

پیش بینی رسوب آسفالتین با استفاده از شبکه عصبی مصنوعی بر مبنای الگوریتم ازدحام ذرات

محمد علی احمدی^۱ دانشجوی کارشناسی ارشد مهندسی نفت، دانشگاه صنعت نفت
نیما رشیدی نیا، محمد عبادی^۲ فارغ التحصیل مهندسی نفت، دانشگاه آزاد واحد علوم و تحقیقات

سید رضا شادی زاده^۳ دانشیار دانشگاه صنعت نفت

چکیده

یکی از پدیده‌های مهم در صنعت نفت رسوب مواد آلی سنگین همچون آسفالتین^۲ می‌باشد که منجر به کاهش ضریب پخش^۳ و تغییر ترشوندگی^۴ سنگ مخزن شده و در نتیجه تأثیر نامطلوب در بازیافت نفت و بازده اقتصادی را به دنبال خواهد داشت. در این مقاله از شبکه عصبی مصنوعی با سیستم پیشخور^۵ برای پیش‌بینی رسوب آسفالتین، در اثر اضافه نمودن حلال استفاده شده است. در ادامه با بهینه‌سازی الگوی ازدحام ذرات^۶ (PSO)، شبکه عصبی مصنوعی^۷ (ANN) نیز بهینه‌سازی گردیده است. بهینه‌سازی الگوریتم ازدحام ذرات به منظور تعیین وزن‌های اولیه مورد استفاده قرار گرفته است. در این مقاله ترکیب شبکه عصبی مصنوعی به همراه بهینه‌سازی الگوی ازدحام ذرات (PSO-ANN) بر روی داده‌های آزمایشگاهی به کار گرفته شده است. در انتها عملکرد PSO-ANN با مدل مقیاس^۸ مقایسه شد که نتایج نشان‌دهنده اثر بخشی مدل PSO-ANN می‌باشد.

واژه‌های کلیدی | رسوب آسفالتین، شبکه عصبی مصنوعی، بهینه‌سازی ازدحام ذرات

مقدمه

یکی از پدیده‌های مهم در صنعت نفت رسوب مواد آلی سنگین همچون آسفالتین می‌باشد که باعث کاهش ضریب پخش و تغییر ترشوندگی سنگ مخزن شده و در نتیجه بازیافت نفت و بازده اقتصادی را تحت تأثیر منفی قرار خواهد داد.

سنسور نرم^۹ یک ابزار ادراکی است که خروجی می‌تواند بر حسب بقیه پارامترها که به یک فرآیند یکسان وابسته‌اند، مدل‌سازی شود. طبق اظهارات Rallo و همکاران [۹] شبکه عصبی مصنوعی می‌تواند به عنوان یک ساختار سنسور نرم مورد استفاده قرار گیرد. شبکه عصبی مصنوعی یک ابزار رایج غیر خطی و غیر پارامتری در تفسیر نمودارهای چاه‌نگاری بوده و به صورت گسترده‌ای برای پیش‌بینی خواص مخزن به وسیله نمودارهای چاه‌نگاری^{۱۰} به کار گرفته می‌شود.

تعیین ساختار و پارامترهای شبکه بسیار با اهمیت می‌باشد. بدین منظور می‌توان از تعدادی الگوریتم تکاملی پویا مانند الگوریتم ژنتیک^{۱۱}، الگوریتم پس‌انتشار^{۱۲}، الگوریتم هرس^{۱۳} و شبیه‌سازی باز پخت^{۱۴} استفاده نمود.

آموزش^{۱۵} شبکه عصبی مصنوعی را نیز می‌توان مسئله‌ای از نوعی بهینه‌سازی در نظر گرفت. اخیراً تعدادی الگوریتم تکاملی با الهام از رفتار اجتماعی در طبیعت برای حل آموزش شبکه عصبی مصنوعی گسترش پیدا نموده است. الگوی ذره‌ای ازدحام، الگوریتمی با الهام از رفتار اجتماعی در طبیعت می‌باشد که رفتار گروه مورچگان یا پرندگان را شبیه‌سازی می‌کند. توسعه بهینه‌سازی الگوی ازدحام ذرات (PSO) هم اکنون مطرح و در دست مطالعه می‌باشد. به دلیل ساختار ساده و پیاده سازی آسان این الگوریتم، تعداد مقالات مرتبط با PSO در حال افزایش است.

در این تحقیق، از PSO به عنوان ابزاری جهت بهینه‌سازی وزن‌های^{۱۶} پیشخور شبکه عصبی مصنوعی استفاده شده است. نتایج شبیه‌سازی نشان‌دهنده قدرت و پتانسیل شبکه جدید در مقایسه با مدل مقیاس است.

۱- شبکه عصبی مصنوعی

هوش مصنوعی مجموعه‌ای از روش‌های پردازش موازی است که می‌تواند پیچیدگی و ارتباط خطی را می‌تواند با استفاده از تعدادی الگوی آموزش ورودی-خروجی از داده‌های آزمایشگاهی بیان نماید. شبکه عصبی مصنوعی بوسیله قابلیت ذاتی خود، رابطه‌ای خطی بین ورودی و خروجی برقرار می‌کند. موفقیت در به دست آوردن شبکه قابل اعتماد و قوی بستگی به پیش‌پردازش درست، انتخاب ساختار مناسب و به ویژه انتخاب شبکه آموزش قوی دارد. مرسوم‌ترین شبکه عصبی مصنوعی نوع پیشخور آن می‌باشد. شبکه پیشخور ساختاری است که اطلاعات یا سیگنال‌ها فقط در یک جهت از ورودی به خروجی منتشر می‌شوند. یک شبکه عصبی مصنوعی پیشخور سه لایه با الگوریتم انتشار برگشت می‌تواند هر تابع پیوسته غیر خطی را با دقت دلخواه تخمین بزند. شبکه با بهینه‌سازی وزن برای هر نقطه^{۱۷} مرتبط و ترم‌های بایاس^{۱۸} آموزش داده می‌شود. این آموزش تا زمانی که مقدار خروجی در لایه خروجی نرون‌ها^{۱۹} تا حد امکان به مقدار واقعی نزدیکتر شود ادامه پیدا می‌کند. بر این اساس میانگین مجذور خطای شبکه به صورت زیر تعریف می‌شود:

$$MSE = \frac{1}{2} \sum_{k=1}^G \sum_{j=1}^m [Y_j(k) - T_j(k)]^2 \quad (1)$$

که در آن m تعداد نقطه‌ها، G تعداد نمونه‌های آزمایش، Yj(k) خروجی پیش‌بینی شده و Tj(k) خروجی واقعی است.




۳- نتایج مدل PSO-ANN

در این مطالعه شبکه عصبی مصنوعی جهت مدل سازی پیش بینی رسوب آسفالتین مورد استفاده قرار گرفته است. بهترین ساختار شبکه عصبی مصنوعی شامل ۳ ورودی، ۴ نرون در اولین لایه مخفی، ۱۰ نرون در دومین لایه مخفی و ۱ نرون در خروجی بوده است. مدل شبکه عصبی مصنوعی با استفاده از شبکه پس انتشار آموزش داده شده (شکل ۱) و بر اساس سه پارامتر (وزن مولکولی، نسبت رقت^{۲۷} و دما) به عنوان ورودی و با استفاده از Levenberg-Marquardt به منظور پیش بینی رسوب آسفالتین ساخته شده است. توابع انتقال در لایه های مخفی و خروجی به ترتیب به صورت خطی و سیگموئیدی^{۲۸} می باشند.

PSO به عنوان الگوریتم بهینه ساز شبکه عصبی مصنوعی و میانگین مجذور خطا (MSE) به عنوان تابع هزینه در این الگوریتم مورد استفاده قرار گرفته اند. هدف از این الگوریتم کمینه کردن تابع هزینه است. تمامی وزن ها به صورت تصادفی در بازه $[-1, +1]$ مقداردهی اولیه شده اند. مقدار اولیه و نهایی اینرسی $\theta_{\min} = 0.4$ و $\theta_{\max} = 0.5$ می باشد. مقادیر ثابت های c_1 و c_2 معادل ۲ و ۲_۱ و دو عدد تصادفی بین صفر و یک در نظر گرفته می شود.

در این مطالعه از ۱۱۴ داده تصادفی استفاده شده است که ۷۶ داده برای آزمایش و ارزیابی یکبارچگی و قدرت شبکه مورد استفاده قرار گرفته اند. خواص و اجزای مولی تشکیل دهنده هیدرو کربور مورد استفاده در این مطالعه نیز در جدول ۱ نمایش داده شده است.

پیش بینی رسوب آسفالتین در فازهای آموزش و آزمایش در شکل ۲ و همین پیش بینی با استفاده از مدل مقیاس در شکل ۳ نمایش داده شده اند. عملکرد شبیه سازی با استفاده از میانگین مجذور خطا (MSE) و ضریب راندمان R^2 ارزیابی شده است. جدول ۲ مقادیر (MSE) و R^2 را برای دو مدل متفاوت در فاز ارزیابی نشان می دهد. حالت آموزش و عملکرد PSO-ANN به ترتیب در شکل های ۴ و ۵ نمایش داده شده اند. می توان نتیجه گرفت که عملکرد



شکل ۱ | ساختار یک شبکه عصبی مصنوعی سه لایه

داده ها را به سه قسمت داده های آموزش، داده های تست^{۲۹} و داده های ارزیابی^{۳۱} تقسیم بندی می کنند. مدل با استفاده از داده های آموزش ساخته می شود و سپس داده های تست و ارزیابی برای بررسی دقت مدل به کار گرفته می شود. هدف اصلی در بخش آموزش شبکه، بهینه سازی وزن ها می باشد. زمانی که تعداد وزن ها از تعداد داده های در دسترس بیشتر باشد، خطا در داده های آموزش داده نشده کاهش می یابد. ولی با فرا آموزش^{۳۲} دیدن شبکه این خطا افزایش پیدا می کند. در مقابل زمانی که تعداد وزن ها از تعداد داده ها کمتر باشد، مشکل تطابق بیش از حد تأثیر گذار نیست^{۳۳}.

۲- بهینه سازی ازدحام ذرات (PSO)

در الگوی PSO از رفتار اجتماعی جاندارانی همچون پرندگان الهام گرفته شده است. همچون سایر الگوریتم های جمعیت محور، (مانند الگوریتم ژنتیک) الگوریتم PSO نیز بر اساس چندین حل تصادفی، مقداردهی اولیه می شود که به آن ذرات^{۳۴} می گویند. این ذرات با سرعت قابل تنظیم، اطراف ناحیه جستجو^{۳۵} حرکت کرده و بهترین نقطه در ناحیه جستجو را پیدا می کنند. هر ذره می تواند بردار خودش را بر اساس تجربه پرواز خود و دیگر ذرات در فضای جستجو پیدا کند.

با فرض D به عنوان تعداد ابعاد برای فضای جستجو و N به عنوان تعداد کل ذرات، موقعیت i امین ذره با $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ و سرعتش با $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ نمایش داده می شود. بهترین موقعیت پیشین i امین ذره با $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ و بهترین ازدحام پیشین آن با $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ مشخص می شود. سپس می توان سرعت ذرات و موقعیت جدیدشان را به صورت دو معادله زیر نوشت.

$$V_{id}(t+1) = V_{id}(t) + c_1 r_1 [P_{id} - X_{id}(t)] + c_2 r_2 [P_{gd} - X_{gd}(t)] \quad (2)$$

$$X_{id}(t+1) = X_{id}(t) + V_{id}(t+1) \quad (3)$$


که در آن c_1 و c_2 به ترتیب نرخ یادگیری اولیه و نرخ یادگیری اجتماعی هستند. r_1 و r_2 نیز اعداد تصادفی بین صفر و یک با توزیع یکنواخت هستند. از معادله بالا می توان نتیجه گرفت که ذرات بسیار سریع سرعت می گیرند و ممکن است به سمت پاسخ نامناسب پیش بروند. Shi و Eberhat [۱۱] راهکار اینرسی وزن^{۳۶} اصلی PSO را برای پایین آوردن سرعت ارائه نموده اند. سرعت ذرات همراه با ترم اینرسی به صورت زیر بیان می شود.

$$V_{id}(t+1) = \theta V_{id}(t) + c_1 r_1 [P_{id} - X_{id}(t)] + c_2 r_2 [P_{gd} - X_{gd}(t)] \quad (4)$$

که در آن θ اینرسی وزن بوده و به صورت خطی با تعداد تکرار به صورت زیر کم می شود.

$$\theta_i = \theta_{\max} - \left(\frac{\theta_{\max} - \theta_{\min}}{i_{\max}} \right) i \quad (5)$$


در این معادله θ_{\max} و θ_{\min} به ترتیب مقدار اولیه و نهایی اینرسی وزن، i تعداد تکرار جاری و i_{\max} بیشترین تکرار مورد استفاده در PSO می باشند. با توجه به مطالعات تجربی بهترین مقدار θ_{\max} و θ_{\min} به ترتیب ۰/۹ و ۰/۴ می باشد.




شکل ۳ نمودار رگرسیون برای مدل مقیاس

جدول ۲ مقایسه نتایج مدل‌های PSO-ANN و مدل مقیاس

مقیاس	PSO-ANN	
۰/۶۹۳۹۶	۰/۰۰۲۳۵۲۵	MSE
۰/۹۶۴۱۳	۰/۹۹۶۵۱	R ^۲



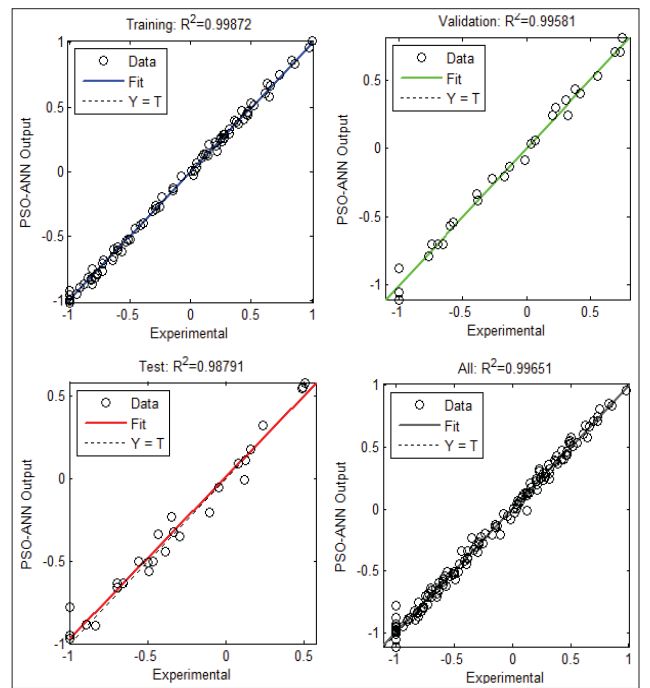
شکل ۴ نمودار کیفیت مدل PSO-ANN



شکل ۵ نمودار کارایی مدل PSO-ANN

جدول ۱ | خواص و اجزای مولی تشکیل دهنده هیدروکربور مورد استفاده در این مطالعه

Separator gas	Degassed oil	اجزاء
۲/۹۶	۰/۰	CO ₂
۱/۱۸	۰/۰	N ₂
۸۹/۳۷	۰/۰	C ₁
۳/۳۴	۰/۰	C ₂
۲/۱۰	۰/۰	C ₃
۰/۳۲	۰/۰	i-C ₄
۰/۲۶	۰/۰	n-C ₄
۰/۲۲	۰/۱۶	i-C ₅
۰/۱۵	۰/۵۸	n-C ₆
۰/۱۲	۱/۲	n-C ₆
	۹۸/۰۶	C ₇ ⁺
	۸۷/۱۶	C ₁₁ ⁺
	۵۰۲/۶	C ₇ ⁺ molecular weight (g/mol)
	۰/۹۵۲۶	C ₇ ⁺ density (at 293K)
	۳۴۳	Reservoir temperature (K)
	۹/۸	Bubble point pressure at 343K(MPa)
	۳۰/۲	Gas oil ratio (GOR, m ³ /m ³)
	۳۸/۰	Saturates (wt %)
	۴۷/۶	Aromatics (wt %)
	۷/۲۶	n-C ₅ asphaltenes (wt %)
	۱۸/۶	Resins (wt %)



شکل ۶ نمودار رگرسیون مدل PSO-ANN



ارزیابی الگوریتم ازدحام ذرات نیز توسط شبکه مشخص میگردد. برای جلوگیری از همگرایی پیش از موعد نتایج الگوریتم، پارامترهای الگوریتم ازدحام ذرات با دقت در نظر گرفته شده‌اند. مقایسه نتایج به دست آمده از مدل ارائه شده با نتایج آزمایشگاهی، قدرت و توانایی مدل PSO-ANN را به خوبی اثبات می‌نماید. این موضوع توسط آنالیز وزن‌های اتصالی و بایاس‌های موجود در شبکه امکان‌پذیر می‌گردد. مشکلی که در ترکیب شبکه‌های عصبی مصنوعی و الگوریتم ازدحام ذرات با هدف پیش‌بینی رسوب آسفالتین رخ می‌دهد، تعیین مکان بهینه برای شبکه عصبی مصنوعی می‌باشد. روش جایگزین در این مورد استفاده از الگوریتم ازدحام ذرات برای بهینه کردن ساختار شبکه‌های عصبی مصنوعی است که قسمتی از پروژه آینده می‌باشد.

PSO-ANN بهتر از مدل مقیاس است. مقدار R^2 بالاتر از ۰/۹ نشان دهنده عملکرد رضایت بخش مدل است. R^2 بین ۰/۸ تا ۰/۹ حاکی از عملکرد قابل قبول مدل و مقدار کمتر از ۰/۸ نشان دهنده عملکرد نامطلوب مدل می‌باشد.

۴- نتیجه گیری

در این مطالعه ترکیبی از الگوریتم ازدحام ذرات و شبکه‌های عصبی مصنوعی ارائه گردیده است. این روش بیانگر استفاده از شبکه عصبی مصنوعی بر مبنای الگوریتم ازدحام ذرات می‌باشد که در آن توانایی جستجوی الگوریتم ازدحام ذرات به کار گرفته می‌شود. در واقع ایده اصلی این الگوریتم آن است که نقطه آغازین شبکه عصبی مصنوعی توسط الگوریتم ازدحام ذرات مشخص شده و

پانویس‌ها

- | | | |
|--|--------------------------------------|-------------------------------|
| ¹ ahmadi6776@yahoo.com | ¹¹ Genetic Algorithm (GA) | ²¹ Validating Data |
| ² Asphaltene | ¹² Back Propagation (BP) | ²² Over-trained |
| ³ Diffusivity Reduction | ¹³ Pruning Algorithm | ²³ Over Fitting |
| ⁴ Wettability | ¹⁴ Simulated Annealing | ²⁴ Particles |
| ⁵ Feed-forward | ¹⁵ Training | ²⁵ Search Space |
| ⁶ Particle Swarm Optimization | ¹⁶ Weights | ²⁶ Inertia Weight |
| ⁷ Artificial Neural Network | ¹⁷ Node | ²⁷ Dilution Ratio |
| ⁸ Scaling Model. | ¹⁸ Bias Terms | ²⁸ Sigmoid |
| ⁹ Soft Sensor | ¹⁹ Neuron | |
| ¹⁰ Well Log | ²⁰ Testing Data | |

منابع

- [1] Brown, M., Harris, C. "Neural fuzzy adaptive modeling and control." Englewood Cliffs, NJ: Prentice-Hall. 1994
- [2] Eberhart, R. C., Kennedy, J.: "A New Optimizer Using Particle Swarm Theory. Proceedings of the 6th International Symposium on Micro Machine and Human Science". Nagoya, Japan (1995) 39-432.
- [3] Galoppini G, Tambini M. Asphaltene Deposition Monitoring and Removal Treatments: An Experience Deep Wells. Soc Pet Eng ;1994 (SPE27622).
- [4] Garcia-Pedrajas, N., Hervas-Martinez, C., Munoz-Perez, J. COVNET: "A cooperative co evolutionary model for evolving artificial neural networks." IEEE Transaction on Neural Networks, (2003), 14, 575-596.
- [5] omick, K., Stinchcombe, M., White, H. "Multilayer feed forward networks are universal approximators." (1989). Neural Networks, 2, 359-366
- [6] Hornik, K., Stinchcombe, M., White, H., "Universal approximation of an unknown mapping and its derivatives using multilayer feed forward networks." NeuralNetw 1990;3(5):551-60.
- [7] Juang, C. F.: "A Hybrid of Genetic Algorithm and Particle Swarm Optimization for Recurrent Network Design." IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics, 34(2) (2004) 997-1006
- [8] Qu1, X., Feng, J., Sun, W. "Parallel Genetic Algorithm Model Based on AHP and Neural Networks for Enterprise Comprehensive Business", IEEE Intl. Conf. on Intelligent Information Hiding and Multimedia Signal Processing, 2008, pp.897-900.
- [9] Rallo, R., Ferre-Gin, J., Arenas, A., Giral, F. (2002). Neural virtual sensor for the inferential prediction of product quality from process variables. Computers and Chemical Engineering, 26, 1735-1754.
- [10] Reed, R., "Pruning algorithms-a survey", IEEE Trans. Neural Networks Vol.4, 1993, pp.740-747.
- [11] Shi Y.H., Eberhart R.C.: A modified particle swarm optimizer, in: Proc. of IEEE World Conf. on Computation Intelligence, (1998) 69-73.
- [12] Souto, M.C.P.de, Yamazaki, A., Ludemir, T.B., "Optimization of neural network weights and architecture for odor recognition using simulated annealing", Proc. 2002 Intl. Joint Conf. on Neural Networks, Vol.1, 2002, pp.547-552.
- [13] Speight JG. The chemistry and technology of petroleum. 2nd ed. New York: Marcel Dekker; 1991.
- Tang, P., and Xi, Z., "The Research on BP Neural Network Model Based on Guaranteed Convergence Particle Swarm Optimization", Second Intl. Symp. on Intelligent Information Technology Application, IITA '08, Vol.2, Dec. 2008, pp.13 - 16.
- [14] Van den Bergh, F. and Engelbrecht A. P.: "Training Product Unit Networks Using Cooperative Particle Swarm Optimisers." Proceedings of the IEEE International Joint Conference on Neural Networks, Washington DC, USA (2001) 126 - 131