



Predicting the Performance of Commercial Demulsifiers for Separating Brine Water from Crude Oil Emulsion using Support Vector Machine

Hassan Talebi¹, Mehrdad Mozaffarian^{*1}, Bahram Dabir¹ and Nima Esmaelian Amrabadi²

1. Department of Chemical Engineering, Amirkabir University of Technology (Tehran Polytechnic), Tehran, Iran

2. Department of Textile Engineering, Amirkabir University of Technology (Tehran Polytechnic), Tehran, Iran

mozaffarian@aut.ac.ir

DOI:10.22078/pr.2024.5189.3304

Received: July/20/2023

Accepted: March/18/2024

Introduction

In crude oil reservoirs a stable emulsion of salt water in crude oil is produced due to: the proximity of salt water to crude oil, strong mixing and the presence of natural surface active compounds such as asphaltene, resin and solid particles [1]. Emulsion of crude oil causes reduction of crude oil quality, increased viscosity, corrosion of equipment used in various sectors of the oil industry, and poisoning of catalysts in oil refineries. The most common method of demulsification of crude oil emulsion is the application of chemical compounds. The most important challenge of this method is the selection of suitable chemicals based on different operating conditions, because the performance of chemical compounds depends on the structure and compounds present in the crude oil, especially the structure and amount of asphaltene and resin [2]. For example, the results of the study by Anisimov et al [3] show that with the increase in the ratio of resin to asphaltene, the size of dispersed asphaltene particles decreases and the dispersion rate increases drastically. In addition to the ratio of resin to asphaltene, the amount of asphaltene present in the continuous phase is also important, because the amount of asphaltene directly affects the density of produced chemical surfactant's composition. The results of Anisimov and Ramala study shows that the distribution size of asphaltene particles is directly related to the performance of commercial demulsifiers

as well as the degree of aromatic nature of crude oil. On the other hand, it is not possible to determine the exact structure of asphaltene and resin. In addition to the importance of crude oil characteristics, the performance of chemical surfactants is also dependent on operating conditions. Generally, in industrial units, the temperature of the emulsion is raised by furnaces and heat exchangers before entering the desalting unit, because the performance of electrical desalters depends on the viscosity of the continuous phase and the ionic strength of the emulsion [4]. The majority of industrial desalters located in the desalting region of the country operate with alternative current and perform better with lower ionic strength and viscosity. The amount of applied heat is usually limited by considering the time of the year and the type of crude oil.

Increasing the temperature for the emulsion has limitations such as the limited heat load capacity of the furnaces and reduced quality of crude oil in case of evaporation of light compounds in the oil. In addition to increasing the temperature, dilution water is used to increase the diameter of the dispersed particles, which increases the probability of collisions of the dispersed phase. Costs incurred by acquiring dilution water are a challenge for operational units. However, the most important operational challenge is the costs incurred by the supply and environmental harm of surfactants, which means that the consumption concentration should be optimal. Until now, other methods such as

the response surface method, machine learning, etc. have been used to optimize operating conditions. For example, Dhandhi et al. [5] investigated the effect of three parameters; the demulsifier concentration, process temperature and settling time on the performance of two chemical demulsifiers based on the efficiency of brine water separation from crude oil using the response surface method.

The problem with most of the studies done on predicting the efficiency of chemical demulsifiers in the operation of separating salt water from crude oil emulsion is the lack of checking the type of crude oil in the model. In fact, models that are designed even with high coefficients of determination, but without considering the type of crude oil are not practical because a model that is designed only for a specific emulsion sample predicts the results for only one sample with high accuracy. The reason for not paying attention to the type of crude oil in these studies is the complexity of the structure of crude oil and the large number of parameters affecting the stability of brine water emulsion in crude oil. The most important parameter affecting the efficiency of an intelligent model is the ability of the model to predict the results for the evaluation data [6]. In this study, the preparation of an intelligent model that has the ability to predict the performance of commercial demulsifiers in any set of conditions, especially against the change of crude oil type, was investigated by a support vector machine. The most important point for the design of support vector machine is the tuning of hyperparameters, because most of the models and methods provided for setting Hyperparameters cannot have the same performance as theoretical and practical results. In this research, a recursive and innovative algorithm was used to adjust Hyperparameters with the priority of reducing risk and increasing the correlation coefficient for efficiencies higher than 85% in predicting the results.

Materials and Methods

Materials

Crude Oil

Four samples of crude oil were obtained from the National Iranian South Oil Company. Normal heptane and alumina column were used for SARA analysis. In addition, the percentages of water and salt, viscosity and specific density of each sample were determined according to international standards. The stability index was determined according to Equation 1.

$$ESI = \frac{As}{Ar + Re} \quad (1)$$

Demulsifier

Two samples of widely used demulsifiers were prepared in the southwestern units of the country. The prepared demulsifiers used in operational units are different from each other in terms of structure and

performance.

Dilution Water

Distilled water with pH=7.2 was used.

Methods

At first, to prepare a suitable sample for evaluating the final model, a new crude oil sample was prepared from the blending of four initial samples. To prepare a new sample, the same volume of 4 oil samples was poured into a container at a temperature of 55 °C and mixed for 5 minutes to make the new sample uniform. Experiments were performed on four prototypes at temperatures of 50 and 60 degrees, concentrations of 80, 100, and 120 ppm, and the ratios of dilution water to crude oil emulsion were 3 and 6%. For each test, 10 ml of each crude oil sample was mixed with a stirrer for 5 minutes at a speed of 4000 rpm at the conditions of temperature, dilution water ratio and the desired demulsifiers concentration. The contents were transferred into plastic bottles and placed in a thermal oven for 12 hours. The performance of each demulsifier was determined according to Equation 2.

$$R_a = \frac{V_2}{0.1(Wc_i + V_1)} \quad (2)$$

Support Vector Machine

Performance results for each demulsifier were categorized into two groups of above 85% performance and below 85% performance. Considering the advantages that a support vector machine can provide, this model was used to predict the performance results of each demulsifier according to four parameters; Emulsion stability index, temperature, demulsifier concentration and ratio of dilution water to crude oil emulsion. The efficiency of the support vector machine depends on the tuning of hyperparameters in this method of machine learning. Due to the importance of selecting the demulsifiers, a recursive algorithm was used to adjust the hyperparameters. The applied algorithm is different from the common algorithms that generally evaluate the coefficient of determination to tune the hyperparameters. In the applied method, two parameters of correlation coefficient and risk of error were used for tuning. To compare the efficiency of the proposed algorithm, the results of the adjusted model based on forecasting risk were compared with the adjusted model with the Bayesian optimization algorithm. The kernel function of the support vector machine for both demulsifiers is Gaussian function

Results and Discussion

After tuning the hyperparameters using the heuristic algorithm based on the risk of error and the algorithm based on the Bayesian optimization method for both commercial demulsifiers, the results were categorized into two classes of efficiency, namely efficiencies above and below 85%. The results show that the

optimization algorithm based on risk of error and correlation coefficient predicts the type of efficiency class for demulsifier A and demulsifier B better than the

Bayesian algorithm by 2 and 4.2 percent, respectively. Fig. 1 and 2 show the confusion matrixes of the results.




Fig. 1 Confusion matrix for Demulsifier A.

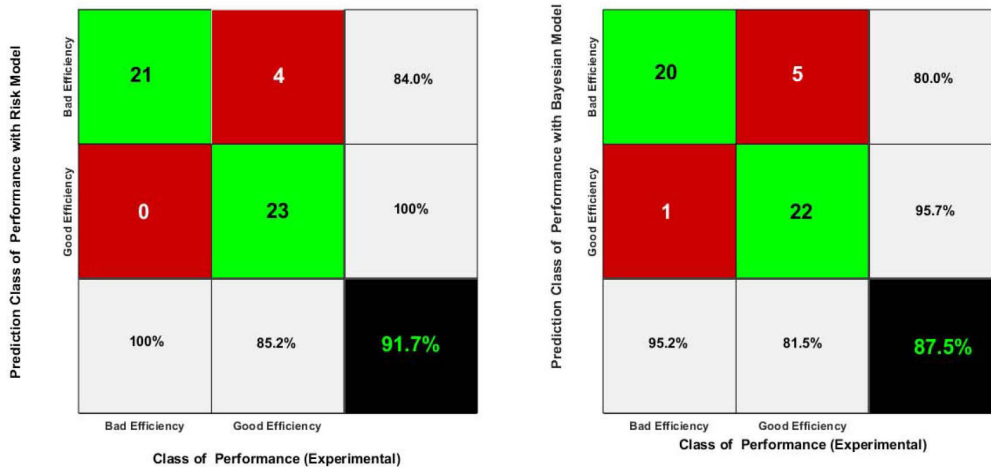


Fig. 2 Confusion matrix for Demulsifier B.

For a better comparison of the applied algorithm, the results were fitted between the experimental data and the prediction of both models for training data, validation and the total database and for both demulsifiers. The results of the comparison between the two optimization methods for demulsifier A show that the risk of error based algorithm is generally less accurate than the Bayesian algorithm for total database, but the accuracy of the risk algorithm for validation data, which indicates the efficiency of the model for data outside the training space, is better than Bayesian algorithm. Examining the model prepared for this demulsifier and for the evaluation data shows that the model tune based on the risk of error predicts the results much better than the model based on the

Bayesian algorithm. Fig. 3 and 4 show the fitting results for demulsifier A for the initial database and the evaluation data, respectively.

Similar to demulsifier A and according to Fig. 5, the risk-based model for evaluation data performs much better than the model based on the Bayesian algorithm. The results show that by using the support vector machine, which is tuned based on risk of error and correlation of coefficient, it is possible to predict the operating conditions and the type of demulsifier suitable for each crude oil sample with an accuracy of more than 85%. Predicting the performance of demulsifiers is very important in reducing laboratory and operational costs in the oil industry.

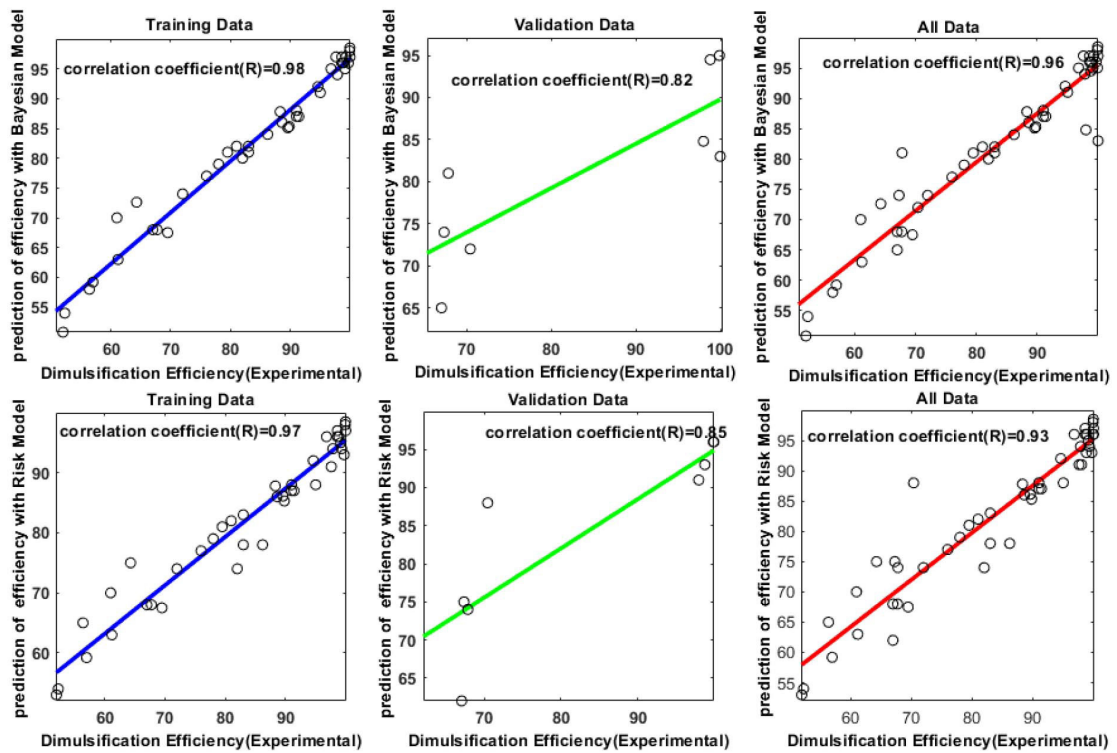


Fig. 3 Fitted result for Demulsifier A.

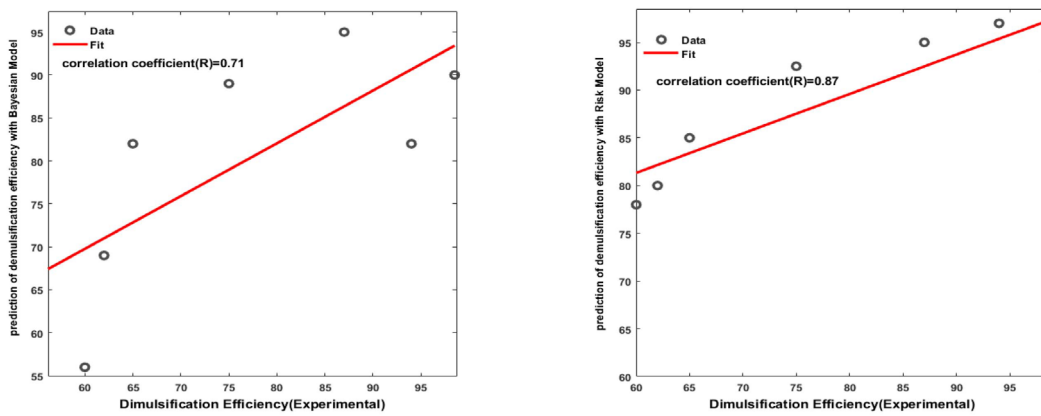


Fig. 4 Fitted result for Demulsifier A; Comparisons Evaluation of risk and Bayesian Model.

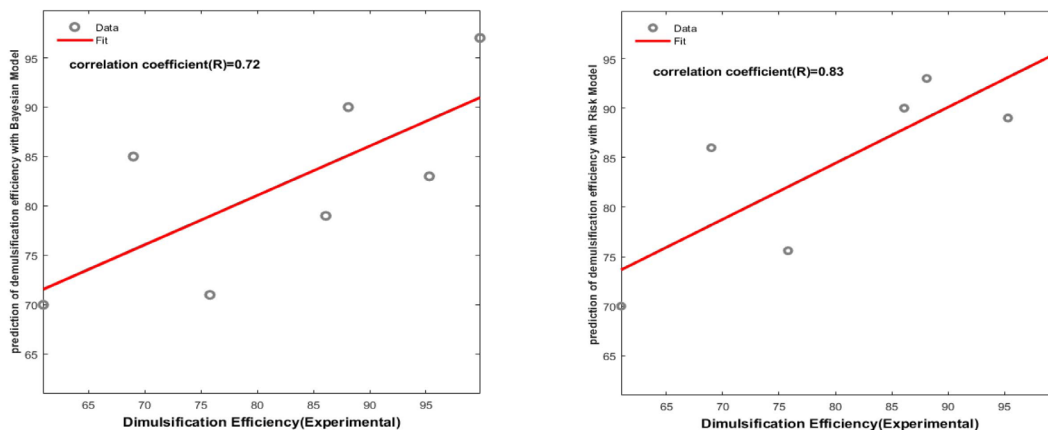


Fig. 5 Fitted result for Demulsifier A; Comparisons Evaluation of risk and Bayesian Model.

Conclusions

Emulsion of brine water in crude oil is considered harmful in many ways. Due to the high complexity of the structure of crude oil, especially the active surface compounds of asphaltene and resin, predicting the stability of crude oil is a complicated matter. The selection of commercial demulsifiers and the determination of optimal operating conditions depend on the stability of the emulsion. By using the stability index and modeling with support vector machine, the performance of commercial demulsifiers can be predicted. To improve the prediction of the model and increase the accuracy of the evaluation, a recursive algorithm based on the risk of error and the coefficient of determination was used to tune hyperparameters. By using the above mentioned algorithm, the prepared model increases the accuracy of predicting, and increases classification of the performance of commercial demulsifier into high and low efficiencies. Also, the model's evaluation results for the tuned model based on risk of error are much better than the model based on the Bayesian algorithm.

Acknowledgment

The authors express their gratitude to the research council of Amirkabir University of Technology and the engineers of the operation and research and technology units of the National Iranian South Oil Company (NISOC) for their financial and spiritual support of this research.

References

1. Abdel Raouf M. E. (2012). Crude oil emulsions-composition stability and characterization, Edition 1, Crude Oil Emulsions- Composition Stability and Characterization, BoD-Books on Demand, InTech. <https://doi.org/10.5772/2677>.
2. Speight, J. G. (2014). Chapter 3 - Corrosion in Refinery Units (J. G. B. T.-O. and G. C. P. Speight (Ed.)),39-66, Gulf Professional Publishing, doi.org/10.1016/B978-0-12-800346-6.00003-X.
3. Lashkarbolooki, M. and Ayatollahi, S. (2018). Effects of asphaltene, resin and crude oil type on the interfacial tension of crude oil/brine solution. Fuel, 223, 261-267. doi.org/https://doi.org/10.1016/j.fuel.2018.03.029.
4. Shi, Y., Chen, J. and Meng, H. (2022). Experimental study on the performance of an electric field enhanced separator for crude oil production fluid, Journal of Petroleum Science and Engineering, 212, 110315, doi.org/10.1016/j.petrol.2022.110315
5. Dhandhi, Y., Prakash, O., Naiya, T. K. and Guria, C. (2022). Statistical design and process optimization for using chemical demulsifiers for the dehydration of the crude oil, Journal of Petroleum Science and Engineering, 217, 110876, doi.org/10.1016/j.petrol.2022.110876.
6. Malley, J. D., Malley, K. G. and Pajevic, S. (Eds.). (2011). Error analysis and model validation, In statistical learning for biomedical data, 215-244, Cambridge University Press, doi: 10.1017/CBO9780511975820.012.

پیش‌بینی کارایی تعلیق شکن‌های تجاری جداکننده آب شور از امولسیون نفت خام به کمک ماشین بردار پشتیبان

حسن طالبی^۱، مهرداد مظفریان^{۱*}، بهرام دبیر^۱ و نیما اسماعیلیان عمروآبادی^۲

۱- دانشکده مهندسی شیمی، دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، ایران

۲- دانشکده مهندسی نساجی، دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، ایران

تاریخ دریافت: ۱۴۰۲/۰۴/۲۹ تاریخ پذیرش: ۱۴۰۲/۱۲/۲۸

چکیده

امولسیون آب شور در نفت خام موجب کاهش ارزش نفت خام، مسمومیت کاتالیست‌ها در صنایع پایین دستی و خوردگی تجهیزات در بخش‌های مختلف انتقال، پالایش و نگهداری نفت خام می‌شود. متداول‌ترین روش صنعتی جداسازی آب شور از نفت خام، استفاده از ترکیبات شیمیایی می‌باشد. تامین ترکیبات شیمیایی مورد نیاز هزینه قابل توجهی دارد. به علاوه عملکرد تعلیق شکن‌های شیمیایی وابستگی بسیار زیادی به نوع نفت خام دارد. پیچیدگی موجود در ساختار نفت خام باعث می‌شود مدل سازی عملکرد تعلیق شکن‌ها دشوار باشد. به منظور کاهش تعداد پارامترهای مهم نفت خام از نسبت آسفالتین به مجموع رزین و آروماتیک به عنوان مولفه نفت خام استفاده شد. با توجه به پیچیدگی مدل مدنظر، از ماشین بردار پشتیبان به منظور پیش‌بینی عملکرد تعلیق شکن‌های تجاری استفاده شد. مهم‌ترین چالش در ماشین‌های بردار پشتیبان تنظیم فرآپارامترها می‌باشد. در این مطالعه برای تنظیم فرآپارامترها از معیار ریسک در پیش‌بینی راندمان های بالاتر از ۸۵٪ و افزایش ضریب همبستگی استفاده شد. به منظور جمع‌آوری داده‌های مدل سازی، چهار نمونه نفت خام به همراه دو نمونه تعلیق شکن تجاری رایج در واحدهای بهره‌برداری میداین جنوب غرب کشور تهیه و با استفاده از روش بطری، عملکرد تعلیق شکن تجاری در شرایط عملیاتی مختلف بررسی شد. عملکرد الگوریتم پیشنهادی برای تنظیم فرآپارامترها با الگوریتم بهینه‌سازی بیزین مورد مقایسه قرار گرفت. نتایج نشان می‌دهد تنظیم فرآپارامترهای ماشین بردار پشتیبان با معیار ریسک کمک می‌کند یک مدل با دقت بهتر برای پیش‌بینی عملکرد تعلیق شکن‌های تجاری طراحی شود. با توجه به اهمیت مدل سازی عملکرد مواد تعلیق شکن در صنعت نفت، اعتبار سنجی مدل با یک نمونه امولسیون جدید مورد بررسی قرار گرفت. نتایج نشان می‌دهد ماشین بردار پشتیبان می‌تواند مدلی کارآمد برای پیش‌بینی تعلیق شکن‌های تجاری ارائه کند.

کلمات کلیدی: امولسیون زدایی، تعلیق شکن شیمیایی، شاخصه پایداری امولسیون، ماشین بردار پشتیبان، هوش مصنوعی.

*مسئول مکاتبات

mozaffarian@aut.ac.ir

آدرس الکترونیکی

شناسه دیجیتال: (DOI:10.22078/pr.2024.5189.3304)

مقدمه

محسوب می شود. روش‌های مختلفی مانند روش شیمیایی، الکتریکی، حرارتی، زیستی، امواج مافوق صوت و ... برای جداسازی آب شور از نفت خام وجود دارد [۶]. اما رایج ترین روش، استفاده از ترکیبات شیمیایی می باشد. مهم ترین چالش روش مذکور، انتخاب مواد شیمیایی مناسب تحت شرایط عملیاتی مختلف می باشد، زیرا عملکرد ترکیبات شیمیایی وابسته به ساختار و ترکیبات موجود در نفت خام به ویژه ساختار و میزان آسفالتین و رزین می باشد. آسفالتین بخشی از ترکیبات نفت خام است که در آلکان‌های سبک نظیر نرمال هپتان و نرمال پنتان رسوب می کند. از طرفی جرم مولکولی بسیار زیاد و ساختاری حلقوی دارد. همچنین ساختار آسفالتین شامل هترو اتم‌های گوناگون است. به همین علت آسفالتین خاصیت آمفیفیلیکی دارد. آمفیفیلیکی بودن آسفالتین مهم ترین نقش را در پایداری امولسیون نفت خام ایفا می کند. با توجه به قطبی بودن بخشی از آسفالتین، این ماده از سمت قطبی حول قطرات آب با توجه به نیروهای دوقطبی - دوقطبی و پیوندهای هیدروژنی جمع می شود و یک لایه سخت حول قطرات آب شور شکل می گیرد. آسفالتین‌ها از جهت ترکیبات اشباع نفت دوست نیستند و به همین علت تمایل به پراکندگی در فاز اشباع دارند، اما رزین ترکیبی نفت دوست محسوب می شود و به همین دلیل آسفالتین با وجود رزین تثبیت می شود. رزین‌ها بخشی از ترکیبات نفت خام هستند که مانند آسفالتین ساختاری حلقوی دارند، اما در آلکان‌های سبک حل می شوند. رزین‌ها به تنهایی باعث تشکیل یک امولسیون پایدار نمی شوند، اما وجود آنها بر توزیع و اندازه ذرات آسفالتین مؤثر است. از طرفی، اندازه ذرات آسفالتین تاثیر مستقیمی بر پایداری امولسیون نفت خام دارد [۷]. بنابراین نسبت رزین به آسفالتین بر پایداری امولسیون بسیار مؤثر است. مطالعه لشکر بلوکی و آیت اللهی [۸] نشان می دهد

در مخازن نفت، آب شور و نفت خام در مجاورت هم قرار دارند. فشار این مخازن به طور متوسط حدود ۲۰۰ atm و فشار سرچاهی حدود ۶۵ atm است. باتوجه به این افت فشار، اختلاط شدیدی بین آب شور و نفت خام در حفاصل مخزن تا سرچاه صورت می گیرد. همچنین در نفت خام مواد فعال سطحی مانند رزین، آسفالتین و ذرات جامد وجود دارند که در نتیجه وجود این ترکیبات و اختلاط شدید، امولسیون پایدار آب شور در نفت خام تولید می شود [۱]. به ازای هر ۱ mg/L آب شور در نفت خام، به طور متوسط حدود ۱ دلار از ارزش هر بشکه نفت خام کاهش پیدا می کند [۲]. علاوه بر کاهش ارزش نفت خام، امولسیون آب شور در نفت خام مضرات گوناگونی در بخش انتقال، نگهداری و پالایش نفت خام نیز ایجاد می کند. برای مثال در فرآیند انتقال نفت خام، قطرات پراکنده آب شور در نفت خام باعث افزایش ویسکوزیته سیال شده و بر روی عملکرد پمپ‌ها تأثیر منفی دارند. علاوه بر این افت فشار امولسیون‌های آب در نفت بیش تر از حالتی است که امولسیون وجود ندارد [۳]. در بخش پالایش نفت خام به طور کلی شوری منجر به مسمومیت و کاهش عملکرد کاتالیست‌های مختلف در فرآیندهای صنایع پایین دستی در پالایشگاه‌ها، پتروشیمی‌ها و در نتیجه باعث افزایش هزینه‌های عملیاتی در این صنایع خواهد شد. زمانی که نمک موجود در نفت خام در معرض دمای بیش از ۱۰۰ °C قرار گیرد به واسطه ایجاد پدیده آبکافت^۱ تبدیل به اسیدهای معدنی نظیر هیدروکلریک اسید می شود که این اسیدها عوامل اصلی ایجاد خوردگی در تجهیزات فرآیندی و انتقال هستند [۴]. طالبی و همکاران [۵] خوردگی چندین واحد و تجهیز پالایشگاهی مستعد خوردگی را بررسی نمودند. با توجه به گزارش ایشان خوردگی حفره‌ای و اسیدی عمده ترین نوع خوردگی در اثر آبکافت نمک‌های موجود در نفت خام در واحدها و تجهیزات پالایشگاهی

دارد. همچنین طبق گزارش ایشان اندازه و توزیع اندازه ذرات آسفالتین وابسته به میزان آروماتیکی بودن نفت خام است. علاوه بر اهمیت مشخصات نفت خام، عملکرد تعلیق شکن‌های شیمیایی وابسته به شرایط عملیاتی نیز می‌باشد. عموماً در واحدهای صنعتی دمای امولسیون قبل از ورود به واحد نمک‌زدایی توسط کوره‌ها و مبدل‌های حرارتی بالا می‌رود. شکل ۱ طرحواره واحد نمک‌زدایی یکی از میادین جنوب کشور را نشان می‌دهد. مطابق با شکل ۱، امولسیون نفت خام در ابتدا با آب رقیق کننده و تعلیق شکن شیمیایی در شیر اختلاط مخلوط شده و وارد مخزن ادغام می‌شود. در این مرحله بخشی از آب شور موجود در امولسیون نفت خام جدا شده و سپس با نفت موجود در مخزن نامرغوب مخلوط می‌شود. هدف از مخزن نامرغوب، کنترل هرچه بهتر فرآیند و حفظ راندمان جداسازی آب شور از امولسیون نفت خام در حد استاندارد است. سپس امولسیون به مبدل‌های حرارتی منتقل شده و پس از آن وارد کوره‌های حرارتی و در مرحله بعد با آب رقیق کننده مخلوط شده و وارد نمک‌زدهای برقی می‌شود. افزایش دما بر پارامترهای مختلفی مانند ویسکوزیته فاز پیوسته، الاستیسیته لایه سطحی حول قطرات آب شور و افزایش نرخ جذب مواد فعال سطحی اثر مستقیم دارد [۶]. از طرفی، عملکرد نمک‌زدهای برقی وابسته به ویسکوزیته فاز پیوسته و قدرت یونی امولسیون است. عمده نمک‌زدهای صنعتی در میادین نمک‌زدایی کشور از نوع جریان متناوب هستند و هر چقدر قدرت یونی و ویسکوزیته کمتر باشد عملکرد بهتری دارند. در نتیجه به ازای افزایش نرخ جداسازی آب شور از امولسیون در مخزن ادغام، عملکرد نمک‌زدهای برقی و ظرفیت عملیاتی افزایش و نرخ خوردگی کوره و مبدل حرارتی نیز کاهش پیدا می‌کند [۱۳]. در واحدهای عملیاتی با توجه به فصل سال و نوع نفت خام دمای اعمال شده محدود می‌شود.

نسبت کسر H/C در ساختار رزین و نسبت کسر رزین به آسفالتین بر عملکرد مواد فعال سطحی موثر است، ولی شدت تاثیر وابسته به دیگر مشخصات نفت می‌باشد. در این راستا بررسی مطالعه اسکورلینگ و همکاران [۹] نشان می‌دهد نسبت رزین بر آسفالتین بر توزیع اندازه قطرات پراکنده، ویسکوزیته و کیفیت پساب شور امولسیون موثر است. کوکال و همکاران [۱۰] پارامترهای موثر بر پایداری امولسیون نفت خام را بررسی نمودند. نتایج ایشان بیان می‌کند نسبت آسفالتین به مجموع رزین و آروماتیک موجود در نفت خام یک همبستگی خطی با پایداری امولسیون دارد. آنها نسبت آسفالتین به مجموع رزین و آروماتیک نفت خام را به عنوان شاخص پایداری امولسیون^۱ در نظر گرفتند. منظور از شاخص پایداری امولسیون پارامتری است که به وسیله آن مقاومت امولسیون‌ها در برابر جداسازی آب شور قابل مقایسه باشد. نتایج آنها بیان کرد که پایداری امولسیون با شاخص در نظر گرفته شده یک همبستگی خطی دارد. علاوه بر نسبت رزین به آسفالتین، میزان آسفالتین موجود در فاز پیوسته نیز اهمیت دارد، زیرا میزان آسفالتین بر غلظت بهینه ترکیب فعال سطحی شیمیایی اثر مستقیم دارد. در این راستا روندن و همکاران [۱۱] تاثیر میزان آسفالتین بر عملکرد تعلیق شکن‌های شیمیایی را بررسی نمودند. مطالعه ایشان نشان می‌دهد که با توجه به نوع ماده فعال سطحی مورد بررسی مقدار کمینه غلظت ماده فعال سطحی مورد نیاز برای امولسیون‌زدایی رابطه مستقیمی با میزان آسفالتین موجود در نفت خام دارد. از طرفی در غلظتی بیش از غلظت کمینه فعال سطحی، غلظت فعال سطحی مورد نیاز مستقل از آسفالتین موجود درون نفت خام است. باتیستا و رامالها [۱۲] ارتباط بین ساختار تعلیق شکن‌های تجاری را با راندمان و کیفیت امولسیون‌زدایی بررسی نمودند. نتایج مطالعه ایشان نشان می‌دهد توزیع اندازه ذرات آسفالتین ارتباط مستقیم با عملکرد تعلیق شکن‌های تجاری

1. Emulsion Stability Index (ESI)

کردند. مطالعه ایشان نشان می‌دهد با توجه به چگالی ویژه و همچنین میزان رزین و آسفالتین میزان تاثیر اسیدیته بر پایداری امولسیون تغییر می‌کند. در کشور روزانه حدود ۳ میلیون بشکه نفت برداشت می‌شود. از طرفی، تنوع نفت برداشتی میداین نفتی در ایران قابل توجه است. با توجه به تنوع زیاد نمونه‌های برداشت شده سالانه ده‌ها تعلیق شکن شیمیایی در حجم قابل توجهی برای میداین نفتی تهیه می‌شود. تامین تعلیق شکن واحدها علاوه بر وابستگی به نوع نفت و شرایط عملیاتی تحت تاثیر شرایط سیاسی و اقتصادی نیز می‌باشد. بنابر چالش‌های موجود در تامین مواد مصرفی، وجود یک مدل کارآمد که توانایی پیش بینی حجم مورد نیاز مواد تعلیق شکن را در یکسال داشته باشد بسیار ضروری است.

سالانه بیش از ده‌ها میلیون دلار صرف تامین مواد تعلیق شکن برای واحدهای بهره برداری و نمک‌زدایی در کشور می‌شود. لازم به ذکر است از نمونه تعلیق شکن‌های تهیه شده توسط صنایع ممکن است چند نمونه تعلیق شکن کارایی مناسبی برای یک نمونه امولسیون داشته باشند. به علاوه در آزمایشگاه اصولاً از آزمون بطری برای انتخاب تعلیق شکن مناسب هر واحد بهره‌برداری و نمک‌زدایی استفاده می‌شود. با توجه به تنوع میداین نفتی، تنوع تعلیق شکن‌های در دسترس و شرایط عملیاتی ممکن برای یک واحد، انجام آزمایش بطری بر روی هر نمونه امولسیون نفت برداشت شده با استفاده از تمامی تعلیق شکن‌ها، هزینه قابل توجهی را از منظر زمان و مواد مصرفی شامل می‌شود. بنابراین وجود یک مدل هوشمند که با توجه به نوع نفت خام، توانایی تشخیص تعلیق شکن‌های کارآمد در شرایط عملیاتی مد نظر را داشته باشد و به مهندسين عملیاتی در انجام امور آزمایشگاهی کمک کند بسیار سودمند است، زیرا علاوه بر کاهش هزینه‌های آزمایشگاهی، موجب می‌شود مهندسين واحد با توجه به شرایط عملیاتی، نمونه در دسترس و

آموزش و ارزیابی گزارش نمودند. دهاندى و همکاران [۱۷] تاثیر سه پارامتر غلظت تعلیق شکن، دمای فرآیند و زمان ته‌نشینی را بر عملکرد دو تعلیق شکن شیمیایی و بر اساس راندمان جداسازی آب شور از نفت خام با استفاده از روش سطح پاسخ بررسی نمودند. عیب اکثر مطالعات صورت گرفته حول پیش‌بینی کارایی تعلیق شکن‌های شیمیایی و بهینه‌سازی فرآیند جداسازی آب شور از امولسیون نفت خام عدم بررسی نوع نفت خام در مدل است. در حقیقت مدل‌هایی که بدون در نظر گرفتن نفت خام طراحی می‌شوند، علی‌رغم ضرایب همبستگی بالا، کارایی عملی ندارند، زیرا مدل طراحی شده فقط برای یک نمونه امولسیون خاص، با دقت بالا نتایج را پیش‌بینی می‌کند و با تغییر نمونه نفت خام هیچ گونه توانایی در مورد پیش‌بینی عملکرد تعلیق شکن‌ها ندارد. دلیل عدم بررسی نوع نفت خام در مدل، پیچیدگی بسیار زیاد ساختار نفت خام و تعداد زیاد پارامترهای موثر بر پایداری امولسیون آب شور در نفت خام است. در این راستا یوتانی و همکاران [۱۸] تاثیر واکس، آسفالتین، رزین و شوری را بر پایداری امولسیون بررسی نمودند. مطالعات ایشان نشان می‌دهد هر یک از پارامترهای مورد بررسی بر اندازه قطرات پراکنده و ویسکوزیته فاز امولسیون موثر هستند. کاظم زاده و همکاران [۱۹] تاثیر نوع و غلظت یون‌های موجود در آب را بر پایداری امولسیون بررسی نمودند. ایشان بیان کردند نوع و غلظت کاتیون‌ها بر پایداری امولسیون موثر است، به گونه‌ای که در فشارهای بالا کاتیون‌های دو ظرفیتی امولسیون پایدارتری نسبت به کاتیون‌های تک ظرفیتی تشکیل می‌دهند. از طرفی در شوری‌های کمتر از ۱۰۰۰۰ ppm، با افزایش شوری پایداری افزایش پیدا می‌کند و در شوری با غلظت بیش از ۱۰۰۰۰ ppm پایداری امولسیون کاهش پیدا می‌کند. لشکر بلوکی و آیت‌اللهی [۲۰] تاثیر اسیدیته، میزان رزین و آسفالتین را بر پایداری امولسیون آب شور در نفت خام بررسی

بینی سوخت مصرفی کشتی‌ها را با استفاده از ماشین بردار پشتیبان مطالعه نمودند. ایشان با استفاده از الگوریتم بیزین^۳ فرآپارامترهای مدل خود را تنظیم نمودند. مطالعات فراوانی مشابه با موارد یاد شده در حوزه تنظیم فرآپارامترهای ماشین بردار پشتیبان وجود دارد و به صورت کلی بهترین روش برای تنظیم فرآپارامترهای ماشین بردار پشتیبان با توجه به نوع مدل و هدف از طراحی آن مشخص می‌شود. در این مطالعه برای تنظیم فرآپارامترها از یک مدل ابتکاری با اولویت گرفتن خطرپذیری مدل در پیش‌بینی نتایج به عنوان معیار اصلی و ضریب همبستگی به عنوان معیار فرعی انتخاب فرآپارامتر بهینه استفاده شد. برای جمع‌آوری داده‌های مورد نیاز در طراحی مدل، از چهار نمونه امولسیون نفت خام و دو نمونه تعلیق شکن پرمصرف در میادین نمک‌زدایی جنوب کشور و شرایط آزمایش مشابه با شرایط عملیاتی در واحدهای نمک‌زدایی استفاده شد.

مواد و روش انجام آزمایشات نفت خام

چهار نمونه امولسیون نفت خام از میادین جنوب کشور تهیه شد. عموم نمونه نفت‌های برداشت شده در جنوب کشور از منظرنسبت رزین به آسفالتین در بازه ۲ تا ۱۲ و از منظر چگالی ویژه در بازه ۰/۸۳ تا ۰/۹ می‌باشند. با حمایت شرکت ملی نفت ایران تلاش شد نمونه نفت‌های مورد بررسی از نظر خواص فیزیکی و شیمیایی تاحد امکان متفاوت از یکدیگر باشند و دو بازه بیان شده را پوشش دهند تا بدین‌وسیله مدل تهیه شده از پراکندگی داده خوبی برخوردار باشد. پراکندگی داده‌ها موجب می‌شود مدل جامع‌تری طراحی شود و کارایی آن با انجام آزمون‌های کمتر مورد ارزیابی قرار گیرد. میزان آسفالتین، رزین و ترکیبات آروماتیک درون نفت خام با استفاده از ستون آلومینا و حلال نرمال هپتان

سودمند را به سرعت شناسایی کنند. مهم‌ترین پارامتر در کارا بودن یک مدل هوشمند، توانایی مدل در پیش‌بینی نتایج برای داده‌های خارج از محدوده آموزش است. از دیدگاه کاربردی مدلی که در برابر ورودی‌های جدید توانایی پیش‌بینی نتایج را با دقت مناسب نداشته باشد، حتی با وجود تحلیل‌های آماری مناسب در طراحی اولیه، هیچ کارایی ندارد [۲۱]. در این مطالعه، تهیه یک مدل هوشمند که توانایی پیش‌بینی عملکرد تعلیق شکن‌های تجاری را در شرایط مختلف به ویژه در برابر تغییر نوع نفت خام داشته باشد به‌وسیله ماشین بردار پشتیبان بررسی شد. در مدل مورد بحث نسبت آسفالتین به مجموع رزین و آروماتیک به عنوان شاخصه پایداری امولسیون نفت خام در کنار شرایط عملیاتی دما، غلظت تعلیق شکن و نسبت آب رقیق کننده به عنوان ورودی ماشین بردار پشتیبان در نظر گرفته شد. مهم‌ترین نکته برای طراحی ماشین‌های بردار پشتیبان تنظیم فرآپارامترها^۱ می‌باشد، زیرا اکثر مدل‌ها و روش‌های ارائه شده برای تنظیم فرآپارامترها، نمی‌توانند عملکرد یکسانی در برابر نتایج تئوری و عملی داشته باشند. در همین راستا، وانگ و همکاران [۲۲] تابع هدف به منظور پیش‌بینی نتایج را مستقل از داده‌های ارزیابی و وابسته به داده‌های آموزشی تعریف نمودند. ایشان برای یک پایگاه داده از نتایج مطالعات تجربی مختلف، مدل‌سازی به وسیله ماشین بردار پشتیبان را بررسی کردند و بیان نمودند روش پیشنهادی ایشان با دقت بهتری فرآپارامترها را تنظیم می‌کند. ریکی و همکاران [۲۳] عملکرد دانشجویان را با توجه به شرایط زندگی و اجتماعی به‌وسیله ماشین بردار پشتیبان بررسی نمودند. ایشان برای بهینه‌سازی فرآپارامترهای ماشین بردار پشتیبان مورد مطالعه از الگوریتم ژنتیک و ازدحام ذرات^۲ استفاده کردند. نتایج آنها نشان می‌دهد که استفاده از الگوریتم‌های فراابتکاری موجب بالا رفتن دقت مدل نسبت به حالت متداول می‌شود. ژائو و همکاران [۲۴] پیش

1. Hyperparameters Tuning
2. Particle Swarm Optimization
3. Bayesian Optimization

اندازه‌گیری شد. ویسکوزیته سینماتیک مطابق با استاندارد ASTM D445 با استفاده از ویسکومتر شیشه‌ای آبلهود^۱ (نوع c1-) و آب همراه مطابق با استاندارد ASTM D4007 تعیین شد. در این روش ۵۰ ml از امولسیون نفت خام با ۵۰ ml محلول تولوئن به همراه ۰/۲ ml ماده فعال سطحی (قابل انحلال در تولوئن) درون تیوب‌های ۱۰۰ میلی لیتری سانتریفیوژ ریخته می‌شوند. پس از قرار گرفتن تیوب درون حمام گرم (حداقل ۱۵ min در دمای ۶۰ °C)، تولوئن و امولسیون نفت درون تیوب مخلوط می‌شوند (۱۰ مرتبه به صورت دورانی). پس از اختلاط کامل، تیوب‌ها درون سانتریفیوژ (دما ۶۰ °C و حداقل سرعت ۶۰۰ rcf) قرار داده می‌شوند. سپس حجم آب همراه موجود درون امولسیون خوانده می‌شود. مشخصات اندازه‌گیری شده هر چهار نمونه امولسیون در **جدول ۱** قابل مشاهده است.

تعلیق شکن

با توجه به اهداف این مطالعه در مورد پیش‌بینی عملکرد تعلیق شکن‌ها، به منظور کاهش هزینه‌های تامین به وسیله تخمین نوع و حجم مورد نیاز واحدهای صنعتی، کاهش هزینه‌های آزمایشگاهی و اتخاذ تصمیم مناسب برای بالا بردن راندمان جداسازی آب شور از نفت خام، دو نمونه تعلیق شکن تجاری و پرکاربرد از میان چندین نمونه تعلیق شکن مورد استفاده در واحدهای بهره‌برداری میادین نفتی جنوب کشور تهیه شد. تعلیق شکن‌های

جدول ۱ مشخصات نمونه امولسیون‌های آب شور در نفت خام تهیه شده از میادین جنوب کشور.

آروماتیک (w/w %)	رزین (w/w %)	آسفالتین (w/w %)	آب همراه Vol(%).	ویسکوزیته سینماتیکی (mm ² /sec@20°C)	چگالی ویژه	مشخصه امولسیون
۱۹/۱	۵/۶	۱/۶	۳/۴	۱۵/۳	۰/۸۷	اول
۳۰/۵	۸/۸	۳/۹	۹/۶	۷۱/۱	۰/۹۲	دوم
۲۱/۳	۷/۱	۲/۵	۵/۵	۲۱/۸	۰/۸۹	سوم
۱۶/۲	۹/۸	۰/۹	۲/۳	۷/۱	۰/۸۴	چهارم

1. Ubbelohde viscometer (Type 1C)
2. Required Centrifugal Force

جدول ۲ مشخصات دو تعلیق شکن تجاری مورد استفاده در آزمایشات.

نمونه	ویسکوزیته (Pa.sec @ 20 °C)	چگالی ویژه	ماده فعال سطحی پایه	حلالیت در ایزوپروپانول	حلالیت در آب
الف	۹/۶	۱/۰۳	غیر یونی - (EO) ₄	قابل حل	پراکندگی سطحی
ب	۱۱/۸	۱	غیر یونی - (EO) ₆	غیر قابل حل	غیر قابل حل

روش انجام کار

در این مطالعه در ابتدا یک مدل هوشمند با استفاده از چهار نمونه امولسیون تهیه شده طراحی شد. سپس برای اعتبار سنجی مدل از یک نمونه امولسیون جدید استفاده شد. برای این منظور ۱۰۰ mL از هر نمونه امولسیون به درون ظرف استیل منتقل شد. ظرف استیل درون حمام آب ۵۵ درجه سلسیوس به مدت ۱۰ min قرار داده شد. پس از پایا شدن دمای ظرف، چهار نمونه با سرعت ۳۰۰۰ rpm توسط همزن با پروانه نوع تیغه‌ای^۱ و به مدت ۵ دقیقه با یکدیگر مخلوط شدند. اختلاط نمونه‌های موجود درون ظرف با یکدیگر الزامی است، زیرا در صورت عدم اختلاط نمونه‌ها امولسیون جدید یکنواخت نیست. به عبارتی اختلاط با همزن کمک می‌کند امولسیون جدید مشخصات فیزیکی یکنواختی در تمامی حجم نمونه جدید داشته باشد. همچنین توزیع پراکندگی قطرات نیز برای نمونه جدید بهتر و یکنواخت تر است، زیرا زمانی که نمونه امولسیون‌ها بدون استفاده از همزن باهم مخلوط شوند، یک نمونه امولسیون پایدار تهیه می‌شود، اما نمونه جدید از نظر مشخصات فیزیکی و توزیع پراکندگی قطرات یکنواخت نیست و در نتیجه بر دقت نتایج و تکرار پذیری آزمایشات اثر منفی دارد. نمونه جدید به مدت یک هفته در آزمایشگاه نگهداری شد تا پایداری آن بررسی شود. پس از تهیه امولسیون جدید در ابتدا شاخصه پایداری امولسیون برای هر پنج نمونه امولسیون نفت خام مطابق با رابطه ۱ مشخص شد.

$$ESI = \frac{As}{Ar + Re} \quad (1)$$

در این رابطه As، Re و Ar به ترتیب درصد وزنی ترکیبات آسفالتین، رزین و آروماتیک هر امولسیون است. برای هر مرتبه از آزمایش، ۱۰ mL از هر

نمونه نفت خام با نسبت آب رقیق کننده، غلظت تعلیق شکن و دمای تعیین شده در **جدول ۳ تا ۵** با سرعت ۴۰۰۰ rpm توسط همزن با پروانه نوع دیسکی^۲ و به مدت ۵ min مورد اختلاط قرار گرفت. پس از اختلاط، محتویات ظرف اختلاط به ظروف مدرج پلاستیکی منتقل شد. با توجه به شرایط دمای موجود در جدولهای مذکور، بطری‌های مدرج به مدت ۱۲ hr درون آون حرارتی ARTA Mod.BO55 گذاشته شد. پس از ۱۲ hr ظروف از آون خارج و حجم آب جدا شده ثبت شد. شرایط آزمایش در **جدول‌های ۳، ۴ و ۵** برای سه پارامتر مذکور مطابق با مقادیر عملیاتی در فصل گرم و سرد سال در نظر گرفته شد. عموماً در واحدهای عملیاتی غلظت تعلیق شکن مصرفی در محدوده ۸۰ mg/L تا ۱۲۰ mg/L، نسبت آب رقیق کننده به نفت ۳ و ۶٪ حجمی و دما در بازه ۵۰ الی ۶۰ °C می‌باشد. پس از تعیین حجم آب شور جدا شده از امولسیون، مطابق با رابطه ۲، راندمان جداسازی آب شور محاسبه شد. در رابطه ۲، V₂ بیانگر حجم آب جمع آوری شده در پایین بطری‌های مخروطی است. Wc₁ آب همراه موجود درون امولسیون و V₁ نسبت آب رقیق کننده به نفت خام در هر آزمایش است. ظروف پلاستیکی مخروطی مدرج هستند، اما در مواقعی که مانند **شکل ۲**، حجم فاز آبی کمتر از سطوح مدرج باشد، از شاهد گیری به کمک روغن موتور صنعتی با چگالی ویژه ۰/۸۲ استفاده شد. **شکل ۲** دو نمونه از آزمایش تشریح شده برای تعلیق شکن الف را نشان می‌دهد.

$$Ra = \frac{V_2}{0.1(Wc_1 + V_1)} \quad (2)$$

1. Pitch Blade Impeller

2. Disc Impeller

جدول ۳ شرایط عملیاتی آزمایش برای چهار نمونه امولسیون نفت خام (داده آموزش)

ردیف	امولسیون	دما (°C)	غلظت (ppm)	نسبت آب رقیق کننده به نفت	درصد بازیابی تعلیق شکن الف	درصد بازیابی تعلیق شکن ب
۱	۱	۵۰	۸۰	۶	۸۹/۵۷	۷۵/۸
۲	۱	۵۰	۱۲۰	۶	۹۱/۴	۸۲/۸
۳	۱	۵۰	۱۰۰	۳	۸۶/۲	۶۴/۲
۴	۱	۵۰	۱۰۰	۶	۸۹/۸	۷۸/۲
۵	۱	۵۰	۱۲۰	۳	۸۸/۶	۷۹/۸
۶	۱	۶۰	۸۰	۶	۹۹/۷	۹۰/۸
۷	۱	۶۰	۱۰۰	۳	۹۹/۱۵	۹۴/۷۹
۸	۱	۶۰	۸۰	۳	۹۸/۸۶	۸۵/۸
۹	۱	۶۰	۱۲۰	۳	۹۹/۳	۹۶/۷
۱۰	۱	۶۰	۱۰۰	۶	۹۹/۹	۹۹/۸
۱۱	۲	۵۰	۱۰۰	۳	۵۶/۴	۷۵/۲
۱۲	۲	۵۰	۱۲۰	۳	۵۷	۹۲/۸
۱۳	۲	۵۰	۱۰۰	۶	۶۱/۲	۹۹/۹۵
۱۴	۲	۵۰	۸۰	۳	۵۲/۳	۷۰/۲
۱۵	۲	۵۰	۱۲۰	۶	۶۴/۳	۹۹/۹۴
۱۶	۲	۶۰	۸۰	۳	۹۴/۶	۸۶/۲
۱۷	۲	۶۰	۸۰	۶	۹۷/۸۵	۹۷/۸
۱۸	۲	۶۰	۱۰۰	۳	۹۶/۸	۹۸/۵
۱۹	۲	۶۰	۱۲۰	۳	۹۷/۶	۹۹/۸
۲۰	۲	۶۰	۱۲۰	۶	۹۸/۶	۹۹/۹۵
۲۱	۳	۵۰	۱۲۰	۳	۶۷/۷۵	۶۳/۷
۲۲	۳	۵۰	۱۲۰	۶	۹۸/۶	۷۸/۲
۲۳	۳	۵۰	۸۰	۳	۶۹/۵	۵۲
۲۴	۳	۵۰	۱۰۰	۶	۸۳	۷۶/۲
۲۵	۳	۵۰	۸۰	۶	۸۲	۶۰
۲۶	۳	۶۰	۸۰	۳	۷۸	۹۲/۸
۲۷	۳	۶۰	۸۰	۶	۹۱	۹۴/۸
۲۸	۳	۶۰	۱۰۰	۳	۸۸/۳	۹۸/۲
۲۹	۳	۶۰	۱۰۰	۶	۹۹/۹۵	۹۹/۷
۳۰	۳	۶۰	۱۲۰	۶	۹۹/۹۹	۹۹/۹۵
۳۱	۴	۵۰	۸۰	۳	۵۲	۴۲
۳۲	۴	۵۰	۸۰	۶	۷۹/۵	۵۵/۱
۳۳	۴	۵۰	۱۰۰	۳	۶۱	۵۸/۲

ادامه جدول ۳

۶۷/۸	۷۶	۳	۱۲۰	۵۰	۴	۳۴
۷۰/۳	۸۳	۶	۱۲۰	۵۰	۴	۳۵
۷۳/۲	۶۷	۳	۸۰	۶۰	۴	۳۶
۸۶/۲	۹۱	۶	۸۰	۶۰	۴	۳۷
۹۰/۸	۷۲	۳	۱۰۰	۶۰	۴	۳۸
۹۶/۸	۹۵	۶	۱۰۰	۶۰	۴	۳۹
۹۴/۸	۸۱	۳	۱۲۰	۶۰	۴	۴۰

جدول ۴ شرایط آزمایش برای هر نمونه نفت خام برای تهیه مدل مناسب با ماشین بردار پشتیبان (داده ارزیابی^۱)


ردیف	امولسیون	دما (°C)	غلظت (ppm)	نسبت آب رقیق کننده به نفت	درصد بازیابی تعلیق شکن اول	درصد بازیابی تعلیق شکن دوم
۴۱	۱	۵۰	۸۰	۳	۶۷/۳	۶۸
۴۲	۱	۶۰	۱۲۰	۶	۹۹/۹	۹۹/۹۹
۴۳	۲	۵۰	۸۰	۶	۶۷	۹۱
۴۴	۲	۶۰	۱۰۰	۶	۹۸	۹۹/۹۵
۴۵	۳	۵۰	۱۰۰	۶	۶۷/۸	۷۷
۴۶	۳	۶۰	۱۲۰	۳	۹۸/۸	۹۹/۹۹
۴۷	۴	۵۰	۱۰۰	۶	۷۰/۴	۶۹
۴۸	۴	۶۰	۱۲۰	۶	۹۹/۹۹	۹۷

جدول ۵ شرایط آزمایش برای امولسیون پنجم به منظور اعتبارسنجی مدل ماشین بردار پشتیبان برای هر تعلیق شکن

ردیف	دما (°C)	غلظت (ppm)	نسبت آب رقیق کننده به نفت	درصد بازیابی تعلیق شکن اول	درصد بازیابی تعلیق شکن دوم
۱	۵۰	۸۰	۳	۶۰	۶۱
۲	۵۰	۸۰	۶	۶۲	۷۵/۸
۳	۵۰	۱۰۰	۶	۶۵	۸۶/۱
۴	۵۰	۱۲۰	۳	۷۵	۶۹
۵	۶۰	۸۰	۶	۹۴	۹۵/۳
۶	۶۰	۱۰۰	۳	۸۷	۸۸/۱
۷	۶۰	۱۰۰	۶	۹۸/۵	۹۹/۸

ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از انواع روش‌های یادگیری ماشین نظارت شده محسوب می‌شود. این روش هم در طبقه‌بندی اطلاعات و هم در برآزش داده‌ها قابل کاربرد است. مهم‌ترین ویژگی در برآزش با این روش نسبت به بقیه روش‌های یادگیری ماشین مانند شبکه‌های عصبی چندلایه^۲



شکل ۲ حجم آب شور جدا شده پس از ۱۲ h برای امولسیون اول؛ نسبت آب رقیق کننده به نفت خام ۳ درصد حجمی، غلظت ۱۰۰ ppm تعلیق شکن الف، دما (الف): ۶۰ °C: ب: ۵۰ °C

1. Validation Data
2. Multilayer Perceptron (MLP)

داده‌های ورودی توسط کرنل مدنظر و مطابق با رابطه ۴ محاسبه می‌شود.

$$\omega = \sum_{i=1}^N (\alpha_i^* - \alpha_i) \varphi(x_i) \quad (4)$$

منظور از $\varphi(x_i)$ و α در رابطه ۴، به ترتیب تابع تبدیل (کرنل) و ضرایب لاگرانژ می باشد. ضرایب لاگرانژ مورد نیاز در رابطه ۴ از معادله ۵ به صورت زیر محاسبه می شوند.

$$\max_{(\alpha, \alpha^*)} \left\{ -\varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N (-\alpha_i + \alpha_i^*) y_i - \frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N (-\alpha_i + \alpha_i^*) (-\alpha_j + \alpha_j^*) k(x_i, x_j) \right\}$$

$$\alpha, \alpha^* \in [0, C] \quad \sum_{i=1}^N (-\alpha_i + \alpha_i^*) = 0 \quad (5)$$

پس از تعیین مقادیر آلفا، تابع مدنظر برای پیش‌بینی مقادیر واقعی مطابق با رابطه ۶ محاسبه می شود.

$$F(x) = \sum_{i=1}^N (\alpha_i^* - \alpha_i) k(x_i, x) \quad (6)$$

در این پژوهش از کرنل گوسی $K_{Gaussian}(x_i, x) = \exp(-\gamma \|x_i - x\|^2)$ برای مدل‌سازی هر دو ماشین بردار پشتیبان استفاده شد. در حالت کلی، کرنل گوسی عملکرد بسیار مطلوب تری نسبت به دو کرنل دیگر هنگام مواجهه با مدل‌های با پیچیدگی قابل توجه و حجم کم پایگاه داده دارد [۲۸].

تنظیم فرآیندها

در این مطالعه با توجه به هندسه و هدف‌های مدنظر برای مدل‌سازی، برای تعیین فرآیندهای ماشین بردار پشتیبان از یک روش بازگشتی با در نظر گرفتن ریسک پیش‌بینی استفاده شد. به عبارتی بر خلاف الگوریتم‌های بهینه‌سازی پیش فرض در نرم‌افزار متلب و یامطالعات مختلف که ضریب تعیین را به عنوان معیار اصلی تابع هدف برای بهینه‌سازی فرآیندها در نظر می‌گیرند، در این مطالعه ریسک پیش‌بینی نتایج برای راندمان‌های

تعیین یک میزان خطای قابل انتظار (ε) با این روش است. میزان خطای قابل انتظار موجب می‌شود برای داده‌های چند بعدی یا مجموعه داده با قابلیت کلاس‌پذیری، این روش عملکرد مناسب‌تری نسبت به بقیه روش‌های یادگیری ماشین داشته باشد. در حقیقت در این روش بهترین ابرصفحه^۱ با میزان قابل انتظار خطا توسط کرنل‌های مشخص برای برآزش داده‌ها تعیین می‌شود. به ماشین بردار پشتیبانی که با تعیین یک ابرصفحه داده‌ها را برآزش می‌کند به اختصار بردار پشتیبان برآزشی^۲ گفته می‌شود و منظور از ماشین بردار پشتیبان در این پژوهش همان بردار پشتیبان برآزشی است. کرنل‌های مطرح در ماشین بردار پشتیبان وظیفه انتقال داده‌ها به فضای ویژگی بزرگتر را دارند و این انتقال باعث مدل‌سازی با قدرت پیش‌بینی بهتر برای مدل‌های پیچیده می‌شود. کرنل‌های ماشین بردار پشتیبان به سه دسته کلی خطی، چند جمله‌ای و گوسی طراحی می‌شوند. استفاده از کرنل مناسب دقت تخمین توابع غیرخطی و پیچیده مدل را بالا می‌برد. رابطه ۳، معادله کلی طراحی ماشین بردار پشتیبان برای برآزش داده‌ها محسوب می‌شود [۲۷].

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N \xi_i + \xi_i^* \quad (3)$$

ξ_i و ξ_i^* در رابطه ۳ بیانگر مقادیری هستند که ماشین بردار پشتیبان اجازه دارد خارج از مقدار خطای قابل پیش‌بینی عمل کند. به عبارتی، داده‌های خارج از محدوده توسط این دو پارامتر تعیین می‌شوند. ω در رابطه ۳، بردار نرمال صفحه‌ای است که برای برآزش داده‌ها نیاز است و C تابع هزینه است. به عبارتی در رابطه ۳، پارامترها باید به گونه‌ای تنظیم شوند که مجموع اندازه بردار نرمال و هزینه مقادیر خارج از محدوده کمترین مقدار ممکن شود. همچنین شرایط زیر باید بین پارامترهای موجود در رابطه ۳ و نتایج واقعی برقرار باشد.

$$\begin{cases} y_i - \omega^T \varphi(x_i) \leq \varepsilon + \xi_i^* \\ \omega^T \varphi(x_i) - y_i \leq \varepsilon + \xi_i \end{cases}$$

بردار نرمال موجود در رابطه ۳، پس از انتقال

1. Hyperplane

2. Support Vector Regression (SVR)

بردار پشتیبان برای کل پایگاه داده با دستور شرطی دوم مطابق با رابطه ۹ بررسی شد. R در رابطه ۹، ضریب همبستگی بین نتایج ماشین بردار پشتیبان و نتایج تجربی برای کل پایگاه داده است. ضریب همبستگی مطابق با رابطه ۱۰ محاسبه می‌شود. در رابطه ۱۰، \bar{y}^* و \bar{y} به ترتیب متوسط نتایج پیش بینی شده توسط مدل و متوسط نتایج تجربی می‌باشند.

$$\left(\frac{(NE_{H85})_{prediction}}{(NE_{H85})_{Experimental}} \text{ AND } \frac{(NE_{L85})_{prediction}}{(NE_{L85})_{Experimental}} \text{ AND } R \right) \geq 0.9 \quad (9)$$

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(y_i^* - \bar{y}^*)}{\sqrt{\left(\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (y_i^* - \bar{y}^*)^2 \right)}} \quad (10)$$

پس از بررسی دستور شرطی دوم، رشته ای که کمترین ریسک پیش بینی را برای راندمان های بیش تر و کمتر از ۰.۸۵٪ و بالاترین ضریب همبستگی را برای داده های ارزیابی داشت به عنوان رشته برگزیده انتخاب و فرآپارامترهای ماشین بردار پشتیبان مطابق آن تنظیم شد. شکل ۳ طرحواره الگوریتم تنظیم فرآپارامترهای ماشین بردار پشتیبان را نشان می‌دهد. علاوه بر استفاده از الگوریتم پیشنهادی برای تعیین فرآپارامترها، مدل سازی با استفاده از الگوریتم پیش فرض در نرم افزار متلب نیز صورت گرفت. در نرم افزار متلب فرآپارامترها با استفاده از الگوریتم بیزین^۳ به صورت بهینه تعیین می‌شوند. در الگوریتم بیزین، ابتدا فرآپارامترهای مدل حدس زده شده و بر طبق آنها ماشین بردار پشتیبان به نحوی ایجاد می‌شود که در ابتدا ضریب تعیین برای داده های آموزشی، بیش ترین حد ممکن باشد. سپس با استفاده از مدل، ضریب تعیین داده های ارزیابی و کل پایگاه داده مشخص می‌شوند و در صورت ضریب تعیین برای داده های ارزیابی و کل پایگاه داده حدس اولیه اصلاح شده و فرآیند تنظیم پارامتر تکرار می‌شود.

بیشتر و کمتر از ۰.۸۵٪ به عنوان معیار اصلی و ضریب همبستگی به عنوان معیار فرعی تابع هدف در نظر گرفته شد. در صنعت نفت، آب همراه و ذرات جامد^۱ نفت خروجی در بدترین حالت باید ۰/۳٪ باشد. از طرفی طبق آمار ثبت شده در مناطق نفتخیز، میزان آب همراه نفت خام در میادین بهره برداری و نمکزدایی حداقل ۲ vol.٪ است. بنابراین طبق رابطه ۷ حداقل راندمان یک تعلیق شکن برای هر نمونه امولسیون نفت خام ۰.۸۵٪ باید باشد. در رابطه V_{wf}, V_{wi}, V_c به ترتیب حجم نفت خام، حجم آب همراه اولیه و حجم آب همراه پس از تعلیق شکنی هستند.

$$\frac{V_{wf}}{V_c} \leq 0.003 \rightarrow \frac{V_{wi}(1-Ra)}{V_c} \leq 0.003 \rightarrow Ra \geq 0.85 \quad (7)$$

به همین دلیل ریسک پیش بینی نتایج برای راندمان بیش تر و کمتر از ۰.۸۵٪ در نظر گرفته شد. هدف از انتخاب ریسک به عنوان معیار اصلی در بهینه سازی تابع هدف، بالا بردن دقت و اعتبار مدل به ازای ورودی های جدید و خارج از بازه آموزش است. در ابتدا به ازای هر مجموعه فرآپارامتر ممکن برای ماشین بردار پشتیبان، یک رشته از مقادیر تعریف شد که تعداد اعضای هر رشته برابر تعداد فرآپارامترهای مدنظر است و برای مقدار هر فرآپارامتر، بردارهای مقدار خاصی تشکیل شد. سپس با سری بستن حلقه های هر فرآپارامتر، مجموعه رشته های ممکن برای ماشین بردار پشتیبان تهیه شد. در هر مرتبه تکرار حلقه ارشد^۲ یک رشته به عنوان مقادیر فرآپارامتر ماشین بردار پشتیبان فرض و سپس نتایج ماشین بردار پشتیبان برای داده های آموزشی با استفاده از دستور شرطی اول مطابق با رابطه ۸ بررسی شد. منظور از (NE_{H85}) ، (NE_{L85}) در رابطه ۸ به ترتیب تعداد راندمان های کمتر و بیش تر از ۰.۸۵٪ برای داده های آموزشی مدل می‌باشند.


$$\left(\frac{(NE_{H85})_{prediction}}{(NE_{H85})_{Experimental}} \text{ OR } \frac{(NE_{L85})_{prediction}}{(NE_{L85})_{Experimental}} \geq 0.95 \right) \quad (8)$$

پس از دستور شرطی اول، پیش بینی مدل ماشین

1. Basic Sediment and Water (BS&W)

2. MaSter Loop

3. Bayesian Optimization



شکل ۳ طرحواره روش به کاررفته برای تنظیم فراپارامترها با استفاده از معیار ریسک در پیش‌بینی نتایج.

کارآمد باشد نباید وابسته به تعلیق شکن باشد و این در صورتی قابل ارزیابی است که شرایط عملیاتی برای هر دو مدل یکسان باشد. سوم؛ دو نمونه داده از هر امولسیون تا حد امکان به گونه‌ای باشند که یک داده راندمان بالای ۸۵٪ و دیگری کمتر از ۸۵٪ باشد. رعایت این نکته کمک می‌کند قابلیت پیش‌بینی مدل با توجه به ریسک در نظر گرفته شده به خوبی بررسی شود.

نتایج و بحث

پس از انجام آزمایشات مطابق با دستورالعمل ذکر شده، درصد بازیابی آب شور از نفت مطابق با رابطه ۲ محاسبه شده و در **جدول ۳** برای داده‌های آموزشی و **جدول ۴** برای داده‌های ارزیابی جمع‌آوری شد. همچنین آزمایشات مطابق با شرایط موجود در **جدول ۵** بر روی امولسیون پنجم صورت گرفت. منظور از درصد بازیابی، نسبت درصد حجم فاز آبی جدا شده به مجموع حجم آب شور در امولسیون و حجم آب رقیق کننده به هنگام آزمایش می‌باشد.

برای پیاده‌سازی دو الگوریتم مورد بحث، از نرم‌افزار متلب b ۲۰۲۱ به منظور پیش‌بینی نتایج آزمایشگاهی استفاده شد. قبل از مدل‌سازی انتخاب داده‌ها مهم‌ترین بخش مطالعه است. به عبارتی در صورت انتخاب نادرست داده‌های آموزش و ارزیابی، مدل مناسبی ایجاد نمی‌شود. داده آموزشی یعنی داده‌هایی که برای طراحی مدل اولیه نیاز هستند و عموماً بیش از ۷۵٪ کل پایگاه داده را شامل می‌شوند. داده‌های ارزیابی یعنی داده‌هایی که در آموزش مدل اولیه شرکت نداشته‌اند و پس از مدل‌سازی اولیه برای ارزیابی دقت مدل استفاده می‌شود. برای انتخاب داده‌های ارزیابی از میان کل پایگاه داده سه نکته بسیار مهم در نظر گرفته شد. اول؛ از هر امولسیون ۲ نمونه داده برای ارزیابی وجود داشته باشد. این امر کمک می‌کند پراکندگی پارامترها حفظ شود. دوم؛ شرایط عملیاتی برای هر دو تعلیق شکن یکسان باشند، به عبارتی دما، غلظت تعلیق شکن و نسبت آب رقیق کننده برای هر دو تعلیق شکن یکسان باشند. دلیل رعایت این نکته بدین خاطر است که اگر مدل پیشنهادی

۸۵٪ برای تعلیق شکن الف می‌شود. به عبارتی با استفاده از الگوریتم بی‌زین ۸۸/۵٪ احتمال تشخیص عملکرد مناسب تعلیق شکن وجود دارد، در صورتی که با استفاده از معیار ریسک این احتمال به ۹۶/۲٪ افزایش پیدا می‌کند. همچنین استفاده از معیار ریسک احتمال تشخیص عملکرد کلی را از ۹۳/۸ به ۹۵/۸٪ افزایش می‌دهد. شکل ۵ نیز نشان می‌دهد استفاده از معیار ریسک برای تنظیم فرآپارامترهای ماشین بردار پشتیبان احتمال خطا در تشخیص عملکرد کلی تعلیق شکن ب را از ۱۲/۵٪ به ۸/۳٪ کاهش می‌دهد. همچنین مدل تهیه شده برای تعلیق شکن ب، با دقت کامل عملکرد نامطلوب را تشخیص داده است. به عبارتی به ازای کل داده‌ها با راندمان کمتر از ۸۵٪، مدل مقادیر کمتر از ۸۵٪ را ذکر می‌کند. شکل ۶ و شکل ۷ به ترتیب برازش و ب را با استفاده از دو مدل ماشین بردار پشتیبان نشان می‌دهند.

جدول ۶ مشخصات و فرآپارامترهای تعیین شده برای مدل‌سازی عملکرد هر نمونه تعلیق شکن.

پارامتر	بی‌زین تعلیق شکن الف	مدل ریسک تعلیق شکن الف	بی‌زین تعلیق شکن ب	مدل ریسک تعلیق شکن ب
حجم داده آموزشی	۴۰	۴۰	۴۰	۴۰
حجم داده ارزیابی	۸	۸	۸	۸
نوع کرنل	گوسی	گوسی	گوسی	گوسی
سطح نویز ^۲	۰/۰۱	۰/۰۰۵	۰/۰۴	۰/۰۰۵

پیش بینی کلاس راندمان مبتنی بر الگوریتم کاهش ریسک

راندمان پایین	۲۱	۱	٪۹۵/۵
راندمان بالا	۱	۲۵	٪۹۶/۲
	٪۹۵/۵	٪۹۶/۲	٪۹۵/۸
	راندمان پایین	راندمان بالا	

نتایج طبقه بندی شده (نتایج تجربی)

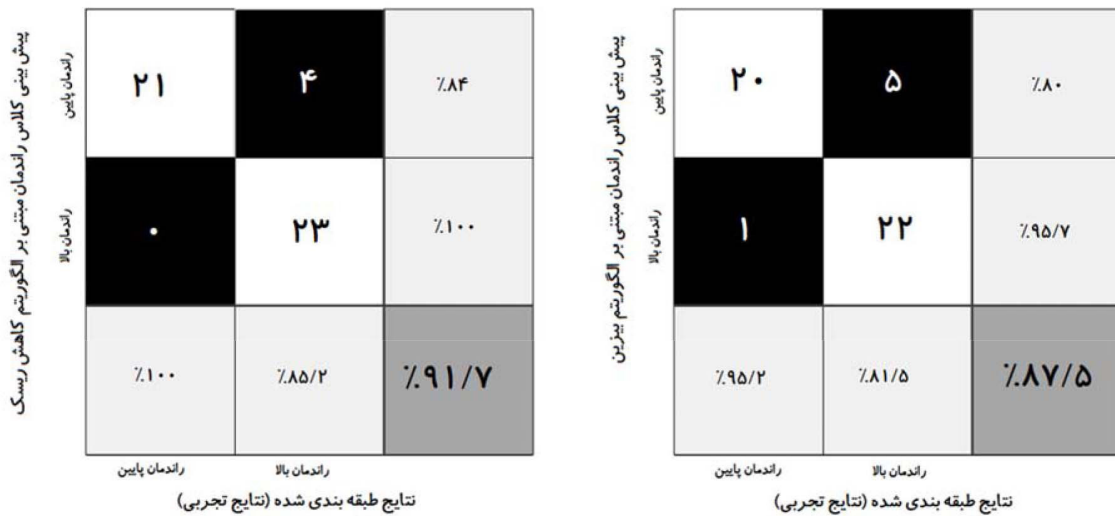
پیش بینی کلاس راندمان مبتنی بر الگوریتم بی‌زین

راندمان پایین	۲۲	۳	٪۸۸
راندمان بالا	۰	۲۳	٪۱۰۰
	٪۱۰۰	٪۸۸/۵	٪۹۳/۸
	راندمان پایین	راندمان بالا	

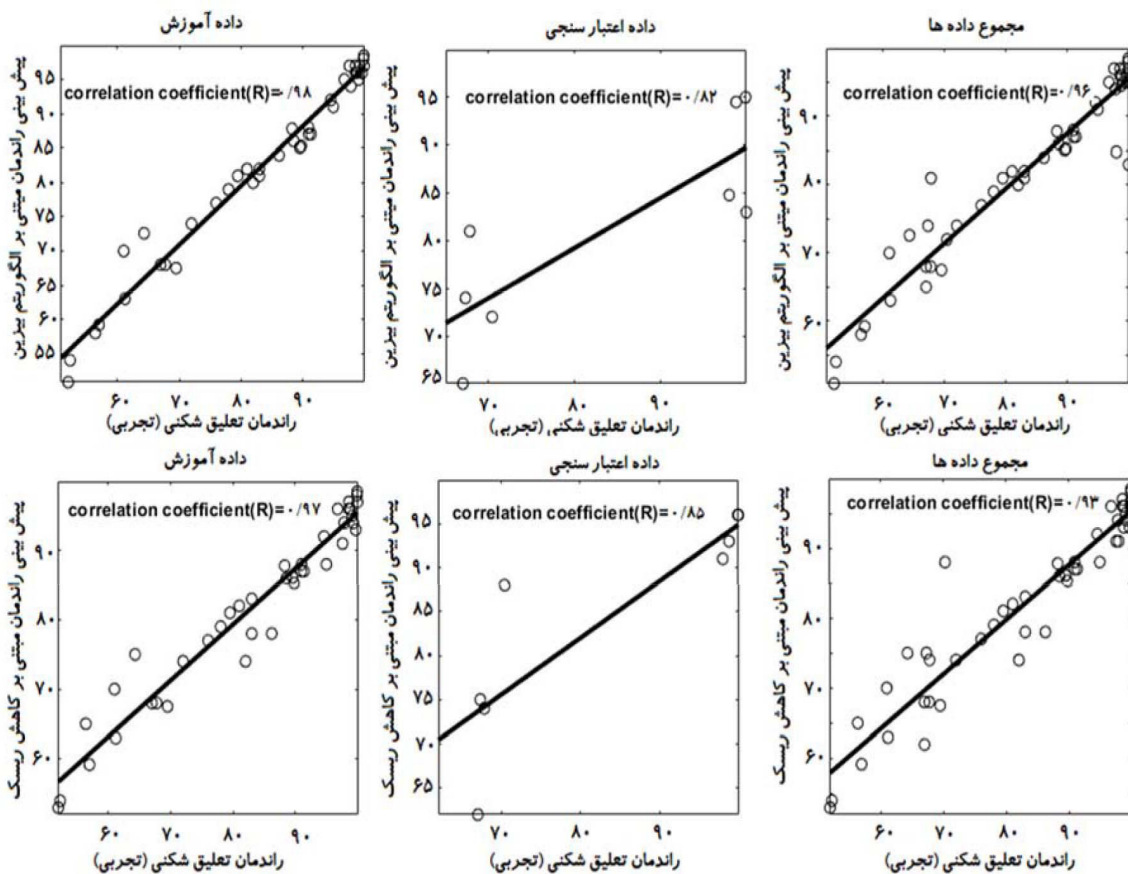
نتایج طبقه بندی شده (نتایج تجربی)

شکل ۴ ماتریس درهم ریختگی بین نتایج ماشین بردار پشتیبان و نتایج آزمایشگاهی برای تعلیق شکن الف.

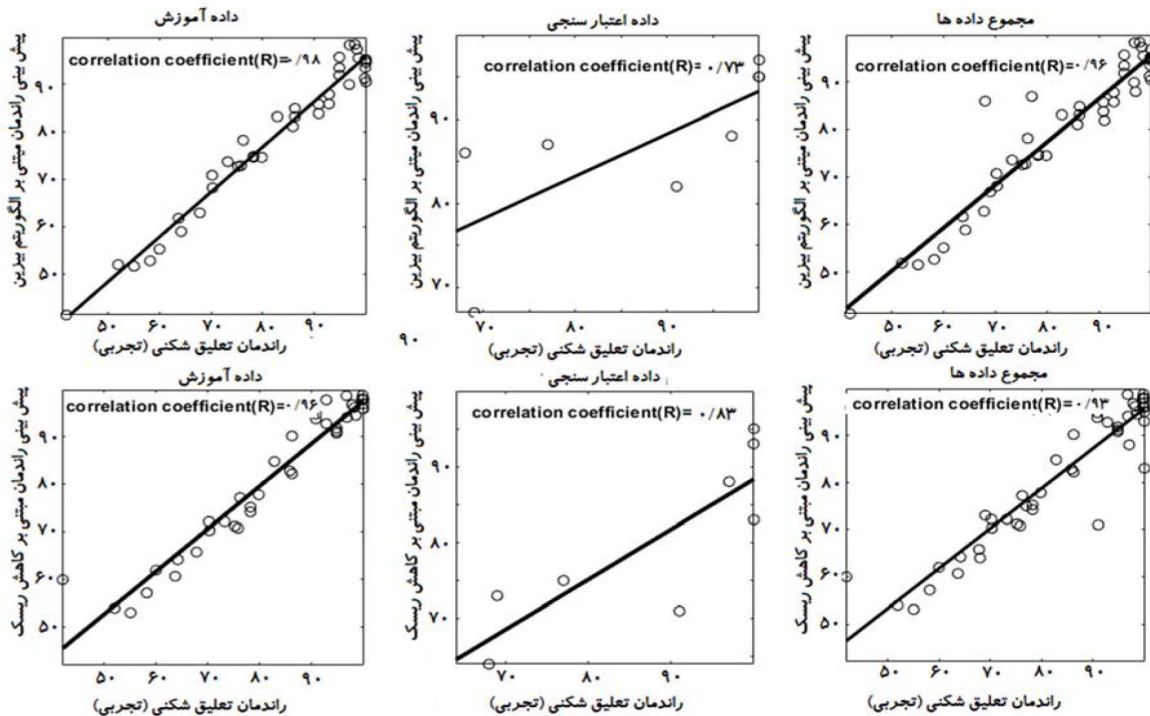
1. Confusion Matrix
2. Noise Level



شکل ۵ ماتریس درهم ریختگی بین نتایج ماشین بردار پشتیبان و نتایج آزمایشگاهی برای تعلیق شکن ب.



شکل ۶ برازش پیش‌بینی نتایج دو مدل ماشین بردار پشتیبان با نتایج آزمایشگاهی برای تعلیق شکن الف.



شکل ۷ برازش پیش‌بینی نتایج دو مدل ماشین بردار پشتیبان با نتایج آزمایشگاهی برای تعلیق شکن ب.

نشان می‌دهند. منظور از e و n در روابط ۱۱ و ۱۲ به ترتیب خطای پیش‌بینی و تعداد داده‌های مدل است. **جدول ۷ و جدول ۸** به ترتیب تحلیل آماری عملکرد دو مدل ماشین بردار پشتیبان را برای تعلیق شکن‌های الف و ب نشان می‌دهند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (11)$$

$$MAE = \frac{\sum_{i=1}^n |e_i|}{n} \quad (12)$$

تحلیل آماری **جدول ۷** نشان می‌دهد، استفاده از معیار ریسک به جای الگوریتم بیزین برای تنظیم فرآپارامترهای ماشین بردار پشتیبان موجب افزایش ضریب همبستگی مدل برای راندمان‌های بالاتر از ۸۵٪ می‌شود. ضریب همبستگی بالاتر کمک می‌کند با احتمال بهتری روند عملکرد تعلیق شکن در راندمان‌های بالا پیش‌بینی شود که این مورد برای انتخاب شرایط بهینه عملیاتی بسیار ضروری است.

شکل ۶ و شکل ۷ نشان می‌دهند فرآپارامترهای تنظیم شده با استفاده از الگوریتم بیزین برازش بهتری بین نتایج آزمایشگاهی و دو مدل ماشین بردار پشتیبان برای داده‌های آموزشی و کل پایگاه داده دارد. اما تنظیم فرآپارامترها با در نظر گرفتن معیار ریسک منجر به بهبود پیش‌بینی نتایج ماشین بردار پشتیبان برای داده‌های ارزیابی هر دو مدل شد. تعلیق شکن نسبت به استفاده از الگوریتم بیزین شده است. از طرفی هدف از مدل‌سازی عملکرد تعلیق شکن‌ها پیش‌بینی عملکرد آنها در شرایط مختلف برای دستیابی به راندمان‌های بالا است. به همین منظور با توجه به مقادیر به دست آمده از ماشین بردار پشتیبان، بین نتایج آزمایشگاهی و مقادیر پیش‌بینی شده هر مدل با استفاده از ضریب همبستگی^۱، جذر متوسط مجموع مربعات خطا^۲ و متوسط قدرمطلق خطا^۳ تحلیل آماری برای راندمان‌های بالاتر از ۸۵٪ و کمتر از آن صورت گرفت.

روابط ۱۱ و ۱۲ به ترتیب نحوه محاسبه جذرانحراف از میانگین مربعات خطا و متوسط قدرمطلق خطا را

1. Correlation Coefficient
2. Root Mean Square Error (RMSE)
3. Mean Absolute Error (MAE)

جدول ۷ برازش پیش‌بینی نتایج دو مدل ماشین بردار پشتیبان با نتایج آزمایشگاهی برای تعلیق شکن ب

راندمان کمتر از ۰.۸۵٪			راندمان بالای ۰.۸۵٪			تحلیل آماری	مدل
MAE	RMSE	R	MAE	RMSE	R		
۴/۱	۵/۶	۰/۸۲	۳/۹	۴/۲	۰/۹۲		مدل تنظیم شده با معیار ریسک
۳/۱	۴/۹	۰/۸۹	۳/۹	۵/۳	۰/۷۴		مدل تنظیم شده با الگوریتم بیزین



جدول ۸ تحلیل آماری بین نتایج آزمایشگاهی و دو مدل ماشین بردار پشتیبان برای تعلیق شکن ب.

راندمان کمتر از ۰.۸۵٪			راندمان بالای ۰.۸۵٪			تحلیل آماری	مدل
MAE	RMSE	R	MAE	RMSE	R		
۳/۰۴	۴/۷	۰/۸۶	۴/۴	۶	۰/۷۸		مدل تنظیم شده با معیار ریسک
۳/۴	۴/۴	۰/۹۶	۴/۹	۶/۱	۰/۷۷		مدل تنظیم شده با الگوریتم بیزین

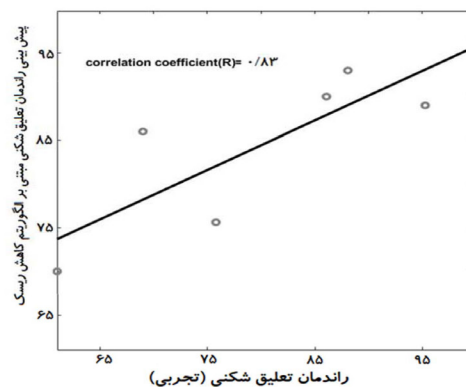

مدل ماشین بردار پشتیبان دستیابی و پیش‌بینی راندمان‌های بالا در جداسازی آب شور از امولسیون نفت خام است.

جدول ۸ نشان می‌دهد با استفاده از معیار ریسک برای تنظیم فرآپارامترها در راندمان‌های بالاتر از ۰.۸۵٪، پیش‌بینی روند تغییرات و متوسط دقت پیش‌بینی برای تعلیق شکن ب افزایش پیدا کرده است. تحلیل آماری و ماتریس درهم ریختگی نتایج هر دو تعلیق شکن نشان می‌دهد، استفاده از معیار ریسک برای تنظیم فرآپارامترهای ماشین بردار پشتیبان باعث افزایش دقت تشخیص و پیش‌بینی عملکرد آنها می‌شود. اما از دیدگاه صنعتی مدلی ارزشمند است که برای داده‌هایی خارج از فضای اولیه نیز نتایج قابل قبول ارائه دهد. به عبارتی داده‌های ارزیابی و آموزشی مورد بحث، همگی در شرایط عملیاتی مشخصی به مدل ارائه شدند. مثلاً نوع امولسیون‌ها، دما، غلظت تعلیق شکن و نسبت آب رقیق کننده اعداد مشخصی دارند و مدل به نحوی تنظیم می‌شود که بهترین پیش‌بینی را داشته باشد. شکل ۸ و شکل ۹ نشان می‌دهند استفاده از معیار ریسک برای تنظیم فرآپارامترهای مدل به جای استفاده از الگوریتم بیزین سبب بالارفتن دقت مدل به ترتیب برای پیش‌بینی عملکرد تعلیق شکن الف و ب برای نمونه‌ای خارج از محدوده می‌شود.

به عبارتی اگر راندمان تعلیق شکن الف برای نمونه خاص عدد مشخصی باشد و نیاز به پیش‌بینی نتایج در شرایط عملیاتی دیگر باشد با استفاده از معیار ریسک، ۹۲٪ احتمال وجود دارد که روند تغییر راندمان درون مدل با نتایج آزمایشگاهی همخوانی داشته باشد، در صورتی که این مقدار برای مدل بیزین ۷۴٪ است. همچنین استفاده از معیار ریسک باعث کاهش جذر متوسط مربعات خطا شده است. با کاهش جذر متوسط مربعات خطا برای هر مدل، دقت مدل در پیش‌بینی نتایج افزایش پیدا می‌کند. به عبارتی برای تعلیق شکن الف، استفاده از معیار ریسک برای تنظیم فرآپارامترهای ماشین بردار پشتیبان موجب افزایش دقت مدل برای راندمان‌های بالاتر از ۰.۸۵٪ می‌شود. در نتیجه برای تعلیق شکن الف برای دست‌یابی به راندمان‌های بالا، تنظیم فرآپارامترها با استفاده از الگوریتم پیشنهادی به مراتب بهتر از الگوریتم بیزین می‌باشد، زیرا روند تغییرات با این روش بهتر پیش‌بینی می‌شود. به علاوه به صورت متوسط مقدار پیش‌بینی شده توسط مدل اختلاف کمتری با مقادیر تجربی دارد. تحلیل آماری موجود در جدول ۷ نشان می‌دهد استفاده از معیار ریسک برای راندمان‌های پایین‌تر از ۰.۸۵٪ دقت کمتری نسبت به الگوریتم بیزین دارد. البته دقت کمتر در پیش‌بینی راندمان‌های پایین از اهمیت کمی برخوردار است. زیرا هدف از طراحی



شکل ۸ برازش نتایج آزمایشگاهی با نتایج پیش‌بینی دو مدل ماشین بردار پشتیبان برای اعتبارسنجی مدل تعلیق شکن الف.



شکل ۹ برازش نتایج آزمایشگاهی با نتایج دو مدل ماشین بردار پشتیبان برای تعلیق شکن ب.

تنظیم شده براساس الگوریتم بی‌زین فقط دو راندمان از چهار راندمان بالا را تشخیص داده است. به عبارتی مدل تنظیم شده با معیار ریسک برای تعلیق شکن ب با دقت ۱۰۰٪ راندمان‌های بالاتر از ۸۵٪ را برای نمونه جدید پیش‌بینی می‌کند، در صورتی که دقت مدل تنظیم شده با الگوریتم بی‌زین ۵۰٪ است. تحلیل آماری نتایج برای داده‌های اعتبارسنجی نشان می‌دهد، مدل تنظیم شده با معیار ریسک با دقت قابل قبولی عملکرد تعلیق شکن‌ها را در راندمان‌های بالای ۸۵٪ نسبت به مدل تنظیم شده با الگوریتم بی‌زین پیش‌بینی می‌کند. جدول ۹ تحلیل آماری نتایج دو مدل بردار پشتیبان برای هر نمونه تعلیق شکن را در راندمان‌های بالای ۸۵٪ نشان می‌دهد.

به علاوه در شکل ۸ مشخص است که مدل ماشین بردار پشتیبان راندمان‌های بالاتر از ۸۵٪ را برای تعلیق شکن الف به صورت کامل پیش‌بینی نموده است و فقط یک راندمان کمتر از ۸۵٪ را به اشتباه بیش‌تر از ۸۵٪ تشخیص داده است. به عبارتی دقت تشخیص عملکرد برای داده‌های اعتبارسنجی تعلیق شکن الف برای راندمان‌های بالاتر از ۸۵ درصد، ۱۰۰٪ و برای کل مجموعه داده ۸۶٪ است، در صورتی که برای الگوریتم بی‌زین این مقادیر به ترتیب ۶۶٪ و ۷۱٪ می‌باشند. در شکل ۹ برای تعلیق شکن ب نیز شرایط مشابه است. به عبارتی مدل تنظیم شده براساس معیار ریسک تعلیق شکن ب نیز هر چهار راندمان بالاتر از ۸۵٪ را به خوبی تشخیص داده است، در صورتی که مدل

جدول ۹ تحلیل آماری بین نتایج آزمایشگاهی و نتایج دو مدل ماشین بردار پشتیبان برای داده‌های اعتبارسنجی در راندمان‌های بالای ۸۵٪

تعلیق شکن ب		تعلیق شکن الف		تحلیل آماری	مدل
MAE	RMSE	MAE	RMSE		
۴/۵	۴/۶	۵/۸	۶/۲	تنظیم شده بر اساس ریسک	
۵/۸	۷/۱	۹/۵	۹/۶	تنظیم شده با الگوریتم بی‌زین	

نتیجه‌گیری

امولسیون پایدار آب شور در نفت خام باعث کاهش ارزش نفت خام، خوردگی تجهیزات در انتقال، نگهداری و پالایش نفت خام می‌شود. ترکیبات متنوعی در نفت خام وجود دارد که برهمکنش بین آنها بر پایداری امولسیون موثر است. با توجه به پیچیدگی و تعداد بالای ابعاد یا ترکیبات موثر بر پایداری امولسیون، انتخاب یک مولفه مناسب که توسط آن پیش‌بینی پایداری امولسیون و رفتار آن با مواد فعال سطحی شیمیایی میسر شود بسیار مفید است، زیرا تامین تعلیق شکن‌ها با چالش‌های خاصی همراه است به علاوه وجود یک مدل مناسب باعث کاهش هزینه‌های آزمایشگاهی با توجه به تنوع نمونه نفت‌های برداشتی و مواد تعلیق شکن می‌شود. به عبارتی طراحی یک مدل هوشمند کمک می‌کند انتخاب شرایط عملیاتی مناسب باریسک کم پیش‌بینی شود. به علاوه باعث کاهش چشمگیر هزینه‌های واحدهای نمکزدایی و بهره‌برداری می‌شود. منظور از کنترل زمانی است که با استفاده از مخزن نامرغوب نفت خام مولفه‌ای خاص از نفت خام در محدوده مناسب مدل تنظیم شود. در این مطالعه از نسبت آسفالتین به مجموع رزین و آروماتیک به عنوان معیار پایداری نفت خام استفاده شد. برای پیش‌بینی عملکرد تعلیق شکن‌های تجاری از ماشین بردار پشتیبان استفاده شد. مهم‌ترین چالش ماشین‌های بردار پشتیبان تنظیم فرآپارامترهای آنها می‌باشد. با توجه به اهداف صنعتی مطالعه، فرآپارامترهای ماشین بردار پشتیبان به جای استفاده از ضریب تعیین یا کاهش مقدار خطای مدل، بر اساس کاهش ریسک در پیش‌بینی نتایج به عنوان معیار اصلی و افزایش ضریب همبستگی به عنوان معیار دوم تنظیم شد. عملکرد الگوریتم پیشنهادی با الگوریتم بیزین که کاربرد گسترده‌ای در تنظیم فرآپارامترهای بردار پشتیبان دارد مقایسه شد. نتایج نشان می‌دهد استفاده از معیار ریسک در تنظیم

فرآپارامترهای ماشین بردار پشتیبان دقت بهتری در تشخیص عملکرد تعلیق شکن‌های تجاری برای راندمان‌های بالاتر از ۸۵٪ نسبت به الگوریتم بیزین دارد. به علاوه عملکرد مدل طراحی شده برای هر تعلیق شکن با یک نمونه امولسیون جدید به منظور اعتبار سنجی هر دو مدل مورد بررسی قرار گرفت. نتایج اعتبارسنجی نشان می‌دهند استفاده از معیار ریسک کمک می‌کند دقت پیش‌بینی مدل برای داده‌های خارج از محدوده طراحی به مراتب بیش تر از الگوریتم بیزین باشد.

تشکر و قدردانی

نویسندگان از شورای پژوهشی دانشگاه صنعتی امیرکبیر و مهندسين واحدهای عملیات و پژوهش و فناوری شرکت ملی مناطق نفتخیز جنوب به سبب حمایت‌های مالی و معنوی از این پژوهش کمال تشکر و قدردانی را دارند.

علائم و نشانه‌ها

* α, α : ضرایب دوگانه لاگرانژ که برای تعیین بردارهای پشتیبان لازم هستند
 γ : پارامتر تنظیم کرنل های گوسی
 ξ, ξ : مقادیر تعیین کننده داده های خارج از محدوده
 ω : بردار نرمال ابرصفحه ای که برای برازش داده ها استفاده می شود.
 A_r : درصد وزنی ترکیبات آروماتیک موجود در نفت خام
 A_s : درصد وزنی آسفالتین موجود در نفت خام
 C : پارامتر تنظیم شبکه (پارامتر جریمه)
 ϵ : اختلاف بین مقادیر تجربی با پیش بینی ماشین بردار پشتیبان
 ESI : شاخص پایداری امولسیون، برابر نسبت آسفالتین بر مجموع رزین و آروماتیک نفت خام
 n : تعداد داده مورد بررسی
 R_a : راندمان تعلیق شکنی
 Re : درصد وزنی رزین موجود در نفت خام

آزمایش	NE_{H85} : مجموعه نتایجی که راندمان تعلیق شکن
WC_i : درصد حجمی آب همراه اولیه امولسیون نفت	بیش از ۰.۸۵٪ است
خام	NE_{L85} : مجموعه نتایجی که راندمان تعلیق شکن
y_i : مقدار تجربی آزمایش مرتبه i	کمتر از ۰.۸۵٪ است
\bar{y} : میانگین مقادیر تجربی	V_c : حجم نفت خام
y_i^* : مقدار پیش بینی شده آزمایش مرتبه i توسط	V_{wi} : حجم اولیه آب همراه درون امولسیون نفت خام
ماشین بردار پشتیبان	V_{wf} : حجم آب شور باقی مانده درون نفت خام پس
\bar{y}^* : متوسط مقادیر پیش بینی شده توسط ماشین	از امولسیون زدایی
بردار پشتیبان	V_1 : نسبت آب رقیق کننده به نفت خام
	V_2 : حجم آب شور جدا شده از امولسیون پس از اتمام

مراجع

- [1]. Abdel Raouf M. E. (2012). Crude oil emulsions- composition stability and characterization, Edition 1, Crude Oil Emulsions- Composition Stability and Characterization, BoD-Books on Demand, InTech. <https://doi.org/10.5772/2677>.
- [2]. Vafajoo, L., Ganjian, K., and Fattahi, M. (2012). Influence of key parameters on crude oil desalting: An experimental and theoretical study, Journal of Petroleum Science and Engineering, 90, 107–111, doi.org/10.1016/j.petrol.2012.04.022.
- [3]. Bhardwaj, A. and Hartland, S. (1994). Dynamics of emulsification and demulsification of water in crude oil emulsions, Industrial & Engineering Chemistry Research, 33(5), 1271–1279. <https://doi.org/10.1021/ie00029a025>.
- [4]. Speight, J. G. (2014). Chapter 3 - Corrosion in Refinery Units (J. G. B. T.-O. and G. C. P. Speight (Ed.)), 39–66, Gulf Professional Publishing, doi.org/10.1016/B978-0-12-800346-6.00003-X.
- [5]. Talebi, H., Maghsoudy, S., and Habibzadeh, S. (2022). Synthesis and characterization of corrosion inhibitor nanoparticles in oil and gas industry, Iranian Chemical Engineering Journal, 21(124), 7–29, doi.org/10.22034/ijche.2021.309739.1144.
- [6]. Saad, M. A., Kamil, M., Abdurahman, N. H., Yunus, R. M., and Awad, O. I. (2019). An overview of recent advances in state-of-the-art techniques in the demulsification of crude oil emulsions, Processes, 7(7), 470, doi.org/10.3390/pr7070470.
- [7]. Ramirez-Corredores, M. M. (2017). Asphaltenes. In The Science and Technology of Unconventional Oils, 41–222, Elsevier, doi.org/10.1016/B978-0-12-801225-3.00002-4.
- [8]. Lashkarbolooki, M. and Ayatollahi, S. (2018). Effects of asphaltene, resin and crude oil type on the interfacial tension of crude oil/brine solution. Fuel, 223, 261–267. [doi.org/https://doi.org/10.1016/j.fuel.2018.03.029](https://doi.org/10.1016/j.fuel.2018.03.029).
- [9]. Schorling, P. C., Kessel, D. G. and Rahimian, I. (1999). Influence of the crude oil resin/asphaltene ratio on the stability of oil/water emulsions, Colloids and Surfaces A: Physicochemical and Engineering Aspects, 152(1): 95–102, [doi.org/10.1016/S0927-7757\(98\)00686-4](https://doi.org/10.1016/S0927-7757(98)00686-4).
- [10]. Kokal, S. and Al-Juraid, J. (1999). Quantification of various factors affecting emulsion stability: watercut, temperature, shear, asphaltene content, demulsifier dosage and mixing different crudes, In Proceedings - SPE Annual Technical Conference and Exhibition, 2 (PI), 91–99, doi.org/10.2118/56641-ms.
- [11]. Rondón, M., Pereira, J. C., Bouriat, P., Graciaa, A., Lachaise, J. and Salager, J. L. (2008). Breaking of water-in-crude-oil emulsions. 2. influence of asphaltene concentration and diluent nature on demulsifier action, Energy & Fuels, 22(2), 702–707. doi.org/10.1021/ef7003877.
- [12]. Ramalho, J. B. V. S., Lechuga, F. C. and Lucas, E. F. (2010). Effect of the structure of commercial poly (ethylene oxide-b-propylene oxide) demulsifier bases on the demulsification of water-in-crude oil emulsions: elucidation of the demulsification mechanism, Quimica Nova, 33, 1664–1670, <https://doi.org/10.1590/S0100-40422010000800009>.
- [13]. Shi, Y., Chen, J. and Meng, H. (2022). Experimental study on the performance of an electric field enhanced separator for crude oil production fluid, Journal of Petroleum Science and Engineering, 212, 110315, doi.org/10.1016/j.petrol.2022.110315.

- [14]. Tadros, T. F. (2005). *Applied Surfactants*, Wiley, doi.org/10.1002/3527604812.
- [15]. Ahmadi, S., Khormali, A. and Meerovich Khoutoriansky, F. (2022). Optimization of the demulsification of water-in-heavy crude oil emulsions using response surface methodology, *Fuel*, 323, 124270, doi.org/10.1016/j.fuel.2022.124270.
- [16]. Adewunmi, A. A., Kamal, M. S. and Olatunji, S. O. (2022). Demulsification of crude oil emulsions using ionic liquids: A computational intelligence approach, *Journal of Petroleum Science and Engineering*, 208, 109279, doi.org/10.1016/j.petrol.2021.109279.
- [17]. Dhandhi, Y., Prakash, O., Naiya, T. K. and Guria, C. (2022). Statistical design and process optimization for using chemical demulsifiers for the dehydration of the crude oil, *Journal of Petroleum Science and Engineering*, 217, 110876, doi.org/10.1016/j.petrol.2022.110876.
- [18]. Uetani, T., Kai, J., Hitomi, T., Seino, H., Shimbori, K. and Yonebayashi, H. (2020). Experimental investigation of crude-oil emulsion stability: effect of oil and brine compositions, asphaltene, wax, toluene insolubles, temperature, shear stress, and water cut, In *SPE Production and Operations*, 35, 2: 320–334, doi.org/10.2118/192064-PA.
- [19]. Kazemzadeh, Y., Ismail, I., Rezvani, H., Sharifi, M. and Riazi, M. (2019). Experimental investigation of stability of water in oil emulsions at reservoir conditions: Effect of ion type, ion concentration, and system pressure, *Fuel*, 243, 15–27, doi.org/10.1016/j.fuel.2019.01.071.
- [20]. Lashkarbolooki, M. and Ayatollahi, S. (2018). The effects of pH, acidity, asphaltene and resin fraction on crude oil/water interfacial tension, *Journal of Petroleum Science and Engineering*, 162, 341–347, doi.org/10.1016/j.petrol.2017.12.061.
- [21]. Malley, J. D., Malley, K. G. and Pajevic, S. (Eds.). (2011). *Error analysis and model validation*, In *statistical learning for biomedical data*, 215–244, Cambridge University Press, doi: 10.1017/CBO9780511975820.012.
- [22]. Wang, Y. G., Wu, J., Hu, Z.-H. and McLachlan, G. J. (2023). A new algorithm for support vector regression with automatic selection of hyperparameters, *Pattern Recognition*, 133, 108989, doi.org/10.1016/j.pat-cog.2022.108989.
- [23]. Apriyadi, M. R., Ermatita and Rini, D. P. (2023). Hyperparameter optimization of support vector regression algorithm using metaheuristic algorithm for student performance prediction, *International Journal of Advanced Computer Science and Applications*, 14(2), 144–150, doi.org/10.14569/IJACSA.2023.0140218.
- [24]. Zhou, T., Hu, Q., Hu, Z. and Zhen, R. (2022). An adaptive hyper parameter tuning model for ship fuel consumption prediction under complex maritime environments, *Journal of Ocean Engineering and Science*, 7(3), 255–263, doi.org/10.1016/j.joes.2021.08.007.
- [25]. Alvarado, J. G., Delgado-Linares, J. G., Forgiarini, A. M. and Salager, J. L. (2019). Breaking of water-in-crude oil emulsions. 8. demulsifier performance at optimum formulation is significantly improved by a small aromatic content of the oil, *Energy & Fuels*, 33(3), 1928–1936, doi.org/10.1021/acs.energyfuels.8b03994.
- [26]. Umar, A. A., Nnakenyi, N. I., Abba, M. K. and Roy-Omeni, I. H. (2021). Surfactants as integral components of chemical demulsifiers BT - surfactants in upstream E&P (T. Solling, M. Shahzad Kamal, & S. M. Shakil Husain (Eds.), 443–466, Springer International Publishing, doi.org/10.1007/978-3-030-70026-3_16
- [27]. Awad, M. and Khanna, R. (2015). *Support Vector Regression*, In *Efficient Learning Machines*, 67–80, Apress, doi.org/10.1007/978-1-4302-5990-9_4.
- [28]. Forghani, Y., Tabrizi, R. S., Yazdi, H. S., & Akbarzadeh-T, M. R. (2008). *Support Vector Machines*, In 2011 1st International eConference on Computer and Knowledge Engineering, ICCKE 2011, Springer New York, doi.org/10.1007/978-0-387-77242-4.