



# Determining Characteristics of Two-Phase Oil-Water Flows by the Convolutional Neural Network

Amir Poorya Sadegh Samimi, Ali Esfandiyari Bayat\* and Abulqasem Emamzadeh

Department of Reservoir Engineering, Faculty of Petroleum and Chemical Engineering, Science and Research Branch, Islamic Azad University (IAU), Tehran, Iran

alies.bayat@srbiau.ac.ir

DOI:10.22078/PR.2022.4895.3189

Received: August/21/2022

Accepted: November/08/2022

## Introduction

A two-phase flow (i.e. liquid-liquid or gas-liquid) is a usual occurrence in chemical and petrochemical industries. In a gas-liquid system, density difference and viscosity ratio of phases are greater than in a liquid-liquid system, and so, flow regimes are quite different. Many studies have focused on the behavior of gas-liquid two-phase flow. After experimental tests, flow pattern (flow regime) and holdup fractions as two crucial factors can be evaluated by conventional or new approaches (i.e. machine/deep learning) for the flow characterization [1]. Deep learning or generally machine learning has a wide application in various areas such as pattern recognition, machine vision, image processing, volumetric data analysis, as well as two-phase flow characterization [2-3]. Deep learning algorithms have been basically developed to utilize images for computer vision, feature extraction, visual/image processing, and parameter estimation in various research areas. To the best of our knowledge, there is no attempt to utilize two-phase flow images in the deep learning programs for flow characterization. The current study investigates the capability of a newly developed deep learning framework called flow conventional neural network (FCNN) on a two-phase oil-water flow characterization. For this goal, the flow behavior was investigated in a horizontal and

30-degree inclined pipe through the captured flow images.

## Materials and Methods

An experimental setup was designed to evaluate two-phase oil-water flow in a Plexiglas pipe with length of 14 m and inner diameter (ID) of 3 cm. The pipe was once positioned horizontally and then was inclined at 30°.

In this study, a tap water (density 0.995 g/cm<sup>3</sup> and viscosity 1.01 cP at ambient temperature) and a lamp oil (density 0.785 g/cm<sup>3</sup> and viscosity of 1.68 cP at ambient temperature) were utilized. The phases were pumped in various flow rates (0.1- 0.9 m/sec) and water fractions (between 0.18 and 0.98) to provide a comprehensive dataset. Practically, the oil phase is flowed first, and the water is introduced to the line gradually to reach the desired initial phase fraction [4]. The interfacial tension between tap water and lamp oil was measured to be 17.2 (mN/m).

In the current study, a deep learning model is proposed which is capable to predict flow regime and liquid holdup based on analyzing input flow pattern image and the learning of underlying physics. The proposed model embeds physical phenomena into the network layers. The schematic of proposed framework is presented in Figure 1.




Fig. 1 Structure of the designed FCNN, M: Max Pooling, C: Convolution Layer, F: Flatten Layer, A: Activation ReLU function.

**Results and Discussions**

Figure 2a demonstrates the flow regime map in the proposed experiments. At lower mixture velocities, the stratified flow regime is the common flow pattern in all input fraction of water. At moderate mixture velocities, dominating flow is dual continuous which shapes in input water fractions above 0.5. In addition, at high mixture velocities, dispersed flows were observed, either dispersed oil in water which is when the water input fraction is high, or dispersed water in oil which is when the water input fraction is low. Another discussed parameter is the liquid holdup fraction which is measured using the fast closing valves in the all experiments. The comparison between water input fraction and water holdup fraction is depicted in Figure 2b. Approximately, most of data is spread in a linear trend. However, in the dispersed oil in water flow, the holdup fraction deviates from the straight linear line due to oil and water interaction and wettability preference of Plexi-glass. The deviation is depicted in dashed ellipse region.




Fig. 2 (a) Resulted flow pattern map – Horizontal pipe, (b) Comparison between water input fraction and holdup fraction – Horizontal pipe, the dashed ellipse confirms that holdup fraction show more deviation in dispersed oil in water flow regime.

In addition to horizontal experiments, a similar flow rate condition for 30o upward inclined pipe was evaluated. Figures 3a and 3b present the flow pattern and holdup fraction in the 30o inclined pipe. As expected, the inclination helps better separation of flow pattern boundaries. The flow patterns of dispersed water in oil were better extended which relates to gravity force [5]. In addition, some points with stratified labeling in horizontal flow received the label of dual continuous when the pipe inclination is increased to 30-degree. Another notable difference occurred in holdup fraction where, a notable reduction was observed in holdup fraction in all cases due to the gravity impact.

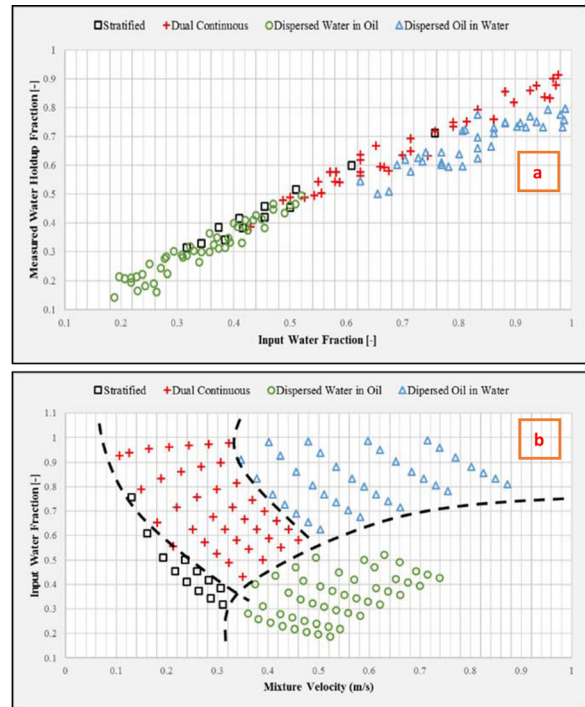


Fig. 3 (a) Resulted flow pattern map – 30° inclined pipe, (b) Comparison between water input fraction and holdup fraction – 30° inclined pipe.

To prepare images for machine learning, the image should be in binary format which contains only 0 and 1. The total number of experimental data is 270 which consisted from stratified, dual continuous, dispersed water in oil and dispersed oil in water in two inclination angles of zero and 30°.

About 70% of database was selected randomly for

network training and the remained 30% for testing. The selected structure for FCNN is the most suitable for training due to testing different scenarios and training evaluations. The results of comparing the holdup fraction measured and predicted values show that the model is capable for prediction of holdup fractions with overall Average Absolute Relative Error (AARE) of 1.216% and 0.981% for horizontal and 30° inclined pipelines, respectively.

### Conclusions

This study contributes to knowledge gaps in flow pattern detection and holdup estimation through a promising methodology to recognize and predict two-phase flow patterns by a deep learning neural network, named FCNN, which was trained, tested and validated via an experimental dataset. The main key of this research is to present a comprehensive investigation of flow regime map and holdup fraction in horizontal pipe, and a 30° inclined pipe using the FCNN model. The proposed model is able to predict the flow pattern of input images with an accuracy of 91% and 96% for horizontal and inclined flows, respectively. This great matching between observed and predicted flow regime confirms the model capability for flow pattern recognition. In addition, the water holdup fraction was predicted with accuracy of 1.22% and 0.98% in horizontal and inclined flows, respectively. The results have revealed that the proposed model is enough accurate and reliable. Therefore, the researchers will be able to apply the flow images, and accurately, categorize flow regimes and estimate the holdup

fractions by the developed FCNN.

### References

1. Hussein MM Al-Sarkhi A Badr HM Habib MA (2019) CFD modeling of liquid film reversal of two-phase flow in vertical pipes, *Journal of Petroleum Exploration and Production Technology* 9: 3039–3070. <https://doi.org/10.1007/s13202-019-0702-1>.
2. Ershadnia R Amooie MA Shams R Hajirezaie S Liu Y Jamshidi S Soltanian MR (2020) Non-Newtonian fluid flow dynamics in rotating annular media: Physics-based and data-driven modeling, *Journal of Petroleum Science and Engineering* 185: 106641. <https://doi.org/10.1016/j.petrol.2019.106641>.
3. Rabbani A Babaei M Shams R Wang YD Chung T (2020) DeePore: A deep learning workflow for rapid and comprehensive characterization of porous materials, *Advances in Water Resources* 146: 103787, <https://doi.org/10.1016/j.advwatres.2020.103787>.
4. Shams R Tavakoli A Shad S (2017) Experimental investigation of two-phase flow in horizontal wells: Flow regime assessment and pressure drop analysis, *Experimental Thermal and Fluid Science* 88: 55-64. <https://doi.org/10.1016/j.expthermflusci.2017.05.011>.
5. Hanafizadeh P Hojati A Karimi A (2015) Experimental investigation of oil-water two phase flow regime in an inclined pipe, *Journal of Petroleum Science and Engineering*, 136: 12–22. <https://doi.org/10.1016/j.petrol.2015.10.031>.

# تعیین مشخصات جریان‌های دو فاز نفت- آب توسط شبکه عصبی کانولوشنی جریانی

سید امیر پوریا صادق صمیمی، علی اسفندیاری بیات\* و سید ابوالقاسم امامزاده  
گروه مهندسی نفت، دانشکده نفت و مهندسی شیمی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۰۵/۳۰ تاریخ پذیرش: ۱۴۰۱/۰۸/۱۷

## چکیده

تا به امروز، مدل‌های مکانیکی و روابط تجربی مختلفی برای توصیف و مدل‌سازی سیستم‌های جریان دو فاز نفت- آب معرفی شده‌اند. اما، در اکثر این مدل‌ها و روابط پیشنهادی از مفروضات ساده با رویکرد حل تکرار شونده استفاده شده، که از دقت کافی جهت تخمین خصوصیات جریانی برخوردار نمی‌باشند. هدف از مطالعه حاضر، غلبه بر این مشکل با کمک توسعه یک شبکه عصبی کانولوشنالی جریانی از طریق یادگیری عمیق می‌باشد. بدین منظور، ۲۷۰ آزمایش جریانی شامل آزمایش‌های جریانی پراکنده آب در نفت، دو گانه پیوسته و پراکنده نفت در آب در دو حالت افقی و شیب دار (۳۰°) انجام گردیده است. شبکه عصبی بر روی ۷۰٪ این داده‌های آزمایشگاهی آموزش داده شد. لازم به توضیح است که از تصاویر الگوی جریانی دو بعدی به عنوان داده‌های ورودی و از الگوهای جریان و مقادیر کسر حجمی پسماند به عنوان داده‌های خروجی استفاده شده است. نتایج حاصل از این مطالعه نمایانگر آن است که مدل شبکه عصبی کانولوشنالی جریانی آموزش داده شده بر روی داده‌های آزمایشگاهی قادر است رژیم‌های جریان را با دقت ۹۱٪ و ۹۶٪ به ترتیب در جریان‌های افقی و شیب‌دار پیش‌بینی نماید. این مدل همچنین قادر است کسر حجمی پسماند را با یک خطای معقول ۱/۲۲٪ و ۰/۹۸٪ به ترتیب در جریان‌های افقی و شیب‌دار پیش‌بینی کند. از این‌رو می‌توان گفت که رویکرد پیشنهادی قادر به پیش‌بینی خودکار و دقیق رژیم جریان و کسر حجمی پسماند در جریان‌های افقی و شیب‌دار از طریق تصاویر جریان است.

**کلمات کلیدی:** جریان دو فاز، الگوی جریان نفت- آب، یادگیری عمیق، شبکه عصبی کانولوشنی  
جریانی، کسر حجمی پسماند

مقدمه

جریان‌های دو فاز (یعنی مایع-مایع یا گاز-مایع) یک اتفاق معمول در صنایع نفت و پتروشیمی است. در یک سیستم دو فاز مایع-گاز، اختلاف چگالی و گرانشی فازها بیشتر از یک سیستم مایع-مایع است و بنابراین، رژیم‌های جریان کاملاً متفاوت هستند. بسیاری از مطالعات پیشین بر رفتار جریان دو فاز مایع-گاز متمرکز شده‌اند. به دلیل ماهیت پیچیده تعامل بین نفت و آب، فازها به صورت رقابتی در مسیر جریان می‌یابند و رژیم‌های جریان متفاوتی نسبت به یکدیگر ایجاد می‌کنند. این توزیع هندسی یا ساختار فضایی در داخل مسیر جریان، رژیم‌های نام دارد [۱-۳]. رژیم‌های جریان الگوی جریان تابعی از خواص سیالات، دبی جریان و همچنین، شعاع و زبری لوله است [۴]. هر رژیم‌های جریان نشان‌دهنده ویژگی‌های منحصر به فردی است و جریان دو فاز را کنترل می‌کند [۵].

پس از آزمایش‌های تجربی، الگوی جریان (رژیم جریان) و کسرهای حجمی پسماند<sup>۱</sup> به‌عنوان دو عامل حیاتی می‌توانند با رویکردهای سنتی یا جدید (مانند یادگیری ماشین/عمیق) برای توصیف جریان ارزیابی شوند [۵ و ۲]. به رویکردهای سنتی برای تعیین ویژگی‌های جریان در طول دهه‌های گذشته، توجه زیادی شده است [۶-۷]. به طور معمول محققان رژیم‌های جریانی متفاوتی را در طی آزمایش‌های تجربی دریافته‌اند [۸ و ۳]. در این مطالعات تأثیرات طول، قطر، جهت و شیب لوله [۸ و ۱۸]، خواص سیال و حضور عوامل کاهش‌دهنده افت فشار [۱۹-۲۵]، برروی الگوی جریان مورد بررسی قرار گرفته‌اند. در مطالعات فوق‌الذکر، الگوهای جریان مختلفی بر اساس شرایط آزمایشگاهی شناسایی شدند. تلاش‌هایی برای شناسایی کسر حجمی پسماند با رویکردهای سنتی نیز انجام شده است [۱۰ و ۱۴ و ۲۶]. کسر پسماند یک مایع، الگوی جریان را در لایه مرزی

مشوش می‌کند و نقش کلیدی در پیش‌بینی رفتار جریان و الگوی جریانی به ویژه در خطوط لوله افقی و شیب‌دار دارد [۲۷]. با توجه به محدودیت‌های آزمایشگاهی و عدم قطعیت در آزمایش‌های جریان دو فاز، محققان در حال بررسی الگوریتم‌های جدیدی برای توصیف و مدل‌سازی جریان به شیوه‌ای خودکار مانند روش‌های یادگیری ماشینی/عمیق<sup>۲</sup> هستند.

یادگیری عمیق شاخه‌ای از هوش مصنوعی می‌باشد که سعی بر آن دارد تا مسائل را از طریق روشی مشابه مغز انسان و بینایی او پردازش کند. یادگیری عمیق یا به طور کلی یادگیری ماشین کاربرد گسترده‌ای در زمینه‌های مختلفی مانند تشخیص الگو، بینایی ماشین، پردازش تصویر، تجزیه و تحلیل داده‌های حجمی و همچنین تشخیص جریان دو فاز دارد [۲۸-۳۱]. عزت آبادی‌پور و همکاران یک پرسپترون<sup>۳</sup> چندلایه برای استخراج الگوی جریان از خصوصیات و شرایط جریان بر اساس پایگاه داده جمع‌آوری شده پیشنهاد کردند [۳۲]. رئیسی و همکاران یک چارچوب مکانیک جریان پنهان<sup>۴</sup> را برای پیش‌بینی سرعت جریان و توزیع فشار با استفاده از داده‌های الگوی جریان توسعه داده‌اند. مدل آموزش داده شده، معادلات ناویر-استوکس را در یادگیری ماشین، رمزگذاری می‌کند و چالش محققان را در مورد تشخیص الگوی جریانی حل می‌کند [۳۳]. در تحقیقی دیگر، یک روش ماشین‌بردار پشتیبان<sup>۵</sup> برای پیش‌بینی الگوی جریان بدون تجزیه و تحلیل پارامترهای مؤثر ایجاد شده است [۳۴]. کانین و همکاران یک روش یادگیری ماشین جدید بر روی داده‌های آزمایشگاهی برای افزایش دقت روش‌های مکانیکی و مبتنی بر همبستگی پیشنهاد دادند [۳۵]. آنها روش جدیدی را برای محاسبه گرادیان فشار در

1. Holdup Fraction  
 2. Deep Learning  
 3. Perceptron  
 4. Hidden Flow Mechanics  
 5. Support Vector Machine (SVM)

یک جعبه ابزار پردازش تصویر، از قبل پردازش شده و سپس به یک بسته یادگیری عمیق وارد شده‌اند. مدل عمیق بر روی تصاویر جریان، آموزش داده شده و برای اعتبار سنجی قابلیت و توانمندی الگوریتم مورد آزمایش قرار داده شده است.


### مواد مورد نیاز و روش انجام کار راه‌اندازی آزمایش

یک مجموعه آزمایشی برای ارزیابی جریان دو فازی نفت-آب در یک لوله شیشه‌ای با جنس پلکسی به طول ۱۴ m و قطر داخلی ۳ cm طراحی شد. ابعاد لوله انتخاب شده در محدوده اکثر مطالعات قبلی برای بررسی جریان‌های دوفازی است [۳۷-۳۹]. لوله یک بار به صورت افقی و سپس با زاویه ۳۰° قرار داده شد. راه‌اندازی آزمایش شامل دو واحد پمپاژ و دبی سنج، لوله شیشه‌ای از جنس پلکسی، یک واحد جداکننده، مجموعه‌ای از شیرهای بسته شونده سریع<sup>۳</sup> برای اندازه‌گیری پسماند و یک دوربین با سرعت بالا برای عکاسی از رژیم‌های جریانی است. روش‌های مختلفی برای گرفتن مقدار کسر حجمی پسماند وجود دارد که یکی از دقیق‌ترین آنها، استفاده از شیرهای بسته شونده سریع است [۴۰]. شیرهای بسته شونده سریع، بلافاصله بخش مورد نظر خط لوله را در طول آزمایش جدا می‌کنند. پس از استخراج و جداسازی کسر حجمی هر سیال در یک خط لوله، مقدار کسر حجمی پسماند محاسبه می‌شود. شکل ۱ آرایشی از نحوه آزمایش را نشان می‌دهد. آرایش ارائه شده یک به عنوان نقشه راه در ساخت و بهره‌وری از دستگاه مورد مطالعه می‌باشد. در این مطالعه از آب شیر با دانسیته  $0.995 \text{ g/cm}^3$  و ویسکوزیته  $1 \text{ cP}$  (در دمای محیط) و کروزن با دانسیته  $0.785 \text{ g/cm}^3$  و ویسکوزیته  $1/68 \text{ cP}$  در دمای محیط به‌عنوان نفت استفاده شد.

هر بخش از مسیر جریان از طریق سه مدل جایگزین بر اساس یادگیری ماشین بر روی داده‌های تجربی ارائه کردند. این مدل‌ها ابتدا کسر پسماند را محاسبه کرده و سپس الگوی جریان و گرادیان فشار را به دست می‌آورد. از آنجایی که این پیش‌بینی یک روش تکراری بوده، ماشین آموزش داده شده از تکرار صرف نظر کرده و پارامترها را در هر مرحله تخمین می‌زند. تحقیق دیگری بین مدل جایگزین و یادگیری ماشینی توسط کانین و همکاران انجام گردید [۳۵]. ویژگی‌های سیال و داده‌های سرعت، ورودی‌های مدل توسعه‌یافته و پاسخ افت فشار و کسر پسماند از خروجی‌های مدل مذکور بوده‌اند. گائو و همکاران یک شبکه عصبی کانولوشنی مبتنی بر کانال زمان<sup>۱</sup> را برای تخمین توقف در یک جریان دو فازی ارائه دادند. این الگوریتم یک روش نظارتی بود که داده‌های ورودی را از چهار حسگر رسانایی توزیع شده دریافت می‌کرد [۳۶]. بیشتر مطالعات قبلی اشاره شده بر روی سیستم‌های گاز-مایع متمرکز شده‌اند.

همان‌طور که معمولاً گفته می‌شود، الگوریتم‌های یادگیری عمیق اساساً برای استفاده از تصاویر برای بینایی کامپیوتر، استخراج ویژگی، پردازش بصری/تصویر، و تخمین پارامترها در زمینه‌های مختلف تحقیقاتی توسعه یافته‌اند. تا جایی که ما می‌دانیم، تلاشی‌های مختصر و ناکافی برای استفاده از تصاویر جریان دو فازی در برنامه‌های یادگیری عمیق برای توصیف جریان وجود دارد. مطالعه حاضر قابلیت یک الگوریتم یادگیری عمیق جدید توسعه یافته به نام شبکه عصبی مرسوم جریان<sup>۲</sup> را بر روی یک جریان نفت-آب دو فازی مشخص بررسی می‌کند. برای این هدف، رفتار جریان در یک لوله افقی و شیبدار با زاویه ۳۰° از طریق تصویربرداری از جریان بررسی گردیده است. در بخش آزمایشگاهی، نفت و آب به طور همزمان با سرعت‌های مختلف از ۰/۱ تا ۰/۹ m/s و کسرهای آب ورودی (بین ۰/۱۸ و ۰/۹۸) تنظیم شده‌اند. تصاویر گرفته شده از جریان از طریق

1. Multitask-based Temporal-channel-wise Convolutional Neural Network (MTCCNN)  
2. Flow Conventional Neural Network (FCNN)  
3. FaSt Closing Valves



شکل ۱ آرایشی تنظیمات آزمایش مورد استفاده در مطالعه حاضر

یافته و تصاویر جریان توسط یک دوربین سریع (دوربین دیجیتال کنون مدل Canon EOS M50) گرفته شده‌اند. سرعت تصویربرداری، سرعت فریم دوربین در عکس‌برداری‌ها برابر با ۳۶۰۰ فریم بر ثانیه می‌باشد.

#### شبکه‌های عصبی کانولوشنی


در مطالعه حاضر، یک مدل یادگیری عمیق که قادر به پیش‌بینی رژیم جریان و کسر پسماند مایع بر اساس تحلیل تصویر الگوی جریان ورودی و یادگیری فیزیک زیربنایی است، پیشنهاد شده‌است. مدل پیشنهادی پدیده‌ای فیزیکی را در لایه‌های شبکه تعبیه می‌کند. شبکه عصبی کانولوشنی به عنوان یکی از مشهورترین روش‌های یادگیری عمیق، قادر به تخمین پارامترهای فیزیکی غیرخطی براساس داده ورودی است [۴۱-۴۲]. یک شبکه عصبی کانولوشنی تصاویر ورودی را فیلتر می‌کند، ویژگی‌های سطح بالا را از طریق لایه‌های مختلف شبکه محاسبه می‌کند و به طور مداوم ابعاد تصویر ورودی را به یک کد کاهش می‌دهد تا بتواند مقدار خروجی را اندازه‌گیری کند. سپس خروجی شبکه عصبی از سه لایه نرونی متراکم عبور داده می‌شود تا ماشین قادر به پیش‌بینی ویژگی‌های ذکر شده در قالب نظارتی باشد. یادگیری تحت نظارت وظیفه‌ای است که مستقیماً یک ورودی را به یک خروجی

فازها در دبی‌های مختلف از  $0.1$  تا  $0.9$  m/s و کسرهای آب (بین  $0.18$  و  $0.98$ ) پمپ شده‌اند تا امکان جمع‌آوری یک مجموعه داده جامع فراهم گردد. عملاً ابتدا فاز نفتی جریان می‌یابد و آب به تدریج به خط وارد می‌شود تا به کسر فاز اولیه مطلوب برسد [۶]. کشش سطحی بین آب و کروزن  $17/2$  mN/m اندازه‌گیری شد. علاوه بر این، برای بررسی صحیح الگو، جریان باید کاملاً توسعه یافته و تثبیت شده باشد [۱۰]. مشخصات سرعت جریان کاملاً توسعه یافته، در طول جریان سیال تغییر نمی‌کند، بنابراین الگوی جریان در تمام جهات در مسیر پایدار می‌باشد. به طور کلی، معیاری به عنوان طول ورودی تعریف شده است، که شرایط کاملاً توسعه یافته را تعیین می‌کند. در این شرایط با در نظر داشتن خصوصیات لوله (طول و قطر لوله) و خصوصیات سیال عبوری، مقدار مشخصی از طول اولیه برای جریان عبوری نیاز است تا جریان کاملاً به صورت توسعه یافته باشد. طول ورودی لوله مورد نیاز، بخشی از لوله است که یک سیال پس از ورود به لوله در آن جریان می‌یابد و با شرایط کاملاً توسعه یافته مواجه می‌شود [۳]. در اینجا، توزیع جریان در داخل لوله به صورت بصری بررسی شده و طول لوله ورودی در حدود  $3/6$  m به صورت تجربی اندازه‌گیری گردید. پس از این طول، جریان به طور کامل توسعه

تصویر از چندین لایه عبور داده شده تا الگوی جریانی مورد نظر و کسر پسماند آن را به خروجی برساند. شبکه تحت نظارت طراحی شده به عنوان شبکه عصبی کانولوشنی جریانی<sup>۱</sup> نام‌گذاری می‌شود. شبکه مشخص شده در **شکل ۲** بیانگر لایه‌های اصلی اثرگذار بر روی آنالیزهای تصویر هستند. با عبور از هر لایه، مجموعه‌ای از اقدامات و توابع ریاضیاتی بر روی تصاویر اعمال می‌شوند تا ویژگی‌های تصویری را استخراج نمایند. جزئیات هر یک از این لایه‌ها و اندازه تصویری ورودی که خروجی لایه قبلی می‌باشد نیز در **جدول ۱** ارائه شده است.

از طریق فرآیند آموزش، ترسیم می‌کند. در تمامی مطالعات حوزه یادگیری عمیق مشخص شده است که شبکه‌های عصبی کانولوشنی دقت عملکرد بالاتری نسبت به سایر روش‌ها در زمان کمتر یادگیری هستند. علت این مساله را می‌توان در مزیت این شبکه نسبت به سایر روش‌ها به دلیل در اختیار داشتن ابزار کانولوشن بین لایه‌های مختلف آنالیز تصویر دانست.

آرایش ساختار پیشنهادی در **شکل ۲** و در **جدول ۱** به تفصیل توضیح داده شده است. تصویر جریان دوفازی گرفته شده به عنوان ورودی وارد شبکه می‌شود.



**شکل ۲** ساختار طراحی شده برای شبکه عصبی کانولوشنی جریانی (M) بیشینه ادغام، (C) لایه کانولوشنی، (F) لایه ادغام، (A) فعال‌سازی تابع ReLU.

**جدول ۱** شرح جزئیات مدل شبکه عصبی کانولوشنی جریانی

| لایه | نوع            | اندازه ورودی              | هسته <sup>۱</sup> | گزینه‌ها                 |
|------|----------------|---------------------------|-------------------|--------------------------|
| ۱    | ورودی          | $320 \times 320 \times 3$ | -                 | عادی سازی                |
| ۲    | لایه ادغام     | $160 \times 160 \times 3$ | -                 | $2 \times 2$ بیشترین پول |
| ۳    | لایه کانولوشنی | $80 \times 80 \times 6$   | $3 \times 3$      | $2 \times 2$ بیشترین پول |
| ۴    | لایه کانولوشنی | $40 \times 40 \times 12$  | $3 \times 3$      | $2 \times 2$ بیشترین پول |
| ۵    | لایه کانولوشنی | $20 \times 20 \times 18$  | $3 \times 3$      | $2 \times 2$ بیشترین پول |
| ۶    | کاملاً متصل    | $1 \times 1 \times 14401$ | -                 | لایه مسطح                |
| ۷    | کاملاً متصل    | $1 \times 1 \times 2$     | -                 | فعال سازی ReLU           |
| ۸    | خروجی          | $1 \times 1 \times 2$     | -                 | عادی سازی نشده           |

هر لایه کانولوشن با یک لایه ادغام حداکثر دنبال می‌شود تا اندازه داده‌ها را بدون از دست دادن اطلاعات قابل توجه، فشرده کند.

در شبکه عصبی کانولوشنی جریانی، بلوک شبکه عصبی از لایه‌های مختلفی تشکیل می‌شود که در آن‌ها هر یک عملکرد خاص خود را برای پردازش ویژگی‌های استخراج شده، دارند. سه لایه کانولوشن به تصویر کشیده شده، داده‌های ورودی را در هر مرحله برای استخراج ویژگی‌ها ادغام می‌کنند.

1. Flow Convolutional Neural Network (FCNN)

2. Flatten Layer

3. Kernel

را به صورت ابزارهای محاسباتی در اختیار کاربر قرار دهند، اما این فرضیات معمولاً فرضیات ساده شونده هستند. در همین راستا همیشه استفاده از روش‌های آزمایشگاهی مطالعات مناسبی را در اختیار پژوهشگران قرار می‌دهند. در زمینه جریان دو فازی، به طور کلی نموداری به نام الگوی جریان/نقشه رژیم، نمای کلی از موقعیت‌های آزمایشی را که رژیم‌های جریان متفاوتی را تولید می‌کنند، نشان می‌دهد. نقشه رژیم جریان یک نمای کلی از مشاهدات آزمایشگاهی ارائه می‌دهد و شرایط مرزی را برای انتقال بین رژیم‌های جریان مختلف نشان می‌دهد [۱ و ۳ و ۲۶].

قبل از تولید نقشه جریان، لازم است جریان را از طریق طبقه‌بندی‌های فیزیکی دسته‌بندی کرد. رویکردهای مختلفی برای طبقه‌بندی جریان بر اساس شکل جریان یا سلطه نفت-آب وجود دارند [۳ و ۲۳ و ۲۶]. یک طبقه‌بندی موفق که توسط محققان قبلی اعمال شده است، الگوهای جریان را به سه دسته اصلی تقسیم می‌کند: طبقه‌بندی شده<sup>۵</sup> (فازها در لایه‌های جداگانه جریان می‌یابند)، پیوسته دوگانه<sup>۶</sup> (فازها به صورت لایه‌هایی که در فصل مشترک دوفاز، اختلاط دارند، یا در قالب حلقوی که یکی از فازها، دیگری را احاطه نماید) و رژیم‌های جریان پراکنده<sup>۷</sup> (یک فاز در فاز دیگر پراکنده است) [۲۶]. باید توجه داشت که الگوی جریان را می‌توان از طریق بررسی بصری، کاوشگرهای صوتی [۴۳]، سنسورهای رسانایی [۴۰]، رفتار کاهش فشار [۶] و چگالی سنجی پرتو گاما چند پرتویی<sup>۸</sup> [۴۴] تعیین کرد. شکل الف<sup>۳</sup> نقشه رژیم جریان را در آزمایش‌های پیشنهادی نشان می‌دهد.

خروجی این لایه‌ها از یک تابع مسطح، عبور می‌کند که نوعی لایه کاملاً متصل است و در اندازه مناسب برای لایه‌های متراکم قرار می‌گیرد. لایه‌های کاملاً متصل، نورون‌ها را در یک لایه به نورون‌های لایه دیگر متصل می‌کنند. قبل از ارسال خروجی به لایه‌های متراکم، داده‌ها توسط توابع فعال‌سازی کنترل می‌شوند. واحدهای خطی اصلاح شده<sup>۱</sup> یا همان ReLU به‌عنوان تابع فعال‌سازی، خروجی‌های منفی نتایج کانولوشن را به صفر تبدیل می‌کند. مزیت این توابع در این است که جزئیات و ویژگی‌های بهتری نسبت به توابع خطی استخراج می‌نماید. از طریق پردازش تصویر و استخراج ویژگی، ساختارهای مختلف مورد ارزیابی قرار گرفته‌اند و فرمت فعلی با دقت مناسب، بهینه شده است. طرح‌های مختلف برای تنظیم دقیق ساختار مدل، آزمایش گردیدند. در هر طرح، پارامترهای قابل تنظیم در هر لایه از طریق یک الگوریتم بهینه‌سازی (بهینه‌ساز آدام<sup>۲</sup>) که از آنتروپی متقاطع باینری وزنی<sup>۳</sup> به‌عنوان تابع هدرفت<sup>۴</sup> استفاده می‌کند، اصلاح می‌شوند. یکی از مهمترین ویژگی‌های آنتروپی متقاطع باینری وزنی دقت آن‌ها در آموزش شبکه‌های از نوع دسته‌بندی می‌باشد.

$$BCE = \frac{1}{2} \sum_{i=1}^2 [m_i (-\log(p_i)) + (1-m_i) (-\log(1-p_i))] \quad (1)$$

در اینجا  $m$  مقدار واقعی به‌دست آمده از آزمایش و  $p$  تخمین مدل برای تحقق  $i$  است. حد بالای "2" در رابطه نشان می‌دهد که دو مجموعه داده الگوی جریان و کسر پسماند مایع وجود دارد. این نوع تابع هدرفت دقت یک طبقه‌بندی باینری را ارزیابی می‌کند و مقادیر بین ۰ و ۱ را برمی‌گرداند. در جدول ۱ اطلاعات دقیق در مورد لایه‌های مختلف موجود در ساختار بهینه‌شده برای شبکه عصبی کانولوشنی جریانی ارائه شده است.

## نتایج و بحث و بررسی

### نتایج مطالعه آزمایشگاهی

روش‌های مطالعاتی تجربی و مکانیکی همیشه در بردارنده فرضیاتی در مطالعات هستند که آنالیز

1. Rectified Linear Units (ReLU)

2. Adam

3. Weighted Binary Cross Entropy (WBCE)

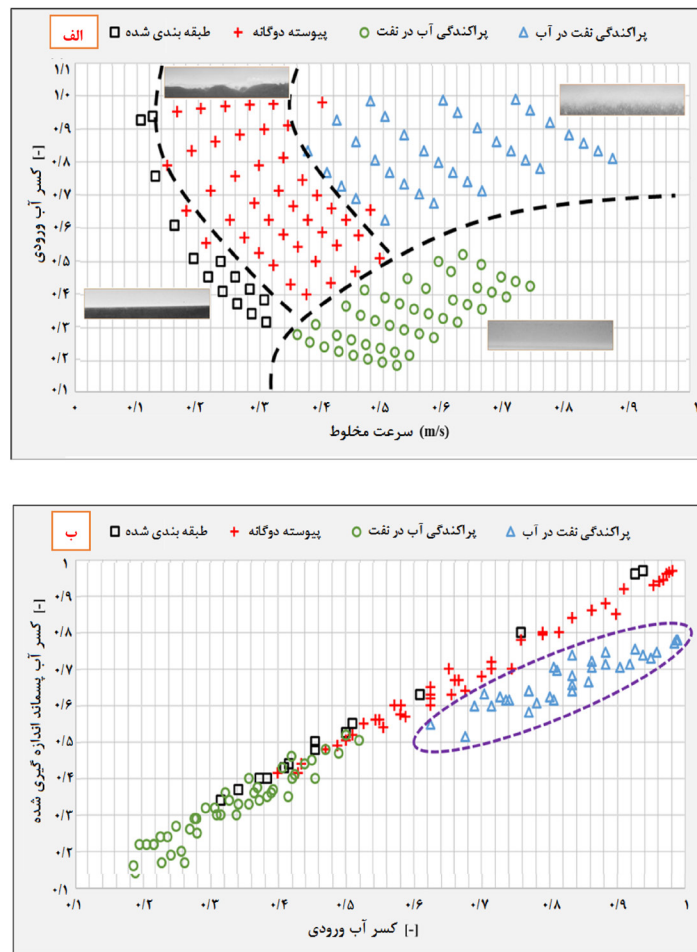
4. Loss Function

5. Stratified

6. Dual Continuous

7. Dispersed Flow

8. Multi-beam gamma-ray Densitometry



شکل ۳ (الف) نقشه الگوی جریان حاصل - لوله افقی و (ب) مقایسه بین کسر ورودی آب و کسر پسماند - لوله افقی

جریان‌های پراکنده یعنی جریان پراکنده نفت در آب زمانی که کسر ورودی آب زیاد بوده و جریان پراکنده آب در نفت زمانی که کسر ورودی آب کم بوده است، مشاهده گردید. به عبارت دیگر، زمانی که هر یک از فازهای جریان در درصد کمتری را در ورودی داشته است به وسیله فاز دیگر مخلوط و جریان یافته است. یکی دیگر از پارامترهای مورد بحث، کسر پسماند مایع است که با استفاده از درجه‌های بسته شونده سریع در تمام آزمایش‌ها اندازه‌گیری گردید. درجه‌های سریع شونده اندازه‌گیری دقیق مقدار کسر پسماند فازها را فراهم می‌سازد. مقایسه بین کسر ورودی آب و کسر پسماند آب در شکل ۳ نشان داده شده است. تقریباً بیشتر داده‌ها در یک روند خطی پخش می‌شوند. با این حال، در جریان پراکنده نفت در آب، کسر پسماند به دلیل تعامل

خط چین‌های کشیده شده در شکل موید جدایش‌های فازی است که مبنای بسیاری از مطالعات تشخیص نوع رژیم جریانی می‌باشد. علت این مساله در این نکته نهفته است که هر رژیم جریانی معمولاً عملکرد یکسانی از منظر رفتار مکانیکی از خود نشان می‌دهد. در نتیجه ضروری است تا تشخیص الگوی جریانی به طرز مناسبی انجام شود. در سرعت‌های پایین‌تر مخلوط، رژیم جریان طبقه‌بندی شده، الگوی جریان رایج در تمام کسرهای ورودی آب است.

در سرعت‌های متوسط مخلوط، جریان غالب پیوسته دوگانه است که در بخش‌های آب با کسر ورودی بالاتر از ۰/۵ شکل می‌گیرد. علت این مساله غلبه فاز آب در بحث اختلاف بین دانسیته دو سیال می‌باشد. علاوه بر این، در سرعت‌های مخلوط بالا،

مایع به عنوان خروجی ذخیره گردیدند. در مطالعات جریان دو فازی، داده‌های چشمگیر الگوی نوع جریان است که از تصاویر استخراج می‌شود. **شکل الف ۵** میانگین هیستوگرام برای مقادیر مقیاس خاکستری هر نوع رژیم جریانی را نشان می‌دهد. تفاوت بین این موارد و ارزیابی عملی از طریق آموزش‌های مختلف نشان می‌دهد که داده‌های تصویر برای تشخیص رژیم جریانی و کسر پسماند کافی است و نیازی به داده‌های بیشتر نیست. منظور از داده‌های بیشتر داده‌های مورد استفاده در مدل‌های تجربی و یا مکانیکی ارائه شده می‌باشد.

برای تهیه تصاویر برای یادگیری ماشین، تصویر باید در فرمت باینری یا همان دوتایی بوده که فقط شامل ۰ و ۱ می‌باشد. مدیریت تصویر از طریق الگوریتم باینری شده آتسو انجام می‌شود [۴۵]. مبنای آنالیز دوتایی سازی تصاویر به این نحو است که پس از انجام آزمایشات و تشخیص نوع الگوی جریانی، باینری سازی تصویر براساس الگوریتم اشاره شده انجام می‌شود تا همان تصویر به فرمت باینری و پس از بررسی مجدد توسط آزمایش‌گر جهت یادگیری شبکه عمیق آماده گردد. ساختار پایگاه داده آماده شده در **جدول ۲** ارائه شده است. تست‌های آزمایشگاهی پایه، مبنای آماده‌سازی پایگاه داده بوده است. پایگاه داده تولید شده شامل تصویر الگوی جریان، نوع رژیم جریانی و کسر پسماند مایع برای هر یک از آزمایش‌های انجام شده است. تعداد کل داده‌های آزمایشگاهی ۲۷۰ عدد بوده که شامل جریان پراکنده آب در نفت، دوگانه پیوسته و پراکنده نفت در آب در دو زاویه شیب صفر و ۳۰° می‌باشند.

#### شبکه عصبی کانولوشنی جریانی آموزش دیده

مورد بعدی آموزش و بهینه‌سازی شبکه عصبی کانولوشنی جریانی و ارزیابی عملکرد شبکه آموزش دیده است. حدود ۷۰٪ پایگاه داده به صورت تصادفی برای آموزش شبکه و ۳۰٪ باقیمانده برای آزمایش انتخاب گردیدند.









نفت و آب و تمایل ترشوندگی شیشه پلکسی، از خط مستقیم منحرف می‌شود. این انحراف، در ناحیه بیضوی جدا شده با نقطه چین نشان داده شده است. تمایل ترشوندگی در لوله‌های مورد مطالعه مساله‌ای است که تا کنون در اکثر روش‌های مکانیکی لحاظ نشده است. با آنالیز تصویری می‌توان این خلا مطالعاتی سایر روش‌های موجود را پاسخ داد.


علاوه بر آزمایش‌ها با لوله افقی، شرایط مشابه برای لوله‌های شیبدار ۳۰° به سمت بالا اعمال شد. **شکل ۴** الگوی جریان و کسر پسماند را در لوله شیبدار ۳۰° نشان می‌دهد. در لوله شیبدار انتظار جدایش سیالات به دلیل اختلاف در تاثیر نیروی گرانش نیز می‌رود. همان‌طور که انتظار می‌رود، شیب به تفکیک بهتر مرزهای الگوی جریان، کمک می‌نماید. محققان پیشین نیز اعلام داشته‌اند که الگوهای جریانی پراکنده آب در نفت که به نیروی گرانش مربوط می‌شود، در سطوح شیبدار بهتر گسترش یافته‌اند [۱۵ و ۱۶]. علاوه بر این، برخی از نقاط که در جریان افقی با عنوان جریان طبقه‌بندی شده تعیین گردیدند، زمانی که شیب لوله تا ۳۰° افزایش یافت، به جریان دوگانه پیوسته تبدیل گردیدند. تفاوت دیگر در کسر پسماند مایع بود که کاهش قابل توجهی در همه موارد به دلیل تاثیر گرانش داشته است. اضافه شدن نیروی گرانش به نوعی سبب فراهم شدن انسجام درون فازی برای هریک از فازها شده است که کسر پسماند مایع به همین دلیل کاهش یافته است.

#### آماده‌سازی پایگاه داده


پس از انجام تست‌های جامع آزمایشگاهی و طبقه‌بندی نوع جریان بر اساس تصاویر، مرحله بعدی تهیه و ارزیابی پایگاه داده است. همان‌طور که قبلاً ذکر شد، آزمایش‌های مختلفی در شرایط گوناگون برای ایجاد یک نقشه رژیم جریانی یا پایگاه داده جامع برای توصیف‌های بیشتر انجام شد. نتایج در یک قالب برداری حاوی تصاویر جریان دوتایی به عنوان ورودی و کد الگوی جریان و کسر پسماند

جدول ۲ ساختار پایگاه داده تهیه شده

| داده ورودی  |  | داده خروجی        |           |
|---|--|-------------------|-----------|
| تصویر جریان   | تصاویر باثیری (دو تایی)  | رژیم جریانی       | پسماند آب |
|    |    | طبقه بندی شده     | ۰/۴       |
|    |    | پیوسته دوگانه     | ۰/۵۵      |
|   |    | آب پراکنده در نفت | ۰/۱۷      |
|  |  | نفت پراکنده در آب | ۰/۷۲۵     |



شکل ۴ (الف) نقشه الگوی جریان حاصل - لوله شیبدار و (ب) مقایسه بین کسر ورودی آب و کسر پسماند - لوله شیبدار




شکل ۵ (الف) نمودار هیستوگرام برای گروه‌های مختلف تصاویر موجود در پایگاه داده و (ب) کاهش عملکرد هدر رفت در طول فرآیند آموزش

کانولوشنی جریانی آموزش دیده را در پیش‌بینی رژیم جریانی از تصاویر الگوی جریان، نشان می‌دهد. در سیستم پراکنده آب در نفت در لوله افقی، دقت مدل به دلیل تار بودن تصاویر نسبت به سایر تصاویر، کمتر می‌باشد. به طور کلی، این مدل قادر به پیش‌بینی الگوی جریان افقی با دقت ۹۱٪ است. در مطالعه لوله شیبدار، نتایج به این دلیل که لوله شیبدار است و گرانش به شکل‌گیری رژیم‌های جریانی واضح‌تر، کمک می‌کند، از دقت بالاتری برخوردار می‌باشند. به طور کلی، دقت برای پیش‌بینی الگوی جریان در الگوهای جریانی شیبدار ۹۶٪ می‌باشد.

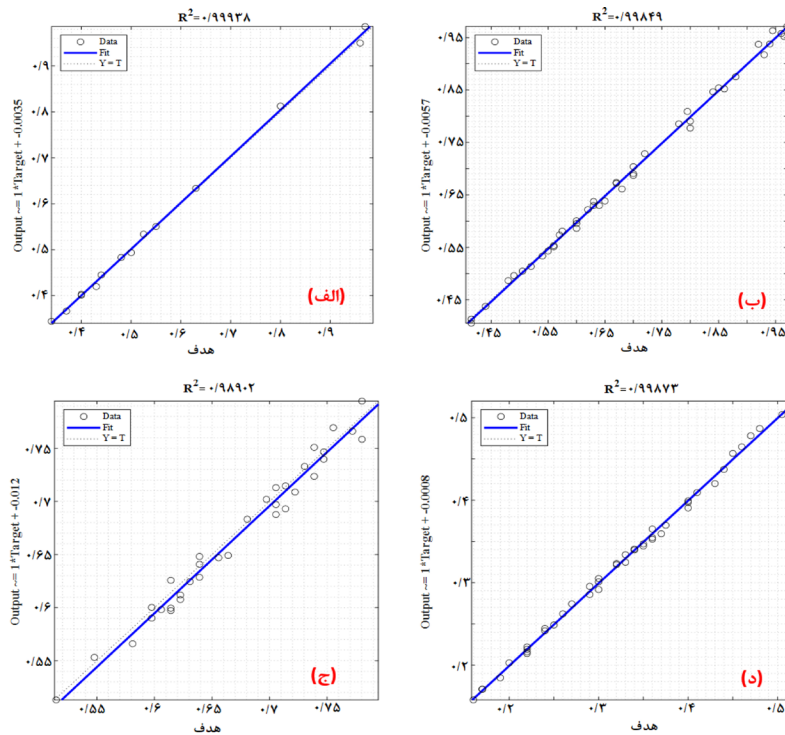
**شکل‌های ۷ و ۸** کسر پسماند ( $\alpha$ ) اندازه‌گیری شده و مقادیر پیش‌بینی شده را با هم مقایسه می‌کنند. نتایج نشان می‌دهد که مدل قادر به پیش‌بینی کسرهای پسماند با متوسط خطای نسبی مطلق (AARE)  $1/216$  و  $0/981$  به ترتیب برای خط لوله افقی و شیب  $30^\circ$  است. نحوه اندازه‌گیری متوسط خطای نسبی مطلق در فرمول شماره ۲ تعریف شده است:

$$AARE(\%) = 100 \times \frac{\sum_{i=1}^n |H_{measured_i} - H_{estimated_i}|}{n} \quad (2)$$


درصد تقسیم‌بندی بر اساس استاندارد مطالعات یادگیری عمیق انجام شده است. ساختار انتخاب شده برای شبکه عصبی کانولوشنی جریانی، بر اساس **جدول ۱**، به دلیل آزمایش طرح‌های مختلف و ارزیابی‌های آموزشی، مناسب‌ترین ساختار برای آموزش است. آموزش از طریق پردازنده گرافیکی در سیستمی با کارت گرافیک Nvidia GeForce GTX 1080 Ti که قابلیت حافظه محاسباتی آن ۱۱ گیگابایت و با فرکانسی حدود ۱۴۰۰ MHz است، انجام گردید. مدت زمان آموزش بر روی کارت گرافیک حدود ۴۰ h بوده است. **شکل ۵** کاهش عملکرد هدررفت شبکه آموزش دیده و کاهش تدریجی آن را در طول آموزش که باعث بهبود دقت مدل شده را نشان می‌دهد. منظور از کاهش عملکرد یا مقدار هدررفت، کاهش اختلاف بین نتایج به‌دست آمده از تشخیص شبکه عمیق و مقدار آزمایشگاهی می‌باشد. با کاهش اختلاف اشاره شده خطای محاسباتی کاهش یافته و شبکه آموزش دیده بر مبنای ساختار شبکه قابلیت تشخیص رژیم جریانی و کسر حجمی پسماند را دارد. برای بررسی دقت مدل، داده‌های آزمایش از طریق شبکه آموزش دیده منتقل می‌شوند و نتایج با اندازه‌گیری‌های آزمایشگاهی مقایسه گردیدند. در ادامه، نتایج تمامی نمونه‌های موجود در پایگاه داده ارائه شده است. **شکل ۶** دقت شبکه عصبی



شکل ۶ مقایسه دقت پلتفرم آموزش دیده در پیش‌بینی رژیم‌های جریانی مختلف



شکل ۷ مقایسه بین پسماند پیش‌بینی شده و اندازه‌گیری شده در خط لوله افقی: (الف) رژیم جریان طبقه‌بندی شده، (ب) رژیم جریان مداوم دوگانه، (ج) آب پراکنده در نفت و (د) نفت پراکنده در آب



شکل ۸ مقایسه بین پسماند پیش‌بینی شده و اندازه‌گیری شده در خط لوله شیب‌دار: (الف) رژیم جریان طبقه‌بندی شده، (ب) رژیم جریان مداوم دوگانه، (ج) آب پراکنده در نفت و (د) نفت پراکنده در آب

ارائه می‌دهد. بالاترین مقدار میانگین مربعات خطا مربوط به نفت پراکنده در آب می‌باشد که دلیل آن به خاطر نحوه جریان نفت در آب است که پیچیده‌تر از سایر الگوهای جریان می‌باشد. علت این پیچیدگی اختلاط فازی بوده که ذرات نفت به صورت ریزتر در آب جابه‌جا می‌شوند و البته جدایش آنها نیازمند کاهش سرعت سیال است. در این سرعت‌ها تصویر اخذ شده نیز دارای پیچیدگی بوده و تشخیص شبکه عمیق را کمی سخت می‌نماید. با این حال، مقدار میانگین مربعات خطا مربوطه در خط لوله شیدار، کمتر می‌باشد که دلیل این امر جداسازی فازها در سطح شیدار است.

در اینجا  $n$  تعداد کل آزمایش‌ها است.  $\alpha_m$  پسماند اندازه‌گیری شده و  $\alpha_p$  پسماند برآورد شده توسط شبکه عصبی کانولوشنی جریانی است. پارامتر دیگری که تخمین زده شد، میانگین مربعات خطا (MSE) بود که برای پیش‌بینی دقت استفاده شد (معادله ۳).

$$MSE = \frac{\sum_{i=1}^n [(H_{measured_i} - H_{estimated_i})]^2}{n} \quad (3)$$

مقادیر میانگین مربعات خطا برای خط لوله افقی و شیدار به ترتیب  $0.000736$  و  $0.000418$  محاسبه گردید. جدول ۳ مقادیر متوسط خطای نسبی مطلق و میانگین مربعات خطا را برای هر رژیم جریانی

جدول ۳ مقادیر متوسط خطای نسبی مطلق و میانگین مربعات خطا را برای هر رژیم جریانی

| رژیم جریانی       | پسماند- لوله افقی        |                    | پسماند- لوله شیدار       |                    |
|-------------------|--------------------------|--------------------|--------------------------|--------------------|
|                   | متوسط خطای نسبی مطلق (%) | میانگین مربعات خطا | متوسط خطای نسبی مطلق (%) | میانگین مربعات خطا |
| طبقه بندی شده     | ۱/۰۸۹۹                   | ۰/۰۰۰۰۵۹۱          | ۰/۸۶۶۶                   | ۰/۰۰۰۰۲۴۶          |
| پیوسته دوگانه     | ۱/۰۹۸۵                   | ۰/۰۰۰۰۸۵۲          | ۱/۱۰۶۱                   | ۰/۰۰۰۰۷۲۳          |
| آب پراکنده در نفت | ۱/۲۳۸۶                   | ۰/۰۰۰۰۲۳۱          | ۰/۹۶۷۷                   | ۰/۰۰۰۰۵۶۴          |
| نفت پراکنده در آب | ۱/۴۳۶۹                   | ۰/۰۰۰۰۱۲۷          | ۰/۹۸۴۱                   | ۰/۰۰۰۰۱۳۷          |

مدل‌های مکانیکی معمولاً جهت آنالیز افت فشار جریانی استفاده می‌شوند. این مدل‌ها معمولاً محدود به الگوی جریانی هستند، به عنوان نمونه روش مدل هموزن بیشتر برای جریانات پراکنده، مدل دو سیال و مدل دریافت فلاکس نیز عموماً برای جریان جدا شده به کار برده می‌شوند [۳۲].

به منظور مقایسه با روش‌های تجربی، از مدل‌سازی انتقال بین الگوهای جریان با روش ارائه شده توسط [۶] می‌پردازیم. در مطالعه ارائه شده با استفاده از فرمول ۴ جدایش بین فازهای جریانی انجام می‌شود.

$$V_w = aV_o + bV_o \left[ \left( \frac{V_o}{V_m} \right)^c \times \left( \frac{V_m \mu_m}{\sigma} \right)^d \right] \quad (4)$$

در این رابطه منظور از  $V_w$  سرعت فاز آب،  $V_o$  سرعت فاز نفت،  $V_m$  سرعت مخلوط،  $\mu_m$  ویسکوزیته ترکیب و  $\sigma$  کشش سطحی بین فازها می‌باشد. ضرایب  $a$ ,  $b$

شایان ذکر است مشکلی که باعث ایجاد انحراف و خطا در پیش‌بینی دقیق می‌شود، تار شدن تصاویر جریان در دبی‌های بالا در نزدیکی مرز بین الگوهای جریان مختلف است. با این حال، نتایج به‌دست آمده این ایده را تایید می‌کند که مدل در دبی‌های متوسط و پایین، دقیق‌تر است. منظور از تار شدن تصاویر اختلال فازی و درهم تنیدگی به وجود آمده در دبی‌های بالاتر است، که معمولاً در نزدیکی مرزهای جریانی مشخص می‌شود.

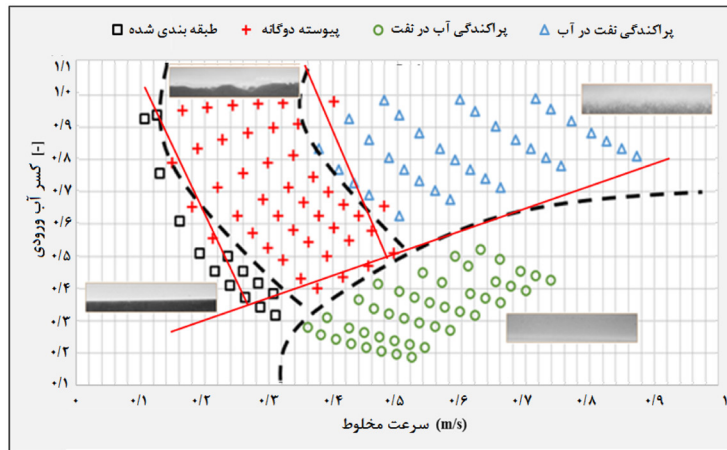
در ادامه به بررسی کیفیت مدل‌سازی داده‌های جریان افقی انجام شده در این مطالعه توسط روش یادگیری عمیق با مدل‌های تجربی (پیش‌بینی‌کننده رژیم جریانی) می‌پردازیم. از آنجایی که مدل‌های تجربی عمدتاً در جریانات افقی هستند، آنالیز را صرفاً برای جریان افقی انجام می‌دهیم. شایان ذکر است که

نتایج به دست آمده حکایت از دقت مناسب روش ارائه شده در جدایش فازی و قابلیت تطبیق با مرزبندی به روش‌های تجربی ارائه شده توسط سایر محققان این حوزه را دارد.

c, d نیز ثوابت تجربی به دست آمده هستند که در مقادیر آنها در **جدول ۴** ارائه شده است. مقایسه بین نتایج این جدایش فازی با نتایج تحقیق به دست آمده در **شکل ۹** انجام شده است.

**جدول ۴** پارامترهای مورد استفاده جهت مدل‌سازی مرزبندی الگوهای جریان

| پارامتر | پیوسته دوگانه-نفت پراکنده در آب | پیوسته دوگانه-آب پراکنده در نفت | طبقه‌بندی شده-پیوسته دوگانه |
|---------|---------------------------------|---------------------------------|-----------------------------|
| a       | -۱/۲۲۴۶                         | ۰                               | -۰/۹۴۱۵                     |
| b       | ۱/۲۸۹۹                          | ۰/۱۴۵۱                          | ۱/۳۵۵۹                      |
| c       | -۰/۹۷۸۶                         | -۲/۲۸۶۳                         | -۱/۰۸۴۵                     |
| d       | ۰/۰۴۴۸                          | ۰/۰۰۱۰                          | ۰/۱۰۳۱                      |



**شکل ۹** مقایسه بین مرزبندی انجام شده در مطالعه حاضر و مرزبندی الگوهای جریان در مطالعه انجام شده توسط [۶]

### نتیجه‌گیری

در این مطالعه از یک روش امیدوارکننده به نام شبکه عصبی کانولوشنی جریان‌ی که مبتنی بر یادگیری عمیق می‌باشد، جهت شناسایی و پیش‌بینی الگوهای جریان دو فازی آب-نفت در لوله‌های افقی و شیب‌دار، استفاده گردید. هدف اصلی این تحقیق ارائه بررسی جامع نقشه رژیم جریان و کسر پسماند در لوله‌های افقی و شیب‌دار (زاویه ۳۰°) با استفاده از مدل شبکه عصبی کانولوشنی جریان‌ی بوده است. شبکه عصبی پیشنهادی در تشخیص الگوی جریان و تخمین پسماند کمک شایانی می‌نماید. مدل شبکه پیشنهادی قادر است الگوی جریان تصاویر ورودی را به ترتیب با دقت ۹۱٪ و ۹۶٪ برای جریان‌های

افقی و شیب‌دار پیش‌بینی نماید. تطابق بین رژیم‌های جریان‌ی آزمایشگاهی و خروجی پیش‌بینی شده توسط شبکه عصبی، قابلیت و کارایی شبکه عصبی را برای تشخیص الگوهای جریان، تأیید می‌نماید. همچنین کسر پسماند آب به ترتیب با دقت ۱/۲۲٪ و ۰/۹۸٪ برای جریان‌های افقی و شیب‌دار پیش‌بینی شده‌اند. نتایج نشان می‌دهد که مدل پیشنهادی به اندازه کافی دقیق و قابل اعتماد می‌باشد. از این‌رو، محققان با کمک مدل شبکه عصبی کانولوشنی جریان‌ی قادر خواهند بود با استفاده از تصاویر جریان، رژیم‌های جریان را به طور دقیق طبقه‌بندی نموده و پسماند حاصله را تخمین بزنند.

## مراجع

- [1]. Beggs D H, Brill J P (1973) A study of two-phase flow in inclined pipes, *Journal of Petroleum Technology*, 25: 607–617, doi.org/10.2118/4007-PA.
- [2]. Carcione J M, Picotti S, Santos J E, Qadrouh A, Almalki H S (2014) Numerical simulation of two-phase fluid flow, *Journal of Petroleum Exploration and Production Technology*, 4: 233–243.
- [3]. Trallero J L, Sarica C, Brill J P (1997) A study of oil/water flow patterns in horizontal pipes, *SPE Production and Facilities*, 12, 03: 165-172, doi.org/10.2118/36609-PA.
- [4]. Kim H J, Kim G N, Kim Y J, Woo N S, Huh S C (2021) A study on the separation efficiency of in-line type subsea oil-water separator, *Journal of the Korean Society of Industry Convergence*, 24: 253–260, doi.org/10.21289/KSIC.2021.24.3.253.
- [5]. Hussein M M, Al-Sarkhi A, Badr H M, Habib M A (2019) CFD modeling of liquid film reversal of two-phase flow in vertical pipes, *Journal of Petroleum Exploration and Production Technology*, 9: 3039-3070.
- [6]. Shams R, Tavakoli A, Shad S (2017) Experimental investigation of two phase flow in horizontal wells: Flow regime assessment and pressure drop analysis, *Experimental Thermal and Fluid Science*, 88: 55-64, doi.org/10.1016/j.expthermflusci.2017.05.011.
- [7]. Li Z C, Fan C L (2020) A novel method to identify the flow pattern of oil–water two-phase flow, *Journal of Petroleum Exploration and Production Technology*, 10: 3723-3732.
- [8]. Kabiri Samani A R, Borghei S M (2010) Pressure loss in a horizontal two-phase slug flow, *Journal of Fluids Engineering*, 132: 7, doi.org/10.1115/1.4001969.
- [9]. Abubakar A, Al-Wahaibi Y, Al-Wahaibi T, Al-Hashmi A R, Al-Ajmi A, Eshtrati M (2018) Effect of pipe diameter on horizontal oil-water flow before and after addition of drag-reducing polymer part II: holdup and slip ratio, *Journal of Petroleum Science and Engineering*, 162: 143-149, doi.org/10.1016/j.petrol.2017.12.015.
- [10]. Angeli P, Hewitt GF (2000) Flow structure in horizontal oil–water flow, *International Journal of Multiphase Flow*, 26: 1117–1140, doi.org/10.1016/S0301-9322(99)00081-6.
- [11]. Baik S, Hanratty T J (2003) Effects of a drag reducing polymer on stratified gas–liquid flow in a large diameter horizontal pipe, *International Journal of Multiphase Flow*, 29, 11: 1749-1757, doi.org/10.1016/j.ijmultiphaseflow.2003.07.004.
- [12]. Burlutskii E (2018) CFD study of oil-in-water two-phase flow in horizontal and vertical pipes, *Journal of Petroleum Science and Engineering*, 162: 524-531, doi.org/10.1016/j.petrol.2017.10.035 .
- [13]. Charles M E, Govier G T, Hodgson G W (1961) The horizontal pipeline flow of equal density oil-water mixtures, *The Canadian Journal of Chemical Engineering*, 39, 1: 27-36, doi.org/10.1002/cjce.5450390106.
- [14]. Edomwonyi-Otu L C, Angeli P (2015) Pressure drop and holdup predictions in horizontal oil–water flows for curved and wavy interfaces, *Chemical Engineering Research and Design*, 93: 55-65, doi.org/10.1016/j.cherd.2014.06.009.
- [15]. Hanafizadeh P, Hojati A, Karimi A (2015) Experimental investigation of oil–water two phase flow regime in an inclined pipe, *Journal of Petroleum Science and Engineering*, 136: 12-22, doi.org/10.1016/j.petrol.2015.10.031.
- [16]. Zhu Y, Wu X, Zhao R (2017) R32 flow boiling in horizontal mini channels: Part I. Two-phase flow patterns, *International Journal of Heat and Mass Transfer*, 115: 1223-1232, doi.org/10.1016/j.ijheatmasstransfer.2017.07.101.
- [۱۷]. میثاق ن، نیسانی سامانی ن، عبدالهی کاکرودی ع، علوی پناه س ک، بحرودی ع (۱۳۹۶) مدل‌سازی پهنه‌های اکتشاف نفتی با شبکه عصبی پرسپترون چند لایه (MLP) در GIS. پژوهش نفت، ۲۶، (۶-۹۵): ۱۶۰-۱۴۸، ..doi: 10.22078/pr.2017.724
- [18]. Bonizzi M, Issa R I (2003) A model for simulating gas bubble entrainment in two-phase horizontal slug flow, *International Journal of Multiphase Flow*, 29, 11: 1685-1717, doi.org/10.1016/j.ijmultiphaseflow.2003.09.001.
- [19]. Al-Wahaibi T, Smith M, Angeli P (2007) Effect of drag-reducing polymers on horizontal oil–water flows, *Journal of Petroleum Science and Engineering*, 57, 3-4: 334–346, doi.org/10.1016/j.petrol.2006.11.002.
- [20]. Abubakar A, Al-Wahaibi T, Al-Hashmi A R, Al-Wahaibi Y, Al-Ajmi A, Eshtrati M (2015) Influence of drag-reducing polymer on flow patterns, drag reduction and slip velocity ratio of oil–water flow in horizontal pipe, *International Journal of Multiphase Flow*, 73: 1-10, doi.org/10.1016/j.ijmultiphaseflow.2015.02.016.
- [21]. Wyatt N B, Gunther C M, Liberatore M W (2011) Drag reduction effectiveness of dilute and entangled xanthan in turbulent pipe flow, *Journal of Non-Newtonian Fluid Mechanics*, 166, 1-2: 25-31, doi.org/10.1016/j.jnnfm.2010.10.002 .
- [22]. Shams R, Shad S (2019) Experimental study of two-phase oil–polymer flow in horizontal flow path, *Experimental Thermal and Fluid Science*, 100: 62-75, doi.org/10.1016/j.expthermflusci.2018.08.028.

- [23]. Nädler M, Mewes D (1997) Flow induced emulsification in the flow of two immiscible liquids in horizontal pipes, *International Journal of Multiphase Flow*, 23, 1: 55-68, doi.org/10.1016/S0301-9322(96)00055-9.
- [24]. Li H, Wong T N, Skote M, Duan F (2014) Non-Newtonian two-phase stratified flow with curved interface through horizontal and inclined pipes, *International Journal of Heat and Mass Transfer*, 74: 113-120, doi.org/10.1016/j.ijheatmasstransfer.2014.02.052.
- [25]. Langsholt M (2012) An experimental study on polymeric type DRA used in single-and multiphase flow with emphasis on degradation, diameter scaling and the effects in three-phase oil-water-gas flow, In 8th North American Conference on Multiphase Technology, OnePetro.
- [26]. Lovick J, Angeli P (2004) Experimental studies on the dual continuous flow pattern in oil-water flows, *International Journal of Multiphase Flow*, 30, 2: 139-157, doi.org/10.1016/j.ijmultiphaseflow.2003.11.011.
- [27]. Acharya T, Casimiro L (2020) Evaluation of flow characteristics in an onshore horizontal separator using computational fluid dynamics, *Journal of Ocean Engineering and Science*, 5, 3: 261-268, doi.org/10.1016/j.joes.2019.11.005.
- [28]. Rabbani A, Babaei M, Shams R, Da Wang Y, Chung T (2020) DeePore: A deep learning workflow for rapid and comprehensive characterization of porous materials, *Advances in Water Resources*, 146: 103787, doi.org/10.1016/j.advwatres.2020.103787.
- [29]. Goodfellow I, Bengio Y, Courville A (2016) *Deep learning*, MIT press.
- [30]. Ershadnia R, Amooie M A, Shams R, Hajirezaie S, Liu Y, Jamshidi S, Soltanian M R (2020) Non-Newtonian fluid flow dynamics in rotating annular media: Physics-based and data-driven modeling, *Journal of Petroleum Science and Engineering*, 185: 106641, doi.org/10.1016/j.petrol.2019.106641.
- [31]. Chang C W, Dinh N, Cetiner S M (2017) Physics-constrained machine learning for two-phase flow simulation using deep learning-based closure relation, In American Nuclear Society Winter Meeting, Washington, DC, 1749-1752.
- [32]. Ezzatabadipour M, Singh P, Robinson M D, Guillén-Rondon P, Torres C (2017) Deep learning as a tool to predict flow patterns in two-phase flow, arXiv preprint arXiv:1705.07117, doi.org/10.48550/arXiv.1705.07117.
- [33]. Raissi M, Yazdani A, Karniadakis G E (2018) Hidden fluid mechanics: A Navier-Stokes informed deep learning framework for assimilating flow visualization data, arXiv preprint arXiv:1808.04327.
- [34]. Guillén-Rondon P, Robinson M D, Torres C, Pereya E (2018) Support Vector Machine Application for Multiphase Flow Pattern Prediction, arXiv preprint arXiv:1806.05054 https://doi.org/10.48550/arXiv.1806.05054.
- [35]. Kanin E A, Osipov A A, Vainshtein A L, Burnaev E V (2019) A predictive model for steady-state multiphase pipe flow: Machine learning on lab data, *Journal of Petroleum Science and Engineering*, 180, 727-746, doi.org/10.1016/j.petrol.2019.05.055.
- [36]. Gao Z, Hou L, Dang W, Wang X, Hong X, Yang X, Chen G (2020) Multitask-based temporal-channelwise CNN for parameter prediction of two-phase flows, *IEEE Transactions on Industrial Informatics*, 17, 9: 6329-6336.
- [37]. Wang W, Gong J, Angeli P (2011) Investigation on heavy crude-water two phase flow and related flow characteristics, *International Journal of Multiphase Flow*, 37, 9: 1156-1164, doi.org/10.1016/j.ijmultiphaseflow.2011.05.011.
- [38]. Oshinowo T, Charles M E (1974) Vertical two-phase flow part I. Flow pattern correlations, *The Canadian Journal of Chemical Engineering*, 52, 1: 25-35, doi.org/10.1002/cjce.5450520105.
- [39]. Mukherjee H, Brill J P (1983) Liquid holdup correlations for inclined two-phase flow, *Journal of Petroleum Technology*, 35, 05: 1003-1008, doi.org/10.2118/10923-PA.
- [40]. Gao Z, Yang Y, Zhai L, Jin N, Chen G (2016) A four-sector conductance method for measuring and characterizing low-velocity oil-water two-phase flows, *IEEE Transactions on Instrumentation and Measurement*, 65, 7: 1690-1697, doi: 10.1109/TIM.2016.2540862.
- [41]. LeCun Y (1989) Generalization and network design strategies, *Connectionism in Perspective*, 19, 143-155: 18.
- [42]. LeCun Y, Bengio Y, Hinton G (2015) Deep learning, *Nature*, 521, 7553: 436-444.
- [43]. Albion K, Briens L, Briens C, Berruti F (2008) Flow regime determination in horizontal hydrotransport using non-intrusive acoustic probes, *The Canadian Journal of Chemical Engineering*, 86, 6: 989-1000, doi.org/10.1002/cjce.20112.
- [44]. Tjugum S A, Hjertaker B T, Johansen G A (2002) Multiphase flow regime identification by multibeam gamma-ray densitometry, *Measurement Science and Technology*, 13, 8: 1319, doi:10.1088/0957-0233/13/8/321.
- [45]. Otsu N (1979) A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, 9, 1: 62-66.