SID

فیلم های آموزشی | عضویت در خبرنامه | بلاگ مرکز اطلاعات علمی | کارگاه های آموزشی | سرویس ترجمه تخصصی | سرویس های ویژه

کارگاه های آموزشی مرکز اطلاعات علمی جهاد دانشگاهی

کارگاه آنلاین آشنایی با پایگاه های اطلاعات علمی
بین المللی و
ترفند های جستجو



مباحث پیشرفته یادگیری عمیق؛
شبکه های توجه گرافی
(Graph Attention Networks)

کارگاه آنلاین مقاله نویسی IEEE و ISI
ویژه فنی و مهندسی

Archive of SID

ششمین همایش انجمن زمین شناسی اقتصادی ایران
۲۲ لغایت ۲۳ شهریور ماه ۱۳۹۳

مقایسه الگوریتم های مختلف شبکه عصبی مصنوعی در برآورد عیار مس مطالعه موردی: کانسار مس پورفیری دره زرشک، جنوب غرب یزد

زراسوندی، علیرضا [۱]؛ نیامدپور، احمد [۲]؛ خواس، مریم*[۱]؛ پورکاسب، هوشنگ[۱]
۱- دانشگاه شهید چمران، دانشکده علوم، گروه زمین شناسی
۲-هیئت علمی دانشگاه آزاد واحد مسجد سلیمان
Email: Khavas.maryam@yahoo.com

چکیده

از آنجا که حفاری امری پرهزینه و زمان‌بر می‌باشد به منظور کاهش هزینه نیاز به ابزارهای قوی در پردازش حجم عظیم اطلاعات با انعطاف‌پذیری زیاد است. شبکه‌های عصبی توانایی بالایی در استخراج الگوها از میان داده‌ها و همچنین حل مسائل پیچیده با ماهیت طبیعی دارند. درواقع این شبکه‌ها با مدیریت حجم عظیم داده‌های ورودی و پردازش آنها، تحلیل درستی از ارتباط میان آنها و شواهد زمینی استخراج و الگوها را تشخیص می‌دهند. هدف از این مطالعه مقایسه الگوریتم‌های آموزشی مختلف شبکه عصبی جهت برآورد عیار مس و ارائه روند بهینه‌سازی تهیه نقشه-های پتانسیل معدنی می باشد. نتایج حاصل از تحقیق حاضر، نشان می‌دهد که در میان هشت الگوریتم آموزشی پس-انتشار خطای مورد بررسی، الگوریتم آموزشی LM و BR با تابع لگاریتمی و ضریب تطابق ۰.۹۵و ۰.۹۴ از بیشترین دقت برای پیش‌بینی عیار مس کانسار مس پورفیری دره‌زرشک برخوردار هستند.

کلیدواژه‌ها: شبکه‌های عصبی مصنوعی، الگوریتم پس‌انتشار خطا، اکتشاف معدنی، مس پورفیری.

Comparison of different algorithms of artificial neural network in estimating the copper grade Case Study: Darreh Zerreshk porphyry copper deposit, South West of Yazd

Zarasvandi, Alireza; Niamadpur, Ahmad; Khavas, Maryam*; Hoshang, Porkaseb
Maryam Khavas: Khavas.maryam@yahoo.com

Abstract

The drilling is a costly affair and too much time is needed for the doing this work, it seems powerful tools with flexible options are necessary for the information processing and subsequentreducing the costs. The neural networks have a high ability in extracting the data and resolving the complex issues with natural nature.Indeed, these networks with managing of a large amount of input data and processingthem identify correct analysis of the relationship between them and extraction evidences from earth and models. The aim of this study is the comparison of different algorithms of artificial neural networkto estimate the copper grade and representing the optimal trend in the preparation of mining potential map. The results of present study indicate that among the 8 training algorithms, LM and BR training algorithms with

www.SID.ir

Archive of SID

logarithmic functionand correlation coefficient of 0.95and0.94 have a high accuracy in prediction of copper grade at Darreh Zerreshk porphyry copper deposit.

Keyword: Artificial Neural Networks, Back propagation algorithm, Mineral Exploration, Porphyry copper.

مقدمه

از آنجایی که حفاری در اکتشاف معدنی فرآیندی زمان بر و پرهزینه می‌باشد بهینه سازی، کنترل و ارزیابی عملیات اکتشافی مستلزم در دست داشتن یک مدل دقیق و همه جانبه می باشد. برای ارائه چنین مدلی باید تمام پارامترهای موثر شناسایی و تاثیر هم زمان آنها بر خروجی سیستم و یکدیگر به طور دقیق مشخص شود. وجود خطا در داده‌ها، الگوهای پنهان و خواص غیرخطی داده‌ها اکتشاف ذخایر معدنی کاری مشکل است با توجه به مناسب بودن این شرایط برای شبکه عصبی مصنوعی در چند سال اخیر این روش به منظور مدل سازی و شبیه سازی فرآیندهای مختلف مورد استفاده قرار گرفته‌اند. مهم‌ترین ویژگی شبکه‌های عصبی، غیرخطی بودن و قابلیت حذف نویز می‌باشد. که نیاز به دستورات کاملاً صریح و مشخص و مدل‌های ریاضی محض ندارند و برای حل مسائلی که فرمول حل آنها ناشناخته است و یا ابهامی در آنها دیده می شود، کاربرد دارند. از آنجا که در مسائل معدنی، همواره الگوی موجود بین داده‌ها پیچیده و غیر خطی است، لذا شبکه‌های عصبی و مصنوعی، می‌توانند تکنیک مؤثری برای حل این مسأله به شمار آیند. یکی از کاربردهای شبکه عصبی درمسائل علوم زمین، تخمین ذخایر معدنی می‌باشد. در مسأله تخمین ذخیره توسط شبکه عصبی، در حقیقت الگوی بین مختصات (ورودی شبکه) و عیار در آن مختصات (خروجی شبکه) توسط شبکه یادگرفته می شود. سپس به ازای هر مختصات جدید ارائه شده به شبکه عصبی آموزش دیده، خروجی متناظر که عیار تخمینی در آن مختصات می باشد، بدست می آید (شهابی‌فر، ۱۳۸۳). این شبکه‌ها قادرند با مدیریت حجم عظیم داده-های ورودی و پردازش آنها، تحلیل درستی از ارتباط میان آن‌ها و شواهد زمینی را استخراج نموده و الگوها را تشخیص دهند (Bishop, 1995). هدف از این مطالعه بررسی االگوهای آموزشی مختلف با تعداد نرون‌های متفاوت به منظور دست‌یابی به الگوریتم مناسب جهت ارائه روند بهینه‌سازی برای تهیه نقشه‌های پتانسیل معدنی مس دره زرشک و شناسایی مکان‌های مستعد کانه زایی جهت حفاری می باشد.

بحث

منطقه مورد مطالعه

بیشتر کانسارهای مس پورفیری ایران در ارتباط با گرانیتوئیدهای نئوژن در کمربند ولکانیک-پلوتونیک ایران مرکزی، معروف به ارومیه-دختر قرار دارند (e.g.,Bazin and Hubner,1969;Jankovic,1984).

کانسارمس دره‌زرشک در ۶۰ کیلومتری جنوب غرب یزد با طول جغرافیایی ۵۳°/۵۳ شرقی و عرض جغرافیایی ۳۱°/۳۸ شمالی واقع می‌باشد. این کانسار به لحاظ جایگاه تکتونیکی در زون ساختاری ایران مرکزی و کمربند آتشفشانی-نفوذی ایران (ارومیه-دختر) قرار دارد (شکل ۱).

www.SID.ir

Archive of SID



شکل۱- منطقه مورد مطالعه (با تغییراز Zarasvandi et al., 2013)

به طور کلی منطقه مورد مطالعه متشکل از واحدهای رسوبی از کرتاسه زیرین تا حال می‌باشد که توسط طیف وسیعی از سنگ‌های آتشفشانی و نفوذی قطع شده‌اند. قدیمی‌ترین سنگهای این منطقه واحدهای کنگلومرایی، شیلی و ماسه‌ای سنگستان با سن کرتاسه زیرین می‌باشند که توسط سنگهای آهکی سازند تفت با سن کرتاسه میانی تا بالایی پوشانده شده‌اند (Zarasvandi et al., 2004).

شبکه‌های عصبی (Neural Network)

شبکه‌های عصبی مصنوعی (ANNs) ابزار ریاضی‌ای هستند که با تقلید از سیستم عصبی بیولوژیک ساخته شده اند (Fulop et al., 1998). قدرت انعطاف و تصحیح پذیری بالایی در انطباق خود با داده های موجود را دارند (Ranjithan et al., 1995). درواقع شبکه‌های عصبی مصنوعی، یک پردازشگر تشکیل شده از واحدهای کوچکی است که به طور موازی ساختار یافته‌اند. این پردازشگرکه نورون نامیده می‌شود با استفاده از دانش تجربی آموزش داده می-شوند و سپس با تعمیم دانش بدست آمده درک بهتری از محیط بدست می‌آورند (شکل۲). منظور از تعمیم ارائه خروجی قابل قبول برای ورودی‌هایی است که قبلاً وارد سیستم نشده‌اند (Hagan et al., 1996).



شکل۲- ساختار یک نرون مصنوعی

هر یک از نرون‌ها، ورودی‌ها را دریافت نموده و پس از پردازش روی آنها، یک سیگنال خروجی تولید می‌نمایند. لذا هر نرون در شبکه به عنوان مرکز پردازش و توزیع اطلاعات عمل کرده، ورودی و خروجی مخصوص به خود را دارد (sadorsky, 2006). آنچه عملا مورد توجه است توانایی محاسباتی شبکه در انجام یک فعالیت خاص، همانند تقریب زدن یک تابع می باشد (Demuth and Beale,1998).

روش پس‌انتشار (Back propagation)

یکی از مهم‌ترین الگوریتم‌های یادگیری شبکه‌های عصبی مصنوعی، که در این تحقیق نیز از آن استفاده شده است، قانون یادگیری پس انتشار خطا نامیده می شود. یک شبکه عصبی مصنوعی با ساختار پس‌انتشار خطا از یک لایه

www.SID.ir

Archive of SID

ورودی، یک لایه خروجی و حداقل یک لایه میانی تشکیل شده است. در این الگوریتم هر تابع مشتق‌پذیر و پیوسته‌ای که به طور یکنواخت افزایش یابد, می‌تواند در حکم تابع محرک استفاده شود (Nikravesh and Aminzadeh, 2001)._شبکه‌های عصبی براساس آموزش قبلی، عمل پردازش را انجام می‌دهند. بدین معنی‌که معمولاً شبکه‌های عصبی با سری‌های خاص از ورودی و هدف‌های (خروجی های متناظر) آن آموزش دیده و اوزان داخلی (Internal Weights) در خلال عملیات آموزش شبکه آنقدر تغییر داده می‌شوند تا شبکه به طور کامل و صحیح الگوهای موجود در ورودی را شناسایی نماید. تنظیم و تغییر اوزان شبکه و درنهایت تنظیم خود شبکه برمبنای مقایسه پاسخ شبکه (خروجی) برای ورودی خاصی که خروجی مطلوب آن (هدف) مشخص است، انجام می پذیرد، قابل ذکر است که این روش برای تنظیم اوزان در نوعی از شبکه‌ها با یادگیری با ناظر (Supervised Learning) مورد استفاده قرار می‌گیرد (Berry et al.,1997). بطور کلی مراحل الگوریتم پس‌انتشار خطا را می‌توان به صورت زیر بیان کرد:

۱- شبکه یک مثال آموزشی را دریافت می‌کند و با استفاده از اوزان موجود در شبکه که در ابتدا به صورت تصادفی مقداردهی می‌شوند، خروجی را محاسبه می‌کند.

۲- خطا (اختلاف میان نتیجه محاسبه شده(خروجی) و مقدار مورد انتظار) محاسبه می‌شود.

۳- خطا درون شبکه منتشر می‌شود و اوزان برای کمتر کردن خطا، از نو تنظیم می‌شوند (Hornik et al, 1989).

متدولوژی اجرا

با توجه به هدف این مطالعه که مقایسه الگوریتم‌های مختلف شبکه عصبی برای برآورد عیار مس می‌باشد در زیر متدولوژی اجرا به طور مختصر تشریح گردیده است.

تعیین فاکتورهای کنترل کننده کانی‌سازی

فاکتورهای کنترل‌کننده مورد استفاده جهت انجام این پژوهش شامل داده‌ها و اطلاعاتی نظیر: مختصات X و Y گمانه‌های دره‌زرشک، نقشه منحنی هم‌عیار و آنومالی عنصر مس، نقشه تیپ سنگ شناسی، نقشه گسل‌های اصلی و فرعی، نقشه آلتراسیون هیدروترمال و نقشه توپوگرافی منطقه می‌باشد. باید توجه داشت پارامترهای ورودی شبکه به صورتی باشند که محدودیتی در بدست آوردن آنها وجود نداشته باشد یا به عبارتی عملی باشد. از طرف دیگر باید از انتخاب تعداد زیاد و غیر ضروری و همچنین غیر مستقل پارامترهای ورودی خودداری نمود زیرا این امر باعث پیچیدگی بیش ازحد شبکه و عملکرد نامناسب آن خواهد شد (Hornik et al., 1989).

سازماندهی و آماده‌سازی لایه‌های اطلاعاتی

از آنجایی که لایه‌های اطلاعاتی (نقشه‌ها) در کانی‌سازی مس دره‌زرشک دارای ارزش یکسانی نبوده و تاثیر آنها بر روی پاسخ نهایی، یکسان نیست باید پیش از انجام هر عملیاتی ارزش‌گذاری آنها صورت پذیرد. به این منظور در محیط GIS با استفاده از ایجاد بافر و کلاسه‌بندی مجدد، نقشه‌های معیار هر لایه اطلاعاتی تهیه شد. سپس فاکتورهای کنترل‌کننده موثر در کانی‌سازی مس به‌عنوان داده‌های آموزشی ورودی شبکه و اطلاعات مربوط به عیار هر گمانه به‌عنوان داده‌های آموزشی هدف در نرم‌افزار MATLAB در نظر گرفته شدند.

آموزش شبکه‌عصبی

فرایند آموزش شبکه را می توان به عنوان جستجویی برای تعیین کمینه کلی یک تابع هزینه (که به طور معمول مجموع مربعات خطا یا میانگین مربعات خطا است) در نظر گرفت. سطح خطا در فضای وزن ارتباطی موجود بوده و بعد این فضا برابر با تعداد اوزان موجود در شبکه است. بنابراین در طول فاز آموزش، جستجوی مجموعه مختصاتی از فضای اوزان که مربوط به کمینه مقدار عمومی سطح خطای حاصل از انطباق مدل با داده های واقعی،

www.SID.ir

Archive of SID

صورت می گیرد. در واقع پس از آماده سازی داده‌های ورودی و خروجی شبکه‌عصبی در هر مرحله یکی از این بخش‌ها از شبکه عصبی خارج شده و شبکه عصبی با سایر داده‌ها، آموزش داده می‌شود و از داده‌های خارج شده به عنوان داده‌هایی برای تست کارآیی شبکه عصبی استفاده می‌شود. با تکرار این پروسه، در هر تکرار بخش دیگر داده‌های آموزشی از میان داده‌ها خارج می‌شود و آموزش شبکه عصبی به همان روش مذکور، انجام می‌گیرد. در آغاز هر مرحله اجرایی برای کشف اصلاحات مورد نیاز در مدل، پیش از هر کاری یک ساختار اولیه و خام برای شبکه در نظر گرفته و در هر مرحله تا تعیین مدل بهینه اصلاحاتی در مدل اولیه ایجاد می‌شود. تعیین این مدل بهینه پایانی به طور معمول عبارت است از تعیین نوع الگوریتم یادگیری، تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، شکل مناسب داده‌های ورودی، نوع توابع تحریک و روش ارتباط میان نرون‌ها و متغیرهای آزاد مدل که هرکدام از این مسائل به نوبه خود بر روند کار تأثیر می‌گذارند. در مرحله‌ی آخر متغیرهای مدل بهینه شبکه عصبی ذخیره می‌شوند و این شبکه، آموزش دیده نامیده می‌شود. در این مرحله ورودی‌هایی که برای آزمایش مدل مورد نظر هستند به شبکه وارد می‌شوند و خروجی‌های حاصل از مدل برای محاسبه مدل ایجاد شده مورد تجزیه و تحلیل قرار می‌گیرند (طهماسبی و هزارخانی، ۱۳۹۰). شبکه مورد استفاده از نوع پیشخور، با تعداد ۷ ورودی، تعداد ۳ لایه پنهان،با تابع انتقال لایه پنهان لگاریتمی، داده‌ها به صورت گروهی با وضعیت عددی در بازه[۱ ۰] نرمال شده، با تابع عملکرد MSE به مقدار $۱۰^{-۶}$ و الگوریتم آموزشی پس انتشار خطا می‌باشد. نتایج حاصل از آزمایش الگوریتم‌های مختلف در جدول ۱ نشان داده شده است.

جدول ۱- مقایسه نتایج الگوریتم‌های آموزشی مختلف با آرایش نرون‌های متفاوت

Alg	Function	Training	Rmax	Neuron No	Alg	Function	Training	Rmax	Neuron No
LM	logsig	0.992	0.933	29-15-1	SCG	logsig	0.850	0.849	6-25-1
LM	logsig	0.999	0.959	19-22-1	SCG	logsig	0.969	0.847	24-29-1
BR	logsig	0.980	0.945	5-12-1	CGB	logsig	0.984	0.892	25-10-1
BR	logsig	0.999	0.913	29-30-1	CGB	logsig	0.936	0.887	19-15-1
BFG	logsig	0.964	0.870	25-12-1	CGP	logsig	0.957	0.899	12-22-1
BFG	logsig	0.893	0.853	29-26-1	CGP	logsig	0.990	0.916	14-16-1
RP	logsig	0.929	0.908	15-11-1	CGF	logsig	0.823	0.794	21-28-1
RP	logsig	0.969	0.937	23-27-1	CGF	logsig	0.830	0.842	22-24-1

نتیجه‌گیری

استفاده از شبکه‌های عصبی مصنوعی در تعیین ذخیره عیار، به لحاظ صرفه‌جویی در زمان و هزینه موجود، بر روشهای متداول برتری دارد زیرا روش بسیار دقیقی است. از طرفی این روش نیازمند استفاده از فرضیات و ساده سازی‌های گوناگون و مدل‌سازی پیچیده نمی باشد. با توجه به هدف این مطالعه که رسیدن به شبکه با ساختار بهینه به وسیله متغییرهای موجود برای کنترل کارایی شبکه می‌باشد تابع نوع لگاریتمی مورد استفاده قرار گرفت. تعداد لایه‌های پنهان در شبکه طراحی شده سه لایه می باشد که تعیین تعداد نرون های لایه میانی کاملا تجربی و وابسته به تکرار شبکه با تعداد نرون‌های مختلف می‌باشد. در این مطالعه از هشت الگوریتم آموزشی پس انتشار خطا با تعداد نرون مختلف در لایه‌ی میانی (جدول ۱) جهت تعیین مناسب ترین الگوریتم آموزشی بررسی شد به گونه ای که درنهایت الگوریتم آموزشی LM و BR با تابع لگاریتمی با تعداد ۱-۲۲-۱۹ و ۱-۱۲-۵ نرون در لایه‌ی پنهان و ضریب تطابق ۰.۹۵ و ۰.۹۴ بیشترین دقت را در برآورد عیار مس پورفیری دره زرشک نسبت به سایر الگوریتم های آموزشی دربرداشت (شکل ۳).

www.SID.ir

Archive of SID



(الف) (ب)

شکل ۳- (الف) الگوریتم آموزشی LM (ب) الگوریتم آموزشی BR

منابع

۱. شهابی‌فر، م.، ۱۳۸۳. تخمین ذخیره کانسار با تکنیک شبکه عصبی مصنوعی، کنفرانس مهندسی معدن ایران.

۲. طهماسبی، پ.، هزارخانی، الف.، ارائه روشی برای بهینه‌سازی شبکه عصبی برای برآورد عیار با استفاده از اطلاعات سیستم مس پورفیری سوناجیل- اهر. ، ۱۳۹۰. فصل‌نامه علوم زمین، سال بیست و یکم، شماره ۸۱، صفحه ۳۱ تا ۳۶.

3. Bishop, c. M., 1995. Neural networks for pattern recognition, 1st edition. Oxford Clarendon.

4. Berry, M. J.A., Linoff. G., 1997. Data mining techniques, John Wiley and Sons, p.454.

5. Demuth, H., Beale, M., 1988. Naural Network Toolbox User´s Guide, ver. 3, The Mathworks.

6. Fulop, I. A., Jozsa, J., Karamer. T., 1998. A neural network application in estimating wind induced shallow lake motion, Hydoro informatics 98, 2, p 753-757.

7. Hagan, M.T., Demuth, H.B., Beale, M.H., 1996. Neural Network Desing, PWS Pulishin Company, Boston.

8. Hornik, k., Stinchcombe, M., White, H., 1989. Multilayer Feed Forward Network Are Universal Approximators, Neural Network, Vol. 2, p. 359-366.

9. Nikravesh, M., Aminzadeh, F., 2001. Mining and fusion of petroleum data with fuzzy logicand neural network agents, J. Petrol. Sng. 29, 221-238.

10. Ranjithan, J., Eheart, J., Garrett, J. H., 1995. Application of neural network in groundwater under condition of uncertainty, New Uncertainty Hydrology and Water Resources, p 133-140.

11. Sadorsky, P.,2006. Modeling and forecasting petroleum futures volatility, Energy Economics 28, 467-488.

12. Zarasvandi, A., Liaghat, S., Zentilli, M., 2004. Geology of the Darreh-Zerreshk and Ali-Abad porphyry copper deposit, central Iran, International Geology Reviews, Vol. 47, P. 620-646.

www.SID.ir

SID

فیلم های آموزشی | عضویت در خبرنامه | بلاگ مرکز اطلاعات علمی | کارگاه های آموزشی | سرویس ترجمه تخصصی | سرویس های ویژه

کارگاه های آموزشی مرکز اطلاعات علمی جهاد دانشگاهی

کارگاه آنلاین آشنایی با پایگاه های اطلاعات علمی
بین المللی و
ترفند های جستجو



مباحث پیشرفته یادگیری عمیق؛
شبکه های توجه گرافی
(Graph Attention Networks)

کارگاه آنلاین مقاله نویسی IEEE و ISI
ویژه فنی و مهندسی