



دانشگاه کاشان
University of Kashan

مجله محاسبات نرم

SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



توسعه یک مدل رتبه کاسته بدون معادله مبتنی بر الگوهای متفاوت استخراج ویژگی روی مجموعه داده انتقال حرارت دو بعدی پایا[♦]

سمیه افضل^۱، دانشجوی کارشناسی ارشد، محمدکاظم مؤیدی^{۲*}، استادیار، فرانک فتوحی^۱، استادیار
^۱ گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه قم، قم، ایران.
^۲ گروه مهندسی مکانیک، دانشگاه قم، قم، ایران.

اطلاعات مقاله

چکیده

تاریخچه مقاله:

دریافت ۰۱ خرداد ماه ۱۴۰۰
پذیرش ۰۱ آذر ماه ۱۴۰۰

کلمات کلیدی:

مدل‌سازی انتقال حرارت پایا
کاهش مرتبه
تحلیل مؤلفه‌های اصلی
خودرمنزنگار
خطای میانگین مربعات

با توجه به هزینه زمانی و محاسباتی بالای روش‌های حل مستقیم یا عددی معادلات دیفرانسیل حاکم بر پدیده‌ها، پژوهش حاضر به ارائه روشی بدون معادله و مبتنی بر الگوریتم‌های یادگیری عمیق با استفاده از روش‌های کاهش بعد می‌پردازد. دو روش تحلیل مؤلفه‌های اصلی (خطی) و خودرمنزنگار (غیرخطی) برای شبیه‌سازی پدیده انتقال حرارت پایا با استفاده از مجموعه داده‌های انتقال حرارت پایا دو بعدی در ابعاد 64×64 و 128×128 بکار رفت و از طریق ابزارها و کتابخانه‌های موجود در محیط پایتون پیاده‌سازی شد. طبق نتایج حاصل، در کاهش مرتبه شدید، خودرمنزنگار و در کاهش مرتبه جزئی، تحلیل مؤلفه‌های اصلی دقت بالاتری دارد. همچنین خروجی‌های حاصل از مدل رتبه کاسته پیشنهادی با شبیه‌سازی‌های حاصل از مدلی مبتنی بر شبکه عصبی کانولوشنی با تعداد لایه‌ها و فیلترهای متعدد مقایسه شد. نتایج حاصل از شبیه‌سازی توزیع دمای پایا برحسب خطای میانگین مربعات (MSE) با استفاده از مدل‌های مبتنی بر تحلیل مؤلفه‌های اصلی، خودرمنزنگار و مدل مبتنی بر شبکه‌های عصبی کانولوشنی در ابعاد 64×64 به ترتیب برابر با 1.617×10^{-4} ، 2.528×10^{-6} و 0.15 و در ابعاد 128×128 نیز برابر با 2.046×10^{-4} ، 7.253×10^{-6} و 0.058 درجه سلسیوس در هر پیکسل است. بنابراین، مدل‌های رتبه کاسته پیشنهادی به‌ویژه مدل مبتنی بر روش خودرمنزنگار از دقت بسیار بالاتری نسبت به مدل مبتنی بر شبکه‌های عصبی کانولوشنی برخوردار می‌باشد.

© ۱۴۰۰ - مجله محاسبات نرم، کلیه حقوق محفوظ است.

۱. مقدمه

مدل‌سازی بسیاری از پدیده‌ها در دنیای واقعی است. برخی از پدیده‌ها در طبیعت دارای معادله فیزیکی مشخصی نبوده و تغییرات در رفتار آن به‌واسطه یک قاعده جامع قابل تفسیر نمی‌باشد. علاوه بر این بسیاری از معادلات دیفرانسیل حاکم بر سیستم‌ها غیرخطی و بسیار پیچیده هستند، بنابراین دستیابی به پاسخ آن‌ها بسیار مشکل بوده و به‌طور معمول با روش‌های ریاضی و کاملاً دقیق، قابل حل نمی‌باشند و حل آن‌ها بصورت

معادلات دیفرانسیل با مشتقات جزئی یکی از ابزارهای اصلی در

♦ نوع مقاله: پژوهشی

* نویسنده مسئول

پست(های) الکترونیک: afzali_somayeh@yahoo.com (افضلی)

moayyedi@qom.ac.ir (مؤیدی)

fotouhi@qom.ac.ir (فتوحی)

نحوه ارجاع به مقاله: افضل^۱، سمیه، مؤیدی، محمدکاظم، فتوحی، فرانک، «توسعه یک مدل رتبه کاسته بدون معادله مبتنی بر الگوهای متفاوت استخراج ویژگی روی مجموعه داده انتقال حرارت دو بعدی پایا»، مجله محاسبات نرم، جلد ۱۰، شماره ۱، ص ۱۶-۳۱، بهار و تابستان ۱۴۰۰.

سخت^۲ می‌شود. حتی افزایش مداوم سرعت رایانه‌های مدرن و پردازش‌های موازی، چالش تحلیل داده‌های با ابعاد بالا را کاهش نمی‌دهد [۱۴]. بنابراین، پردازش تصاویر در مقیاس‌های بزرگ نیز به دلیل استفاده از شبکه‌های عصبی با تعداد لایه‌ها و فیلترهای متعدد، هزینه زمانی و توان محاسباتی بسیار بالایی می‌طلبند. روش‌های کاهش مرتبه، داده‌ها را از فضایی با ابعاد بالا به فضایی با ابعاد پایین‌تر به گونه‌ای انتقال می‌دهد که اطلاعات ارزشمند و معنادار داده اصلی حفظ شده و پیچیدگی آن کاهش یابد. با استفاده از روش‌های کاهش مرتبه، پردازش و مدل‌سازی داده‌های با ابعاد بالا از جمله تصاویر در مقیاس‌های بزرگ با هزینه‌های بسیار پایین‌تر و در مدت زمان کوتاه‌تری به انجام خواهد رسید. کاهش ابعاد به‌طور معمول در رشته‌هایی همچون پردازش سیگنال [۱۶، ۱۵]، تشخیص گفتار [۲۲-۱۷]، علوم اعصاب محاسباتی^۳ [۲۹-۲۳] و زیست‌شناسی محاسباتی^۴ [۳۰] بکار می‌رود که با مجموعه بزرگی از مشاهدات یا متغیرها و ویژگی‌ها سروکار دارند [۳۱]. در کاهش ابعاد با کاهش حجم محاسبات، سرعت پردازش داده‌ها افزایش می‌یابد. همچنین محاسبات مربوط به روش‌های تحلیل و پردازش داده‌ها همچون رگرسیون یا طبقه‌بندی در فضای کاهش یافته به‌طور معمول با دقت بسیار بیشتری انجام می‌شود [۳۲].

مدل‌های کاهش مرتبه یافته یا رتبه کاسته، از طریق کاهش ابعاد و با کاستن از قیود مدل، سرعت شبیه‌سازی مساله مورد نظر را به میزان زیادی افزایش می‌دهند. در منبع [۳۳]، برای افزایش سرعت شبیه‌سازی تغییرات زمانی فرآیند نفوذ جابجایی از طریق روش حل عددی (که نیاز به محاسبات سنگین و زمان‌بری دارد)، یک مدل رتبه کاسته با استفاده از روش کاهش مرتبه تجزیه متعامد بهینه توسعه یافته تا جایگزین معادلات اصلی شده و با دقت بسیار مناسبی رفتار سیستم مورد نظر را پیش‌بینی کند. در پژوهش حاضر، پدیده مورد بررسی، انتقال حرارت دو بعدی در حالت پایا است. هدف، توسعه مدلی رتبه کاسته و بدون معادله بوده که قادر است بدون نیاز به یافتن و حل مستقیم یا

عددی نیز به صرف هزینه زمانی و محاسباتی بسیار بالایی می‌انجامد. در مقابل، الگوریتم‌های یادگیری عمیق قادر بوده بدون آگاهی از معادلات دیفرانسیل حاکم به شبیه‌سازی سریع پدیده‌های دینامیکی پردازند. روش‌های مبتنی بر یادگیری عمیق با امکان رمزنگاری اطلاعات مناسب از دینامیک سیستم روی شبکه عصبی، این امکان را فراهم می‌کند که حتی در صورت ناشناخته بودن و عدم دسترسی به قوانین فیزیکی حاکم بر سیستم دینامیکی، نحوه عملکرد آن را به شبکه عصبی آموزش داده و مدل‌سازی سیستم‌های پیچیده را بصورت دقیق‌تر، سریع‌تر و با میزان هزینه محاسباتی بسیار کمتری انجام دهد. همچنین در مدل‌های مبتنی بر شبکه عصبی برخلاف مدل‌سازی‌های عددی نیاز به فرضیات محدودکننده نیست.

در سال‌های اخیر، پیشرفت‌های بسیاری در زمینه بینایی ماشین و پردازش زبان طبیعی حاصل شده که توسط یادگیری عمیق انجام گرفته است [۸-۱]. در مسائل مربوط به بینایی ماشین و پردازش تصاویر، از شبکه‌های عصبی کانولوشنی^۱ استفاده می‌شود. شبکه عصبی کانولوشنی، نمونه‌ای از یک معماری مدرن مبتنی بر یادگیری عمیق می‌باشد. این شبکه شامل مجموعه‌ای چند لایه از عملیات پیچشی بهینه بوده که روابط غیرخطی موجود در داده‌ها را محاسبه می‌کند. عملیات هر لایه به گونه‌ای تنظیم می‌شود که داده ورودی، خود را به شیوه‌ای تغییر دهد که یک بازنمایی صحیح و منحصر به فرد در خروجی تولید گردد.

یکی از چالش‌های پیش رو، تجزیه، تحلیل و پردازش داده‌های با ابعاد بالا است. موضوعات چالش برانگیز بسیاری در مورد داده‌های عظیم وجود دارد [۱۳، ۹]. حتی با وجود مجموعه داده‌های با اندازه متوسط یا مناسب، ابعاد بالا می‌تواند مشکلات جدیدی ایجاد کند [۱۴]. مجموعه داده‌های با ابعاد بالا، با داشتن ساختاری نامشخص و همچنین وجود خطاهای بزرگ در داده‌های آن‌ها با مشکلات پردازشی جدی روبرو هستند. علاوه بر این با رشد نمایی ترکیبات احتمالی دسته‌های موجود در داده‌های با ابعاد بالا خوشه‌بندی تبدیل به یک مساله ان پی

² Nondeterministic polynomial-time Hard

³ Neuroinformatics

⁴ Bioinformatics

¹ Artificial Neural Network

داده‌ها است. میزان اطلاعات از دست رفته در این روش نسبت به سایر روش‌های خطی، کمتر است. تحلیل مؤلفه‌های اصلی یک تبدیل خطی متعامد است که به منظور تبیین حداکثر مقدار وردایی^۳ متغیرها، ترکیب خطی آن‌ها را برآورده می‌سازد. بدین منظور داده‌ها را به یک سیستم مختصات جدید انتقال می‌دهد به طوری که بزرگترین وردایی داده بر روی اولین محور مختصات، دومین بزرگترین وردایی بر روی دومین محور مختصات قرار می‌گیرد [۳۷]. بدین ترتیب اولین مؤلفه بیشترین وردایی متغیرها را تبیین می‌کند. سپس مؤلفه دوم بیشترین مقدار وردایی باقیمانده در متغیرها را بعد از مؤلفه اول توضیح می‌دهد و برای تمامی مؤلفه‌های پس از آن نیز به همین ترتیب خواهد بود. در این روش، مؤلفه‌هایی از مجموعه داده که بیشترین تأثیر را در وردایی دارند، حفظ می‌شوند. بدین ترتیب موجب کاهش ابعاد داده‌ها با حفظ اطلاعات مهم آن خواهد شد.

تحلیل مؤلفه‌های اصلی شامل تجزیه مقادیر و بردارهای ویژه ماتریس هم‌وردایی^۴ داده‌ها می‌باشد. اگر $X_{m,n}$ ماتریس داده‌ها و $C_{n,n}$ ماتریس هم‌وردایی X باشد، $A_{n,n}$ ماتریس مقادیر ویژه و $B_{n,n}$ نیز ماتریس بردارهای ویژه محاسبه شده از ماتریس C خواهد بود. اگر هر عضو A را با a و هر عضو B را با b نمایش دهیم آنگاه $P_{n,t}$ ، ماتریس مؤلفه‌های اصلی متناظر با t مقدار ویژه بزرگتر و Y نیز ماتریس بردارهای ویژه جدید برای مجموعه داده X خواهند بود [۳۸].

$$A: a_1 > a_2 > \dots > a_t > \dots > a_n$$

$$P = [b_1, b_2, \dots, b_t] \quad (1)$$

$$Y = X \times P \quad (2)$$

۲.۲. خودرمنگار

خودرمنگار نوعی شبکه عصبی مصنوعی است که از روشی بدون نظارت برای یادگیری کدگذاری کارآمد داده‌ها استفاده می‌کند [۳۹]. خودرمنگارها از طریق آموزش شبکه به منظور

عددی معادلات دیفرانسیل انتقال حرارت پایا، پویایی سیستم را به یک شبکه عصبی فاقد لایه‌های پیچیده کانولوشنی منتقل نماید به گونه‌ای که در کمترین زمان و با کسب بیشترین میزان دقت، راه‌حل‌های صحیحی از وضعیت آینده میدان رسانای دو بعدی پس از اعمال حرارت به آن در حالت پایا با استفاده از روش‌های کاهش ابعاد تولید گردد. روش‌های معرفی شده و مدل‌های ارائه شده در این پژوهش با استفاده از ابزارها و کتابخانه‌های موجود در محیط پایتون پیاده‌سازی شده است.

۲. روش‌های کاهش بعد

روش‌های کاهش ابعاد شامل دو دسته روش‌های خطی و غیرخطی می‌باشد [۳۱]. همچنین به دو رویکرد انتخاب ویژگی و استخراج ویژگی تقسیم‌بندی می‌شوند [۳۴]. روش‌های مبتنی بر رویکرد انتخاب ویژگی سعی در یافتن زیرمجموعه‌ای از ویژگی‌های اصلی دارد که از اهمیت بالاتری برخوردارند، بنابراین با حذف ویژگی‌های غیرمرتبط و زائد منجر به کاهش بعد می‌شود [۳۵]. کاهش ابعاد با استفاده از این روش‌ها معایب بسیاری دارند. از جمله اینکه هزینه‌بر بوده و همیشه منجر به یافتن بهترین جواب نخواهد شد. همچنین الگوریتم مورد استفاده حریصانه بوده و در کاربردهایی همچون چهره‌شناسی روش مناسبی برای کاهش مرتبه داده نمی‌باشد. روش‌های مبتنی بر رویکرد استخراج ویژگی با ترکیب ویژگی‌های اصلی به کاهش بعد دست می‌یابند. از این رو قادر به ساخت ویژگی‌های جدیدی و اغلب فشرده‌تر با خاصیت متمایزکنندگی بیشتری است [۳۶]. در این پژوهش دو روش خطی و غیرخطی از مجموعه روش‌های استخراج ویژگی مورد بررسی قرار می‌گیرد. روش خطی، تحلیل مؤلفه‌های اصلی^۱ و روش غیرخطی، خودرمنگار^۲ می‌باشد.

۲.۱. تحلیل مؤلفه‌های اصلی

تحلیل مؤلفه‌های اصلی بهترین روش خطی برای کاهش ابعاد

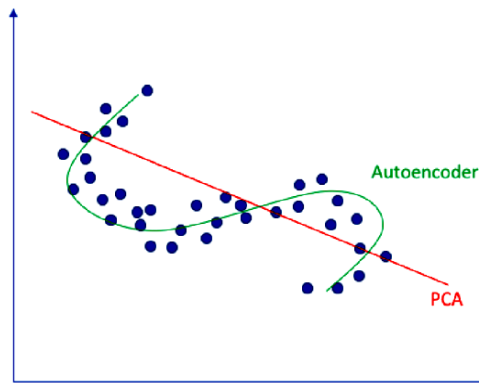
³ Variance

⁴ Covariance

¹ Principal Component Analysis

² Autoencoder

داده‌ها می‌باشند [۴۱]. در شکل (۲) مقایسه و تفاوت بین این دو روش به خوبی نشان داده شده است.



شکل (۲): مقایسه دو روش خودرمننگار و تحلیل مؤلفه‌های اصلی [۴۱]

۳. معرفی مجموعه داده‌ها

مجموعه داده‌های مورد بررسی، داده‌های انتقال حرارت دو بعدی پایا است. هر داده در این مجموعه، توزیع دمایی پایای یک صفحه رسانا را پس از اعمال حرارت به مرزهای عایق‌بندی شده آن نشان می‌دهد. این داده‌ها در قالب مجموعه داده‌های مختلف با اندازه و ابعاد گوناگون مورد بررسی قرار گرفته‌اند و مشخصات هر کدام در جدول (۱) نشان داده شده است.

جدول (۱): مشخصات فایل مجموعه داده‌ها و ابعاد آنها

شماره مجموعه داده	تعداد داده‌ها	ابعاد داده‌ها
1	5000	4096(64×64)
2	15000	4096(64×64)
3	10000	256(16×16)
4	10000	1024(32×32)
5	10000	4096(64×64)
6	10000	16384(128×128)

۴. پیاده‌سازی و ارزیابی روش‌های کاهش بعد

در این بخش تاثیر خصوصیات مختلف مجموعه داده‌ها همچون ماهیت، اندازه و ابعاد داده‌های موجود در آنها بر روی میزان دقت حاصل از کاهش مرتبه به ابعاد مختلف با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمننگار، مورد بررسی قرار می‌گیرد. برای این کار، هر یک از ۸ مجموعه داده معرفی شده در بخش قبل از طریق دو روش مذکور به ابعاد مختلف کاهش یافته، سپس مجدداً به ابعاد اولیه بازسازی و میزان خطای

حذف سیگنال خطا، ویژگی‌های مفید درون داده‌ها را استخراج کرده و در نتیجه منجر به کاهش ابعاد داده‌ها می‌شوند [۴۰]. خودرمننگارها از رمزنگار، گلوگاه و رمزگشا تشکیل شده‌اند. ابتدا داده ورودی وارد بخش رمزنگار شده و پس از فشردگی -سازی و کاهش ابعاد، یک بازنمایی فشرده شده در لایه گلوگاه ظاهر می‌شود. سپس توسط رمزگشا، به گونه‌ای بازسازی می‌شود که تا حد امکان شبیه به داده ورودی اصلی باشد.

$$h^{(t)} = f_{\theta}(x^{(t)}) \quad (3)$$

$$x^{(t)} = \{x^{(1)}, \dots, x^{(T)}\}$$


که در آن h بردار ویژگی‌های فشرده شده ورودی f_{θ} رمزنگار و $x^{(t)}$ ها مجموعه داده‌ها می‌باشند. رمزگشا نیز تابعی خواهد بود که با g_{θ} نمایش داده می‌شود و با استفاده از رابطه (۴)، نگاشتی از فضای ویژگی به فضای ورودی انجام می‌دهد.

$$r = g_{\theta}(h) \quad (4)$$

آموزش خودرمننگار، شامل یافتن بردار پارامتر θ برای حداقل کردن خطای بازسازی است.

$$l_{AE}(\theta) = \sum_t L(x^{(t)}, g_{\theta}(f_{\theta}(x^{(t)}))) \quad (5)$$

با حداقل کردن خطای بازسازی، خودرمننگار می‌تواند مهمترین ویژگی‌های داده ورودی و چگونگی بازسازی بهتر آن را از حالت رمزنگاری شده یاد گیرد. شکل (۱) نمای کلی خودرمننگار را نمایش می‌دهد.



شکل (۱): ساختار خودرمننگار

روش تحلیل مؤلفه‌های اصلی سعی در یافتن روابط خطی میان داده‌ها دارد. در مقابل خودرمننگارها با بکارگیری شبکه‌های عصبی قادر به یادگیری روابط غیرخطی و غیرقابل توصیف میان

را در کاهش بعد با روش تحلیل مؤلفه‌های اصلی نشان می‌دهد. روش تحلیل مؤلفه‌های اصلی در کاهش مرتبه مجموعه داده‌های کوچکتر دقت بالاتری دارد.

جدول (۲): مقایسه خطاهای حاصل از بازسازی مجموعه داده‌های ۱ و ۲ در کاهش مرتبه با روش تحلیل مؤلفه‌های اصلی به ابعاد مختلف

مجموعه داده ۲	مجموعه داده ۱	بعد
0.0197	0.0184	2
1.008×10^{-5}	2.618×10^{-7}	8
1.348×10^{-6}	7.924×10^{-8}	32
8.924×10^{-9}	6.132×10^{-10}	128
7.421×10^{-10}	4.619×10^{-11}	512
9.318×10^{-11}	7.851×10^{-13}	2048

جدول (۳) خطاهای حاصل از بازسازی دو مجموعه داده را در کاهش بعد با روش خودرمنگار نشان می‌دهد. برخلاف روش تحلیل مؤلفه‌های اصلی، دقت خودرمنگار بر روی مجموعه داده ۲ با تعداد داده‌های بیشتر، همواره بالاتر از مجموعه داده ۱ است. بنابراین این روش در کاهش ابعاد مجموعه داده‌های بزرگ‌تر، میزان دقت بیشتری دارد. خودرمنگار برای کاهش ابعاد از شبکه عصبی استفاده می‌کند. در شبکه‌های عصبی با افزایش داده میزان دقت تولید خروجی افزایش می‌یابد. در کاهش مرتبه دو مجموعه داده به ابعاد بسیار پایین، خودرمنگار و در ابعاد بالا، تحلیل مؤلفه‌های اصلی دقت بیشتری دارد.

جدول (۳): مقایسه خطاهای حاصل از بازسازی مجموعه داده‌های ۱ و ۲ در کاهش مرتبه با روش خودرمنگار به ابعاد مختلف

مجموعه داده ۲	مجموعه داده ۱	بعد
0.0141	0.0153	2
4.438×10^{-8}	1.706×10^{-7}	8
5.196×10^{-10}	6.089×10^{-8}	32
9.314×10^{-11}	2.754×10^{-9}	128
8.843×10^{-12}	5.649×10^{-10}	512
7.166×10^{-12}	6.045×10^{-10}	2048

شکل (۳)، یکی از داده‌های انتقال حرارت پایا را نشان می‌دهد. این داده صفحه مربعی رسانا در حالت پایا با شرایط مرزی ۳۴، ۱۱، ۱۲ و ۲۹ درجه سانتی‌گراد به ترتیب در مرزهای چپ، راست، بالا و پایین می‌باشد. این داده با استفاده از الگوی حاصل شده از کاهش مرتبه دو مجموعه داده ۱ و ۲ با دو روش مذکور

میانگین مربعات^۱ (MSE) حاصل از بازسازی آن‌ها محاسبه می‌شود. بدیهی است روشی که از میزان خطای بازسازی کمتری برخوردار باشد، روش مناسب‌تری برای کاهش بعد خواهد بود. برای پیاده‌سازی دو روش کاهش بعد بر روی هر مجموعه داده، ابتدا داده‌ها نرمال‌سازی می‌شود. سپس برای کاهش بعد با روش تحلیل مؤلفه‌های اصلی به n بعد، پس از محاسبه ماتریس هم-وردایی مجموعه داده موردنظر، بردارهای ویژه متناظر با n مقدار ویژه بزرگتر آن انتخاب و داده‌ها در ترانهاده این ماتریس ضرب می‌شوند تا داده‌های کاهش یافته بدست آیند. برای بازسازی به ابعاد اصلی، داده‌ها مجدداً در ماتریس مؤلفه‌های اصلی ضرب شده و داده‌های بازسازی شده بدست می‌آیند. برای پیاده‌سازی این روش در محیط پایتون از PCA در کتابخانه sklearn استفاده شده است.

به منظور پیاده‌سازی خودرمنگار، یک شبکه عصبی غیربازگشتی متقارن ایجاد شده که گره‌های ورودی و خروجی آن یکسان و برابر با داده‌های مجموعه داده می‌باشد. همچنین در لایه گلوگاه تعداد گره‌ها برابر با تعداد ابعاد کاهش یافته تنظیم می‌شود. در پیاده‌سازی این شبکه، توابع و کلاس‌های کتابخانه keras در محیط پایتون بکار گرفته شده‌اند. از بهینه‌ساز adam برای بهینه‌سازی وزن‌های شبکه و از تابع هزینه MSE برای ارزیابی هر دو روش استفاده شده است.

۴.۱. ارزیابی و مقایسه روش‌های مختلف کاهش بعد بر روی مجموعه داده‌های با تعداد داده‌های متفاوت


یکی از عوامل تاثیرگذار در میزان دقت کاهش مرتبه یک مجموعه داده، تعداد داده‌های آن است. بدین منظور کاهش ابعاد یک مرتبه بر روی ۵۰۰۰ داده (مجموعه داده ۱) و بار دیگر بر روی ۱۵۰۰۰ داده (مجموعه داده ۲) مربوط به انتقال حرارت پایای دو بعدی در ابعاد 64×64 انجام شده و نتایج حاصل از آن مورد بررسی قرار گرفته است.

جدول (۲) خطاهای حاصل از بازسازی دو مجموعه داده ۱ و ۲

^۱ Mean Squared Error

^۲ Neuron

کاهش مرتبه داده‌های با ابعاد بالا با استفاده از هر دو روش به ویژه خودرمنگار از خطای بازسازی کمتری برخوردار است. شکل‌های (۶) و (۷) تصاویر بازسازی شده داده موجود در شکل (۳) را با استفاده از الگوهای حاصل شده از کاهش مرتبه مجموعه داده‌های ۳، ۴، ۵ و ۶ با روش‌های مختلف کاهش بعد نمایش می‌دهد. روش خودرمنگار کاهش مرتبه داده‌ها به ابعاد پایین را با دقت بیشتری انجام می‌دهد. در مقابل تحلیل مؤلفه-های اصلی در کاهش مرتبه داده‌ها به ابعاد بالا بهتر عمل می‌کند.




شکل (۳): توزیع دمای پایای صفحه مربعی رسانا با شرایط مرزی مشخص

در ابعاد مختلف کاهش و سپس مجدداً بازسازی شده و در شکل‌های (۴) و (۵) نمایش داده شده‌است. کاهش دو مجموعه داده به ابعاد پایین با روش خودرمنگار از میزان دقت بالاتری برخوردار می‌باشد.


۴.۲. ارزیابی و مقایسه روش‌های مختلف کاهش مرتبه بر روی مجموعه داده‌های با ابعاد مختلف

روش‌های مختلف کاهش بعد بر روی داده‌های با ابعاد مختلف نتایج متفاوتی خواهد داشت. چهار مجموعه داده ۳، ۴، ۵ و ۶ داده‌های حرارتی مربوط به حالت پایای یک صفحه مربعی رسانا در چهار ابعاد مختلف ۱۶×۱۶، ۳۲×۳۲، ۶۴×۶۴ و ۱۲۸×۱۲۸ می‌باشد. خطاهای حاصل از بازسازی چهار مجموعه داده مذکور پس از کاهش بعد با روش‌های تحلیل مؤلفه‌های اصلی و خودرمنگار به ترتیب در جدول‌های (۴) و (۵) نمایش داده شده است. در هر ستون هر بار ابعاد مجموعه داده به نصف کاهش یافته و خطای بازسازی آن محاسبه و در جدول درج شده است.





کاهش به ۲۰۴۸ بعد



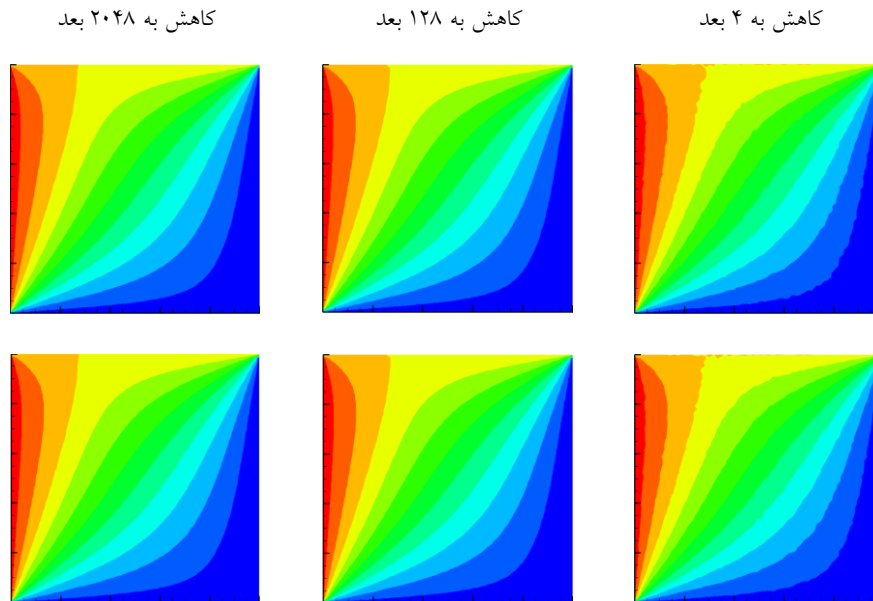
کاهش به ۱۲۸ بعد



کاهش به ۴ بعد



شکل (۴): مقایسه داده‌های حاصل از بازسازی مجموعه داده‌های ۱ (ردیف اول) و ۲ (ردیف دوم) پس از کاهش مرتبه به ابعاد مختلف با استفاده از روش تحلیل مؤلفه‌های اصلی



شکل (۵): مقایسه داده‌های حاصل از بازسازی مجموعه داده‌های ۱ (ردیف اول) و ۲ (ردیف دوم) پس از کاهش مرتبه به ابعاد مختلف با استفاده از روش خودرنگار

جدول (۴): مقایسه خطاهای حاصل از بازسازی مجموعه داده‌های ۳، ۴، ۵ و ۶ با کاهش مرتبه به روش تحلیل مؤلفه‌های اصلی به ابعاد مختلف

بعد	$1/2^8$ ابعاد اولیه	$1/2^7$ ابعاد اولیه	$1/2^6$ ابعاد اولیه	$1/2^5$ ابعاد اولیه	$1/2^4$ ابعاد اولیه	$1/2^3$ ابعاد اولیه	$1/2^2$ ابعاد اولیه
مجموعه داده ۳	0.02898	0.0092	1.478×10^{-5}	1.981×10^{-7}	2.778×10^{-8}	2.743×10^{-9}	7.319×10^{-10}
مجموعه داده ۴	5.403×10^{-6}	6.244×10^{-7}	1.774×10^{-7}	4.678×10^{-9}	4.262×10^{-9}	2.180×10^{-10}	5.548×10^{-11}
مجموعه داده ۵	4.933×10^{-7}	1.764×10^{-7}	5.688×10^{-8}	4.541×10^{-9}	1.055×10^{-9}	2.009×10^{-10}	2.689×10^{-12}
مجموعه داده ۶	3.349×10^{-8}	5.933×10^{-8}	6.185×10^{-9}	8.264×10^{-10}	1.647×10^{-11}	3.792×10^{-11}	1.482×10^{-12}

جدول (۵): مقایسه خطاهای حاصل از بازسازی مجموعه داده‌های ۳، ۴، ۵ و ۶ با کاهش مرتبه به روش خودرنگار به ابعاد مختلف

بعد	$1/2^8$ ابعاد اولیه	$1/2^7$ ابعاد اولیه	$1/2^6$ ابعاد اولیه	$1/2^5$ ابعاد اولیه	$1/2^4$ ابعاد اولیه	$1/2^3$ ابعاد اولیه	$1/2^2$ ابعاد اولیه
مجموعه داده ۳	0.01725	0.0077	8.856×10^{-6}	1.003×10^{-7}	3.108×10^{-8}	5.263×10^{-9}	1.452×10^{-9}
مجموعه داده ۴	2.367×10^{-7}	1.538×10^{-7}	7.216×10^{-8}	2.294×10^{-9}	1.365×10^{-9}	6.348×10^{-10}	4.268×10^{-10}
مجموعه داده ۵	6.185×10^{-8}	3.016×10^{-9}	7.838×10^{-10}	1.897×10^{-10}	9.663×10^{-11}	4.243×10^{-11}	2.647×10^{-11}
مجموعه داده ۶	8.243×10^{-9}	2.571×10^{-9}	3.772×10^{-10}	9.738×10^{-11}	8.967×10^{-12}	6.844×10^{-12}	4.174×10^{-12}

۵. استفاده از روش‌های کاهش بعد در شبیه‌سازی


انتقال حرارت پایا در ابعاد بالا

است. گرما به نوعی به صفحه رسانا اعمال خواهد شد و هدف، مدل‌سازی نحوه انتشار انرژی حرارتی رسانا در شرایط پایا است. بدین منظور از دو روش کاهش بعد تحلیل مؤلفه‌های اصلی و خودرنگار برای مدل‌سازی انتقال حرارت پایا در ابعاد 64×64 و 128×128 استفاده می‌شود. روش کار به این صورت است که طی یک مرحله داده‌های حالت پایا با شرایط مرزی مختلف، پس از نرمال‌سازی و تبدیل به بردارهایی یک بعدی با


در این بخش مدل‌سازی انتقال حرارت پایای میدان‌های دو بعدی با استفاده از روش‌های کاهش ابعاد مورد بررسی قرار خواهد گرفت. میدان موردنظر، یک صفحه مربعی تشکیل شده از برخی مواد رسانا بوده که امتداد چهار لبه آن عایق‌بندی شده

استفاده از روش کاهش بعد موردنظر به ابعاد پایین کاهش یافته، سپس از شرایط مرزی مختلف به عنوان داده و از داده‌های تولید شده در ابعاد پایین به عنوان برچسب برای آموزش شبکه‌ای متشکل از لایه‌های dense استفاده خواهد شد. این شبکه با دریافت شرایط مرزی موردنظر در قالب ۴ دمای مربوط به چهار لبه صفحه رسانا، توزیع دمای حالت پایای دو بعدی را بصورت یک بردار کاهش یافته پیش‌بینی می‌نماید. سپس در مرحله بعد

به‌منظور حصول دمای حالت پایا در ابعاد اصلی، الگوی استخراج شده از داده‌های آموزشی با استفاده از روش کاهش بعد مربوطه در جهت عکس (در جهت افزایش ابعاد) بر روی داده‌های تولید شده از شبکه اعمال می‌گردد. کاهش مرتبه داده‌ها در ابعاد مختلف انجام می‌شود، سپس بعدی که در آن شبیه‌سازی انتقال حرارت پایا دارای بیشترین دقت است، انتخاب می‌گردد.



شکل (۶): مقایسه داده‌های حاصل از بازسازی مجموعه داده‌های ۳ (ردیف اول)، ۴ (ردیف دوم)، ۵ (ردیف سوم) و ۶ (ردیف چهارم) پس از کاهش مرتبه به ابعاد مختلف با استفاده از روش تحلیل مؤلفه‌های اصلی



شکل (۷): مقایسه داده‌های حاصل از بازسازی مجموعه داده‌های ۳ (ردیف اول)، ۴ (ردیف دوم)، ۵ (ردیف سوم) و ۶ (ردیف چهارم) پس از کاهش مرتبه به ابعاد مختلف با استفاده از روش خودرمنگار

۵.۱. شبیه‌سازی انتقال حرارت پایا در ابعاد 64×64

جدول (۶) خطای شبکه را در مدل‌سازی شرایط مرزی مختلف مربوط به صفحه رسانای دارای توزیع دمای پایا در ابعاد 64×64 به داده‌های کاهش یافته‌ای نشان می‌دهد که مطابق دو روش تحلیل مؤلفه‌های اصلی و خودرمنگار در ابعاد مختلف از مرتبه ۱۶ تا 2048 تولید شده‌اند. برای این کار از مجموعه داده ۵ که دماهای حالت پایای صفحه مربعی رسانا را در ابعاد 64×64 نشان می‌دهد، استفاده شده است.

مدل‌سازی شبکه عصبی با استفاده از داده‌های کاهش یافته به ابعاد بسیار پایین به دلیل از دست رفتن میزان زیادی از اطلاعات مفید با خطای بیشتری همراه بوده اما با کاهش به مرتبه‌های بالاتر به دلیل حفظ اطلاعات بیشتر موجود در داده‌ها، میزان دقت مدل‌سازی نیز بالا می‌رود. در مقابل، یادگیری الگوی موجود در داده‌های با ابعاد بسیار بالا برای شبکه دشوار است. علاوه بر این، با کاهش ناچیز ابعاد داده‌ها، ویژگی‌های زائد به میزان کمتری حذف می‌شود، در این حالت یافتن الگوی موجود در داده‌ها برای شبکه دشوار خواهد بود. بنابراین به تدریج با افزایش

به ابعاد بسیار بالا، دقت مدل‌سازی شبکه کاهش می‌یابد. طبق نتایج نمایش داده شده در جدول (۶)، خطای حاصل از مدل‌سازی شبکه با استفاده از داده‌های کاهش یافته با هر دو روش در مرتبه‌های ۱۶ تا ۵۱۲ نزولی بوده اما به تدریج با بکارگیری داده‌های با ابعاد بالاتر خطای بازسازی افزایش می‌یابد. مدل‌سازی شبکه با استفاده از داده‌های کاهش یافته با هر دو روش کاهش ابعاد در مرتبه ۵۱۲ از کمترین خطای میانگین مربعات برخوردار می‌باشد. اما به منظور یافتن بهترین بعد برای مدل‌سازی توزیع دمای پایا با داده‌های کاهش یافته از طریق دو روش، می‌بایست داده‌های حاصل از افزایش ابعاد خروجی‌های تولید شده توسط شبکه محاسبه و مورد ارزیابی قرار گیرد.

جدول (۷) نتایج حاصل از افزایش ابعاد داده‌های تولید شده از شبکه را با استفاده از الگوی استخراج شده از داده‌های انتشار گرمای پایا در ابعاد 64×64 (مجموعه داده ۵) با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمنگار نشان می‌دهد. استفاده از داده‌های کاهش یافته به مرتبه ۱۲۸ با هر دو روش کاهش بعد از بیشترین دقت در مدل‌سازی انتقال حرارت پایا برخوردار می‌باشد. با انتخاب بهترین بعد، در مرحله اول، داده‌های آموزشی مربوط به توزیع دمای پایا پس از تبدیل به برداری به طول $4096 (64 \times 64)$ به مرتبه ۱۲۸ کاهش یافته، سپس از شرایط مرزی داده‌های مربوطه که برداری از دماهای ۴ لبه صفحه مربعی به طول ۴ بوده به‌عنوان داده و از بردار داده‌های کاهش یافته به طول ۱۲۸ به‌عنوان پرچسب برای آموزش شبکه-ای از لایه‌های *dense* استفاده می‌شود. در مرحله دوم، داده‌های تولید شده از طریق الگوی استخراج شده از داده‌های آموزشی با استفاده از روش کاهش بعد مربوطه در جهت عکس افزایش مرتبه یافته تا بدین صورت توزیع دمای حالت پایای صفحه مسطح بدست آید.

شکل (۸) نتایج حاصل از مدل‌سازی انتقال حرارت پایا را در ابعاد 64×64 با استفاده از روش‌های مختلف نمایش می‌دهد. ستون اول، شرایط حرارتی صفحه رسانا را در لحظه نخست اعمال حرارت به آن نشان می‌دهد. داده‌های نمایش داده شده در چهار ستون بعدی، تصاویر ماتریسی 64×64 بوده که مقادیر دما

را در هر نقطه از صفحه پس از آن که فرآیند انتقال حرارت به یک توزیع دمای پایا همگرا شده با استفاده از چهار روش مختلف نشان می‌دهد. در این آزمایش داده‌های تولید شده به روش اختلاف محدود که با استفاده از شبیه‌سازی CFD بدست آمده به عنوان حالت پایای واقعی فرض شده و در ستون دوم قرار داده شده است. در ستون سوم، نتایج بدست آمده از شبیه‌سازی انتقال حرارت پایا با استفاده از شبکه‌ای متشکل از لایه-های کانولوشنی متعدد نشان داده شده است. این شبکه برخلاف دو مدل مبتنی بر روش‌های کاهش بعد از لایه‌های کانولوشنی متعدد با تعداد فیلترهای بسیار برای شبیه‌سازی توزیع دما استفاده می‌کند. دو ستون بعدی نیز مربوط به نتایج بدست آمده از مدل‌سازی انتقال حرارت پایا با استفاده از روش‌های کاهش بعد تحلیل مؤلفه‌های اصلی و خودرمنگار می‌باشد. توزیع دمایی اولیه حجم کنترل مربعی نمایش داده شده در سطر اول در مرزهای چپ، راست، بالا و پایین صفحه رسانا به ترتیب ۹، ۲۳، ۷۱ و ۰ درجه سانتی‌گراد می‌باشد. این شرایط مرزی در سطر دوم به ترتیب ۴۵، ۹۴، ۵۵ و ۵۵ درجه سانتی‌گراد، در سطر سوم ۵، ۴۵، ۲ و ۴۰ درجه سانتی‌گراد، در سطر چهارم ۸۴، ۹۹، ۹۲ و ۳ درجه سانتی‌گراد، در سطر پنجم ۷۴، ۷۱، ۱۲ و ۲۹ درجه سانتی‌گراد، در سطر ششم ۳۴، ۵۵، ۹ و ۶۰ درجه سانتی‌گراد، در سطر هفتم ۳۸، ۰، ۱۲ و ۵۹ درجه سانتی‌گراد، در سطر هشتم ۱۱، ۷۸، ۵ و ۱۲ درجه سانتی‌گراد، در سطر نهم ۱۰۰، ۲۱، ۴۴/۶۸ و ۶/۹ درجه سانتی‌گراد و در سطر آخر ۳۴، ۱۱، ۱۲ و ۲۹ درجه سانتی‌گراد می‌باشد.


خروجی‌های حاصل از مدل‌های مبتنی بر روش‌های کاهش بعد در مقایسه با مدلی که در آن از شبکه‌های عصبی شامل لایه‌های کانولوشنی متعدد استفاده شده از دقت بسیار بالاتری برخوردار می‌باشد. خطای میانگین مربعات خروجی برای شبیه‌سازی توزیع دمای پایا در ابعاد 64×64 با استفاده از مدل‌های مبتنی بر تحلیل مؤلفه‌های اصلی و خودرمنگار به ترتیب برابر با مقادیر $4^{-10} \times 1/617$ و $10^{-6} \times 2/528$ درجه سانتی‌گراد در هر پیکسل است. درحالی‌که این خطا برای مدل مبتنی بر شبکه‌های عصبی کانولوشنی برابر با $0/015$ است.


جدول (۶): خطای شبکه در مدلسازی شرایط مرزی مختلف به داده‌های کاهش یافته در ابعاد مختلف با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمنگار برای داده‌های با ابعاد 64×64

بعد	16	32	64	128	256	512	1024	2048
تحلیل مؤلفه‌های اصلی	1.172×10^{-5}	7.568×10^{-6}	1.416×10^{-6}	5.175×10^{-7}	3.285×10^{-7}	1.686×10^{-7}	0.0004	0.09087
خودرمنگار	8.743×10^{-6}	1.470×10^{-6}	2.658×10^{-7}	6.522×10^{-8}	1.583×10^{-8}	4.620×10^{-9}	7.241×10^{-5}	1.513×10^{-2}

جدول (۷): خطای حاصل از شبیه سازی انتشار گرمای پایا در ابعاد 64×64 با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمنگار طی کاهش به ابعاد مختلف

بعد	16	32	64	128	256	512	1024	2048
تحلیل مؤلفه‌های اصلی	6.581×10^{-4}	5.912×10^{-4}	2.213×10^{-4}	1.617×10^{-4}	2.053×10^{-4}	2.108×10^{-4}	1.1227	4.4543
خودرمنگار	3.093×10^{-4}	1.629×10^{-4}	1.296×10^{-5}	2.528×10^{-6}	2.742×10^{-6}	4.150×10^{-6}	0.0189	2.945





شکل (۸): نتایج حاصل از شبیه‌سازی توزیع دمای پایا با استفاده از روش‌های مختلف در شرایط مرزی گوناگون در ابعاد 64×64

۵.۲. شبیه‌سازی انتقال حرارت پایا در ابعاد 128×128

جدول (۸) خطای شبکه را در مدل‌سازی شرایط مرزی مختلف مربوط به صفحه رسانای دارای توزیع دمای پایا در ابعاد 128×128 (مجموعه داده ۶) به داده‌های کاهش یافته با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمنزنگار در ابعاد مختلف از مرتبه ۶۴ تا ۸۱۹۲ نشان می‌دهد. مدل‌سازی شبکه برای تولید داده در مرتبه ۵۱۲ دارای بیشترین میزان دقت است. جدول (۹) نتایج حاصل از افزایش ابعاد داده‌های تولید شده از شبکه با استفاده از دو روش کاهش بعد را برای ابعاد 128×128 (مجموعه داده ۶) نشان می‌دهد. مدل‌سازی با داده‌های کاهش یافته به روش تحلیل مؤلفه‌های اصلی در مرتبه ۱۲۸ و با روش خودرمنزنگار در مرتبه ۲۵۶ دارای بیشترین دقت می‌باشد.


شکل (۹) نتایج حاصل از مدل‌سازی انتقال حرارت پایا را در ابعاد 128×128 با استفاده از روش‌های مختلف را نشان می‌دهد. توزیع دمایی اولیه حجم کنترل مربعی نمایش داده شده در ستون اول این شکل همانند شکل (۸) می‌باشد. نتایج بدست آمده نشان می‌دهد، خروجی‌های حاصل از دو مدل مبتنی بر روش‌های کاهش بعد در ابعاد 128×128 نیز همانند ابعاد 64×64 نسبت به مدل مبتنی بر شبکه عصبی کانولوشنی میزان مطابقت بیشتری با حالت پایای واقعی دارد. خطای میانگین مربعات خروجی برای شبیه‌سازی توزیع دمای پایا در این ابعاد با استفاده از مدل‌های مبتنی بر تحلیل مؤلفه‌های اصلی و خودرمنزنگار برابر با 4×10^{-4} و 6×10^{-6} و $253/7$ درجه سانتی‌گراد در هر پیکسل است، درحالی‌که این خطا برای مدل مبتنی بر شبکه‌های عصبی کانولوشنی برابر با $0/0058$ است.


جدول (۸): خطای شبکه در مدل‌سازی شرایط مرزی مختلف به داده‌های کاهش یافته در ابعاد مختلف با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمنگار برای داده‌های با ابعاد 128×128

بعد	64	128	256	512	1024	2048	4096	8192
تحلیل مؤلفه‌های اصلی	5.759×10^{-6}	2.619×10^{-6}	2.252×10^{-6}	1.259×10^{-6}	0.15336	0.36154	1.539	3.437
خودرمنگار	1.827×10^{-6}	4.104×10^{-7}	3.479×10^{-7}	1.519×10^{-7}	0.0637	0.184	0.852	2.028

جدول (۹): خطای حاصل از شبیه‌سازی انتشار گرمای پایا در ابعاد 128×128 با استفاده از دو روش تحلیل مؤلفه‌های اصلی و خودرمنگار طی کاهش به ابعاد مختلف

بعد	64	128	256	512	1024	2048	4096	8192
تحلیل مؤلفه‌های اصلی	2.249×10^{-4}	2.046×10^{-4}	3.519×10^{-4}	4.046×10^{-4}	0.958	4.519	8.24	15.19
خودرمنگار	9.083×10^{-5}	6.108×10^{-5}	7.253×10^{-6}	9.340×10^{-5}	0.0349	3.004	6.627	12.08





شکل (۹): نتایج حاصل از شبیه‌سازی توزیع دمای پایا با استفاده از روش‌های مختلف در شرایط مرزی گوناگون در ابعاد 128×128

۶. نتیجه‌گیری

کوچک‌تر و کاهش بعد جزئی‌تر بوده، روش تحلیل مؤلفه‌های اصلی و هرچه هرچه مجموعه داده بزرگ‌تر و کاهش بعد شدیدتر باشد روش خودرمنزنگار دقت بالاتری خواهد داشت. علاوه بر این، هرچه مجموعه داده در ابعاد بالاتری ایجاد شده باشد در فرآیند کاهش مرتبه به ویژه با استفاده از روش خودرمنزنگار میزان اطلاعات کمتری از دست خواهد رفت و در نتیجه خطای بازسازی کمتر و دقت بالاتر خواهد بود. در این تحقیق از روش‌های کاهش ابعاد در مدل‌سازی پدیده انتقال حرارت پایا استفاده شد. با این کار، علاوه بر اینکه حجم محاسبات مدل‌سازی نسبت به مدل مبتنی بر شبکه عصبی متشکل از لایه‌های کانولوشنی متعدد به مقدار قابل توجهی کاهش یافت، سرعت مدل‌سازی و دقت خروجی‌های حاصل شده از آن نیز به میزان زیادی افزایش یافت. همچنین داده‌های

در این پژوهش مدلی رتبه کاسته و بدون معادله برای مدل‌سازی توزیع دمای پایای یک صفحه دو بعدی ارائه شد. استفاده از شبکه‌های عصبی کانولوشنی برای شبیه‌سازی داده‌های با مقیاس بزرگ نیازمند بکارگیری لایه‌های کانولوشنی متعدد با تعداد فیلترهای بسیار می‌باشد که هزینه‌های زمانی و محاسباتی زیادی در پی خواهد داشت. برای حل این مشکل از دو روش کاهش بعد تحلیل مؤلفه‌های اصلی و خودرمنزنگار برای مدل‌سازی توزیع دمای دو بعدی در ابعادی نسبتاً بزرگ استفاده شد. تحلیل مؤلفه‌های اصلی روشی خطی و خودرمنزنگار روشی غیرخطی می‌باشد. نتایج حاصل از اعمال دو روش مذکور بر روی مجموعه داده‌های مختلف نشان داد هرچه یک مجموعه داده

۶۴×۶۴ و ۱۲۸×۱۲۸ برخوردار می‌باشد.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافی ندارند.

تولیدشده از این طریق میزان مطابقت بیشتری با داده‌های تولید شده از روش اختلاف محدود دارد. طبق نتایج بدست آمده، روش خودرمننگار نسبت به تحلیل مؤلفه‌های اصلی از دقت بالاتری در شبیه‌سازی پدیده توزیع دمای پایا در هر دو بعد

مراجع

- [1] Krizhevsky A., Sutskever I., and Hinton G.E., "in Advances in neural information processing systems", pp. 1097–1105, 2012.
- [2] Johnson M., Schuster M., Le Q., Krikun M., Wu Y., Chen Z., Thorat N., Viégas F., Wattenberg M., Corrado G., Hughes M., and Dean J., "Google's Multilingual Neural Machine Translation System: Enabling Zero-Shot Translation", Transactions of the Association for Computational Linguistics, 5:339-351, 2017.
- [3] Goodfellow I., Bengio Y., and Courville A., Deep learning, Cambridge, MIT Press, 2016.
- [4] Zhao, H., "Advances and Prospects in Machine Vision: a Critical Review Based on CiteSpace", Journal of the Frontiers of Society, Science and Technology, 2(16): 86-92, 2020.
- [5] Joshi K., and Patil B., Evaluation of Surface Roughness by Machine Vision Using Neural Networks Approach, Recent Advances in Mechanical Infrastructure. Lecture Notes in Intelligent Transportation and Infrastructure, Springer, Singapore, 2020.
- [6] Torfi A., Shirvani R.A., Keneshloo Y., Tavaf N., and Edward A. F., "Natural Language Processing Advancements By Deep Learning: A Survey", Journal of Computer Science, 2020.
- [7] Otter D. W., Medina J. R., and Kalita J. K., "A Survey of the Usages of Deep Learning for Natural Language Processing", IEEE Transactions on Neural Networks and Learning Systems, 32(2): 604-624, Feb 2021.
- [8] Vedantam V. K., "The Survey: Advances in Natural Language Processing using Deep Learning", Turkish Journal of Computer and Mathematics Education (TURCOMAT), 12(4), 2021.
- [9] Leskovec J., Rajaraman A., and Ullman, J., Mining of Massive Datasets, 2nd edition, Stanford University, California, Cambridge University Press, 2014.
- [10] Samet H., Foundations of Multidimensional and Metric Data Structures, Morgan Kaufmann Publishers, 2006.
- [11] Andrienko G., Andrienko N., Drucker S., Fekete J.-D., and Fisher D., "Big Data Visualization and Analytics: Future Research Challenges and Emerging Applications", 3rd International Workshop on Big Data Visual Exploration and Analytics, Copenhagen, Denmark, Mar 2020.
- [12] Brunson C. and Comber A., "Big Issues for Big Data: challenges for critical spatial data analytics", Journal of Computer Science, 2020.
- [13] Erum M. and Anees T., "Challenges and Solutions for Processing Real-Time Big Data Stream: A Systematic Literature Review", Journal of IEEE Access, 8, 2020.
- [14] Yang X.-S., Lee S., Lee, S., and Theera-Umpon, N., "Information Analysis of High-Dimensional Data and Applications", mathematical problems in engineering journal, 2015.
- [15] Guillemard M., Iske A., and Krause-Solberg S., "Dimensionality Reduction Methods in Independent Subspace Analysis for Signal Detection", Sampling Theory and Applications (SampTA'11), 2011.
- [16] Sharma R., Sircar P., and Pachori R. B., "Automated focal EEG signal detection based on third order cumulant function", Journal of Biomedical Signal Processing and Control, 58, 2020.
- [17] Fewzee P. and Karray F., "Dimensionality Reduction for Emotional Speech Recognition", International Conference on Privacy, Security, Risk and Trust and International Conference on Social Computing, pp. 532-537, Amsterdam, 2012.
- [18] Kumar K.A. and Mazher Iqbal J. L., "Handling high dimensional features by ensemble learning for emotion identification from speech signal", International Journal of Speech Technology, 2021.
- [19] Smietanka L. and Maka T., "Audio Feature Space Analysis for Emotion Recognition from Spoken Sentences", Journal of Archives of Acoustics, 46(2): 271-277, 2021.
- [20] Fernandes Sinead V. and Ullah M. S., "Use of Machine Learning for Deception Detection From Spectral and Cepstral Features of Speech Signals", Journal of IEEE Access, 9: 78925-78935, 2021.
- [21] Ratnovsky A., Malayev S., Ratnovsky S., Naftali S.,

- and Rabin N., "EMG-based speech recognition using dimensionality reduction methods", *Journal of Ambient Intelligence and Humanized Computing*, 2021.
- [22] Agrawal A. and Jain A., "Emotion Recognition of Speech in Hindi Using Dimensionality Reduction and Machine Learning Techniques", *International Conference on Information and Communication Technology and Applications*, pp. 119-129, 2020.
- [23] Mwangi B., Tian S., and Soares J. C., "A review of feature reduction techniques in neuroimaging". *Neuroinformatics* 12, pp 229–244. 2014.
- [24] Fang C., Li, C., Forouzaneshad P., Cabrerizo M. E., Curiel R., Loewenstein D., Duara R., and Adjouadi M., "Gaussian discriminative component analysis for early detection of Alzheimer's disease: A supervised dimensionality reduction algorithm", *Journal of Neuroscience Methods*, 344, 2020.
- [25] Yew A. Y. L. and Rahim M. S. M., "Dimensionality Reduction Methods for Alzheimer's Disease Classification", *Journal of Computing and Digital Systems*, 2021.
- [26] Shinde K. and Thakare A., "Significance of Dimensionality Reduction Techniques for Fetal Brain MRI Analysis", *Proceedings of the 3rd International Conference on Communication*, 2021.
- [27] Messina D., Borrelli P., Russo P., Salvatore M., and Aiello M., "Voxel-wise feature selection method for CNN binary classification of neuroimaging data", *Journal of Frontiers in Neuroscience*, 15, 2021.
- [28] Calesella F., Testolin A., De Grazia M., and Zorzi M., "A comparison of feature extraction methods for prediction of neuropsychological scores from functional connectivity data of stroke patients", *Journal of Brain Informatics*, 8, 2021.
- [29] Miah A. S. M., Rashid M., Rahman R., Hossain T., Sujon S., Nawal N., Hasan M., and Shin J., "Alzheimer's Disease Detection Using CNN Based on Effective Dimensionality Reduction Approach", *International Conference on Intelligent Computing and Optimization*, pp. 801-811, 2021.
- [30] Filipovic V., "Optimization, classification and dimensionality reduction in biomedicine and bioinformatics", *Biologia Serbica* 39(1): 83 – 98, 2017.
- [31] Van Der Maaten L., Postma E., and Van Den Herik J., "Dimensionality Reduction: A Comparative Review", *J Mach Learn Res.* 10:66–71, 2009.
- [32] Rico-Sulayes A., "Reducing Vector Space Dimensionality in Automatic Classification for Authorship Attribution", *Revista Ingeniería Electrónica, Automática y Comunicaciones.* 38(3):26–35, 2017.
- [۳۳] مویدی م.ک.، صباغ زادگان ف.، «توسعه مدل رتبه کاسته برای معادله نفوذ جابجایی بر مبنای روش تجزیه متعامد بهینه»، هجدهمین کنفرانس دینامیک شماره‌ها، مشهد، ۱۳۹۸.
- [34] Pudil P. and Novovičová J., "Novel Methods for Feature Subset Selection with Respect to Problem Knowledge", In Liu, Huan; Motoda, Hiroshi (eds.), *Feature Extraction, Construction and Selection*, pp. 101, 1998.
- [35] Bolón-Canedo V., Sánchez-Marño N., and Alonso-Betanzos A., "Feature Selection for High-Dimensional Data", pp. 65, Springer, 2015.
- [۳۶] نجفی ا.، «فشرده سازی دیتا بیس چهره با تجزیه مؤلفه‌های اصلی غیرخطی با کمک تقسیم بندی»، پایان نامه کارشناسی ارشد مهندسی برق، دانشکده مهندسی برق و کامپیوتر دانشگاه شهید بهشتی، تهران، ص ۱۲، ۱۳۹۴.
- [37] Jolliffe I. T., *Principal Component Analysis*, Series: Springer Series in Statistics, 2nd ed., pp.28, Springer, 2002.
- [۳۸] همایون پور م.م.، شجاع مودب ح.، «ارزیابی و مقایسه چهار روش کاهش بعد ویژگیها برای سیستم تشخیص نفوذ مبتنی بر ماشین بردار»، چهارمین کنفرانس انجمن رمز ایران، ۱۳۸۶.
- [39] Kramer M. A., "Nonlinear principal component analysis using autoassociative neural networks". *AIChE Journal*, 37 (2):233–243, 1991.
- [40] Wang J., He H., and Prokhorov D. V., "A Folded Neural Network Autoencoder for Dimensionality Reduction", In *proceeding of the International Neural Network Society Winter Conference (INNS-WC 2012)* , pp.120 – 127, *procedia computer science* 13, 2012.
- [41] Nugroho H., Susanty M., Irawan A., Koyimatu M., and Yunita A., "Fully convolutional variational autoencoder to features extraction of the fire detection system", *Journal of Computer Science and Information*, 13/1, pp.9-15, 2020.
- [42] Jolliffe I. T. and Cadima J., "Principal component analysis: a review and recent developments", *Phil. Trans. R. Soc. A*, 374(2065), 2016.