

تخمین نگار نوترون با استفاده از ترکیب آنسامبلی شبکه‌های عصبی مصنوعی

ابوالقاسم کامکار روحانی^۱، محمود ذاکری^۲، علی اکبر پویان^۳ و ماشاءاله رحیمی^۴

^۱ دانشکده مهندسی معدن، و ژئوفیزیک، دانشگاه صنعتی شاهرود، ایران

^۲ دانشجوی ژئوفیزیک، دانشگاه صنعتی شاهرود، ایران

^۳ دانشکده مهندسی کامپیوتر و IT، دانشگاه صنعتی شاهرود، ایران

^۴ مدیریت اکتشاف، شرکت ملی نفت، تهران، ایران

چکیده

در این تحقیق، از ترکیب آنسامبلی شبکه‌های عصبی مصنوعی برای تخمین نگار نوترون استفاده شده است. جهت مطالعه موردی، از نگارهای پتروفیزیکی سازند کنگان در میدان پارس جنوبی استفاده گردید. با انجام یک مرحله طولانی آزمون و خطا، ۵ شبکه سه‌لایه با الگوریتم آموزشی پس‌انتشار خطا، که بهترین توان تعمیم را داشتند، برای ساخت ترکیبات آنسامبلی انتخاب شدند. با استفاده از دو روش میانگین‌گیری ساده و الگوریتم MSE-OLC، ۲۶ ترکیب آنسامبلی ممکن این ۵ شبکه، ساخته شدند و نتایج آن‌ها با نتایج بهترین شبکه منفرد مقایسه گردید. میانگین مربعات خطا در بهترین ترکیب آنسامبلی حاصل، در مرحله تعمیم، به میزان ۱۲/۸٪ کاهش یافت.

Abstract

In this research, we have developed ensemble combination of ANNs for prediction of neutron log in Kangan zone of South Pars field. 5 simple three-layer back-propagation ANNs, which in a long trial and error process had best generalization performance, were selected to establish ensemble combination systems. By using two methods, simple averaging and MSE-OLC algorithm, 26 possible ensemble combinations of this 5 networks were made. Their results were compared with the results of the best individual network. Best ensemble combination reduced MSE to 12.8 % in the generalization process


مقدمه

در اکتشافات نفتی، از نگارهای چاه برای ارزیابی دقیق مخازن نفتی شامل تعیین تخلخل، تراوایی، اشباع‌شدگی از آب، نفت و گاز و وضعیت سنگ‌شناسی و زمین‌شناسی زیرسطحی و ... استفاده می‌شود. کسب اطلاعات نسبتاً دقیق و کافی از عملیات چاه‌نگاری مستلزم در اختیار داشتن تعداد کافی نگار می‌باشد زیرا تفسیر نگارهای مختلف در ارتباط با دیگر نگارها می‌تواند به یک بینش جامع درباره پارامترهای پتروفیزیکی مخزن منجر شود در حالی که تفسیر یک نگار بدون در نظر گرفتن ارتباط آن با دیگر نگارها، ممکن است به تفسیری ناقص و یک بعدی و احتمالاً اشتباه منتهی شود. از طرفی ممکن است به دلایلی از بعضی چاه‌ها، برخی از نگارها در دسترس نباشد و چون برداشت مجدد این نگارها، در غالب موارد به لحاظ عملیاتی، فنی و اقتصادی غیرممکن است لذا ضروری به نظر می‌رسد که این نگارها را به طور مصنوعی تخمین بزنیم. معمولاً داده‌های علوم زمین، کاملاً غیرخطی و الگوهای موجود در آن‌ها بسیار مبهم و پیچیده است و این موضوع باعث استفاده روزافزون از شبکه‌های عصبی مصنوعی در محاسبات مربوط به این داده‌ها شده است تا با استفاده از این روش بر سهولت کار افزوده شود و نتایج دقیق‌تری به دست آید. تلاش‌ها برای ارتقاء نتایج ادامه دارد و ترکیب آنسامبلی (Ensemble combination) شبکه‌های عصبی مصنوعی، نمونه‌ای از این تلاش‌ها برای کاهش خطا و بدست آوردن نتایج دقیق‌تر است.

مبانی ترکیب آنسامبلی شبکه‌های عصبی مصنوعی

در روش شبکه‌های عصبی مصنوعی، تعداد زیادی شبکه با ساختار و پارامترهای آموزشی مختلف آزموده می‌شود تا شبکه‌ای با دقت قابل قبول به دست آید. بهترین شبکه انتخاب و بقیه در نظر گرفته نمی‌شود در حالی که ممکن است حاوی اطلاعات مفیدی باشند. ترکیب آنسامبلی شبکه‌های آموزش دیده، روشی برای ساخت سیستم‌های چند شبکه‌ای است که می‌تواند به تلفیق اطلاعات شبکه‌های جزء و در نتیجه عملکرد بهتر منجر شود. ترکیب آنسامبلی می‌تواند به طور خطی یا غیر خطی انجام شود ولی ترکیب خطی هم آسان‌تر است و هم

منطقی تر زیرا همه شبکه‌های جزء، برای تخمین کمیات یکسانی طراحی شده‌اند. در شکل ۱ نمایی از ترکیب خطی شبکه‌ها، نشان داده شده است. چنان که در شکل دیده می‌شود، ترکیب خروجی شبکه‌های مختلف، مشابه ایجاد یک شبکه بزرگ است که شبکه‌های سازنده آن، به طور موازی با هم عمل می‌کنند و وزن‌های ترکیب، همان وزن‌های سیناپسی لایه خروجی هستند. برای ورودی \vec{x} ، خروجی ترکیب، \vec{y} ، جمع وزنی خروجی‌های متناظر شبکه‌های جزء (y_j ها) است و α_j ها وزن‌های مربوط به آن‌ها است. اختلاف اصلی در این تشبیه آن است که در ترکیب، وزن‌های ارتباطی (α_j ها) ثابت هستند و با انجام یک سلسله عملیات ماتریسی حاصل می‌شوند ولی در شبکه عصبی بزرگ معادل، این وزن‌ها که نقش اوزان سیناپسی لایه آخر را دارند در طول آموزش تغییر می‌کنند. مزیت دیگری که این ترکیب نسبت به شبکه هم‌ارز خود دارد آن است که در شبکه بزرگ معادلش، پارامترهای زیادی وجود دارد که لازم است در فرایند آموزش تعیین شوند. بنابراین زمان آموزش زیادتر است و از طرفی به خاطر افزایش پارامترها، احتمال بیش‌برازش (Overfitting) بیشتر می‌شود.



شکل ۱. ترکیب خطی شبکه‌های آموزش دیده.

ترکیب خطی خروجی‌های p شبکه به کار رفته در ساختار ترکیب، عبارت است از $\vec{y}(\vec{x}; \vec{\alpha}) = \sum_{j=1}^p \alpha_j y_j(\vec{x})$ که خطای آن $\delta(\vec{x}; \vec{\alpha}) = r(\vec{x}) - \vec{y}(\vec{x}; \vec{\alpha})$ در این رابطه $r(\vec{x})$ مقدار مطلوب برای ورودی \vec{x} است. به منظور تصحیح بایاس y_j ها، جمله دیگری نیز به این مجموعه افزوده می‌شود. این جمله $\alpha_0 y_0(\vec{x})$ است که در آن $y_0(\vec{x}) = 1$. بنابراین خروجی ترکیب به صورت $\vec{y}(\vec{x}; \vec{\alpha}) = \sum_{j=0}^p \alpha_j y_j(\vec{x}) = \vec{\alpha}' \vec{y}(\vec{x})$ در می‌آید که $\vec{y}(\vec{x})$ و بردارهایی $1 \times (p+1)$ هستند. بنابراین لازم است که مقادیر مناسبی برای α_j ها پیدا کنیم. یک روش همان انتخاب بهترین شبکه (NN_b) است که وزن متناظر آن (α_b) را برابر یک قرار دهیم و بقیه اوزان را صفر در نظر بگیریم. این روش اگر چه ساده است ولی چنان که قبلاً گفته شد، اطلاعات مفید $(p-1)$ شبکه دیگر را از دست می‌دهد. روش دوم میانگین‌گیری ساده (Simple averaging) است که وزن همه شبکه‌ها را مساوی در نظر می‌گیرد. روش دیگر، یافتن وزن‌های بهینه است (Optimal linear combination یا OLC) به طوری که تابع عملکرد را که معمولاً میانگین مربعات خطا (Mean square error یا MSE) است، کمینه کند. به این منظور، از روش تحلیلی هاشم و همکارانش (۱۹۹۴) استفاده می‌کنیم. چون از تابع عملکرد MSE استفاده شده است، آن را MSE-OLC می‌نامند. بر طبق این روش اگر یک سری از داده‌های آموزشی با k عضو داشته باشیم و این سری را به صورت $\mathcal{K} = \{ \mathcal{K}_n : \mathcal{K}_n = (\vec{x}_n, r(\vec{x}_n), \vec{y}(\vec{x}_n)) \}$ ، $n = 1, \dots, k$ نشان دهیم، آن‌گاه بردار وزن‌های بهینه که آن را به صورت $\vec{\alpha}^* = (\alpha_0^*, \alpha_1^*, \dots, \alpha_p^*)$ نشان می‌دهیم از ضرب ماتریسی $\vec{\alpha}^* = \Psi^{-1} \vec{U}$ به دست می‌آید

که در آن: $\Psi = [\Psi_{ij}] = \left[\sum_{n=1}^k (y_i(\bar{x}_n) \times y_j(\bar{x}_n)) / k \right]$ یک ماتریس $(p+1) \times (p+1)$ و $\vec{U} = [u_i] = \left[\sum_{n=1}^k (r(\bar{x}_n) y_i(\bar{x}_n)) / k \right]$ یک بردار $(p+1) \times 1$ است.

مطالعه موردی در سازند کنگان میدان پارس جنوبی

به منظور ارزیابی کارایی روش ترکیب آنسامبلی، مطالعه موردی در سازند کنگان میدان پارس جنوبی اجرا گردید.

طراحی شبکه‌های عصبی جزء


از نگارهای پتروفیزیکی چاه‌های شماره ۱، ۲، ۳، ۴ و ۵ استفاده گردید. از چاه‌های ۱، ۳ و ۵ به منظور آموزش شبکه‌ها و برای بررسی توان تعمیم شبکه‌ها، از تلفیقی از داده‌های چاه‌های ۲ و ۴ استفاده شد. این داده‌ها (Unseen data) به دو قسمت تقسیم شدند، یک سری تحت عنوان سری اعتبارسنجی که برای ارزیابی توان تعمیم شبکه‌ها و انتخاب شبکه‌های مناسب، استفاده شد. سری دوم تحت عنوان سری تست که در انتخاب، نقشی نداشتند و برای تست نهایی شبکه‌ها از آن‌ها استفاده گردید. نگارهای صوتی، چگالی، لاترولوگ عمیق و گامای طبیعی را به عنوان ورودی و نگار نوترون را به عنوان خروجی در نظر گرفتیم. با توجه به این که در فرایند «سعی و خطا»، احتمال بیش‌برازش بسیار کم بود و شبکه‌ها از توان تعمیم بسیار خوبی برای سری اعتبارسنجی برخوردار بودند، نیازی به استفاده از روش‌های مرتب‌سازی (Regularization) یا توقف سریع (Early stopping) احساس نشد و از روش فراآموزش (Overtraining) استفاده گردید. در نهایت ۵ شبکه با الگوریتم آموزشی پس‌انتشار خطا که در سعی و خطا، بهترین توان تعمیم را برای سری اعتبارسنجی داشتند، به عنوان اجزاء ترکیبات آنسامبلی انتخاب شدند که این شبکه‌ها یا در تعداد نرون‌های لایه میانی و یا در وزن‌های اولیه با هم متفاوتند. جدول ۱ ساختار این شبکه‌ها و نتایج آن‌ها را برای داده‌های آموزش و اعتبارسنجی نشان می‌دهد. از داده‌های این جدول مشخص است که بهترین شبکه منفرد، شبکه شماره ۴ است زیرا برای داده‌های اعتبارسنجی کمترین مقدار MSE را دارا است. شکل ۲ نمودار همبستگی (Cross plot) بین نگار نوترون و تخمین شبکه ۴ برای داده‌های آموزش و اعتبارسنجی را نشان می‌دهد.

جدول ۱. ساختار و نتایج حاصل از شبکه‌های منفرد.

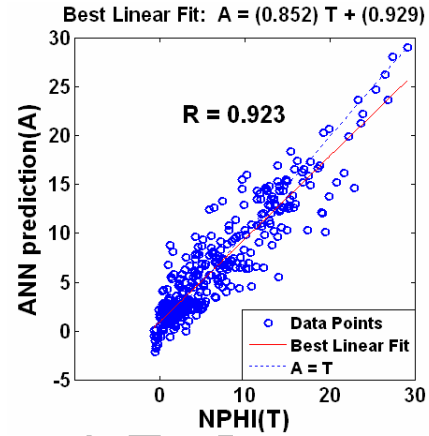
No.	Model	r (%) (Training)	MSE (Training)	r (%) (Validation)	MSE (Validation)
1	4-4-1	89.78	7.1894	84.67	6.044
2	4-4-1	90.15	6.9400	82.05	7.1262
3	4-6-1	91.60	5.9658	85.57	5.8105
4	4-7-1	92.30	5.4845	86.08	5.8038
5	4-8-1	93.45	4.6920	82.95	6.7174

ترکیبات آنسامبلی

با استفاده از این ۵ شبکه، ۲۶ ترکیب آنسامبلی مختلف می‌توان ساخت. ۱۰ ترکیب آنسامبلی ۲ شبکه‌ای، ۱۰ ترکیب آنسامبلی ۳ شبکه‌ای، ۵ ترکیب آنسامبلی ۴ شبکه‌ای و ۱ ترکیب آنسامبلی ۵ شبکه‌ای. برنامه ترکیب خطی شبکه‌ها به دو روش میانگین‌گیری ساده و MSE- OLC در محیط نرم‌افزار MATLAB تهیه و این ترکیبات آنسامبلی ساخته شدند. نتایج آنسامبل‌ها با نتایج شبکه ۴ (NN_b) برای داده‌های اعتبارسنجی مقایسه شد. جدول ۲ نتایج ۴ آنسامبل را که کارایی بهتری داشتند، نشان می‌دهد.




(ب)




(الف)

شکل ۲: نمودار همبستگی بین نگار نوترون و تخمین شبکه شماره ۴ برای الف) داده‌های آموزش ب) داده‌های اعتبارسنجی.



(ب)



(الف)

شکل ۳: نمودار همبستگی بین نگار نوترون و تخمین ترکیب شماره ۱ برای داده‌های اعتبارسنجی با استفاده از روش الف) میانگین‌گیری ساده ب) MSE-OLC

جدول ۲: نتایج ۴ ترکیب آنسامبلی.

No.	Ensemble	Method	r (%) (Training)	MSE (Training)	r (%) (Validation)	MSE (Validation)	Reduction in MSE of validation
1	3,4	MSE-OLC	93.03	4.9830	87.72	5.1293	11.6 %
		averaging	93	5.0188	87.72	5.0588	12.8 %
2	2,3,4	MSE-OLC	93.13	4.9127	87.56	5.2386	9.7 %
		averaging	92.49	5.3756	86.90	5.2944	8.8 %
3	1,2,3,4	MSE-OLC	93.32	4.7856	87.49	5.2629	9.3 %
		averaging	92.02	5.6928	86.63	5.3744	7.4 %
4	1,2,3,4,5	MSE-OLC	94.06	4.2688	86.55	5.5238	4.8 %
		averaging	92.77	5.1867	86.91	5.2726	9.1 %

با توجه به این جدول، ترکیب آنسامبلی شبکه‌های ۳ و ۴ (ترکیب شماره ۱) با روش میانگین‌گیری ساده بهترین نتایج را به دست می‌دهد و نسبت به شبکه ۴ برای داده‌های اعتبارسنجی، MSE را ۱۲/۸٪ و برای داده‌های تست MSE را ۱۴/۳٪ کاهش می‌دهد. شکل ۳ نمودار همبستگی بین نگار نوترون و تخمین ترکیب شماره ۱ به دو روش میانگین‌گیری ساده و MSE-OLC را برای داده‌های اعتبارسنجی نشان می‌دهد.

نتیجه گیری

نتایج این تحقیق حاکی از آن است که ترکیب آنسامبلی شبکه‌های عصبی مصنوعی، قابلیت کاهش خطا و بهبود نتایج شبکه‌های عصبی مصنوعی منفرد را دارد. البته میزان این قابلیت به نوع مسأله، روش ترکیب، تعداد داده‌های سری آموزش و شبکه‌های منفردی که برای ساخت ترکیب به کار می‌روند، بستگی دارد.

منابع

- Bhatt A., 2002, Reservoir properties from well logs using neural networks, PhD thesis, Department of Petroleum Engineering and Applied Geophysics, Norwegian University of Science and Technology.
- Bhatt A. and Helle H.B., 2002, Committee neural networks for porosity and permeability prediction from well logs, *Geophysical Prospecting*, **50**, 645-660.
- Hashem S., 1993, Optimal linear combination of neural networks, PhD thesis, School of Industrial Engineering, Purdue University.
- Hashem S., Shmeiser B. and Yih Y., 1994, Optimal linear combination of neural networks: an overview, School of Industrial Engineering, Purdue University.
- Sharkey A., Sharkey N., Gerecke U. and Chandroth G.O., 2000, The "test and select" approach to ensemble combination, *In Multiple classifier systems* (Eds J.Kittler and F.Roli), 30-44, Lecture notes in computer science, Springer-Verlag, Inc.

Archive of SID