پراکندگی بهتری در فضای داده‌های تولیدشده وجود دارد. جدول ۲ نتیجه مقایسه روش‌ها را با این معیار نشان می‌دهد.

جدول (۲): معیار اختلاف پراکندگی در کلاس برای روش‌های

DC-GAN و VGAN

Method	MNIST	CIFAR
VGAN	224.8±5.4	327.1±3.5
DC-GAN	296±9.1	358.8±4.9

نتایج نشان دهنده این است که توزیع داده‌های تولیدشده در روش پیشنهادی (VGAN) اختلاف کمتری با داده‌های واقعی داشته است. برای بررسی دقیق‌تر این مسئله، در نمودار زیر توزیع تعداد نمونه‌های کلاس‌بندی شده در هر کلاس برای مجموعه داده MNIST نشان داده شده است.



شکل (۶): تعداد نمونه‌های تولیدشده در هر کلاس برای

مجموعه داده MNIST



برخی از تصاویر بیش از چند مرتبه نشان داده شده است. برای نتایج آنلاین<sup>۳۶</sup> نظرسنجی<sup>۳۷</sup> تا انتهای سال ۲۰۲۱ میلادی دردسترس خواهد بود. نتایج آماری به‌دست‌آمده در جدول زیر نشان داده شده‌اند.

در زمان نگارش این مقاله تعداد ۱۳۶ نفر در این نظرسنجی شرکت کردند. کل تصاویر یکتا برابر ۳۰۰۰۰ مورد بوده که به‌صورت میانگین هر کاربر درباره ۲۲۰ تصویر اظهارنظر کرده است. در مجموع، تعداد کل تصاویر نشان داده شده ۱۰۸۹۵۹ مورد بوده است. باید توجه داشت

جدول (۳): مقایسه روش VGAN با روش DC-GAN به‌صورت کیفی.

		برآمده از			مجموع
		واقعی	VGAN	DC-GAN	
کیفیت	واقعی	25224 (69.44%)	19112 (52.83%)	14946 (41.04%)	59282 (54.43%)
	ساختگی	11101 (30.56%)	17065 (47.17%)	21472 (58.96%)	49638 (45.57%)
مجموع		36325 (33.35%)	36177 (33.21%)	36418 (33.44%)	108920

توجه این کار با رابطه استنباط تغییراتی بیان شده است. با نتایج تجربی نشان داده شد با بیشینه‌کردن باند پایین حاشیه‌ای با استفاده از خودرمزگذار و کمینه‌کردن واگرایی بین دو توزیع مولد و واقعی به‌صورت ترتیبی، جواب‌های بهتری به دست می‌آیند. این نتایج به دو صورت کیفی و کمی تحلیل شده‌اند. در روش تحلیل کیفی، کاربران، سامانه اینترنتی را برای مشخص کردن تصاویر واقعی نسبت به تصاویر مصنوعی تهیه کردند و کاربران عادی و دانشجو نظرات خود را با حداقل پیش‌فرض، تصاویر واقعی را از مصنوعی را تمیز دادند. در تحلیل کمی از معیار میانگین لگاریتم راست‌نمایی پنجره پارزن و معیار اختلاف پراکنندگی در کلاس استفاده شد.

با توجه به تحلیل کیفی انجام‌شده، روش ارائه‌شده در این مقاله توانسته است عملکرد بهتری در رابطه با کیفیت تصاویر تولیدشده ارائه دهد. همچنین، نتایج تجربی نشان دادند روش پیشنهادی تا حدودی توانسته است بر مسئله فروافتادگی حالت غلبه کند.

## ۷- کارهای آینده

روش پیشنهادشده در این مقاله برای تولید تصاویر استفاده شده است. این در حالی است که روش پیشنهادی

سطر آخر (مجموع) جدول فوق نشان می‌دهد توزیع نمایش تصاویر (واقعی، ساختگی VGAN و ساختگی DC-GAN) یکنواخت بوده است. ستون آخر نشان می‌دهد با وجود اینکه تنها ۳۳ درصد داده‌ها واقعی بوده‌اند، کاربران در مجموع بیش از ۵۴٪ داده‌ها را واقعی تشخیص داده‌اند. در روش DC-GAN میزان ۴۱٪ کل تصاویر ساختگی، واقعی تشخیص داده شده است؛ در حالی که در روش پیشنهادی VGAN، بیش از نیمی از کاربران (۵۲٪) تصاویر ساختگی این شبکه را واقعی تشخیص داده‌اند. جزئیات آمارهای این نظرسنجی نیز به‌صورت برخط دردسترس‌اند<sup>۳۸</sup>.

## ۶- نتیجه‌گیری

در این مقاله، روشی برای مقابله با فروپاشی حالت ارائه شد. روش پیشنهادی دارای دو مرحله است؛ در مرحله نخست، یک خودرمزگذار تغییراتی آموزش داده می‌شود تا بتواند یک نگاهت از داده‌های آموزشی به نویز تصادفی از توزیع دلخواه قابل رام‌شدنی از رمزگذار باشد. همچنین، قابلیت نگاهت نویز تصادفی از توزیع انتخاب‌شده به توزیع داده‌های واقعی را داشته باشد. در مرحله دوم از همین رمزگذار و رمزگشا به فرم یک شبکه مولد تخصصی استفاده می‌شود. به بیان دیگر، خودرمزگذارهای تغییراتی برای وزن‌دهی اولیه شبکه‌های تخصصی مولد استفاده شده‌اند.

- Learning Representations*, 2017, pp. 168–175.
- [11] S. Reed, Z. Akata, X. Yan, L. Logeswaran, B. Schiele, and H. Lee, “Generative Adversarial Text to Image Synthesis,” in *Proceedings of The 33rd International Conference on Machine Learning (ICML)*, 2016, Vol. 48, pp. 1060–1069, [Online]. Available: <http://proceedings.mlr.press/v48/reed16.html>.
- [12] Y. Liu, Z. Qin, T. Wan, and Z. Luo, “Auto-painter: Cartoon image generation from sketch by using conditional Wasserstein generative adversarial networks,” *Neurocomputing*, vol. 311, pp. 78–87, 2018, doi: 10.1016/j.neucom.2018.05.045.
- [13] J. Luo and J. Huang, “Generative adversarial network: An overview,” *Yi Qi Yi Biao Xue Bao/Chinese Journal of Scientific Instrument*, vol. 40, no. 3, pp. 74–84, 2019, doi: 10.19650/j.cnki.cjsi.J1804413.
- [14] M. Lee and J. Seok, “Controllable generative adversarial network,” *IEEE Access*, vol. 7, pp. 28158–28169, 2019, doi: 10.1109/ACCESS.2019.2899108.
- [15] Y. Deldjoo, T. Di Noia, and F. A. Merra, “A survey on adversarial recommender systems: from attack/defense strategies to generative adversarial networks,” *ACM Comput. Surv.*, Vol. 54, No. 2, pp. 1–38, 2021.
- [16] C. Tao, L. Chen, R. Henao, J. Feng, and L. Carin, “X2 generative adversarial network,” in *35th International Conference on Machine Learning, ICML 2018*, 2018, Vol. 11, pp. 7787–7796, doi: 10.1007/978-1-4842-3679-6\_8.
- [17] T. Salimans, I. Goodfellow, W. Zaremba, V. Cheung, A. Radford, and X. Chen, “Improved Techniques for Training GANs,” in *Conference on Neural Information Processing Systems (NIPS)*, 2016, pp. 1–9, doi: arXiv:1504.01391.
- [18] Q. Mao, H.-Y. Lee, H.-Y. Tseng, S. Ma, and M.-H. Yang, “Mode seeking generative adversarial networks for diverse image synthesis,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019, pp. 1429–1437.
- [19] Y. Yao, Y. Pan, I. W. Tsang, and X. Yao, “Support Matching: A Novel Regularization to Escape from Mode Collapse in GANs,” in *International Conference on Neural Information Processing*, 2019, pp. 40–48.
- [20] H. Eghbal-zadeh, W. Zellinger, and G. Widmer, “Mixture density generative adversarial networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019, pp. 5820–5829.
- [21] A. Ash-Saki and S. Ghosh, “How Multi-Threshold Designs Can Protect Analog IPs,” 2019, doi: 10.1109/ICCD.2018.00075.
- [22] I. Tolstikhin, S. Gelly, O. Bousquet, C. J. Simon-Gabriel, and B. Schölkopf, “AdaGAN: Boosting generative models,” in *Advances in Neural Information Processing Systems*, 2017, vol. 2017-Decem, pp. 5425–5434.
- [23] A. Grover and S. Ermon, “Boosted generative models,” in *32nd AAAI Conference on Artificial Intelligence*, 2018, pp. 1000–1007.
- قابلیت استفاده در تولید انواع داده را دارد؛ خواه این داده، تصویر، ویدئو، متن یا حتی هنر و شعر باشد.
- همچنین، می‌توان راهکارهای دیگری برای مقابله با فروافتادگی حالت مانند اضافه کردن ترم پنالتی به تابع هدف شبکه تخصصی مولد یا آموزش چندین شبکه مولد با روش پیشنهاد شده در این مقاله ترکیب کرد؛ حتی می‌توان روش پیشنهادی را روی توسعه‌های ارائه شده بر شبکه تخصصی مولد مانند WGAN [36]، [31] اعمال کرد و داده‌های باکیفیت‌تری تولید کرد.

## مراجع

- [1] M. Hajizadeh Tahan, M. Ghasemzadeh, and M. Rezaeian, “An evolutionary attention-based deep long short-term memory for time series prediction,” *Comput. Intell. Electr. Eng.*, Vol. 11, No. 4, 2021.
- [2] S. Sheykhivand, S. Meshgini, and Z. Mousavi, “Automatic Detection of Various Epileptic Seizures from EEG Signal Using Deep Learning Networks,” *Comput. Intell. Electr. Eng.*, Vol. 11, No. 3, 2020.
- [3] L. Deng and D. Yu, “Deep Learning: Methods and Applications,” *Found. Trends® Signal Process.*, Vol. 7, No. 3–4, pp. 197–387, 2013, doi: 10.1136/bmj.319.7209.0a.
- [4] Y. Bengio, “Learning Deep Architectures for AI,” *Found. Trends® Mach. Learn.*, Vol. 2, No. 1, pp. 1–127, 2009, doi: 10.1561/22000000006.
- [5] I. J. Goodfellow *et al.*, “Generative Adversarial Nets,” in *Advances in Neural Information Processing Systems (NIPS)*, 2014, pp. 1–9, doi: 10.1017/CBO9781139058452.
- [6] Z. Wang, Q. She, and T. E. Ward, “Generative adversarial networks in computer vision: A survey and taxonomy,” *ACM Comput. Surv.*, Vol. 54, No. 2, pp. 1–38, 2021.
- [7] S. Nowozin, B. Cseke, and R. Tomioka, “f-GAN: Training Generative Neural Samplers using Variational Divergence Minimization,” Vol. 2, No. 1, pp. 1–9, 2016, [Online]. Available: <http://arxiv.org/abs/1606.00709>.
- [8] L. Metz, B. Poole, D. Pfau, and J. Sohl-Dickstein, “Unrolled Generative Adversarial Networks,” in *5th International Conference on Learning Representations*, 2017, pp. 1–25, [Online]. Available: <http://arxiv.org/abs/1611.02163>.
- [9] T. Chavdarova and F. Fleuret, “SGAN: An Alternative Training of Generative Adversarial Networks,” *arXiv Prepr. arXiv1712.02330*, 2017, [Online]. Available: <http://arxiv.org/abs/1712.02330>.
- [10] S. Reed, A. van den Oord, N. Kalchbrenner, V. Bapst, M. Botvinick, and N. de Freitas, “Generating interpretable images with controllable structure,” in *5th International Conference on*

- variational bayes,” 2014.
- [34] A. Makhzani, J. Shlens, N. Jaitly, I. Goodfellow, and B. Frey, “Adversarial Autoencoders,” *arXiv Prepr. arXiv1511.05644*, 2015, [Online]. Available: <http://arxiv.org/abs/1511.05644>.
- [35] M. Mirza and S. Osindero, “Conditional generative adversarial nets,” *arXiv Prepr. arXiv1411.1784*, pp. 1–7, 2014, doi: 10.1017/CBO9781139058452.
- [36] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin, and A. C. Courville, “Improved training of wasserstein gans,” in *Advances in neural information processing systems*, 2017, pp. 5767–5777, doi: 10.1097/WAD.0b013e318211c83c.
- [37] A. Odena, C. Olah, and J. Shlens, “Conditional image synthesis with auxiliary classifier gans,” in *Proceedings of the 34th International Conference on Machine Learning-Volume 70*, 2017, pp. 2642–2651, doi: 10.1016/0021-9614(70)90038-8.
- [38] Y. LeCun, C. Cortes, and C. J. C. Burges, “MNIST handwritten digit database,” *AT&T Labs [Online]*. Available <http://yann. lecun. com/exdb/mnist>, vol. 2, 2010.
- [39] A. Krizhevsky, V. Nair, and G. Hinton, “The CIFAR-10 dataset,” *online: http://www. cs. toronto. edu/kriz/cifar. html*, 2014. .
- [40] O. Breuleux, Y. Bengio, and P. Vincent, “Quickly generating representative samples from an RBM-derived process,” *Neural Computation*, vol. 23, no. 8. pp. 2058–2073, 2011, doi: 10.1162/NECO\_a\_00158.
- [41] Y. Bengio, G. Mesnil, Y. Dauphin, and S. Rifai, “Better mixing via deep representations,” in *30th International Conference on Machine Learning, ICML 2013*, 2013, No. PART 1, pp. 552–560.
- [42] A. Radford, L. Metz, and S. Chintala, “Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks,” *arXiv Prepr. arXiv1511.06434*, 2016, doi: 10.1051/0004-6361/201527329.
- [24] T. Chavdarova and F. Fleuret, “SGAN: An Alternative Training of Generative Adversarial Networks,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2018, pp. 9407–9415, doi: 10.1109/CVPR.2018.00980.
- [25] D. Saxena and J. Cao, “Generative Adversarial Networks (GANs) Challenges, Solutions, and Future Directions,” *ACM Comput. Surv.*, Vol. 54, No. 3, pp. 1–42, 2021.
- [26] N. Yu, L. S. Davis, and M. Fritz, “Attributing fake images to gans: Learning and analyzing gan fingerprints,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2019, pp. 7556–7566.
- [27] S. Bell-Kligler, A. Shocher, and M. Irani, “Blind super-resolution kernel estimation using an internal-gan,” in *Advances in Neural Information Processing Systems*, 2019, pp. 284–293.
- [28] H. Zhang *et al.*, “StackGAN++: Realistic Image Synthesis with Stacked Generative Adversarial Networks,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 41, no. 8, pp. 1947–1962, 2019, doi: 10.1109/TPAMI.2018.2856256.
- [29] D. Guera and E. J. Delp, “Deepfake Video Detection Using Recurrent Neural Networks,” 2019, doi: 10.1109/AVSS.2018.8639163.
- [30] N. Murray, “PFAGAN: An Aesthetics-Conditional GAN for Generating Photographic Fine Art,” in *Proceedings of the IEEE International Conference on Computer Vision Workshops*, 2019, p. 0.
- [31] M. Arjovsky, S. Chintala, and L. Bottou, “Wasserstein gan,” *arXiv Prepr. arXiv1701.07875*, 2017, doi: 10.2507/daaam.scibook.2010.27.
- [32] Y. Burda, R. Grosse, and R. Salakhutdinov, “Importance Weighted Autoencoders,” pp. 1–14, 2015, [Online]. Available: <http://arxiv.org/abs/1509.00519>.
- [33] D. P. Kingma and M. Welling, “Auto-encoding

---

<sup>1</sup> Generative Adversarial Nets

<sup>2</sup> مدلی که آموزش می‌بیند تا داده تولید کند Generative Model

<sup>3</sup> مدلی که آموزش می‌بیند تا داده‌ها را در کلاس‌های متفاوت تفکیک کند Discriminative

<sup>4</sup> minimax

<sup>5</sup> Backpropagation

<sup>6</sup> Approximate inference

<sup>7</sup> Prior probability

<sup>8</sup> Mapping

<sup>9</sup> Data space

<sup>10</sup> Differentiable function

<sup>11</sup> Zero sum game

<sup>12</sup> Mode Collapse

<sup>13</sup> Variational Generative Adversarial Network (VGAN)

<sup>14</sup> Graphical Model

<sup>15</sup> Observation

<sup>16</sup> Hidden Variable

<sup>17</sup> Marginal Distribution

<sup>18</sup> intractable

<sup>19</sup> Kullback–Leibler

<sup>20</sup> Likelihood

<sup>21</sup> Variational Autoencoder

<sup>22</sup> Reconstruction Error

<sup>23</sup> Regularization

<sup>24</sup> <https://colab.research.google.com/drive/1aNnewedDeqmGmZjEqVLK612WV-1eLZhj>

<sup>25</sup> کاربران شرکت کننده در نظرسنجی دانشجویان رشته کامپیوتر دانشکده شهید باهنر شیراز، دانشگاه یزد و تعداد محدودی از

افراد عادی بوده‌اند.

<sup>26</sup> [http://pws.yazd.ac.ir/lcir/GAN\\_project1/stat.php](http://pws.yazd.ac.ir/lcir/GAN_project1/stat.php)

<sup>27</sup> [http://pws.yazd.ac.ir/lcir/GAN\\_project1](http://pws.yazd.ac.ir/lcir/GAN_project1)

<sup>28</sup> [http://pws.yazd.ac.ir/lcir/GAN\\_project1/scoreboard.php](http://pws.yazd.ac.ir/lcir/GAN_project1/scoreboard.php)

