



پیش بینی نسبت گاز میعانی به وسیله شبکه عصبی مصنوعی

شهاب گرابی^۱ پژوهشکده آذماه بوداشت
محمد عبادی^۲ دانشگاه آزاد اسلامی واحد علوم و تحقیقات

محمدعلی احمدی^۳ پژوهشگاه صنعت نفت
سید رضا صادی زاده^۴ دانشگاه صنعت نفت
چکیده

ارزش افزوده اقتصادی حاصل از فروش میعانات گازی و کاهش شدید میزان عبوردهی سنگ به دلیل مسدود شدن در اثر میعانات مهم ترین تفاوت های مخازن گاز میعانی با مخازن گاز خشک است. برای تخمین میزان ارزش افزوده نیاز به محاسبه مقدار نسبت گاز میعانی است که این امر از طریق انجام آزمایش های میدانی و آزمایش های خاص مبتنی بر خواص سیالات میسر می شود. در ابتدای دوران توسعه یک مخزن که انجام آزمایش خواص سیالات امکان پذیر نیست، روش هایی که توانایی مدل سازی کمیت هایی از قبیل نسبت گاز میعانی را دارند مورد توجه مهندسين قرار می گیرند. در این مقاله چگونگی مدل سازی نسبت گاز میعانی به وسیله یک شبکه عصبی مصنوعی که از توانایی جستجوی محدودهای با نام روش پس انتشار استفاده می کند مورد تحقیق قرار گرفته است. نتایج حاصل از شبکه عصبی مصنوعی که بر مبنای استفاده از داده های گزارش شده از مخازن ایران است با مقدار واقعی آنها مقایسه گردید و نتایج حاصل شده مؤید این امر است که روش استفاده شده توانایی بسیار خوب و دقیقی در این زمینه دارد.

واژگان کلیدی: نسبت گاز میعانی، شبکه عصبی مصنوعی، دما، نقطه شبنم، وزن مولکولی

مقدمه

طراحی و بهینه سازی امکانات سرچاهی و تجهیزات واحد بهره برداری باشد [۱۳-۷]. علوی و همکاران (۲۰۱۰) با استفاده از آزمایش های گوناگون و هم چنین معادله حالت Peng-Robinson موفق به احراز همگرایی مورد قبولی بین داده های مشاهده ای و محاسبه ای مربوط به نرخ تولید (به عنوان کمیت بسیار مهمی برای طراحی امکانات سرچاهی) شدند [۱۴]. تولید بیشینه مقدار میعانات گازی (به عنوان یکی از باارزش ترین محصولات مخازن گاز میعانی که ناشی از افت فشار به زیر فشار نقطه شبنم است و در نواحی اطراف دیواره چاه تشکیل می شود) مهم ترین توجیه برای تمام تلاش های انجام شده است. اگر چه میزان میعانات تولیدی را می توان از آزمایش به دست آورد اما کماکان هزینه فراوان و زمان بر بودن این آزمایش ها از معضلات فنی عمده آنهاست. بدین منظور مدل های مرسوم و جدیدی که با هوش مصنوعی تلفیق شده اند برای پیش بینی میزان میعانات پیشنهاد گردیده اند [۱۵]. جوخو و همکاران (۲۰۰۲) با دقت بیشتری میزان تولید میعانات را بر مبنای مدل Whitson and Fevang و بر اساس تراوایی نسبی و داده های سیالاتی پیش بینی کردند. آنان با استفاده از روش های ناپایدار فشاری، تراوایی مؤثر را به عنوان تابعی از فشار به دست آوردند و سپس با استفاده از روش های چاه آزمایی نزدیک ترین ناحیه به دیواره چاه را به عنوان منبع میعانات مشخص کردند [۱۶ و ۱۷]. فرحان و همکاران


توصیف مخازن همواره به عنوان یکی از مهم ترین، چالش برانگیزترین و مسئله سازترین موارد در صنایع بالادستی نفت مطرح بوده است [۱]. ضرورت این مورد زمانی که مباحث مربوط به مخازن گاز میعانی به عنوان یکی از ارزشمندترین نوع مخازن باشند اهمیت بیشتری پیدا می کند [۲]. به عبارت دیگر تخمین کمیت هایی مثل نسبت گاز میعانی نیازمند دقت بسیاری است؛ چرا که جمع بندی و تفسیر این کمیت منجر به تفسیر عملکرد مخازن گاز میعانی خواهد شد. [۳-۶]. به طور مثال روش های گوناگونی بر مبنای اصول تئوری و هم چنین تلفیقی از هوش مصنوعی و روش های آزمایشگاهی مرسوم (مثل انبساط جرمی ثابت) توسط تعدادی از محققین جهت مدل سازی رفتار غیر خطی فشار نقطه شبنم (به عنوان یکی از کلیدی ترین مشخصه های مخازن گاز میعانی) پیشنهاد شده است. روش های زیادی برای ارزیابی عملکرد مخازن گاز میعانی مطرح گردیده است. توماس و همکاران (۲۰۰۹) جهت ایجاد نگرشی عمیق نسبت به مخازن گاز میعانی و برای پیش بینی آینده این نوع از مخازن روشی ارائه کردند که توصیف مناسبی از سیالات درجا و آزمایش جریان های مرتبط دارد. پیش بینی عملکرد مخازن گاز میعانی در آینده زمانی بهتر مشخص می شود که تمامی توجهات هم از دیدگاه فنی و هم از دیدگاه اقتصادی معطوف به

* نویسنده عهده دار مکاتبات (ma.ahmadi.put@gmail.com)


به طور کلی داده‌ها به دو دسته کلی آموزش‌دهنده^۸ و آزمایش‌کننده^۹ تقسیم می‌شوند. هدف از تعیین یک سری از داده‌ها به عنوان آموزش‌دهنده رسیدن به مجموعه‌ای از وزن‌های بهینه است. زمانی که تعداد وزن‌هایی که باید بهینه شوند از تعداد داده‌ها بیشتر باشد در ابتدا خطا نسبت به مناسب‌ساختن داده‌های مورد آزمایش^{۱۰} کاهش می‌یابد. اما با گذشت زمان و رسیدن شبکه به درجه آموزش بیش از حد^{۱۱}، خطا افزایش می‌یابد. در مقابل زمانی که تعداد وزن‌ها کمتر از تعداد داده‌هاست مسائل مربوط به مناسب‌سازی بیش از حد اهمیت می‌یابد.

۱ | بازه کمیت‌های استفاده شده جهت ایجاد مدل شبکه عصبی

ورودی	کمیت (واحد)	کمیته	بیشینه
	دما (°F)	۱۶۵	۲۸۳
	فشار نقطه شبنم (psi)	۲۹۵۰	۶۰۳۵
خروجی	وزن مولکولی (BT)	۱۶/۵	۲۷
	نسبت گاز میعانی (B/MMscf)	۴/۵	۳۶/۵



۱ | الف) مقایسه داده‌های خروجی شبکه عصبی و داده‌های واقعی در حالت آموزش شبکه



۱ | ب) مقایسه داده‌های خروجی شبکه عصبی و داده‌های واقعی در حالت آزمایش شبکه

(۲۰۰۶) نیز میزان میعانات تولیدی را مستقیماً به نسبت گاز میعانی ارتباط دادند؛ چراکه معتقد بودند مقدار میعانات تولیدی از لحاظ کمی و کیفی تابع است از فشار عملیاتی سرچاهی. آنها در مرحله نخست یک جداساز سه مرحله‌ای که در قسمت‌های اول و سوم آن فشار توسط یک کارشناس تعیین شده و در مرحله دوم میزان تولید بیشینه میعانات به عنوان متغیری از فشار است در نظر گرفتند [۱۸]. آنها برای بهینه‌سازی این فرآیند از یک شبکه عصبی پس‌انتشار استفاده کردند که متشکل از سیزده ورودی شامل اجزای سازنده و سه خروجی متشکل از نسبت گاز میعانی، فشار مرحله دوم جداساز و درجه سبکی میعانات تولیدی بود. برای مشخص کردن ساختار شبکه و تعیین کمیت‌های مربوطه (مثل وزن اتصالات بین نرون‌ها) تعدادی از الگوریتم‌های تکاملی مانند الگوریتم ژنتیک^۱ [۱۹]، الگوریتم هرس^۲ [۲۰] و پس‌انتشار^۳ [۲۱] استفاده شد. در این تحقیق از الگوریتم ژنتیک به عنوان بهینه‌ساز وزن‌های^۴ شبکه عصبی استفاده شده و نسبت میعانات به گاز خروجی از شبکه با نتایج اخذ شده در آزمایشگاه مقایسه شده‌اند.

۱- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی از روش‌های آنالیز موازی اطلاعات است که قابلیت مدل‌سازی الگوهای پیچیده و غیرخطی موجود میان تعداد محدودی از داده‌های آزمایشگاهی را دارد. شبکه‌های عصبی بر مبنای خواص ذاتی خود نگاهی غیرخطی بین ورودی‌ها و خروجی‌ها برقرار می‌کنند. تضمین موفقیت یک شبکه در گرو انجام پیش‌پردازش درست روی داده‌ها، انتخاب صحیح ساختار شبکه و انتخاب روش آموزش مناسب برای شبکه است. در شبکه‌های پیش‌خور^۵ به عنوان رایج‌ترین نوع شبکه‌های عصبی مصنوعی تنها امکان انتشار سیگنال‌ها در یک راستا از ورودی‌ها به سوی خروجی‌ها وجود دارد. به طور کلی یک شبکه عصبی سه لایه پیش‌خور که بر مبنای الگوریتم پس‌انتشار است توانایی تقریب‌زدن هر تابع غیرخطی پیوسته‌ای را دارد. فرآیند آموزش که همان تغییرات هدف‌دار وزن‌های اتصالات و عبارات بایاس^۶ است مادامی که معیار خطای مربوط به محور مورد نظر میان پاسخ‌های واکنش داده شده توسط شبکه و پاسخ‌های واقعی حاصل از آزمایشگاه به مقدار کمیته خود نرسد ادامه می‌یابد. رابطه ۱- که به عنوان یکی از این گونه معیارها مورد استفاده قرار می‌گیرد به طور معمول میانگین مربع خطا^۷ را محاسبه می‌کند [۲۲-۲۵].

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

در رابطه ۱-، m تعداد نرون‌های خروجی، G تعداد داده‌های آموزشی، $T_j(k)$ ، داده‌های آزمایشگاهی و $Y_j(k)$ پاسخ‌های شبکه هستند.




۲- مطالعه موردی


بهره‌گیری از داده‌های معتبر را می‌توان مهم‌ترین اصل در طراحی یک شبکه عصبی مصنوعی دانست. برای مهیا کردن این گونه داده‌ها باید در ابتدا کمیت‌هایی را که اثر مستقیم بر مقدار و کیفیت کمیت هدف دارند مشخص کرد.

به‌طور کلی نسبت گاز میعانی به شدت تحت تأثیر شرایط محیط متخلخل و خواص سیالات مخزن است. بر این اساس و بر مبنای مطالعات پیشین فشار نقطه شبنم، دمای مخزن و وزن مولکولی بیشترین تأثیر را بر میزان نسبت گاز میعانی دارند [۲۶].

جدول ۱- نشان‌دهنده خلاصه وضعیت آماری ۲۱۰ سری از داده‌هایی است که برای طراحی شبکه مدنظر جمع‌آوری شده‌اند. ۴۰ سری از این مجموعه مربوط به مخازن ایران است که نمونه‌گیری آنها اخیراً انجام شده و مابقی متعلق به مطالعات قبلی در مخازن جهان است.



شکل ۲ نمودار رگرسیون برای خروجی شبکه عصبی



شکل ۳ نمودار کارایی شبکه عصبی بر مبنای میانگین‌های مجذور خطا

جدول ۲ | کمیت‌های آماری مدل شبکه عصبی برای پیش‌بینی نسبت به میعانات به گاز

	BP-Ank
میانگین مجذور خطا	۰/۰۹۸۱۴
ضریب همبستگی (R^2)	۰/۸۷۸۴۵

۳- نتایج و بحث

در این مطالعه یک شبکه عصبی مصنوعی جهت پیش‌بینی میزان نسبت گاز میعانی توسعه داده شد. مطلوب‌ترین پاسخ‌ها با ساختار ۳ نرون ورودی، ۷ نرون در لایه میانی و یک نرون به‌عنوان خروجی به‌دست آمد. شبکه حاصل از الگوریتم پس‌انتشار خطا و تابع Levenberg-Marquardt استفاده کرده و سه کمیت فشار نقطه شبنم، دما و وزن مولکولی ورودی‌ها هستند. هم‌چنین در نرون‌های میانی از توابع سیگموئیدی و در نرون‌های خروجی از توابع خطی استفاده شده است.

از مجموع ۲۱۰ سری داده جمع‌آوری شده ۱۷۰ سری به‌طور تصادفی برای آموزش شبکه انتخاب شدند و مابقی جهت آزمایش شبکه و ارزیابی قدرت و یکپارچگی آن استفاده گردید.

شکل ۱- مقایسه‌ای میان مقادیر نرمال پیش‌بینی شده توسط شبکه پس‌انتشار و مقادیر نرمال واقعی برای هر دودسته آموزش‌دهنده و تصدیق‌کننده است. از دیدگاه فنی مقادیر ضریب آموزش و ضریب تصحیح مونتوم مربوط به الگوریتم پس‌انتشار به ترتیب ۰/۷۵ و ۰/۰۱ تعیین شدند. شکل ۱- مبین این همگرایی بسیار خوب پاسخ‌های ارائه شده توسط شبکه برای داده‌های آزمایش در مقایسه با مقادیر واقعی است. علاوه بر این از دو معیار میانگین مربع خطا و ضریب بازدهی R^2 برای ارزیابی هر چه بیشتر شبکه استفاده شد که به ترتیب مقادیر قابل قبول ۰/۰۹۸۱۴ و ۰/۸۷۸۴۵ برای آنها به‌دست آمد. معمولاً مقادیر ۰/۹ و بیشتر از آن عملکرد بسیار مطلوب، مقادیر ۰/۸-۰/۹ عملکرد خوب و مقادیر کمتر از ۰/۸ نشان‌دهنده عملکرد غیرقابل قبول برای R^2 است. شکل ۲- عملکرد شبکه عصبی مذکور را بر مبنای نمودارهای پراکنده‌گی نمایش می‌دهد و شکل ۳- نیز نمودار عملکرد خود شبکه عصبی است. هم‌چنین مقادیر میانگین مربع خطا و R^2 برای داده‌های آزمایش در جدول ۲- ارائه شده است.

نتیجه‌گیری

در صنعت نفت همواره طیف گسترده‌ای از تلاش‌ها بر یافتن روش‌های بهتر و با دقت بیشتر جهت توصیف هر چه دقیق‌تر سیالات متمرکز بوده است. در این پژوهش یک راه حل سریع‌تر، ارزان‌تر و کارآمدتر برای تخمین مقدار کمیت نسبت گاز میعانی پیشنهاد شد که با توجه به خطای حاصل بسیار مفید است. شبکه مذکور از توانایی جستجوی منطقه‌ای با نام روش پس‌انتشار استفاده می‌کند. پاسخ‌های حاصل بر مبنای داده‌های جمع‌آوری شده از آزمایش‌های نمونه‌های گرفته شده از یک مخزن نفتی شمال خلیج فارس و داده‌های جمع‌آوری شده از مطالعات مرتبط پیشین، به‌طور کلی عملکرد مناسب شبکه را تصدیق می‌کند. همواره تعیین ساختار بهینه برای یک شبکه عصبی با هدف حل یک مسئله یکی از چالش‌برانگیزترین موضوع‌ها بوده که در این مورد خاص، ساختار شبکه توسط کاربر تعیین شد. در این خصوص می‌توان از الگوریتم‌های تکاملی استفاده کرد که این امر می‌تواند موضوع مقاله‌ای جداگانه قرار گیرد. ■

پانویسها

¹ genetic algorithm	⁴ weight	⁷ Mean Square Error (MSE)	¹⁰ testing dataset
² pruning algorithm	⁵ back-propagation	⁸ training	¹¹ over-fitting
³ back propagation	⁶ bias	⁹ testing	¹² correlation coefficient

منابع

- [1] Kouider El Ouahed Abdelkader, Tiab Djebbar, Mazouzi Amine, "Application of Artificial Intelligence to Characterize Naturally Fractured Zones in HassiMessaoud Oil Field, Algeria", Journal of Petroleum Science and Engineering, 2005, 49(3-4), 122-141.
- [2] Bozorgzadeh Manijeh, Gringarten Alain C., "Condensate-Bank Characterization from Well-Test Data and Fluid PVT Properties", SPE Reservoir Evaluation & Engineering, 2006, 9(5), 596-611.
- [3] Young, Larry C., Stephenson, Robert E., "A Generalized Compositional Approach for Reservoir Simulation", SPE Journal, 1983, 23(5), 727-742.
- [4] Ovalle Adriana P., Swaco M-I, Lenn Chris P., McCain Jr. William D., "Tools To Manage Gas/Condensate Reservoirs; Novel Fluid-Property Correlations on the Basis of Commonly Available Field Data", SPE Reservoir Evaluation & Engineering, 2007, 10(6), 687-694.
- [5] Meisingset K.K., "Uncertainties in Reservoir Fluid Description for Reservoir Modeling", SPE Reservoir Evaluation & Engineering, 1999, 2(5), 431-435.
- [6] Vo, Dyung T., Jones, Jack R., Raghavan, Rajagopal, "Performance Predictions for Gas-Condensate Reservoirs", SPE Formation Evaluation, 1989, 4(4), 576-584.
- [7] Humoud A.A., Al-Marhoun M.A., "A New Correlation for Gas-condensate Dewpoint Pressure Prediction", SPE Middle East Oil Show, Bahrain, 17-20 March 2001.
- [8] Al-Dhamen Mohammad, Al-Marhoun Muhammad, "New Correlations for Dew-Point Pressure for Gas Condensate", SPE Saudi Arabia section Young Professionals Technical Symposium, Dhahran, Saudi Arabia, 14-16 March 2011.
- [9] Karbalaee Akbari Meisam, Jalali Farahani Farhang, Abdy Yaser, "Using Artificial Neural Network's Capability for Estimation of Gas Condensate Reservoir's Dew point Pressure", EUROPEC/EAGE Conference and Exhibition, London, UK, 11-14 June 2007.
- [10] Shokir Eissa M. El-M., "Dewpoint Pressure Model for Gas Condensate Reservoirs Based on Genetic Programming", Energy Fuels, 2008, 22(5), 3194-3200.
- [11] Thomas F.B., Andersen G. Bennion D.B., "Gas Condensate Reservoir Performance", Journal of Canadian Petroleum Technology, 2009, 48(7), 18-24.
- [12] Al-Attar Hazim, "Performance of wellhead chokes during sub-critical flow of gas condensates", Journal of Petroleum Science and Engineering, 2008, 60(3-4), 205-212.
- [13] Yong Li, Baozhu Li, Yongle Hu, Yuwei Jiao, Weihong Zhu, Xiangjiao Xiao, Yu Niu, "Water Production Analysis and Reservoir Simulation of the Jilake Gas Condensate Field", Petroleum Exploration and Development, 2010, 37(1), 89-93.
- [14] Alavi F.S., Mowla D., Esmailzadeh F., "Production Performance Analysis of Sarkhoon Gas Condensate Reservoir", Journal of Petroleum Science and Engineering, 2010, 75(1-2), 45-53.
- [15] Luo Kai, Li Shi, Zheng Xitan, Chen Gang, Liu Ning, Sun Wenyue, "Experimental Investigation Into Revaporization of Retrograde Condensate", SPE Production and Operations Symposium, Oklahoma City, Oklahoma, 24-27 March 2001.
- [16] Jokhio S.A., Tiab D., Escobar F., "Forecasting Liquid Condensate and Water Production In Two-Phase And Three-Phase Gas Condensate Systems", SPE Annual Technical Conference and Exhibition, San Antonio, Texas, 29 September-2 October 2002.
- [17] Fevang Øivind, Whitson C.H., "Modeling Gas-Condensate Well Deliverability", SPE Reservoir Engineering, 1996, 11(4), 221-230.
- [18] Al-Farhan Farhan A., Ayala H. Luis F., "Optimization Of Surface Condensate Production from Natural Gases Using Artificial Intelligence", Journal of Petroleum Science and Engineering, 2006, 53(1-2), 135-147.
- [19] Qu Xilong, Feng Jian, Sun Wenfang, Parallel Genetic Algorithm Model Based on AHP and Neural Networks for Enterprise Comprehensive Business, Intelligent Information Hiding and Multimedia Signal Processing, Harbin, 15-17 August 2008.
- [20] Reed R., Pruning algorithms-a survey, IEEE Transaction on Neural Networks, (1993), 4, 740-747.
- [21] Tang Pingzhou; Xi Zhaocai, The Research on BP Neural Network Model Based on Guaranteed Convergence Particle Swarm Optimization, Second International Symposium on Intelligent Information Technology Application, IITA '08, Shanghai, 20-22 December 2008.
- [22] Brown, M., Harris, C. Neural fuzzy adaptive modeling and control. Englewood Cliffs, NJ: Prentice-Hall. 1994
- [23] 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.
- [24] Hornik, K., Stinchcombe, M., White, H. Multilayer feed forward networks are universal approximators. Neural Networks, (1989), 2, 359-366
- [25] Hornik, K., Stinchcombe, M., White, H., Universal approximation of an unknown mapping and its derivatives using multilayer feed forward networks. Neural Networks (1990); 3(5):551-60.
- [26] William D. McCain Jr., Heavy component Control Reservoir Fluid Behavior. JPT, 1994, September, 746 - 750.
- Prediction of Condensate Gas Ratio by Using Artificial Neural Network
 Mohammad Ali Ahmadi¹, Mohammad Ebadi², Seyed Reza Shadizadeh³, Shahab Gerami⁴
- 1) Department of Petroleum Engineering, Ahwaz Faculty of Petroleum Engineering, Petroleum University of Technology, Ahwaz, IRAN.
 2) Department of Petroleum Engineering, Science and Research Branch, Islamic Azad University, Tehran, IRAN
 3) Department of Petroleum Engineering, Abadan Faculty of Petroleum Engineering, Petroleum University of Technology, Abadan, IRAN.