

استفاده از شبکه‌های عصبی-فازی-ژنتیکی به منظور تخمین عیار در کانسار مس پرفیری دره‌زار-کرمان

پژمان طهماسبی^۱، اردشیر هزارخانی^{۲*}

۱- دانشجوی دوره دکتری دانشگاه صنعتی امیرکبیر، دانشکده مهندسی معدن و متالورژی؛ Email: Pejman@aut.ac.ir

۲- استاد دانشگاه صنعتی امیرکبیر، دانشکده مهندسی معدن و متالورژی؛ Email: Ardehez@aut.ac.ir

(دریافت ۱۵ اسفند ۱۳۸۸، پذیرش ۲۲ خرداد ۱۳۹۰)

چکیده

تخمین عیار یکی از مراحل کلیدی در ارزیابی و بررسی‌های فنی و اقتصادی یک معدن است. مقادیر عیار تأثیر قابل توجهی بر روی برنامه‌ریزی‌ها، طراحی و مدیریت معدن دارد. بنابراین، بکار بردن روش‌هایی که این مقادیر را با دقت بالایی تخمین بزنند ضروری بنظر می‌رسد. یکی از بهترین روش‌ها جهت به دست آوردن عیار در یک کانسار اقدام به حفر گمانه‌های اکتشافی است که بعلت هزینه‌های بالا امکان پذیر نمی‌باشد. در این مطالعه یک روش جدید برای تخمین عیار برپایه منطق فازی، شبکه‌های عصبی و الگوریتم ژنتیک ارائه شده است. این شبکه جدید با بکاربردن الگوریتم ژنتیک در ساختار خود به منظور بهینه نمودن آن و پارامترهای شبکه فازی-عصبی و نیز استفاده همزمان از شاخه‌های مختلف هوش مصنوعی، دارای نتایج بهتری در مقایسه با سایر روش‌های تخمین عیار می‌باشد. این روش در کانسار مس پرفیری دره‌زار کرمان استفاده شد و مطابق نتایج به دست آمده، شبکه توانسته است به خوبی الگوی فضایی مابین ورودی‌ها و خروجی را به درستی تشخیص دهد و عیار را با دقت مطلوبی تخمین بزند. به طوری که مقادیر ضریب همبستگی از ۰/۷۳ و ۰/۷ به ترتیب برای زون‌های هیپوژن و سوپرژن به ۰/۹۶ و ۰/۸۲ بهبود یافت.

کلمات کلیدی

هوش مصنوعی ترکیبی، بهینه‌سازی، عیار، ANFIS-GA، تخمین

* نویسنده مسئول و عهده‌دار مکاتبات

۱- مقدمه

تخمین عیار یکی از مهم‌ترین مشکلات و دغدغه‌های مهندسان معدن و زمین‌شناسی است. علت این امر شاید وابستگی زیاد پروژه‌های معدنی به مقدار دقیق عیار و نیاز به داشتن دانش وسیعی از معدنکاری، برای تخمین عیار و سپس تناژ ماده معدنی باشد. اغلب به علت وجود گسل‌ها، دایک‌ها و شکستگی و ساختارهای پیچیده، مدل‌سازی کانسار با مشکلات خاصی مواجه است. شایان ذکر است که یکی از پیچیده‌ترین و مشکل‌ترین مدل‌سازی‌ها، در ارتباط با مدل‌سازی شاخه‌های علوم زمین می‌باشد؛ دلیل این امر متفاوت بودن ساختار و بروز عوامل منحصر به فرد است.

در سال‌های اخیر، محققین تلاش‌های زیادی برای بهبود تخمین عیار انجام داده‌اند. از میان این روش‌ها، شاید زمین‌آمار یکی از رایج‌ترین روش‌های مورد استفاده باشد. همچنین در مطالعه‌های انجام شده نیز از شبکه‌های عصبی به صورت وسیعی استفاده شده است. برای مثال، سینگر^[۱] از شبکه‌های احتمالی برای بررسی عیار و تناژ ماده معدنی و در نهایت یافتن مناطق با عیار بالا استفاده کرد. همچنین محققین زیادی از شبکه‌های عصبی برای تخمین عیار و ذخیره [۲،۳] و نهایتاً بررسی کارایی آن در مقایسه نتایج حاصل از کریجینگ [۴] پرداخته‌اند. همچنین، یکی دیگر از روش‌هایی که موازی با شبکه‌های عصبی مورد استفاده قرار گرفته است، منطق‌فازی می‌باشد که هدف اصلی آن کار در شرایط همراه با عدم قطعیت بالا و داده‌های ناکافی است (رجوع شود به بخش ۲). از کاربردهای این روش می‌توان به ترکیب آن با روش‌های زمین-آمار برای کمک به عملکرد آن‌ها اشاره کرد [۵،۶]. همچنین، سعی شده است که به توانایی منطق‌فازی برای مدل‌سازی عیار و اکتشاف ذخایر معدنی [۷]، که مورد بحث این مطالعه است، اشاره نمود.

معمولاً در کار با شبکه‌های عصبی و منطق‌فازی مشکلات خاصی وجود دارد. زیرا هر کدام از آنها دارای جنبه‌های خاصی در حل مسائل می‌باشند. مثلاً منطق‌فازی در حل مسائل کنترلی پیچیده و شرایطی که داده‌های زیادی در مورد سیستم وجود ندارد، کاربرد موفقیت‌آمیزی داشته است. همچنین شبکه‌های عصبی به واسطه توانایی خود در یادگیری از داده‌های آموزشی و تعمیم آن به داده‌های تست، دارای توانایی

بالایی در حل مسائل با محاسبات زیاد و غیرخطی می‌باشند. از مشکلات مربوط به این شاخه‌های هوش مصنوعی می‌توان به تعیین توابع عضویت و تعداد آنها و نیز قوانین بکار برده شده در منطق‌فازی اشاره کرد که نیازمند داشتن دانش کاملی در مورد سیستم مورد مطالعه می‌باشد [۸]. همچنین در شبکه‌های عصبی به علت دخیل بودن پارامترهای زیادی که در طراحی وجود دارند و نیز امکان به دام افتادن شبکه در کمینه محلی، طراحی شبکه‌های عصبی را با مشکلات زیادی مواجه ساخته است. بنابراین، ایده ترکیب شبکه‌های عصبی و منطق‌فازی، به منظور برطرف کردن مشکلات مربوط به منطق‌فازی، می‌تواند بسیار جالب باشد.


در این مطالعه ابتدا به مرور کوتاهی بر شبکه عصبی-فازی و نیز مشکلاتی که در مورد این شبکه‌ها وجود دارد پرداخته می‌شود. سپس با تشریح مشکلات موجود، از الگوریتم‌های ژنتیک به عنوان یک روش تکاملی و بهینه‌سازی، به طراحی و بهینه کردن پارامترهای وابسته به شبکه عصبی-فازی پرداخته می‌شود. برای تشریح روش بکار رفته، از نتایج گمانه‌های حفاری حاصل از لاگ‌های کانسار مس پرفیری دره‌زار-کرمان به عنوان مورد مطالعه استفاده شده است.

۲- شبکه‌های عصبی-فازی

مطابق دانسته‌های قبلی می‌دانیم که هر کدام از جنبه‌های هوش مصنوعی در پاره‌ای از بخش‌ها دارای نقطه قوت و در مقابل در پاره‌ای مسائل دارای نقطه ضعف می‌باشند. به طور مثال، شبکه‌های عصبی شدیداً به تعداد داده‌های آموزشی حساس است و در صورت وجود داده‌های ناقص یا داده‌های دارای پراکندگی زیاد از توانایی آنها برای یافتن رابطه بین ورودی و خروجی کاسته می‌شود [۹]. همچنین در سیستم‌های فازی وقتی که از یک سری داده با تعداد زیاد و یکنواختی بالا استفاده می‌شود، از کارایی آن کاسته می‌شود. در واقع در نقطه مقابل سیستم‌های عصبی، منطق‌فازی بیشتر در مورد دسته داده‌هایی بکار می‌رود که در آنها، حالتی از ابهام و یا نقص وجود داشته باشد؛ زیرا این سیستم‌ها با استفاده از قوانین if-then به راحتی می‌توانند شرایط حاکم بر دسته داده‌ها را مدل‌سازی نمایند و قوانین منظمی را از یک سری داده ناقص و مبهم استخراج کند. ولی مشکلی که به صورت عمده درگیر کاربرد سیستم‌های فازی است، مسئله توابع عضویت می‌باشد [۱۰]. بنابراین، ترکیب و استفاده همزمان از توانایی‌های موجود در شبکه عصبی و منطق‌فازی (مدل عصبی-فازی) می‌تواند


۲-۱- قسمت‌بندی شبکه

برای تولید یک سیستم انطباقی فازی اولیه، قسمت‌بندی شبکه برای داده‌های ورودی مربوط به یک مجموعه داده ورودی/خروجی استفاده می‌شود. در مورد مدل عصبی-فازی نشان داده شده در شکل ۲، فضای ورودی دوبعدی به ۹ ناحیه فازی روی هم افتاده (دارای همپوشانی) تقسیم می‌شود که هر کدام از آنها از قانون فازی به صورت اگر-آنگاه، آن چنان که در شکل ۲ نشان داده شده است، تبعیت می‌کنند.



شکل ۱: معماری ANFIS [۱۳]

ساختار مدل عصبی-فازی به تعداد ورودی‌ها و تعداد توابع عضویت ورودی برای هر ورودی بستگی دارد [۱۳]. هر قاعده و تابع عضویت به وسیله یک نرون نمایش داده می‌شود. قوانین استنباطی سیستم هدایت‌کننده فازی مساوی با تعداد توابع عضویت برای هر ورودی به توان تعداد کل ورودی‌های سیستم می‌باشند [۱۳، ۱۴].



شکل ۲: تقسیم بندی ناحیه ورودی به ۹ ناحیه فازی [۱۳]

یک نرون تکی به عنوان یک بایاس برای تعریف اهمیت هر قانون در یک سیستم بکار می‌رود. هر قانون با یک تابع عضویت خروجی ارتباط دارد. یک نرون تکی برای تولید یک خروجی پیچیده استفاده می‌شود.

نویدگر نگرشی جدید برای برخورداری از مزیت‌های آنها و رفع نقاط ضعف موجود باشد.

مدل‌های عصبی-فازی، شبکه‌هایی عصبی با توانایی‌های منطقی فازی می‌باشند. به عبارت دیگر اوزان نرون‌های عصبی در شبکه، پارامترهای پیش فرض و نتیجه شده از یک سیستم مرجع فازی را تعریف می‌کنند [۱۱]. الگوریتم سیستم عصبی-فازی انطباقی (ANFIS)، یک سیستم انطباقی فازی را تولید می‌کند که یک مجموعه داده ورودی را به وسیله تنظیم کردن توابع عضویت با استفاده از یک الگوریتم مختلط که ترکیبی از یک الگوریتم انتشار رو به عقب و روش حداقل مربعات است بر روی یک مجموعه داده خروجی انجام می‌شود. این الگوریتم مستلزم محاسبه کمتری نسبت به الگوریتم انتشار رو به عقب است، به این دلیل که روش حداقل مربعات، ابعاد فضای تحقیق را که از الگوریتم انتشار رو به عقب اصلی به دست می‌آیند، کاهش می‌دهد [۱۲]. در یک روش مشابه شبکه عصبی، ANFIS بر اساس مجموعه‌ای از توابع عضویت اولیه یک سیگنال خروجی را در مدت زمان عبور به جلو تولید می‌کند. پارامترهای نتیجه شده با استفاده از روش حداقل مربعات در عبور رو به جلو تعریف شده‌اند. سپس، خروجی با ورودی‌های لازم مقایسه می‌شود و یک سیگنال خطا برای استفاده در مدت عبور رو به عقب برای اصلاح کردن پارامترهای پیش فرض مورد استفاده در الگوریتم انتشار رو به عقب، به سیستم برگردانده می‌شود. این فرآیند برای چند دوره تکرار می‌شود تا سیگنال خطا به طور قابل قبولی کوچک شود (در حالت مطلوب صفر) [۱۲، ۱۳]. شکل ۱ ساختار ANFIS یک شبکه عصبی-فازی دارای ۲ ورودی (x,y) را که به وسیله ۹ قانون هدایت می‌شود، نشان می‌دهد. فرض می‌شود که هر ورودی سه تابع عضویت وابسته به هم دارد. گره‌های انطباقی A1, A2, A3, B1, B2 و B3 پارامترهای توابع عضویت ورودی را نگه می‌دارند؛ در صورتی که گره‌های انطباقی ۱ تا ۹ بیانگر پارامترهای توابع عضویت خروجی و قوانین حاکم بر شبکه می‌باشند. گره‌های که برچسب گذاری می‌شوند ثابتند و توانایی عملکرد یک قانون را دارند در حالی که گره‌های که با N برچسب گذاری می‌شوند، همان نسبت قدرت عملکرد یک قانون را به مجموعه قدرت‌های عملکرد تمام قوانین نشان می‌دهند.

۳- الگوریتم‌های ژنتیک

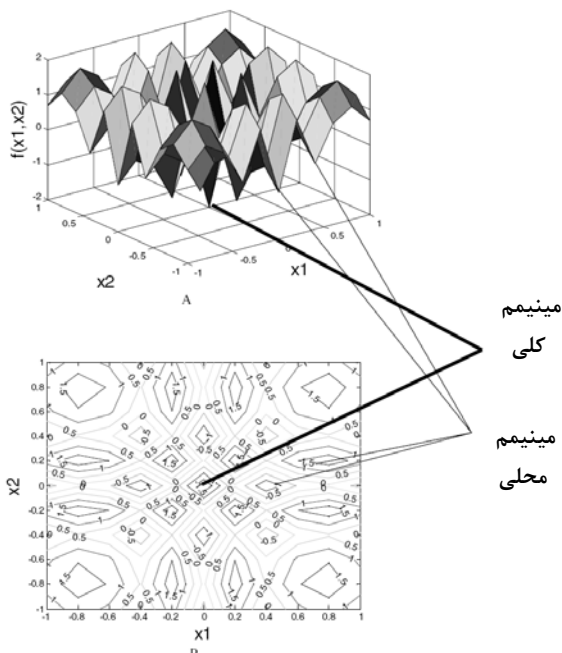
پیشینه الگوریتم ژنتیک به سال‌های حدود ۱۹۶۰ بر می‌گردد. در دهه‌های ۵۰ و ۶۰، تحقیقات متعددی برای استفاده از نظریه تکامل در بهینه‌سازی مسائل مهندسی به طور مستقل صورت گرفت. ایده اصلی در همه این سیستم‌ها، رشد یک جمعیت از پاسخ‌های اولیه یک مسئله به سمت پاسخ بهینه با الهام‌گیری از عملگرهای انتخاب و تغییر ژنتیک طبیعی بود. الگوریتم ژنتیک نخستین بار توسط جان هالند^۲ مطرح شد و گسترش یافت [۱۵].

با توجه به شکل ۳، این منحنی دارای چندین ماکزیمم می‌باشد. که یکی از آنها تنها ماکزیمم کلی است. حال اگر از روش‌های بهینه‌سازی ریاضی استفاده کنیم، مجبوریم تا در یک بازه بسیار کوچک مقدار ماکزیمم تابع را بیابیم. مثلاً از نقطه‌ای فرضی شروع کنیم و تابع را ماکزیمم کنیم. بدیهی است اگر از نقطه‌هایی که با پیکان مشخص شده‌اند شروع کنیم، تنها به مقدار ماکزیمم محلی دست خواهیم یافت و الگوریتم مورد استفاده پس از آن متوقف خواهد شد. اما در روش‌های هوشمند، به خصوص الگوریتم ژنتیک، به دلیل خصلت تصادفی آنها حتی اگر هم از این نقاط شروع کنیم، باز ممکن است در میان راه نقطه ماکزیمم کلی به صورت تصادفی انتخاب شود؛ در این صورت ما شانس دست‌یابی به نقطه بهینه کلی^۳ را خواهیم داشت. در مورد نکته دوم باید متذکر شد که روش‌های ریاضی بهینه‌سازی اغلب منجر به یک فرمول یا دستورالعمل خاص برای حل هر مسئله می‌شوند؛ در حالی که روش‌های هوشمند دستورالعمل‌هایی می‌باشند که به صورت کلی می‌توانند در حل هر مسئله‌ای به کار گرفته شوند [۱۶].

در طی تولیدمثل^۴، در اثر الحاق^۵ ژن‌ها از کروموزوم‌های والدین^۶ با یکدیگر ترکیب می‌شوند تا کروموزوم کامل جدیدی را تشکیل دهند. در طی این تغییرات، ممکن است تغییرات کوچکی در برخی از بخش‌های DNA ژن‌های فرزند، به وجود آید و فرزند دچار جهش^۷ شود. در نهایت تناسب^۸ یک موجود زنده با توجه به احتمال زیستن آن برای تکثیر (زیست پذیری^۹) یا برحسب تابعی از تعداد فرزندان آن گونه (باروری^{۱۰}) تعیین می‌شود.

با توجه به آنچه گذشت، الگوریتم ژنتیک بخشی از نظریه حسابگری تکاملی^{۱۱} است که در حال حاضر به عنوان بخشی از هوش مصنوعی به سرعت در حال رشد می‌باشد. ایده اصلی این الگوریتم در نظریه تکامل داروین نهفته است. از نظر کاربردی،


الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی مسائل است که اساس آن بر انتخاب طبیعی (عامل اصلی تکامل زیستی) و برخی مفاهیمی که از علم ژنتیک الهام گرفته شده‌اند، استوار است. در این روش به بیان ساده، برای بهینه‌سازی تابع هدف (تابع تناسب) مسئله، در هر مرحله، از یک جمعیت^{۱۲} اولیه کروموزوم‌ها (افراد^{۱۳}) که در حقیقت پاسخ‌های اولیه مسئله می‌باشند، به یک جمعیت جدید از کروموزوم‌ها و یا یک نسل^{۱۴} جدید که در حقیقت پاسخ‌های ثانویه مسئله مفروض می‌باشند، می‌رسیم. بنابراین با تکرار این عملیات و تولید جمعیت جدید از جمعیت قبلی، در هر مرحله و در نتیجه رسیدن به نسل‌های موفق، جمعیت به سمت یک پاسخ بهینه رشد خواهد کرد [۱۷].



شکل ۳: نمونه‌ای از شکل یک تابع که دارای چندین بیشینه و کمینه محلی است

۴- زمین‌شناسی کانسار مس پرفیری دره‌زار

از نظر زمین‌شناسی، منطقه دره‌زار (شکل ۴) در میان یک کمربند کوهستانی با جهت شمال شرق - جنوب غربی قرار دارد. این کمربند شامل یک سری سنگ‌های آذرین با سن ترشیاری است. کانسار پرفیری دره‌زار، یک توده نفوذی دیوریت - کوارتز دیوریت باسن میوسن - الیگومیوسن می‌باشد که در کمپلکس آتشفشانی - رسوبی که عمدتاً شامل آندزیت، تراکی آندزیت و آذرآوری‌ها و سنگ‌های رسوبی می‌باشند، نفوذ نموده



شکل ۵: موقعیت گمانه‌های حفاری در کانسار مس دره‌زار

به علت تفاوت‌های جزئی میان آنها از توضیح این سیستم‌ها خودداری می‌کنیم. به خواننده محترم توصیه می‌شود که برای کسب اطلاعات بیشتر در مورد این تفاوت‌ها به منابع منتشر گردیده توسط Jang [۱۳] مراجعه نمایند. شایان ذکر است که تفاوت میان سیستم‌های CANFIS با ANFIS در توانایی آن برای ایجاد چندین خروجی به وسیله قوانین فازی غیرخطی است [۱۴،۴]. همچنین این شبکه‌ها به علت استفاده از قوانین فازی غیرخطی موجود در آن، دارای توانایی جذب بالاتری از پیچیدگی‌های موجود در فضای داده‌های ورودی و خروجی می‌باشد. در این قسمت به صورت خلاصه به ذکر نحوه تلفیق الگوریتم ژنتیک و شبکه عصبی-فازی که در این مطالعه استفاده شده است، برای بهینه‌سازی این شبکه‌ها پرداخته می‌شود. توجه داشته باشید که در آن دسته از سیستم‌های هیبریدی که از یک الگوریتم آموزشی هم استفاده می‌شود، پارامترهای مربوط به الگوریتم آموزشی نیز اضافه می‌گردند.

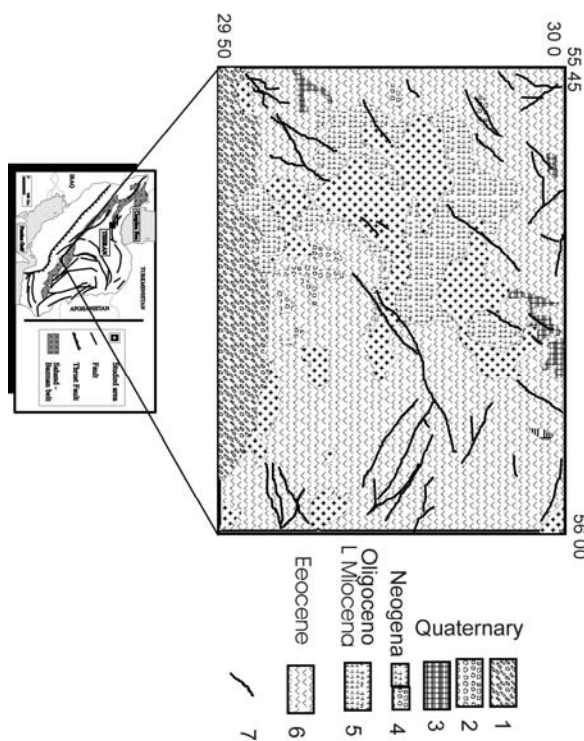
۶- بحث و نتایج

در این مطالعه از تابع تعلق Bell و از مدل فازی TSK استفاده شد. علت استفاده از این تابع انعطاف‌پذیری بیشتر این تابع می‌باشد. چون این تابع دارای چهار پارامتر و تابع گوسی دارای سه پارامتر است. همچنین علت استفاده از مدل فازی TSK، سرعت بالای آن می‌باشد [۹، ۱۸، ۲۰، ۱۹].

الگوریتم یادگیری در این سیستم مومنتم بود و از تابع محرک آکسون برای آموزش استفاده شد. در ادامه کاربرد الگوریتم ژنتیک، تعداد توابع عضویت به ازای هر ورودی، سه تابع تخمین زده شد.

در این قسمت بیان توضیحاتی در مورد پارامترهای مورد استفاده در الگوریتم ژنتیک، لازم است. در این مطالعه از

است. نفوذی دره‌زار در بعضی مناطق ترکیبی گرانودیوریتی دارد.



شکل ۴: نقشه زمین‌شناسی کانسار مس پرفیری دره‌زار

در این مطالعه نمونه‌های سه زون در دسترس بودند، لیچ، سوپرژن و هیپوژن. از در نظر گرفتن نمونه‌های زون لیچ، به علت پایین بودن عیار در آن و وسعت کم منطقه دربرگرفته، صرف نظر شد. پس از انجام عملیات کامپوزیت‌سازی و حذف نمونه‌های نامناسب مغزه‌ها که در آنها امکان آلودگی وجود داشت، تعداد نمونه‌ها تقلیل پیدا کرد و نمونه‌ها در دو زون سوپرژن و هیپوژن به ۱۸۲۷ و ۲۶۲ نمونه رسید. همچنین موقعیت گمانه‌های حفاری در شکل ۵ نشان داده شده است که محورهای X و Y به ترتیب بیانگر طول و عرض جغرافیایی می‌باشند.

۵- روش

در این مطالعه از سیستم CANFIS¹⁵ استفاده شد که کلیه عملیات مربوط به شبیه‌سازی با استفاده از نرم‌افزار MATLAB (R2009a) صورت گرفت. در واقع سیستم‌های CANFIS یک حالت عمومی از سیستم‌های ANFIS است که

آزمایش‌ها در جدول ۲ برای یافتن ضریب تولیدمثل، احتمال جهش ژنتیکی و اندازه جامعه نشان داده شده است. هدف از این امر که نتایج آن نیز در جدول ۲ ذکر شده است، رسیدن به مقادیر پایایی از سه عملگر ژنتیکی به منظور استفاده بهینه از الگوریتم ژنتیک و در نهایت تخمین بهتر عیار مس می‌باشد. چون این پارامترها تأثیر زیادی بر روی الگوریتم ژنتیک و در نتیجه بر روی نتایج نهایی دارند، لازم است که آنالیز حساسیت برای انتخاب مقادیر بهینه آنها صورت گیرد.

مطابق نتایج به دست آمده از این آزمایش‌ها، الگوریتم ژنتیک حساسیت، تغییر قابل توجهی نسبت به مقادیر عملگرهای ژنتیکی نداشته است؛ بنابراین از ردیف سوم جدول ۲ استفاده شد. یعنی به ترتیب از مقادیر ۰/۰۶، ۰/۱۲ و ۵۰ به عنوان اندازه‌های نرخ تولید مثل، نرخ جهش و اندازه جمعیت استفاده گردید. در این مرحله و پس از به دست آوردن مقادیر عملگرهای ژنتیکی، شبکه آماده اجرا شدن است. بنابراین مطابق مطالب توضیح داده شده قبلی و مقادیر به دست آمده، شبکه برای دو زون مورد نظر در کانسار مس دره‌زار اجرا شد که نتایج حاصل از کاربرد الگوریتم ژنتیک به صورت خلاصه در جدول ۳ نشان داده شده است. مطابق این جدول، پارامترهای نسل، کمترین MSE و MSE نهایی برای بهترین نتیجه به دست آمده از کاربرد شبکه ترکیبی (بهترین Fitness) و میانگین جواب‌های به دست آمده در نسل‌های مورد نظر (میانگین Fitness) ذکر شده است. همچنین این جدول درک تفاوت بین سایر جواب‌های شبکه و بهترین جواب به دست آمده مفید است که به نحوی بیانگر پراکندگی نتایج به دست آمده در نسل‌های مختلف نیز می‌باشد.

همچنین نتایج حاصل به صورت گرافیکی در شکل ۶ مشاهده می‌شود. مطابق این شکل، این امکان وجود دارد که روند کاهش خطای شبکه با گذشت زمان (اینجا تعداد دوره‌های آموزشی) را مشاهده کرد. واضح است که مطابق این نمودارها، با استفاده از ترکیب الگوریتم ژنتیک با شبکه مورد نظر، خطای شبکه در حال کاهش است و بعد از گذشت چندین نسل، به یک مقدار ثابت از خطا می‌رسد و به اصطلاح شبکه همگرا می‌شود.

کروموزوم نوع نیم‌دانه^{۱۶}، که حاوی ژن‌های اعداد باینری است، استفاده شد. همان طور که قبلاً اشاره شد، هر کروموزوم حاوی چندین ژن است. در مطالعه کنونی هر کروموزوم از چهار ژن تشکیل شده است. این چهار ژن نمایانگر همان متغیرهایی می‌باشند که باید بهینه انتخاب شوند. اولین ژن بیانگر تعداد ورودی‌ها در لایه اول، دومین و سومین ژن نشانگر نرخ یادگیری و ضریب مومنتم و در نهایت چهارمین ژن بیانگر تعداد توابع عضویت هر ورودی می‌باشد.

در ابتدا سعی بر آن شد که با استفاده از روش‌های سعی و خطا، شبکه را تا حد امکان، بهینه کرد؛ به صورتی که بتوان عیار را با دقت بالایی تخمین زد. نتایج حاصل از این بخش، در جدول ۱ نشان داده شده است. مطابق این جدول، برای دو بخش مورد بررسی در کانسار، با امتحان کردن پارامترهای گوناگون با قسمت‌های مختلف شبکه، ساختار شبکه به همراه کمترین خطای ایجاد شده برای آنها به دست آمد. به عبارت دیگر، این جدول بیانگر تغییرات پارامترهای آماری همراه با تغییر تعداد نرون‌ها است که نتایج آن به صورت خلاصه در جدول ۱ آمده است. داده‌ها برای این امر به سه دسته داده آموزشی (۷۰٪ کل داده‌ها)، اعتبارسنجی (۱۵٪) و تست (۱۵٪) تقسیم شدند. از داده‌های اعتبارسنجی برای نظارت بر روند آموزشی استفاده می‌شود. به عبارت دیگر، همزمان با آموزش شبکه، داده‌های اعتبارسنجی به شبکه داده می‌شود تا امر تخمین را انجام دهد و بدین وسیله هر کجا که خطای شبکه زیاد شد، آموزش آن قطع شود. واضح است که برای بخش شبیه‌سازی که از الگوریتم ژنتیک استفاده شد، دیگر نیازی به داده‌های اعتبارسنجی نیست و داده‌های آن بخش به آموزش شبکه تخصیص داده شد؛ یعنی ۸۵٪ برای آموزش و ۱۵٪ برای تست. شایان ذکر است که داده‌ها برای هر مرحله به صورت تصادفی تخصیص داده شدند. برای تقسیم داده‌های مرحله دوم (مدل‌سازی با ژنتیک)، از آنجایی که در این مدل‌سازی شبکه باید تا انتهای نسل‌ها پیش برود و خود الگوریتم ژنتیک، شبکه را در بهترین نقطه متوقف می‌کند، دیگر نیازی به استفاده از داده‌های اعتبارسنجی برای کنترل روند آموزش شبکه نیست.


یکی از عواملی که بر کارکرد الگوریتم ژنتیک می‌تواند تأثیر داشته باشد، مقادیر عملگرهای ژنتیکی است [۱۸، ۲۲]. بدین منظور ۳۰ مرتبه شبکه مورد نظر برای یافتن بهترین مقدار پارامترها با مقادیر مختلف اجرا شد. نتایج حاصل از این

جدول ۱: نتایج به‌دست‌آمده برای آموزش، اعتبارسنجی و تست شبکه در دو بخش هیپوژن و سوپرژن کانسار مس پرفیری دره‌زار


کلی	تست	اعتبارسنجی	آموزش	تعداد نرون		
-	۰/۰۲۴۰	۰/۰۲۸۸	۰/۰۳۳۸	۷	MSE	زون هیپوژن
۰/۶۲۲۸۱	۰/۵۳۰۹۷	۰/۵۳۲۶۹	۰/۶۶۰۲۴		R	
-	۰/۰۲۷	۰/۰۵۶	۰/۰۱۶	۱۳	MSE	
۰/۷۳	۰/۶۳	۰/۵۸	۰/۷۹۸۴		R	
-	۰/۰۲۶	۰/۰۶۶	۰/۰۲	۱۵	MSE	
۰/۶۷	۰/۵۲	۰/۶۴	۰/۷۴		R	
-	۰/۱۱۶	۰/۱۶۶	۰/۱۴۳	۱۶	MSE	
۰/۵۵	۰/۴۸	۰/۵۲	۰/۵۷		R	
-	۰/۹۷	۰/۱۹۱	۰/۰۸۹	۲۵	MSE	
۰/۷۰	۰/۶۷	۰/۶۳	۰/۷۲		R	
-	۰/۱۷۲	۰/۱۵۸	۰/۰۱۷	۳۰	MSE	
۰/۷۰	۰/۵۰	۰/۵۹	۰/۷۶		R	

جدول ۲: پارامترهای مناسب برای انجام شبیه‌سازی ژنتیکی

مرحله	۱	۲	۳	۴
Crossover rate	۰/۱	۰/۰۳	۰/۶	۰/۹
Mutation rate	۰/۰۱	۰/۰۶	۰/۱۲	۰/۲
Population size	۱۵	۳۰	۵۰	۶۰



الف



ب

شکل ۶: نمودار تولید نسل در مقابل بهترین MSE در الف. زون هیپوژن، ب. زون سوپرژن

جدول ۳: نتایج حاصل از کاربرد الگوریتم ژنتیک

زون کانسار	بهترین Fitness	میانگین Fitness	
زون سوپرژن	۶۴	۶۴	نسل
	۰/۰۰۷۱	۰/۰۱۲۵	کمترین MSE
	۰/۰۰۷۱	۰/۰۰۹۵	MSE نهایی
زون هیپوژن	۱۷	۱۷	نسل
	۰/۰۰۱۱	۰/۰۰۳۷	کمترین MSE
	۰/۰۰۱۱	۰/۰۰۲۵	MSE نهایی

در این مطالعه شبکه بهینه برای تخمین عیار در زون هیپوژن و سوپرژن به ترتیب در نسل‌های ۱۷ و ۶۴ ایجاد شد. نرخ یادگیری و ضریب مومنتم در شبکه زون هیپوژن، ۰/۴۲ و ۰/۲۴ و در زون سوپرژن ۰/۳۸ و ۰/۰۸ به دست آمد و به ترتیب در مقادیر ۰/۰۰۱۱ و ۰/۰۰۷۱، MSE به همگرایی رسید.

استفاده از تجربه یک فرد خبره (دانش زبانی) به مدل‌سازی می‌پردازد.


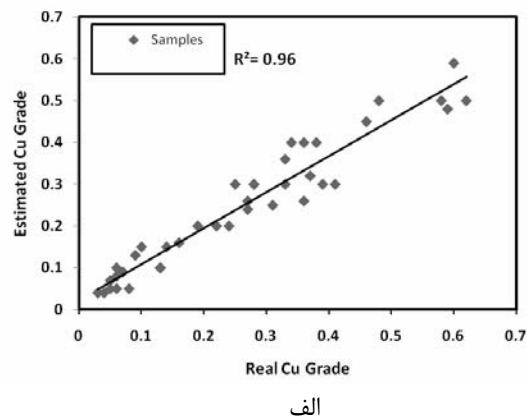
هدف استفاده از این مدل‌سازی، تکمیل، ساده‌سازی و دقیق‌تر کردن مدل‌سازی است. در مطالعه حاضر از آنجا که سیستم کانی‌زایی به علت شرایط غیرقابل پیش‌بینی و همراه با عدم قطعیت زمین‌شناسی دارای درجه ناهمسانگردی و پیچیدگی بالا می‌باشد، فرد خبره نمی‌تواند الگوی مناسبی از روند کانی‌زایی در این معدن ارائه کند. همچنین، یکی دیگر از مشکلاتی که متوجه این شبیه‌سازی می‌باشد آن است که در چنین شرایطی که دانش فرد خبره از سیستم، به علت پیچیده بودن آن کافی نیست، انتخاب توابع عضویت و ایجاد قوانین فازی با مشکلاتی همراه می‌شود. به همین منظور استفاده از سیستم‌هایی که دارای خاصیت یادگیری باشند و انتخاب بهینه این پارامترها را انجام بدهند، احساس شود. بنابراین، از دو سیستم عصبی-فازی CANFIS گردید. مطابق نتایج به‌دست‌آمده از کاربرد سیستم CANFIS-GA، این شبکه به علت استفاده همزمان از توانایی‌های سه شاخه از هوش مصنوعی، دارای عملکردی بهتر در مقایسه با شبکه‌های عصبی است. بنابراین شبکه طراحی‌شده دارای این توانایی است که عیار را به خوبی در نقاط دیگر کانسار تخمین بزند. در واقع با استفاده از یک تخمینگر مناسب، امکان اظهار نظر در مورد برنامه‌های آتی معدن، به صورتی که امکان برنامه‌ریزی درازمدت وجود داشته باشد، ممکن خواهد بود.

منابع

- [1] Singer, D.A.; 2006; "Typing mineral deposits using their associated rocks and grades and tonnages in a probabilistic neural network", *Mathematical Geology* Vol. 38, No. 4, pp. 465-475.
- [2] Kapageridis, I.K., Denby, B. ; 1998; "Neural Network modeling for ore grade spatial variability", *Proceedings of the 8th International Conference on Artificial Neural Networks (ICANN)*, Skovde, Sweden, pp. 209-214.
- [3] Wu, X., Zhou, Y.; 1993; "Reserve estimation using neural network techniques", *Computer & Geosciences* Vol.19, No. 4, pp. 567-575.
- [4] Mizutani, E., Jang, J.S.R.; 1995; "Coactive neural fuzzy modeling", in *proceedings of the International Conference on Neural Network*, pp. 760-765.
- [5] Bardossy, A., Bogardi, I., and Kelly; 1990b; "Kriging with imprecise (fuzzy) variograms. II:

همچنین در این مطالعه تعداد نرون‌های ورودی همانند سایر روش‌ها در مقدار سه ثابت ماند و تعداد توابع عضویت به ازای هر ورودی در زون هیپوزن و سوپرزن به ترتیب چهار و پنج به دست آمد.

همچنین از ۱۵٪ داده‌ها به عنوان داده‌های تست استفاده شد که مقادیر R برای زون‌های هیپوزن و سوپرزن به ترتیب ۰/۹۶ و ۰/۸۲ به دست آمد. این مقادیر بیانگر توانایی شبکه‌های طراحی‌شده در تعمیم موارد یادگرفته و تخمین عیار در مقایسه با روش‌های مبتنی بر سعی و خطای شبکه‌های عصبی است (شکل ۷).



شکل ۷: نمودار رگرسیون برای زون الف: هیپوزن و ب: سوپرزن

۷- نتیجه‌گیری

منطق‌فازی از جمله روش‌های جدیدی است که بعد از شبکه‌های عصبی پا به عرصه هوش مصنوعی گذاشته است و توانسته است با استفاده از توانایی‌های ویژه خود، مدل‌سازی را آسان‌تر کند. در این نوع خاص مدل‌سازی نیازی به یادگیری و نوشتن فرمول‌های پیچیده مدل‌سازی نیست و فرد مدل‌ساز با

- [14] Jang, J.S.R., Sun, C.T., Mizutani, E.; 1997; "Neuro-Fuzzy and soft computing: a computational approach to learning and machine intelligent", Prentice-Hall International.
- [15] Holland, J.H.; 1975; "Adaptation in natural and artificial systems". Ann Arbor: Univ. of Michigan Press. (A second edition was published in 1992: Cambridge: MIT Press).
- [16] Goldberg, D.E.; 1989; "Genetic algorithms in search, optimization, and machine learning", Addison-Wesley, Reading, MA.
- [17] Koza, R.J.; 2000; "Genetic programming, on the programming of computers by means of natural selection", The MIT Press, pp.175.
- [18] Sugeno, M., and Kang, G.T.; 1988; "Structure identification of fuzzy model", Fuzzy Sets System, Vol. 28, pp. 12-33.
- [19] Sugeno, M., Tanaka, K.; 1991; "Successive identification of a fuzzy model and its application to prediction of complex systems": Fuzzy Sets System, Vol. 42, pp. 315-334.
- [20] Sugeno, M.; 1985; "Industrial applications of fuzzy control", Elsevier Science Publication Company, pp. 214.
- [21] Takagi, T., Sugeno, M.; 1985; "Fuzzy identification of systems and its applications to modeling and control", IEEE Trans System Man Cybern, Vol. 15, No. 1, pp. 116-132.
- [22] Tahmasebi, P., Hezarkhani, A.; 2009; "Application of optimized neural network by genetic algorithm", IAMG09, California Stanford.
- [6] Bardossy, A., Bogardi, I., and Kelly, W.E.; 1988; "Imprecise (fuzzy) information in geostatistics", Mathematical Geology, Vol. 20, No. 4, pp. 287-311.
- [7] Bardossy, Gy, Fodor, J.; 2005; "Assessment of the completeness of mineral exploration by the application of fuzzy arithmetic and prior information", Acta Polytechnica Hung, Vol. 2, No. 1.
- [8] Tahmasebi, P., Hezarkhani, A. ; 2010; "Comparison of optimized neural network with fuzzy logic for ore grade estimation", Australian Journal of Basic and Applied Sciences, Vol. 4, No. 5, pp. 764-772.
- [9] Sola, J., Sevilla, J.; 1997; "Importance of input data normalization for the application of neural networks to complex industrial problems". Nuc Sciences IEEE Trans, Vol. 44, No. 3, pp. 1464 - 1468.
- [10] Yager, R.R., Zadeh, L.A.; 1994; "Fuzzy Sets Neural Networks and Soft Computing", Thomson Learning.
- [11] Carpenter, G.A., Grossberg, S. and Rosen D.S.; 1991; "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system", Neural Networks, Vol. 4, pp. 759-771.
- [12] Galatakis, M., Theodoridis, K., Kouridou, O.; 2002; "Lignite quality estimation using ANN and adaptive neuro-fuzzy inference systems (ANFIS)", APCOM, pp. 425-431.
- [13] Jang, J.S.R.; 1993; "ANFIS: adaptive-network-based fuzzy inference system", IEEE Trans on Sys, Man and Cybernetics, Vol. 23, No. 3, pp. 665-685.

¹⁵ Coactive Neuro-Fuzzy Inference System

¹⁶ Haipolid

¹ Singer
² John Holland
³ Global Optima
⁴ Reproduction
⁵ Recombination or crossover
⁶ Parents
⁷ Mutation
⁸ Fitness
⁹ Viability
¹⁰ Fertility
¹¹ Computing evolutionary
¹² Population
¹³ Individuals
¹⁴ Generation

