

علمی-پژوهشی

بازسازی میدان سرعت سیال اندازه‌گیری شده توسط اس.پی.آی.وی با استفاده از شبکه‌های عصبی مصنوعی

^۳^{ID}^۲محسن رستمی^{ID}^{ID}امیر حمزه فرج‌الهی^{ID}دانشگاه امام علی^(۴)، تهران، ایران

(دربافت: ۱۴۰۱/۰۲/۳۰، بازنگری: ۱۴۰۱/۰۳/۲۰، پذیرش: ۱۴۰۱/۰۴/۱۸، انتشار: ۱۴۰۱/۰۶/۰۱)

DOI: <https://dorl.net/dor/20.1001.1.23223278.1401.11.1.4.6>**چکیده**

یکی از ابزارهای مهم و اصلی مطالعه جریان و معیار ارزیابی دیگر روش‌ها مانند روش‌های عددی، داده‌های آزمایشگاهی مکانیک سیالات است. بنابراین، کیفیت مطلوب داده‌هایی که در آزمایشگاه اندازه‌گیری می‌شوند، مهم می‌باشد. میدان سرعت سیال، یکی از اطلاعات مهم هر جریانی است که با ابزارهای مختلفی اندازه‌گیری می‌شوند. یکی از آن ابزارها، ابزار اس.پی.آی.وی است. این ابزار، اطلاعات صفحه‌ای را از مولفه‌های سرعت جریان در اختیار قرار می‌دهد. عموماً، داده‌های استخراج شده از این ابزار، در برخی از نقاط میدان سرعت، به دلایل مختلف و شرایط آزمایشگاهی، دارای خطای زیادی خواهند شد و مقادیر بدست آمده در این نقاط، حذف می‌گردند که اصطلاحاً به آن‌ها، نقاط نقص گویند. بنابراین، برای بازسازی میدان سرعت در نقاط نقص، روش‌هایی موردنیاز است که در این راستا، در پژوهش حاضر، از شبکه‌های عصبی مصنوعی، همانند ام.ال.پی و سی.إن.إن استفاده شده است. بهینه‌سازی تعداد نمونه‌های شبکه ام.ال.پی، توسط میانگین خطای داده‌های تست و تطبیق تصاویر، انجام شده است. خطای نهایی برای هر یک از روش‌ها بدست آمده است که با توجه به خطاهای و تطبیق میدان سرعت بازسازی شده با داده‌های آزمایشگاهی، این نتیجه حاصل شد که برای هر دو مولفه سرعت، شبکه عصبی سی.إن.إن بهترین عملکرد را داشته است.

واژه‌های کلیدی: بازسازی؛ نقاط نقص، میدان سرعت، ام.ال.پی، سی.إن.إن، اس.پی.آی.وی

Reconstruction of the Fluid Velocity Field Measured by SPIV via Artificial Neural Networks

^{ID} Farajollahi, A. H.^{ID} Rostami, M.^{ID} Naderi, A.A

Imam Ali University, Tehran, Iran

(Received:2022/05/20, Revised: 2022/06/20, Accepted: 2022/07/09, Published: 2022/08/23)

ABSTRACT ABSTRACT

The experimental data of fluid mechanics is one of the main important tools for flow study and also an evaluation criterion of some methods such as the numerical methods. Thus, it is important that the quality of the data, measured in the laboratory be acceptable. One of the important properties of any flow is the fluid velocity field that is measured by different instruments. One of those tools is the SPIV tool. This tool provides sheet information from the flow velocity components. Generally, the data extracted from this tool would have big errors in some points of the velocity field, for various reasons and laboratory conditions, and the values obtained in these points known as gappy points, are eliminated. Therefore, some methods are needed to reconstruct the velocity field at these gaps. For this purpose, in the present study we have used artificial neural networks, such as MLP and CNN. The optimization of the number of neurons in the MLP network has been performed by the mean error of the test data and the matching of the images. The final error has been obtained for each of the methods, and considering the errors and taking into account the accommodation between the reconstructed velocity field and the experimental data, the results indicate that for both velocity components, the CNN neural network has had the best performance.

Keywords: Reconstructing, Gappy Points, Velocity Field, MLP, CNN, SPIV

۱- استادیار (نویسنده پاسخگو) : a.farajollahi@sharif.edu

۲- استادیار: cpt.rostami@gmail.com

۳- استادیار: aa.naderi1@yahoo.com

This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license.

Publisher: Imam Hussein University

Authors



۱- مقدمه

کیفیت بازسازی می‌تواند در نتایج تحلیل‌های بعدی میدان جریان تأثیرگذار باشد. در نتیجه انتخاب بهترین روش بازسازی متناسب با داده‌های موجود، بسیار اهمیت دارد.

روشی که در بازسازی نقاط نقص داده‌های پی.آی.وی^۵ بسیار مورد استفاده واقع می‌شود، روش جی.پی.آ.دی^۶ می‌باشد. این روش فرمی از روش تفکیک پی.آ.دی^۷ می‌باشد که در آن تفکیک مودهای جریان سیال بر مبنای سهم انرژی هر مود از انرژی کل صورت می‌گیرد. روش جی.پی.آ.دی که یکی از بهترین روش‌های بازسازی نقاط نقص داده‌های پی.آی.وی می‌باشد، در تحقیقات متعددی به منظور بازسازی داده‌های پی.آی.وی به کار رفته است [۱ و ۵-۲].

گونس و همکاران [۶] در تحقیقی به منظور مقایسه روش‌های کریگینگ و جی.پی.آ.دی عنوان کردند که برای میدان‌های جریان ناپایا، زمانی که تعداد اطلاعات زمانی زیاد باشد، روش جی.پی.آ.دی مناسب‌تر خواهد بود. در مقابل زمانی که اطلاعات زمانی کم و نقاط های میدان بزرگ‌تر و به صورت دسته‌ای باشند، روش کریگینگ عملکرد بهتری دارد.

در سال ۲۰۰۶ نیز ویلکاکس [۵] به مطالعه و پیش‌بینی سازی بازسازی نقاط نامعلوم میدان داده‌ها با استفاده از جی.پی.آ.دی پرداخت. وی در مطالعه خود به بررسی نحوه قرارگیری سنسورهای اندازه‌گیری برای رسیدن به بهترین پیش‌بینی پرداخته است. محققان دیگری با اعمال اغتشاشات به میدان داده‌ها تأثیر آن‌ها را بر روی مودها بررسی نمودند. به طوری که در سال ۲۰۰۶ ونتوری توانست رابطه‌ای میان واریانس اغتشاشات و مودها برای جریان پشت سیلندر معرفی نماید.

در سال ۲۰۰۷ میر [۷]، به منظور شناسایی و رتکس‌های جت‌ها از پی.آ.دی استفاده کرد. وی در روش کاهش ابعادی پی.آ.دی را بر روی داده‌های پی.آی.وی مربوط به یک جت عمود بر جریان انجام داد و توانست ورتكس‌های جریان را آشکار کند. وی همچنین نشان داد که در رینولدزهای پایین، ورتكس‌های ناشی از لایه برشی غالب هستند و در

در مکانیک سیالات، جریان‌های مختلفی وجود دارد، اما جریان توربولانسی و توربولانس در سیالات به دلیل تأثیر آن بر طیف گسترده‌ای از کاربردها، یک موضوع تحقیقاتی فعال بوده است؛ بنابراین، برای مطالعه بهتر جریان‌های موجود، مخصوصاً جریان توربولانسی نیاز به استفاده از مقادیر اندازه‌گیری شده پارامترهای جریان می‌باشد. ابزارهای متفاوتی برای اندازه‌گیری پارامترهای جریان مانند سرعت وجود دارد که معمولاً این ابزارها به دو دسته مزاحم^۱ و غیرمزاحم^۲ تقسیم می‌شوند. ابزارهای مزاحم مانند پیوت تیوب^۳ به شکل مستقیم با میدان جریان سیال در تماس هستند که آن‌ها را همراه جریان نیز می‌نامند. اما ابزارهای غیرمزاحم بیننده رفتار سیال هستند. ابزار اس.پی.آ.ی.وی^۴ یک نمونه از این ابزارها است، به دلیل اینکه تنها بیننده جریان سیال بوده و هیچ‌گونه اثری بر روی جریان سیال ندارد و بدین ترتیب دقت اندازه‌گیری را افزایش می‌دهد. در این ابزار، از ذراتی با مشخصات خاص، به منظور اندازه‌گیری سرعت جریان سیال استفاده می‌شود. به طوری که در اندازه‌گیری توسط این ابزار، سرعت سیال اندازه گرفته نمی‌شود، بلکه سرعت ذره سوار بر جریان اندازه‌گیری خواهد شد. پس این ذرات باید خواص مناسبی داشته باشند تا به خوبی بر جریان سیال سوار شوند.

داده‌های سرعتی که توسط اس.پی.آ.ی.وی به دلیل محدودیت‌های آزمایشگاهی، مانند ناهمگن بودن ذرات، بازنتاب نور، گردوخاک و... دارای نقص خواهند بود. به طوری که در بعضی از نقاط صفحه اندازه‌گیری به دلایلی که ذکر شد، بردارهای غلطی برای سرعت استخراج شده که با استفاده از معیارهایی این بردارهای غلط شناسایی و حذف می‌گردد. به چنین نقاطی، نقاط نقص می‌گویند. با این وجود، برای انجام تحلیل با استفاده از داده‌های سرعت استخراج شده از ابزار اس.پی.آ.ی.وی، باید روشی برای بازسازی نقاط نقص موجود انتخاب شود.

همان‌طور که اشاره شد، بازسازی نقاط نقص میدان سرعت از اهمیت بالایی برخوردار است. به دلیل این که

¹ Intrusive

² Non-Intrusive

³ Pitot Tube

⁴ SPIV (Stereoscopic Particle Image velocimetry)

⁵ PIV (Particle Image Velocimetry)

⁶ GPOD (Gappy Proper Orthogonal Decomposition)

⁷ POD (Proper Orthogonal Decomposition)

برای انجام تجزیه و تحلیل با وضوح فوق العاده از داده‌های میدان جریان آشفته برای بازسازی میدان جریان با وضوح بالا استفاده کردند. آن‌ها این دو مدل را بر روی استوانه دو بعدی به عنوان آزمایش مقدماتی اعمال کرد و توансند توانایی قابل توجهی را برای بازسازی جریان آرام از داده‌های میدان جریان با وضوح پایین نشان دهند. آن‌ها بیشتر عملکرد این مدل‌ها را برای توربولانس همگن دو بعدی ارزیابی نموده و دریافتند که مدل‌های سی.إن.إن و دی.اس.سی.إم.اس جریان‌های آشفته با تصاویر میدان جریان بسیار درشت را با دقت قابل توجه بازسازی می‌کنند. برای مسئله جریان آشفته، مدل با وضوح زیاد، می‌تواند با آموزش ۵۰ داده عکس فوری^۱، با داشتن پتانسیل زیادی برای نشان دادن فیزیک جریان آشفته پیچیده در مقیاس زیر شبکه، وضوح مکانی را بسیار افزایش دهد؛ همچنین با در دست داشتن تعداد داده‌های بیشتر از آزمایش‌هایی با اطمینان بالا، می‌توان به جواب‌های بهتری دست پیدا کرد.

در سال ۲۰۱۸ آرویند موهان و داتا گالیتوندۀ [۱۰]، بر روی یک روش مبتنی بر یادگیری عمیق برای ساختن آر.ا.ام با استفاده از اساس پی.ا.دی مجموعه داده‌های دی.ان.اس متعارف، برای کاربردهای کنترل جریان آشفته کار کرده‌اند؛ در واقع هدف اصلی آر.ا.ام مدل‌سازی فیزیک یا ویژگی‌های مهم یک میدان جریان بدون محاسبه کامل معادلات ناویر-استوکس است. آن‌ها دریافتند که نوعی شبکه عصبی‌هایی مثل ال.اس.تی.ام که در ابتدا برای مسائلی مانند مدل‌سازی گفتار و ترجمه زبان مورد استفاده قرار گرفته بوده است، پتانسیل بالایی را در مدل‌سازی دینامیک زمانی توربولانس نشان می‌دهد.

در سال ۲۰۱۹ شنگزی کای و همکاران [۱۱]، تکنیک-های مبتنی بر یادگیری عمیق را برای مسئله برآورد حرکت سیال بررسی کرد. هدف از این روش جدید استخراج درست و دقیق میدان‌های دو بعدی سرعت از تصاویر سیال است. آن‌ها ابتدا سی.ان.رن را با نام LiteFlowNet معرفی کردند که برای تخمین جریان بصری پایان به پایان -همه مواردی که برای اتصال همه قسمت‌های شبکه رایانه‌ای ضروری

رینولدزهای بالا و رتکس‌های ناشی از دنباله ساختار غالب هستند.

شبکه عصبی مصنوعی، یک روش یادگیری ماشین است که از ایده شبیه‌سازی مغز انسان حاصل شده است. در مقایسه با رویکرد سنتی رگرسیون، شبکه عصبی مصنوعی قادر به مدل‌سازی روابط پیچیده غیرخطی است و همچنین از تحمل خطای بسیار خوبی برخوردار است و با پردازش موازی سریع و بسیار مقیاس‌پذیر است. شبکه‌های عصبی مصنوعی رفته‌رفته پیشرفت‌های خوبی در پردازش و یادگیری عمیق رسیدند که موقوفیت‌های خوبی در پردازش و یادگیری داده‌ها از خود نشان داد. موفقیت اخیر شبکه عصبی عمیق توسط دو مؤلفه مهم امکان‌پذیر است: ۱) رشد مداوم قدرت محاسباتی ۲) مجموعه داده‌های فوق العاده بزرگی که از قدرت معماری چندلایه (عمیق) بهره‌مند می‌شوند. همه این بحث‌ها باعث می‌شود تا نظر محققان به سمت استفاده از قدرت محاسبه و یادگیری این مدل شبکه‌ها جلب شود. انواع مختلفی از شبکه‌های عصبی موجود است که بتوان از آن‌ها در بازسازی نقاط نقص میدان سرعت بهره برد.

در سال ۲۰۱۴ سعد احمد و همکاران [۸]، تحقیقی درباره پیش‌بینی خصوصیات دقیق جریان یک میدان هم‌دما و چرخشی در یک احتراق انسپاٹ ناگهانی متقارن انجام داده‌اند. در این راستا، آن‌ها از شبکه عصبی‌هایی مثل جی.اف.اف^۲، آر.بی.اف^۳ و سی.إن.اف.آی.إس^۴ برای بالا بردن دقت نتایج آزمایشی به دست آمده از إل.دی.وی^۵ استفاده کردند که با مقایسه نتایج بازسازی پروفیل سرعت توربولانسی محوری و مماسی با داده‌های تجربی‌شان، توانایی طراحی بهتر احتراق را ترغیب کردند. در نهایت، به شکل خاص، شبکه جی.اف.اف بهترین پیش‌بینی را با بالاترین دقت ارائه کرد.

کای فوکامی و همکاران [۹] در سال ۲۰۱۹، از دو مدل یادگیری ماشینی؛ یعنی سی.ان.إن و دی.اس.سی.إم.اس^۶

¹Generalized Feed Forward

²Radial Basis Function

³Coactive neuro-fuzzy inference system

⁴Laser Doppler Velocimetry

⁵Down-sampled skip-connection/multi-scale

شده‌اند. سپس عملکرد این روش‌ها با استفاده از میدان سرعت بازسازی آن‌ها و خطای نهایی‌شان با هم مقایسه شده‌اند.

۲- معرفی دستگاه‌ها و داده‌های آزمایشگاهی

در این بخش به توضیح اجزای مورداستفاده در آزمایش و معرفی داده‌ها پرداخته می‌شود. جنس پره‌های روتور از ورق گالوانیزه به ضخامت یک میلی‌متر است. جهت کاهش اثرات سوء ناشی از انعکاس نور لیزر در آزمایش‌های پی‌آی‌وی، سطح روتور توسط پاشش رنگ سیاه مات شده است. فاصله بهینه میان روتور و دهانه ورودی (C) است. بر اساس مطالعه میرزایی [۱۳]، دبی و بازده ماکزیمم در شرایطی ایجاد می‌شود که پارامتر بی‌بعد شده $\frac{c}{2(D_2-D_1)}$ مقداری در حدود ۰/۵۵ داشته باشد و فاصله بهینه میان روتور و دهانه ورودی در حدود ۱۸ میلی‌متر به دست آمده است. برای چرخاندن روتور فن گریز از مرکز از یک الکتروموتور سه فاز با توان نامی ۲ کیلووات استفاده می‌شود. سرعت زاویه‌ای نامی موتور در حالت بی‌باری در حدود ۷۵۰ دور بر دقیقه است. اتصال میان محورهای الکتروموتور و روتور به صورت مستقیم و از طریق یک کوپلینگ ۸ پره صورت گرفته است. از دو یاتاقان جهت مهار محور استفاده شده است.

در مطالعه حاضر، بهمنظور انعطاف‌پذیری مناسب برای شکل‌گیری، از ورق آلومینیومی با ضخامت کم استفاده گردید و بهمنظور امکان بررسی میدان جریان داخل حلزونی با استفاده از سیستم اندازه‌گیری نوری، دیواره‌های جانبی و دیواره بالایی با پلکسی گلاس جایگزین شده‌اند. حلزونی با معلوم بودن موقعیت زبانه (Y)، شعاع پایه (r₀)، پروفیل حلزونی (Sθ) پهنا (B)، اندازه گلوگاه (S) معلوم می‌شود. پارامترهای دیگری از قبیل شعاع انحنای در محل زبانه (r₀) و ارتفاع دهانه خروجی (H) را نیز می‌توان روی حلزونی تعریف کرد. مشخصه‌های هندسی فن بر اساس مطالعات راث در جدول ۱ آورده شده است. فن مورداستفاده در این آزمایش طبق این مشخصات ساخته شده است.

است- پیشنهاد شده است. تنظیمات پیشرفته LiteFlowNet برای تخمین پی‌آی‌وی بهمنظور تصحیح ساختارهای گرداب در مقیاس کوچک به کار گرفته شده است. علاوه بر این، همان‌طور که استراتژی یادگیری نظارت شده در نظر گرفته می‌شود، یک مجموعه داده شامل تصاویر ذرات و حرکات سیال دقیق برای آموزش پارامترهای شبکه ایجاد می‌شود. نتایج تجربی نشان می‌دهد تخمین‌گر پیشنهادی، می‌تواند دقت نزدیک به روش‌های پیشرفته و کارایی بالا، در برآورد زمان واقعی را فراهم کند.

در سال ۲۰۲۰ پژوهشی درباره عملکرد شبکه عصبی سی‌ان‌ان بر روی تصویرهای سونوگرافی توسط اوان اوین و همکارانش [۱۲] صورت گرفته است. تا به امروز، بیشتر تحقیقات بر تقسیم‌بندی و تشخیص دید متتمرکز بوده است، اما آن‌ها الگوریتم‌های مختلف سی‌ان‌ان را برای تخمین حرکت در تصویربرداری اولتراسوند محقق زندند. چندین شبکه مشتق شده از FlowNet2 (یکی از کارآمدترین معماری‌ها در بینایی رایانه) را ارزیابی و مقایسه شدند. این شبکه‌ها با و بدون انتقال یادگیری مورد آزمایش قرار گرفتند و بهترین پیکربندی با روش سرعت سنجی ذرات، الگوریتم مشهور و فوق پیشرفته تطبیق-بلوک مقایسه شد. آن‌ها نشان دادند که این خطاهای برای یک دامنه سرعت زیاد بدون نیاز به تنظیم بیش‌از‌حد پارامترها، که نشان‌دهنده پتانسیل بالا و سازگاری راه حل‌های یادگیری عمیق با تخمین حرکت در تصویربرداری اولتراسوند است، کوچک باقی می‌مانند.

با توجه به موارد ذکرشده در بالا، در مطالعه حاضر، از داده‌های میدان سرعت استخراج شده از ابزار اس‌پی‌آی‌وی استفاده شده است. این داده‌ها معمولاً به دلیل مشکلاتی که در اندازه‌گیری آن‌ها وجود دارد، در بعضی نقاط دارای نقص هستند؛ بنابراین، قبل از هرگونه تحلیلی بر روی این داده‌ها، بازسازی مقادیر سرعت در نقاط نقص و تکمیل داده‌ها در ارجحیت خواهد بود. بهمنظور بازسازی میدان سرعت در نقاط نقص روش‌های گوناگونی وجود دارد. در تحقیق حاضر، از روش‌های جی‌پی‌ا.دی و شبکه‌های عصبی مصنوعی استفاده شده و نقاط نقص با استفاده از این روش‌ها بازسازی

که با تبخیر ذرات سیال استاندارد SAFEX، ذراتی به قطر در حدود یک میکرون تولید کند.

- انکدر: پردازشگر مرکزی اس.پی.آی.وی نیاز به سیگنالی برای هماهنگ‌سازی موارد مختلف آزمایش در موقعیت مشخص روتور دارد که این سیگنال توسط انکدر نوری تولید می‌شود.

- دوربین‌ها: از دو دوربین FlowSense دارای سی.سی.دی.^۱ با قابلیت عکس‌برداری دو فریمی جهت اخذ عکس‌های نواحی دید استفاده شده است. رزولوشن دوربین‌های مورداستفاده 1600×1600 می‌باشد. دوربین‌ها توسط لنزهای AF Micro Nikkor با فاصله کانونی 60 میلی‌متر تجهیز شده‌اند.

- تولیدکننده لیزر: یک تولیدکننده دو محفظه‌ای Quantel Brilliant پالس‌های لیزر موردنیاز را تولید می‌کند که طول موج لیزر تولیدی 532 نانومتر، انرژی ساطع شده در هر پالس در حدود 150 میلی‌ژول و محدوده فرکانسی پالس‌های لیزر $10^{-4} - 10$ هرتز می‌باشد.

- راهنمای نور لیزر به ناحیه آزمایش: نیاز است که پرتو تولیدی توسط تولیدکننده به منطقه آزمایش منتقل گردد. برای این منظور از بازوهای راهنمایی که در آن‌ها آینه‌هایی برای انتقال پرتو لیزر با حداقل پخش‌شدنی نور قرار دارد، استفاده شده است. در انتهای باید پرتو تولیدشده به صفحه تبدیل گردد تا کل ناحیه موردنظر را روشن کند، برای این منظور در انتهای بازوها یک تبدیل کننده پرتو لیزر با مقطع دایروی به صفحه نوری قرار دارد. روی این تبدیل کننده پیچه‌هایی قرار دارد که با استفاده از آن‌ها می‌توان ضخامت صفحه لیزر را تنظیم کرد.

- پردازشگر موازی: سیستم بی.آی.وی یک پردازشگر مرکزی دارد PIV (Dantec FlowMap®) دارد که وظیفه ایجاد هماهنگی میان پالس‌های لیزر، عکس‌برداری دوربین‌ها و سیگنال دریافت شده از انکدر به همراه انتقال و ذخیره عکس‌های گرفته شده توسط دوربین‌ها را به عهده دارد.

جدول (۱). پارامترهای هندسی فن مورداستفاده در تحقیق حاضر

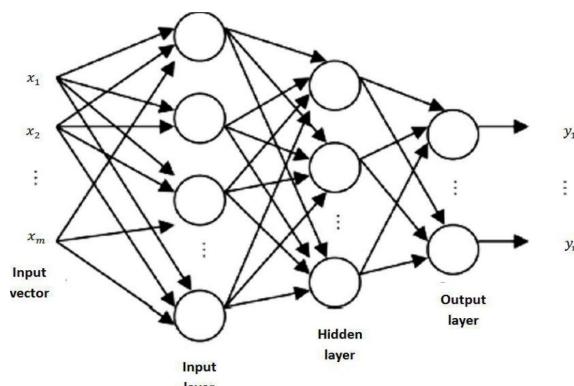
ناحیه/شرایط	پارامتر (علامت) مقدار	پارامتر (علامت) مقدار
روتور	قطر خارجی (D_2) ۳۵۰ mm	قطر داخلی (D_1) ۲۸۵ mm
	عرض (b) ۱۶۵ mm	تعداد پره‌ها (N) ۴۳
	زاویه ورودی پره (β_2) ۱۵۵ درجه	زاویه ورودی پره (β_1) ۹۰ درجه
دهانه	قطر خارجی (d_2) ۳۰۵ mm	قطر داخلی (d_1) ۲۹۵ mm
	فاصله دهانه ورودی از روتور (c) ۱۸ mm	شعاع انحنا (r ₁) ۱۵ mm
ورودی	ارتفاع خروجی (h) ۲۰۰ mm	عرض (B) ۲۰۰ mm
	زاویه گسترش (α) ۶۰ درجه	زاویه گسترش (γ) ۵ درجه
حلزونی	شعاع انحنا گلویی از گلویی (S_2) ۳۵ mm	شعاع انحنا گلویی (r_2) ۱۵/۵ mm
	قطر کanal ۲۴۰ mm	طول کanal ۲/۵۷ m
کanal		طول همسو کننده ۴۸۰ mm
		خروجی

در این مطالعه دو مؤلفه سرعت با استفاده از دستگاه اس.پی.آی.وی به دست آمده است که اجزای آن به صورت زیر می‌باشد:

- تولیدکننده ذرات: برای تولید ذرات دنبال کننده سیال از تولیدکننده SAFEX مدل F2010Pulse استفاده شده است

^۱CCD

را به یکدیگر وصل می‌کنند معادل سینپاشهایی^۲ هستند که رابط بین نرون‌های مغز انسان هستند [۱۵-۱۶]. این شبکه‌ها دارای انواع مختلفی هستند که در این مطالعه از یک مدل آن‌ها که شبکه ام‌ال‌پی نام دارد استفاده می‌شود. این شبکه یک لایه ورودی، یک لایه خروجی و چند لایه پنهان دارد. در اکثر موقع استفاده از یک لایه پنهان کافی است و افزون تعداد بیشتر لایه پنهان تنها باعث پیچیدگی می‌شود. در شکل ۳ شماتیک یک شبکه ام‌ال‌پی با یک لایه پنهان نشان داده است.



شکل (۳). شماتیک شبکه ام‌ال‌پی

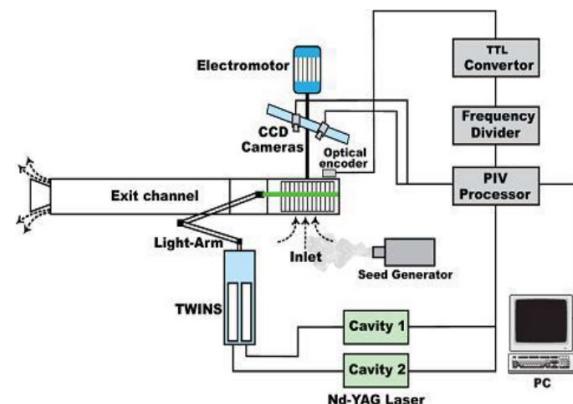
نرون‌ها در لایه ورودی، تنها یک کپی از ورودی‌ها را به لایه بعد می‌فرستند، ولی نرون‌های لایه پنهان و لایه خروجی، واحدهای محاسباتی هستند. همچنین لایه ورودی و لایه پنهان ممکن است دارای یک آستانه با مقدار ثابت (۱ یا -۱) باشند. رابطه‌ای بین نرون‌ها دارای وزن می‌باشند، مجموع وزن دار خروجی‌های لایه قبلی به همه نرون‌های لایه بعد وارد می‌شود و پس از عمل کردن تابع فعال‌سازی^۳ بر مجموع وزن دار، خروجی نرون تولید می‌شود. در رابطه ۱ محاسبات درون نرون‌ها نشان داده شده است.

$$y = f \left(\sum_{i=1}^n w_i x_i - \theta \right) \quad (1)$$

به طوری که y خروجی نرون، x_i ورودی سیگنال‌ها، w_i وزن‌های قابل تنظیم، θ آستانه و f تابع فعال‌سازی است.

تابع زیادی برای استفاده به عنوان تابع فعال‌سازی وجود دارند. در این مطالعه، تابع فعال‌سازی لایه خروجی،

در شکل‌های ۱ و ۲ به ترتیب حالت شماتیک و دستگاه‌های واقعی سیستم اندازه‌گیری اس‌پی‌آی‌وی نشان داده شده است.



شکل (۱). شماتیک سیستم اندازه‌گیری اس‌پی‌آی‌وی [۱۳]



شکل (۲). سیستم اندازه‌گیری اس‌پی‌آی‌وی به همراه متعلقات آن [۱۴]

داده‌های اندازه‌گیری شده نیز، شامل ۲۴۰۰ عکس جریان 64×64 پیکسلی در یک ناحیه دید می‌باشد که هر عکس یک شبکه نقاط با ابعاد $5,744 \times 4,264$ سانتی‌متر می‌باشد و حاوی بردارهای سرعت است. فاصله زمانی بین هر دو عکس ۵ میکرومتری می‌باشد.

۳- ابزارهای مورد استفاده

۱-۱- شبکه ام‌ال‌پی^۱

شبکه‌های عصبی مصنوعی شامل مجموعه‌ای از نرون‌های است که با یکدیگر ارتباط دارند. ایده اولیه این شبکه‌ها از نرون‌های مغز انسان گرفته شده است. رابطه‌ایی که نرون‌ها

² Synapse

³ Activation Function

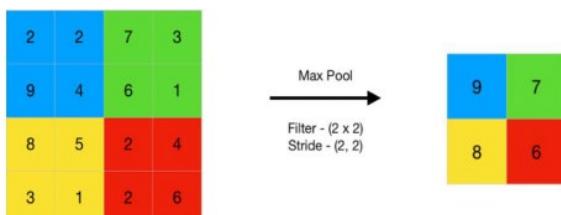
¹ MLP

غیرخطی، هسته، کانولوشن، گام، لایه گذاری، فلتینگ و لایه کاملاً متصل، است.

عملیات پولینگ شامل حرکت یک فیلتر دوبعدی روی هر کanal از نقشه ویژگی و خلاصه کردن ویژگی‌های نهفته در منطقه تحت پوشش فیلتر است. برای یک نقشه ویژگی دارای ابعاد $n_c \times n_w \times n_h$ ابعاد خروجی حاصل از یک لایه پولینگ برابر است با:

$$\frac{n_h - f + 1}{s} \times \frac{n_w - f + 1}{s} \times n_c \quad (3)$$

که n_h و n_w و n_c ابعاد نقشه ویژگی، f به ترتیب ارتفاع نقشه ویژگی، عرض نقشه ویژگی، تعداد کanال‌ها در نقشه ویژگی، اندازه فیلتر و طول گام هستند. از لایه‌های پولینگ برای کاهش ابعاد نقشه‌های ویژگی استفاده می‌شود؛ بنابراین، تعداد پارامترهای یادگیری و میزان محاسبه انجام شده در شبکه را کاهش می‌دهد (شکل ۴). لایه پولینگ ویژگی‌های موجود در یک منطقه از نقشه ویژگی تولیدشده توسط یک لایه کانولوشن را خلاصه می‌کند؛ بنابراین، عملیات بیشتری بر روی ویژگی‌های خلاصه شده به جای ویژگی‌های دقیق قرار گرفته توسط لایه کانولوشن انجام می‌شود. این باعث می‌شود مدل نسبت به تغییرات موقعیت ویژگی‌های موجود در تصویر ورودی مقاومت بیشتری داشته باشد.



شکل (۴). شماتیک عملیات مکس پولینگ

فعال سازی هر نرون با استفاده از یک تابع غیرخطی به مجموع وزن ورودی‌های آن و یک ترم بایاس اضافی، محاسبه می‌شود. این همان چیزی است که به شبکه عصبی امکان تقریب تقریباً هر تابعی را می‌دهد. در طی فرآیندهای کانولوشن و پولینگ، برخی از پیکسل‌های ماتریس دارای

تابع همانی و تابع فعال سازی برای نرون‌های لایه پنهان، یک نوع تابع تانژانت-سیگموید است که در رابطه ۲ نشان داده شده است.

$$f(x) = \frac{2}{1+e^{-x}} - 1 \quad (2)$$

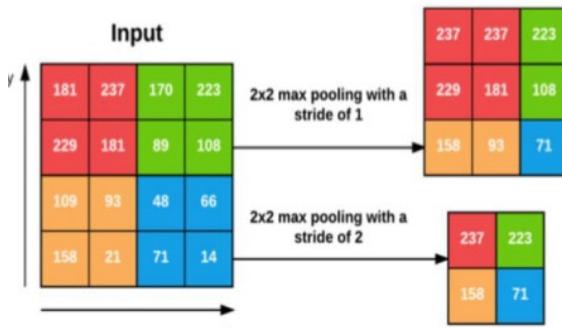
الگوریتم یادگیری شبکه ام.ال.بی، الگوریتم پسانشتر است. این روش از کاهش گرادیانی برای کاهش خطای بین خروجی شبکه و مقدار هدف استفاده می‌کند.

۲-۳- شبکه سی.إن.إن.^۱

سی.إن.إن یک ساختار ریاضی است که به‌طور معمول از سه نوع لایه‌ی کانولوشن، پولینگ و لایه‌های کاملاً متصل، تشکیل شده است. دو لایه اول، استخراج ویژگی را انجام می‌دهند، در حالی که لایه سوم، ویژگی‌های استخراج شده را در خروجی نهایی، مانند طبقه‌بندی، ترسیم می‌کند. لایه کانولوشن نقشی اساسی در سی.إن.إن ایفا می‌کند، که از مجموعه‌ای از عملیات ریاضی تشکیل شده است. در تصاویر دیجیتال، مقادیر پیکسل در یک شبکه دوبعدی ذخیره می‌شود، به عنوان مثال، یک آرایه از اعداد، و یک شبکه کوچک از پارامترها به نام هسته، یک استخراج‌کننده ویژگی بهینه، در هر موقعیت تصویر اعمال می‌شود، که سی.إن.إن را برای پردازش تصویر بسیار کارآمد می‌کند، زیرا ممکن است یک ویژگی در هر جای تصویر وجود داشته باشد [۱۷-۱۹]. همان‌طور که یک لایه، خروجی خود را به لایه بعدی متصل می‌کند، ویژگی‌های استخراج شده می‌توانند به صورت سلسله‌مراتبی و به تدریج پیچیده‌تر شوند. به فرآیند بهینه‌سازی پارامترهایی مانند هسته، آموزش گفته می‌شود که به‌منظور کاهش اختلاف بین خروجی‌ها شبکه و مقادیر واقعی و درست از طریق الگوریتم بهینه‌سازی به نام پس انتشار و کاهش گرادیانی، و غیره انجام می‌شود. اصل کار این شبکه، ورودی، استخراج ویژگی و دسته‌بندی و خروجی است. مؤلفه استخراج ویژگی شبکه عصبی کانولوشن همان چیزی است که سی.إن.إن را از سایر شبکه‌های عصبی چندلایه متمایز می‌کند. به‌طور معمول این شبکه شامل تکرار مجموعه‌ای از عملیات پولینگ، واحد فعال سازی

^۱CNN

کنیم. فلتینگ^۳ تبدیل داده‌ها به یک آرایه ۱ بعدی برای ورود آن‌ها به لایه بعدی است. خروجی لایه‌های کانولوشن را صاف می‌کنند تا یک بردار از ویژگی‌های طولانی ایجاد شود، و این به مدل طبقه‌بندی نهایی متصل می‌شود، که به آن یک لایه کاملاً متصل گفته می‌شود. به عبارت دیگر، ما تمام داده‌های پیکسل را در یک خط قرار می‌دهند و با لایه نهایی ارتباط برقرار می‌نماییم. لایه کاملاً متصل، یک شبکه عصبی جلوخور^۴ است. لایه‌های کاملاً متصل چندلایه آخر شبکه را تشکیل می‌دهند. ورودی لایه کاملاً متصل، خروجی لایه پولینگ یا کانولوشن است که صاف شده و سپس به لایه کاملاً متصل، انتقال می‌یابد.



شکل (۶). تفاوت عملکرد گام‌های مختلف

۴- نتایج

۴-۱- مشخصات و نتایج شبکه E.I.پی

بهتر است قبل از ارائه نتایج شبکه E.I.پی، درباره ساختار آن بحث شود. تعداد کل تصاویر ۲۴۰۰ عدد می‌باشد که هر کدام از آن‌ها در دو راستا شبکه‌بندی شده‌اند، که ابعاد هر کدام از آن‌ها و است، که به ترتیب برابر ۴۹ و ۳۶ هستند. ابتدا این ماتریس سه‌بعدی را به دو بعد یعنی، 1764×2400 تبدیل می‌شود. البته برای بهتر وارد کردن مؤلفه‌ها به شبکه نیاز است که به شکل برداری باشند. برای ورودی شبکه، علاوه بر سرعت از مؤلفه‌هایی مانند موقعیت x و y هم استفاده شده است. خروجی نیز همان سرعت بازسازی شده با روش‌های آزمایشگاهی است. حال با مشخص شدن

مقادیر منفی می‌شوند که با استفاده از واحد فعال‌سازی ReLU^۱، صفر بودن کلیه مقادیر منفی را تضمین می‌کنند.

هسته یک ماتریس دو بعدی کوچک است که برای ایجاد رابطه پیکسل مرکزی با توجه به پیکسل‌های همسایه آن استفاده می‌شود. هسته‌ها در ماتریس‌های بعد فرد یعنی 5×5 و غیره سازمان یافته‌اند.

93	139	101
26	252	196
135	230	18

131	162	232	84	91	207
104	-1	0	+1	237	109
243	-2	0	+2	135	26
185	-1	0	+1	61	225
157	124	25	14	102	108
5	155	16	218	232	249

شکل (۵). نمایش عملکرد هسته در لایه کانولوشن

در شکل ۵ ماتریسی که دارای دو جهت می‌باشد، هسته نام دارد و روی ماتریس بزرگ‌تر حرکت می‌کند تا عملیات کانولوشن به انجام برسد. ماتریس بالایی، ماتریس برش خورده‌ای است که هسته روی آن قرار دارد. با توجه به محاسبات زیر تصویر، پیکسل مرکزی از ۲۳۱ به ۲۵۲ تغییر می‌یابد.

گام‌ها تعداد موقعیت‌هایی را تغییر می‌دهند که ماتریس هسته پس از استفاده از ترکیب در عنصر میانی تغییر مکان می‌دهد. مقدار گام ۱ نشان می‌دهد که ماتریس هسته فقط ۱ پیکسل در هر دو جهت، راست یا پایین جایجا می‌شود. برای اینکه هسته روی هر یک از پیکسل‌ها پیچیده شود، باید یک لایه صفر در امتداد لبه‌های ماتریس بزرگ‌تر اضافه کنیم. این جمع صفرها در هر طرف ماتریس به عنوان پدینگ^۲ شناخته می‌شود. اگر $N \times N$ بعد ماتریس هسته است، باید لایه‌های صفر طبقه $(N/2)$ را به لبه‌ها اضافه

³ Flattening

⁴ Feed Forward

¹ ReLU

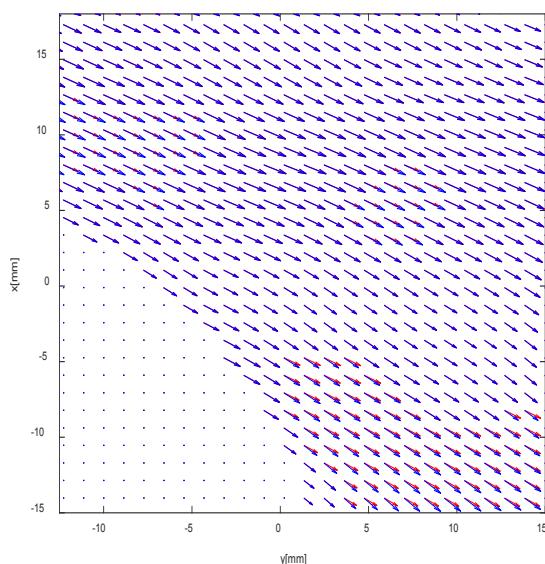
² Padding

سرعت بازسازی است، به دست آید. در جدول ۲ خطاهای آموزش، تست و نهایی برای هر کدام از شبکه‌ها آمده است. این نکته را باید متذکر شد که ارزیابی خود شبکه با خطای میانگین مربعات بوده است.

جدول (۲). خطای شبکه ام.بی.ال

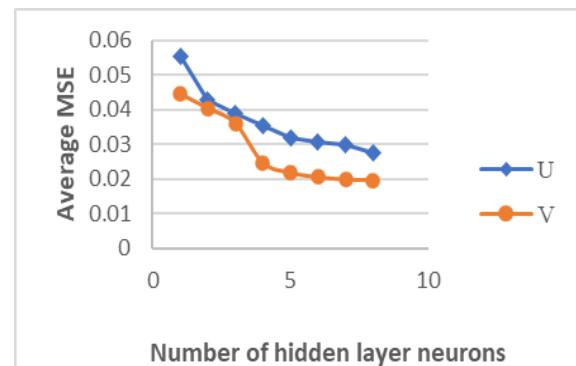
RMSE	MAE	خطای آموزش	خطای تست	شبکه
۰/۵۵۶۱	۱/۱۸۰۶	۰/۰۳۹۱	۰/۰۳۹	U
۱/۶۱۸	۰/۶۳۷۱	۰/۰۲۴۷	۰/۰۲۴۶	V

در ادامه، برای ارائه بهتر نتایج، تعدادی از تصاویر دلخواه میدان سرعت را به نمایش گذاشته شده است. بردارهای آبی رنگ نشان‌دهنده بردارهای سرعت صحیح و بردارهای قرمز، بردارهای بازسازی، در میدان سرعت است. در شکل ۸ و ۹ این بردارها می‌توان مشاهده نمود. اما در شکل ۱۰ و ۱۱ از کانتور سرعت استفاده شده است. همه این شکل‌ها، مربوط به یک تصویر دلخواه از میدان سرعت می‌باشند.



شکل (۸). نمایش هم‌زمان بردارهای بازسازی و صحیح میدان دوبعدی سرعت

مؤلفه‌های ورودی شبکه نیاز به جداسازی داده‌های آموزش و آزمون شبکه داریم، اما قبل از این کار داده‌های موجود را به دلیل افزایش سرعت یادگیری و همگرایی سریع‌تر نرم‌مال می‌کنند.



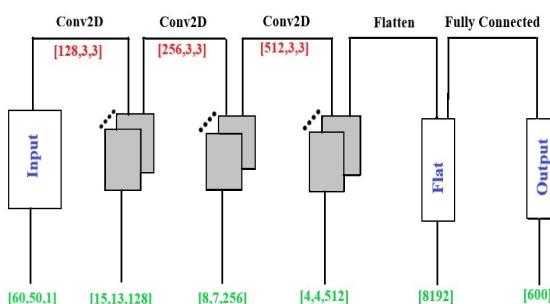
شکل (۷). بررسی خطای تست بر حسب تعداد نرون در سرعت U و V

در شکل ۷ میزان خطای برای تعداد مختلف نرون لایه پنهان نشان داده شده است. میزان خطای برای تعداد ۱ تا ۸ نرون در لایه پنهان بررسی شده است. برای هر حالت، ۵ بار شبکه آموزش داده شده است و نتایجی که در این شکل نشان داده شده است، میانگین این پنج مرتبه است. برای جلوگیری از فراموش شدن شبکه، آموزش شبکه تا جایی ادامه پیدا کرده است که میزان خطای برای داده‌های تست رو به کاهش بوده است. در روند آموزش شبکه ام.بی.ال پیش از یک سری تکرار معین (که بسته به مشخصات شبکه و داده‌ها متفاوت است) حالتی پیش می‌آید که میزان خطای برای داده‌های آموزشی همچنان رو به کاهش است، در حالی که خطای داده‌های تست شروع به افزایش می‌کند. اما مسئله‌ای دیگری نیز مطرح می‌باشد که با توجه به شکل ۴ باید تعداد نرون‌های لایه پنهان ۸ باشد ولی به خاطر اینکه جواب نهایی که همان شکل بردارهای سرعت باشد تطبیق خوبی ندارند و به خوبی بازسازی نشده‌اند ولی نهایت ۳ نرون برای بازسازی سرعت U و ۴ عدد برای بازسازی سرعت V جواب بهتری ارائه کرده‌اند.

در نهایت میدان سرعت حاوی نقاط نقص در همان ابعاد ورودی به شبکه داده می‌شود تا خروجی مدنظر که همان

۲-۴- مشخصات و نتایج شبکه سی ان ان

اما در رابطه با شبکه سی ان ان ابتدا باید درباره ورودی ها و خروجی های شبکه، سپس در مورد ساختار آن بحث کرد. همان طوری که در بخش شبکه ام ال بی بیان گردید هر مؤلفه شبکه آن دارای ابعاد 1764×2400 می باشد. برای آموزش شبکه سی ان ان از پنج مؤلفه یعنی سرعت، موقعیت های x و y و دو مؤلفه از کرنش استفاده شد، سپس این پنج مؤلفه کنار هم قرار گرفتند و یک ماتریس 1764×12000 را تشکیل داده اند و خروجی نیز مانند شبکه ام ال بی است. مانند هر شبکه عصبی ای نیاز است تا شبکه وزن های موجود در خود را بهینه کند تا به خوبی آموزش ببیند که ابتدا ساختار شبکه را در شکل ۱۲ نشان داده شده است، سپس توضیحاتی در مورد آن ارائه می شود.



شکل (۱۲). ساختار شبکه سی ان ان

قبل از اینکه وارد بحث شکل ورودی شویم بهتر است درباره به دست آمدن کرنش برای مؤلفه های سرعت که در ورودی به کار گرفته شده اند، بحث خواهد شد. نحوه محاسبه کرنش در زیر آمده است:

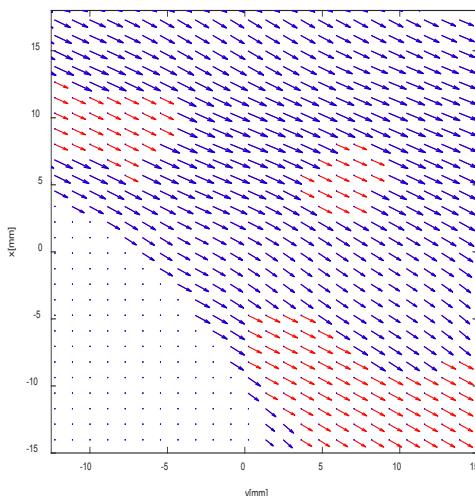
$$S_{11}^{(k)}(i,j) = \frac{U_{(i+1,j)}^{(k)} - U_{(i-1,j)}^{(k)}}{2\delta_x} \quad (4)$$

$$S_{22}^{(k)}(i,j) = \frac{V_{(i,j+1)}^{(k)} - V_{(i,j-1)}^{(k)}}{2\delta_y} \quad (5)$$

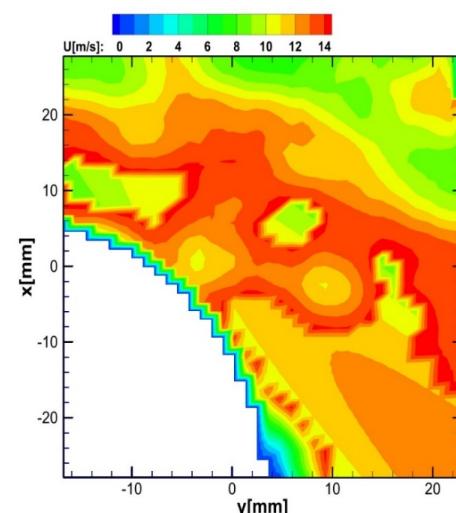
$$S_{12}^{(k)}(i,j) = S_{21}^{(k)}(i,j) \quad (6)$$

$$= \frac{1}{2} \left(\frac{U_{(i,j+1)}^{(k)} - U_{(i,j-1)}^{(k)}}{2\delta_y} + \frac{V_{(i+1,j)}^{(k)} - V_{(i-1,j)}^{(k)}}{2\delta_x} \right)$$

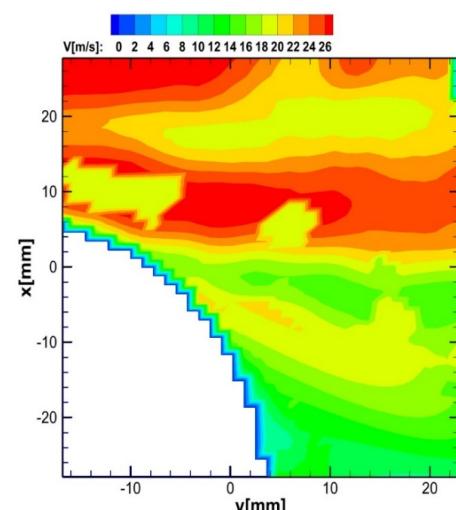
$$\delta_x = \delta_y \approx 1mm \quad \text{که}$$



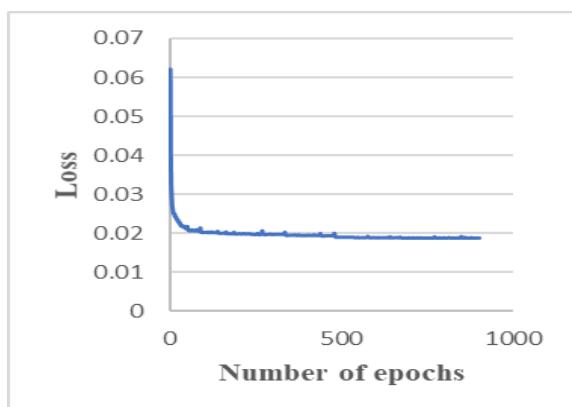
شکل (۹). نمایش تنهای بردارهای بازسازی در نقاط نقص میدان دو بعدی سرعت



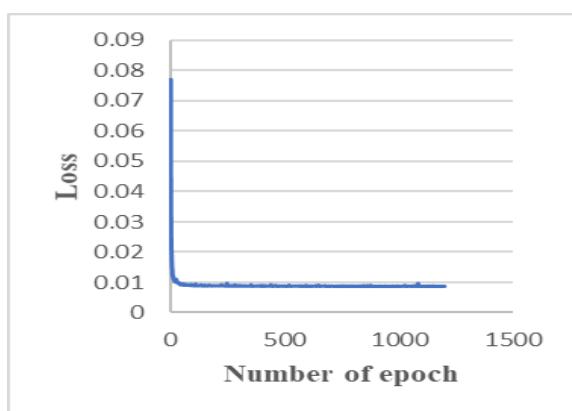
شکل (۱۰). میدان مؤلفه سرعت در جهت (x) سرعت بازسازی شده



شکل (۱۱). میدان مؤلفه سرعت در جهت (y) سرعت بازسازی شده



(الف)



(ب)

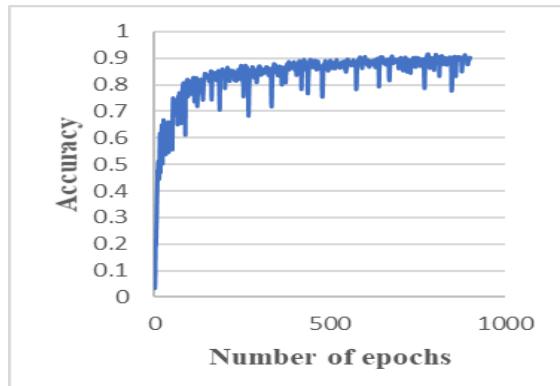
شکل (۱۴). نمودار خطای شبکه سی.ان.ان (الف) برای سرعت U (ب) برای سرعت V

همانند شبکه ام.آل.پی میدان سرعت حاوی نقاط نقص را به شبکه آموخت داده شده می‌دهیم تا سرعت بازسازی شده را به دست بیاوریم. در جدول ۳ خطای نهایی برای هر کدام از شبکه‌ها آمده است. همانند قسمت قبلی، شکل‌های میدان بازسازی با استفاده از سی.ان.ان، از شکل ۱۵ تا ۱۸ خواهند بود. برای هر یک از روش‌های مورداستفاده، معیارهایی برای ارائه خطای آن‌ها ارائه شده است، ولی برای مقایسه هر یک از روش‌ها با هم نیاز به یک مقیاس است که بتوان از آن برای مقایسه استفاده کرد. لذا بعد از انجام بازسازی برای هر یک از روش‌ها دو نمونه خطا به دست آورده‌یم که در شکل ۱۹ آورده شده است.

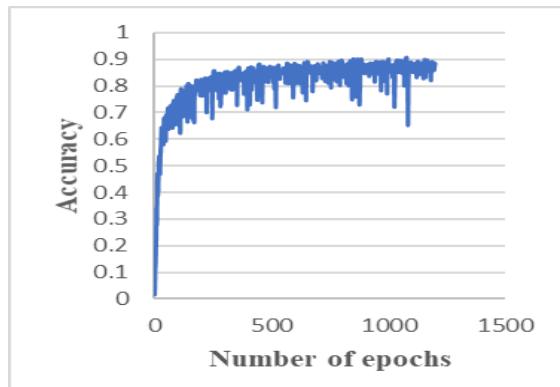
جدول (۳). خطای شبکه سی.ان.ان

MAE	RMSE	شبکه
۰/۸۹۷۱	۲/۱۴۶۵	U
۰/۳۰۴۷	۰/۹۹۰۵	V

حال که همه مؤلفه‌های ورودی برایمان مشخص گردید نیاز است که ساختار شبکه بهتر شناخته شود. همان‌طور که در شکل (۱۲) نشان داده شد، اندازه ورودی به لایه کانولوشن 60×50 است. ابعاد هسته 3×3 است، اما تعداد فیلترهای خروجی هر لایه آن‌ها به ترتیب 128 ، 256 و 512 می‌باشد. خواص تعیین نشده دیگری در لایه کانولوشن باقی می‌ماند که توضیح مختصری در مورد آن‌ها ارائه شده است.تابع فعال‌سازی هر کدام از لایه‌ها را خواهد بود. گام موجود در لایه‌های کانولوشن برای تعیین چگونگی حرکت هسته 2×2 به ترتیب برای لایه‌های اول تا سوم خواهد بود که با مشاهده به ماتریس‌های پایینی شکل ۱۲ درمی‌یابیم که ابعاد به دلیل عملیات مکس پولینگ که ابعاد آن همانند گام است، تغییر کرده است؛ در واقع در نرم‌افزار پایتون گزینه‌ای وجود دارد که گام دو عمل را انجام می‌دهد تا از نوشتن خطوط زیاد در برنامه جلوگیری شود. تابع خطای شبکه هم میانگین مربعات است که با بهینه‌ساز آدام، بهینه خواهد شد.

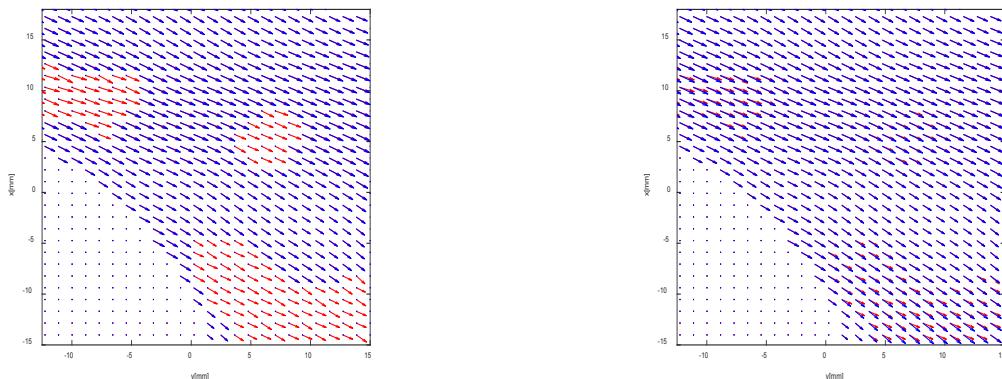


(الف)



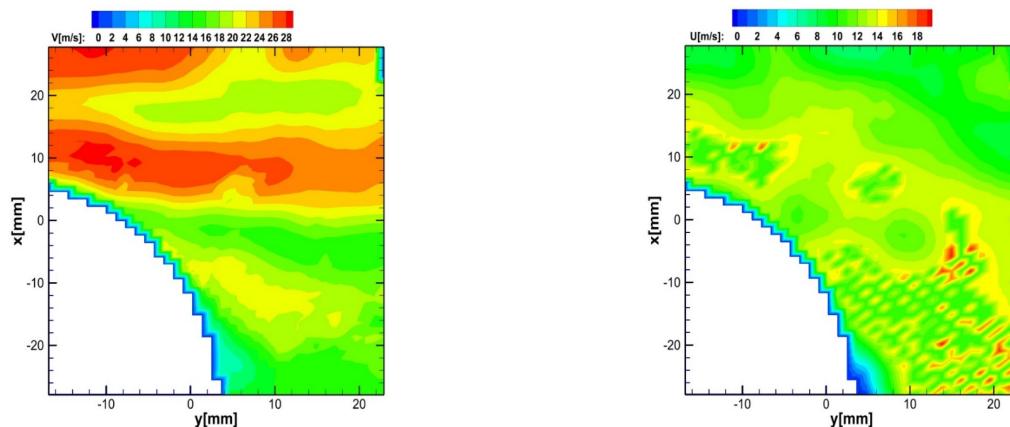
(ب)

شکل (۱۳). نمودار دقت شبکه سی.ان.ان (الف) برای سرعت U (ب) برای سرعت V



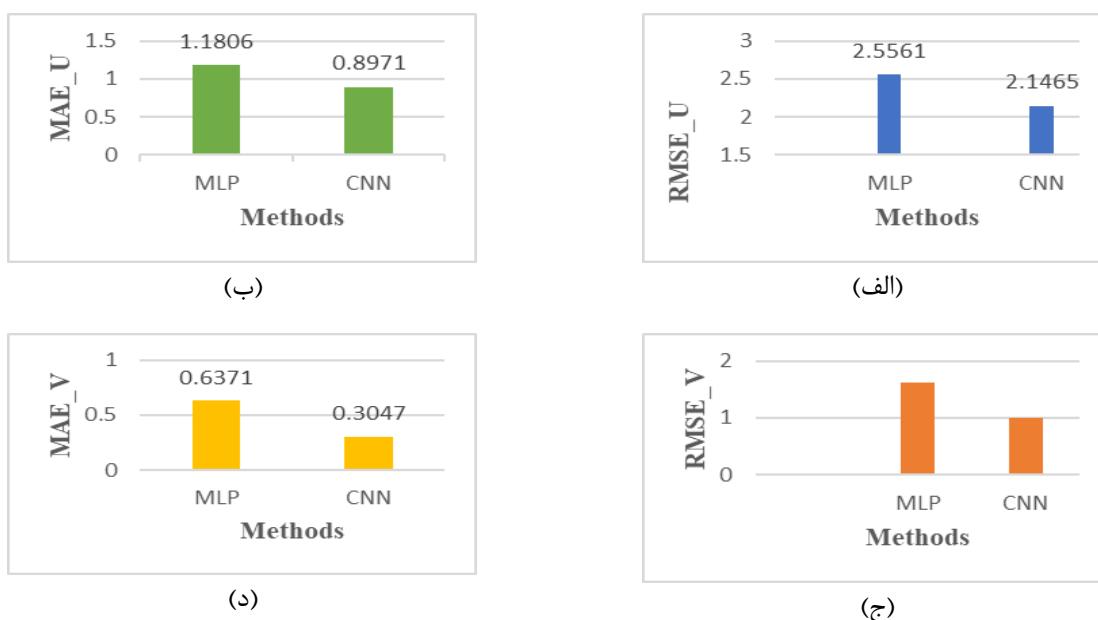
شکل (۱۶). نمایش هم زمان بردارهای بازسازی و صحیح میدان
میدان دو بعدی سرعت

شکل (۱۵). نمایش هم زمان بردارهای بازسازی و صحیح میدان
دو بعدی سرعت



شکل (۱۷). میدان مؤلفه سرعت در جهت (x) سرعت بازسازی
شد

شکل (۱۸). میدان مؤلفه سرعت در جهت (y) سرعت بازسازی
شد



شکل (۱۹). خطای نهایی روش های بازسازی (الف) RMSE_U (ب) MAE_U (ج) RMSE_V (د) MAE_V

ورودی‌های شبکه ام.ال.پی، مؤلفه‌هایی مانند سرعت و موقعیت x و y و خروجی آن نیز میدان سرعت بدست آمده با روش‌های آزمایشگاهی است. برای تعیین تعداد نرون‌های لایه پنهان، شبکه ۵ مرتبه برای هر نرون، آموزش داده شده است؛ بنابراین تعداد نرون‌های لایه پنهان مؤلفه U ، ۳ و برای مؤلفه V ، ۴ عدد به دست آمده است. با استفاده از ورودی‌ها و خروجی‌ها و روش کاوش گرادیانی، پارامترهای مختلف نظری وزن‌ها و بایاس‌ها تعیین می‌شوند. در آموزش شبکه سی.ان.ان از ۵ مؤلفه سرعت، موقعیت‌های x و y و دو مؤلفه از کرنش استفاده شد که با کنار هم قرار گرفتن آن‌ها، ابعاد ورودی شبکه به 1764×1200 تبدیل شد؛ خروجی شبکه همانند خروجی شبکه ام.ال.پی است. ساختار شبکه متشکل از سه لایه کانولوشن با تعداد فیلتر ۱۲۸، ۲۵۶ و ۵۱۲ است که هر لایه هسته‌ای با ابعاد 3×3 دارد.تابع فعال‌سازی برای همه لایه‌ها رلو خواهد بود. گام موجود در لایه‌های کانولوشن برای تعیین چگونگی حرکت هسته ۲، ۴ و ۲ به ترتیب برای لایه‌های اول تا سوم خواهد بود و همین‌طور وزن‌های شبکه مانند شبکه‌های قبلی با استفاده از میانگین مربعات خطای توسط بهینه‌ساز آدام، بهینه می‌شود.

در نهایت با مقایسه خطای نهایی روش‌های مورد استفاده، عملکرد روش‌ها موردنرسی قرار گرفته شد، که مشخص شد، برای بازسازی جفت مؤلفه‌های سرعت U و V ، شبکه عصبی سی.ان.ان عملکرد بهتری را دارد. این مسئله با مشاهده شبکه‌های میدان برداری سرعتی که برای روش‌ها رسم گردید، مشخص است. شبکه سی.ان.ان یک شبکه عصبی عمیق است و برای همین روی داده‌های با حجم بالا بهتر عصبی عمیق مطرح می‌شود، که مثلاً افزودن لایه‌های زیادتر به منظور ایجاد دقت بهتر، بدون در دست داشتن داده‌های کافی می‌تواند در آموزش پارامترهای شبکه تأثیر بدی داشته باشد؛ بنابراین، اگر راههای دیگری برای صرف نکردن زمان و هزینه، به کار گرفته شود، شبکه‌ای مثل ام.ال.پی گزینه مناسبی می‌باشد، تا در صورت موقعي که داده‌ها حجم نیستند یا داده کافی‌ای در دسترس نیست از آن استفاده شود، در غیر این صورت بهتر است از انواع مدل‌های شبکه عصبی عمیق، با حفظ رعایت پارامترهای کافی یادگیری، استفاده شود.

با مقایسه شکل‌های بالا این مسئله مشخص می‌شود که در بازسازی هم مؤلفه سرعت U و هم V ، شبکه عصبی سی.ان.ان عملکرد بهتری را داشته است. این مسئله با مشاهده شبکه‌های میدان برداری سرعتی که برای روش‌ها رسم گردید، مشخص است. به دلیل اینکه شبکه سی.ان.ان یک شبکه عصبی عمیق است و روی داده‌های با حجم بالا بهتر آموزش می‌بیند، عملکرد بهتری را داشته است، اما باید این نکته توجه شود شبکه عصبی عمیق هم در درسرهای خاص خود را به همراه دارد. به عنوان مثال، اگر از شبکه‌ای با پارامترهای یادگیری زیاد و لایه‌های بیشتری برای بالا بردن دقت شبکه استفاده شود، ممکن است شبکه به خاطر نبود وجود غنای کافی داده‌ها، روند آموزش خود را به خوبی طی نکند که نتیجه عکس خواهد داد، هم زمان بیشتری برای یادگیری صرف خواهد شد و هم دقت کمتری به خاطر یادگیری نامناسب پارامترهای شبکه به وجود خواهد آمد. برای همین از شبکه‌ای مثل ام.ال.پی هم استفاده می‌شود تا در صورت موقعي که داده‌ها حجم نیستند یا داده کافی‌ای در دسترس نیست از آن استفاده شود، در غیر این صورت بهتر است از انواع مدل‌های شبکه عصبی عمیق، با حفظ رعایت پارامترهای کافی یادگیری، استفاده شود.

در نهایت، بهتر است که مقایسه‌ای در زمان انجام محاسبات صورت گرفته در روش‌های مختلف انجام شود که در جدول ۴ آمده است. باید این نکته را در نظر گرفت که نتایج این جدول از سیستمی با دو هسته ۲,۱ گیگاهرتزی و ۱۶ گیگابایت حافظه رم استخراج شده است.

جدول (۴). مقایسه زمان محاسبات توسط روش‌های ام.ال.پی و سی.ان.ان

CNN	MLP	روش بازسازی
زمان محاسبه (ثانیه)		
۴۳۲۲۰/۱۵۶۹	۶۰.۳/۵۵۵۱	

۵- نتیجه‌گیری

در مطالعه حاضر، از داده‌های میدان سرعت استخراج شده از ابزار اس.بی.آی.وی استفاده گردید که در بعضی نقاط، به دلیل وجود مشکلاتی دارای نقص می‌باشند؛ بنابراین، بازسازی مقادیر سرعت در نقاط نقص و تکمیل داده‌ها در ارجحیت خواهد بود که با به کار گیری از شبکه‌های عصبی مصنوعی آن نقاط بازسازی شدند.

۷- مراجع

- Craene, and O. Bernard, "A pilot study on convolutional neural networks for motion estimation from ultrasound images", *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, Vol. 67, No. 12, pp. 2565–2573, 2020.
13. Mirzaei. HR, "Optimizing the Inlet of the Squirrel Nest Technique", Msc Thesis, Amirkabir University of Technology, Faculty of Mechanical Engineering, 1998. (In Persian)
14. Firuznia, Neda, "Jet and wake impact analysis and noise generation over fan cut off from PIV experiments", Msc Thesis, Amirkabir University of Technology, Faculty of Mechanical Engineering, 2016. (In Persian).
15. Loboda, I., Feldshteyn, Y., and Ponomaryov, V., "Neural Networks for Gas Turbine Fault Identification: Multilayer Perceptron or Radial Basis Network", *International Journal of Turbo and Jet Engines*, 29(1), 37-48, 2012.
16. D. T. Pham and X. Liu, "Neural Networks for Identification", Prediction and Control, Springer Verlag, London, 1995.
17. Hemmatasfe, M., esfande, S., and akhooundzade, M. "orecasting of Convective Heat Transfer Coefficient in Turbulent Flow of Different Nanofluids in Circular Tubes, Using Artificial Neural Network", *Fluid Mechanics & Aerodynamics Journal*, 7(1), pp. 1-11, 2018.
18. Yu W, Huang S, and Xiao W. Fault Diagnosis Based on an Approach Combining a Spectrogram and a Convolutional Neural Network with Application to a Wind Turbine System. *Energies*. 2018; 11(10):2561. <https://doi.org/10.3390/en11102561>
19. Zhou, D., Yao, Q., Wu, H., and Zhang, H., "Fault diagnosis of gas turbine based on partly interpretable convolutional neural networks", *Energy*, Vol. 200, 1 June 2020, 117467.
1. S. G. Raben, J. J. Charonko, and P. P. Vlachos, "Adaptive gappy proper orthogonal decomposition for particle image velocimetry data reconstruction", *Meas. Sci. Technol.*, Vol. 23, No. 2, p. 25303, 2012.
2. N. E. Murray and L. S. Ukeiley, "An application of Gappy POD", *Exp. Fluids*, Vol. 42, No. 1, pp. 79–91, 2007.
3. R. Everson and L. Sirovich, "Karhunen–Loeve procedure for gappy data", *JOSA A*, Vol. 12, No. 8, pp. 1657–1664, 1995.
4. D. Venturi and G. E. Karniadakis, "Gappy data and reconstruction procedures for flow past a cylinder", *J. Fluid Mech.*, Vol. 519, pp. 315–336, 2004.
5. K. Willcox, "Unsteady flow sensing and estimation via the gappy proper orthogonal decomposition", *Comput. Fluids*, Vol. 35, No. 2, pp. 208–226, 2006.
6. H. Gunes, S. Sirisup, and G. E. Karniadakis, "Gappy data: To Krig or not to Krig?", *J. Comput. Phys.*, vol. 212, No. 1, pp. 358–382, 2006.
7. K. E. Meyer, J. M. Pedersen, and O. Özcan, "A turbulent jet in cross flow analysed with proper orthogonal decomposition", *J. Fluid Mech.*, Vol. 583, pp. 199–227, 2007.
8. S. Ahmed, H. El Kadi, and A. AlSharif, "Three-dimensional turbulent swirling flow reconstruction using artificial neural networks", *J. Mech. Eng. Autom.*, Vol. 4, No. 1, pp. 1–9, 2014.
9. K. Fukami, K. Fukagata, and K. Taira, "Super-resolution reconstruction of turbulent flows with machine learning", *J. Fluid Mech.*, Vol. 870, pp. 106–120, 2019.
10. A. T. Mohan and D. V Gaitonde, "A deep learning based approach to reduced order modeling for turbulent flow control using LSTM neural networks", *arXivPrepr. arXiv1804.09269*, 2018.
11. S. Cai, J. Liang, Q. Gao, C. Xu, and R. Wei, "Particle image velocimetry based on a deep learning motion estimator", *IEEE Trans. Instrum. Meas.*, Vol. 69, No. 6, pp. 3538–3554, 2019.
12. E. Evain, K. Faraz, T. Grenier, D. Garcia, M. De