

دانشگاه صنعتی شاهرود
دانشکده معدن و ژئوفیزیک
گروه استخراج

سمینار کارشناسی ارشد

عنوان:

کاربرد شبکه های عصبی مصنوعی در مکانیک سنگ

استاد راهنما:

دکتر محمد عطائی

ارائه دهنده:

نیما نیّری

پاییز ۱۳۸۴

به نام خدا

تقدیم به:

پدر عزیزم

و مادر مهربانم

معلمان نخستین زندگیم

و تقدیم به آنانکه تلاش و همت را، بر گستره ای
از عشق و ایمان ره توشه ام ساختند و آموختند
فرزانه زیستن را.

اهمیت فاکتورهای مؤثر بر پایداری فضاهاى زیر زمینی به ما کمک کند. یک استفاده جالب از شبکه عصبی استفاده آن برای تصمیم گیری درباره نوع حوادث (زمین لرزه، آتشفبارى معدن و توده انباشته و واکنش‌های شیمیایی و غیره) با توجه به داده‌های زلزله شناسی است. کار مشابهی انجام یافته است که لرزش ناشی از معدن کارى توسط شبکه عصبی تخمین زده می شود.

علاوه بر موارد فوق و کاربردهایی که در این سمینار بیان شده است، شبکه عصبی مصنوعی در زمینه مکانیک سنگ و معدن در مسائلی مانند: انتخاب بهینه سرتمه های حفاری [۱]، ارزیابی مهندسی زمین شناسی [۲]، مدل کردن مقاومت بتن [۳]، سیستم مهندسی سنگ (RES) [۴]، پیش بینی نشست زمین بر اثر تونلسازی [۵]، پیش بینی میزان جابجایی شیب [۶]، مهندسی محیط زیست [۷]، پیش بینی نرخ نفوذ (TBM) [۸]، تخمین میزان ذخیره [۹]، تخمین خصوصیات مخزنی در مهندسی نفت [۱۰]، تخمین تخلخل سنگ از روی نگارهای چاه [۱۱] و تخمین نفوذپذیری سنگ مخزن [۱۲] و... کاربرد دارد.

فهرست مطالب

صفحه	عنوان
	فصل اول:
۲	۱-۱- مقدمه
۳	۲-۱- انگیزه های بیولوژیکی
۵	۳-۱- شبکه عصبی مصنوعی
۶	۱-۳-۱- وزنهای ارتباطی
۷	۴-۱- تشابهات و انتظارات
۷	۱-۴-۱- تشابهات
۸	۲-۴-۱- انتظارات
۸	۵-۱- تاریخچه شبکه های عصبی مصنوعی
۱۰	۶-۱- کاربرد شبکه های عصبی مصنوعی
۱۱	۷-۱- ساختار شبکه عصبی
۱۶	۸-۱- شبکه های پیشخور و پسخور
۱۶	۱-۸-۱- شبکه های پیشخور
۱۶	۲-۸-۱- شبکه های پسخور یا برگشتی
۱۷	۹-۱- دسته بندی شبکه ها براساس روش یادگیری
۱۷	۱-۹-۱- شبکه های دارای یادگیری با ناظر
۱۷	۲-۹-۱- شبکه های دارای یادگیری بدون ناظر
۱۷	۳-۹-۱- یادگیری تشدید (تقویتی)

۴۵ ۱۰-۲- تحلیل حساسیت و بحث در مورد آن

۵۰ ۱۱-۲- نتیجه گیری

فصل سوم:

۵۲ ۱-۳- خلاصه

۵۲ ۲-۳- مقدمه

۵۴ ۳-۳- آموزش شبکه عصبی و تصمیم گیری در مورد پارامترها

۵۶ ۴-۳- ارزیابی مدل شبکه عصبی

۶۰ ۵-۳- اثر مقاومت (استحکام) نسبی

۶۴ ۶-۳- نتیجه گیری

فصل چهارم:

۶۷ ۱-۴- خلاصه

۶۷ ۲-۴- مقدمه

۷۰ ۳-۴- مثال های عددی

۷۵ ۴-۴- مقایسه با مدل پیش بینی یکسان (یک شکل) برای معدن ذغال و لنجه

۸۳ ۵-۴- نتیجه گیری

فصل پنجم:

۸۵ ۱-۵- خلاصه

۸۵	۲-۵- طراحی دهانه
۸۶	۳-۵- گراف دهانه بحرانی لانگ
۸۸	۴-۵- طراحی دهانه ها با استفاده از شبکه عصبی مصنوعی
۸۹	۱-۴-۵- حفاری پایدار
۸۹	۲-۴-۵- حفاری دارای پتانسیل ناپایدار
۹۰	۳-۴-۵- حفاری ناپایدار
۹۰	۵-۵- پایگاه اطلاعات برای تحلیل توسط شبکه عصبی
۹۱	۶-۵- طراحی دهانه توسط شبکه عصبی مصنوعی
۹۴	۷-۵- خطای قابل قبول
۹۴	۸-۵- پارامترهای آموزش
۹۶	۹-۵- بحث در نتایج طراحی شبکه عصبی
۱۰۰	۱۰-۵- نتیجه
	فصل ششم:
۱۰۶	۱-۶- خلاصه
۱۰۶	۲-۶- مقدمه
۱۰۷	۳-۶- پیش زمینه
۱۱۰	۴-۶- روش کار
۱۱۲	۵-۶- آزمایشها
۱۱۲	۱-۵-۶- دستگاه های آزمایشی
۱۱۴	۶-۶- جمع آوری داده ها و پردازش

۱۱۶	۷-۶- آموزش و تست شبکه عصبی
۱۱۷	۸-۶- نتایج آزمایش
۱۲۱	۹-۶- کارهای آینده

فصل هفتم:

۱۲۳	۱-۷- خلاصه
۱۲۳	۲-۷- مقدمه
۱۲۴	۳-۷- پارامترهای طبقه بندی قابلیت آتشباری و شبکه عصبی
۱۲۴	۱-۳-۷- پارامترهای طبقه بندی قابلیت آتشباری توده سنگ
۱۲۵	۴-۷- طریقه محاسبه شبکه عصبی مصنوعی
۱۲۶	۵-۷- مثال و تست
۱۲۶	۱-۵-۷- داده‌های شبکه عصبی
۱۲۷	۶-۷- نتایج تست
۱۲۸	۷-۷- نتیجه گیری
۱۲۹	فهرست مطالب

فصل اول

مبانی شبکه‌های عصبی مصنوعی

۱-۱- مقدمه

در سالیان اخیر شاهد حرکت مستمر، از تحقیقات صرفاً تئوری به تحقیقات کاربردی به خصوص در زمینه پردازش اطلاعات، برای مسائلی که برای آنها راه حلی نیست و یا به راحتی قابل حل نیستند بوده ایم. با عنایت به این امر، علاقه فزاینده‌ای در توسعه تئوریک سیستم‌های دینامیکی هوشمند مدل آزاد^۱ که مبتنی بر داده‌های تجربی هستند-ایجاد شده است. شبکه‌های عصبی مصنوعی جز این دسته از سیستم‌های دینامیکی قرار دارند، که با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین خاطر به این سیستم‌ها هوشمند گویند، چرا که براساس محاسبات روی داده‌های عددی یا مثالها، قوانین کلی را فرا می‌گیرند [۱۳].

دیرزمانی است که بشر در پی یافتن روشی جهت شبیه‌سازی عملکرد مغز انسان در قالب یک سیستم مصنوعی می‌باشد. این امر سبب انجام پژوهش‌های بسیاری در این زمینه شده است، که شبکه‌های عصبی مصنوعی^۲، ماحصل آن می‌باشد.

کنجکاوی جهت مطلع شدن از نحوه عملکرد مغز انسان زمانی آغاز شد که دانشمندان دریافتند مغز برای انجام محاسبات خود، از ساختاری کاملاً مغایر با ساختار کامپیوترهای متداول، برخوردار است. مغز جهت پردازش اطلاعات از ساختاری کاملاً موازی استفاده می‌کند. این ساختار موازی باعث می‌شود که

^۱ = Model Free

^۲ = Artificial Neural Network

حجم عظیمی از داده‌های مختلف به طور همزمان دریافت و پردازش گردد و به این ترتیب اعمال پیچیده‌ای نظیر دیدن و شنیدن میسر می‌گردد [۱۴].

۱-۲- انگیزه‌های بیولوژیکی

تحقیقات و علاقه مندی به شبکه عصبی از زمانی شروع شد که مغز به عنوان یک سیستم دینامیکی با ساختار موازی و پردازشگری کاملاً مغایر با پردازشگرهای متداول شناخته شد. نگرش نوین در مورد کارکرد مغز نتیجه تفکراتی بود که در اوایل قرن بیستم توسط رامون سگال در مورد ساختار مغز به عنوان اجتماعی از اجزای محاسباتی کوچک به نام نرون شکل گرفت.


مغز به عنوان یک سیستم پردازش اطلاعات با ساختار موازی، از ۱۰۰ تریلیون (۱۰^{۱۱}) نرون به هم مرتبط با تعداد (۱۰^{۱۶}) ارتباط تشکیل شده است. نرونها ساده ترین واحد ساختاری سیستمهای عصبی هستند. بافتیایی که عصب نامیده می شوند، اجتماعی از نرونها هستند که اطلاعات و پیامها را از یک قسمت بدن به قسمت دیگر منتقل می کنند.

میلیونها نرون در بدن انسان وجود دارد، حتی ساده ترین کارهای روزمره انسان از قبیل پلک زدن، تنها از طریق همکاری همه جانبه این نرونها میسر است. گرچه همه نرونها کارکرد یکسانی دارند، ولی اندازه و شکل آنها بستگی به محل استقرارشان در سیستم عصبی دارد.

برای درک بهتر عملکرد سیستمهای هوشمند، بهتر است در ابتدا به توصیف عملکرد یک نرون بپردازیم. نرونها، اصلی ترین واحد ساختاری سیستمهای عصبی بیولوژیکی می باشند. هر نرون^۳ مطابق شکل (۱-۱) از یک بدنه (سوما^۴)، اکسون^۵ و گروهی از دندریتها^۶ تشکیل شده است. اکسون رشته باریک و بلندی است که به یک سری شاخه منتهی می شود که انتهای این شاخه‌ها به دندریتهای سلولهای دیگر

^۳=Neuron
^۴=Soma
^۵=Axon
^۶=Dendrites

وصل می‌شود. در واقع این تماس به صورت مستقیم نمی‌باشد، بلکه هر اکسون از دندریتهای سلولهای مجاور توسط فاصله کوچکی موسوم به سیناپس جدا می‌شود. انتقال اطلاعات توسط سیستم عصبی بیولوژیکی ناشی از یک فرآیند الکتروشیمیایی می‌باشد. سلول عصبی در حالت سکون دارای یک عدم توازن الکتریکی، در نتیجه پتانسیلی موسوم به پتانسیل سکون^۷ می‌باشد. چنانچه سلولی تحریک گردد، قطبهای سلول در محل تحریک موقتاً تغییر می‌کند. این تغییر ناگهانی، پتانسیل تحریک نامیده می‌شود که در طول اکسون منتشر می‌شود. البته نرونها دارای این خاصیت می‌باشند که پس از تحریک، دوباره به وضعیت سکون بر می‌گردند. این پالس در انتهای اکسون به سیناپسها برخورد می‌کند و باعث آزاد شدن مواد انتقال دهنده نرونی^۸ می‌شود. ماده شیمیایی آزاد شده، دارای ساختارهای ملکولی متفاوت می‌باشد که آزاد شدن آن باعث تحریک دریافت کننده‌های دندریت نرون دیگر می‌شود این تحریک به صورت تغییر پتانسیل محلی دندریتها بروز می‌کند که می‌تواند در جهت مثبت (محرک) یا منفی (بازدارنده) باشد. سیگنالهای ایجاد شده وارد بدنه نرون دیگر می‌شود و چنانچه مجموع آنها از مقدار آستانه نرون^۹ بیشتر باشد نرون فعال می‌شود در غیر این صورت، همان طور غیر فعال و آرام باقی می‌ماند.



شکل ۱-۱- نرون بیولوژیکی [۱۵]

^۷ =Resting

^۸ -Neurotransmitter

^۹ Thershold of the neuron

هر نرون دارای توانایی تطبیق‌پذیری می‌باشد. این تطبیق‌پذیری چیزی جز تقویت و تضعیف اتصالات سیناپسی نمی‌باشد. به عنوان مثال: فرآیند یادگیری چهره یک شخص جدید، شامل تغییرات مختلف سیناپسی می‌باشد. سیستم شبکه‌های عصبی بیولوژیکی دارای ساختاری کاملاً موازی می‌باشد که در آن تعداد زیادی واحدهای محاسباتی (نرونها) به طور مشترک، انجام فعالیت را بر عهده دارند، این تقسیم کار، پیامدهای مثبتی در پی دارد. چون تعداد زیادی نرون در یک زمان درگیر فعالیت هستند، سهم هر یک از نرونها، چندان حائز اهمیت نیست، بنابراین بروز مشکل در عملکرد یکی از آنها، تاثیر چندانی در نتیجه کار نخواهد داشت. توان انجام فعالیت در حالی که فقط تعدادی از نرونها به درستی کار می‌کنند را در علوم محاسباتی مقاوم بودن^{۱۰} یا تحمل‌پذیری خطا می‌گویند [۱۳ و ۱۴].

۳-۱- شبکه عصبی مصنوعی

دانشمندان با بررسی عملکرد شبکه عصبی بیولوژیکی و شناسایی ویژگیهای آن، سعی در پیاده کردن این ویژگیها در یک شبکه عصبی مصنوعی کردند. مهمترین ویژگیهای شبکه عصبی بیولوژیکی، عبارتند از:

۱- تشکیل شدن از واحدهای محاسباتی ساده به نام نرون

۲- تعیین عملکرد شبکه توسط اتصالات بین نرونها

۳- قابلیت یادگیری

۴- برخوردار بودن از ساختاری کاملاً موازی


شکل (۱-۲) یک نرون مصنوعی را نشان می‌دهد که مدلی از رفتار نرون بیولوژیکی می‌باشد. در مقایسه آن با نرون بیولوژیکی، وزنها (w) معادل سیناپسها می‌باشد، که در ورودیها ضرب شده و وارد

^{۱۰} - Robustness

بدنه نرون می‌شوند و در آن جا یک عمل جمع ساده روی آنها صورت می‌گیرد، با عبور نتیجه این جمع از یک تابع خطی یا غیر خطی، خروجی نرون تعیین می‌شود.

$$y_i = f(z_j) \quad (1-1)$$

که تابع فعالیت^{۱۱} یا محرک نامیده می‌شود. میزان فعالیت یک نرون را تعیین می‌کند. نرون شکل (۲-۱) موسوم به نرون مک کلوت - پیتس^{۱۲} می‌باشد که در آن از یک تابع آستانه‌ای باینری استفاده شده است [۱۴].



شکل ۲-۱ نرون مصنوعی

۱-۳-۱- وزنهای ارتباطی^{۱۳}

این وزن‌ها که در این جا، نقش سیناپسها را بازی می‌کنند، می‌توانند مثبت (محرک) و یا منفی (بازدارنده) باشند.

^{۱۱} - Activation function
^{۱۲} - Maccolloch-pitts
^{۱۳} - Connection Weight

شبکه‌های عصبی از اجتماع نرون‌ها تشکیل می‌شوند. وزن‌ها و توابع محرک، نحوه عملکرد شبکه را تعیین می‌کنند. برخی از شبکه‌ها دارای وزن‌های قابل تطبیق^{۱۴} می‌باشند که از قوانین فراگیری^{۱۵} جهت تطبیق دادن مقادیر وزنی استفاده می‌کنند. در نتیجه آنها دارای قابلیت یادگیری می‌باشند.

قابلیت یادگیری یعنی توانایی تنظیم پارامترهای شبکه (وزن‌های ارتباطی) وقتی که شبکه شرایط جدید را تجربه می‌کند. پس از آموزش شبکه توسط چند مثال، شبکه می‌تواند در مقابل یک ورودی آموزش داده نشده، پاسخ مناسب دهد. که به این امر قابلیت تعمیم^{۱۶} می‌گویند. این فرایند در واقع همان درونیایی^{۱۷} می‌باشد. به این صورت که شبکه، از طریق آموزش، رابطه تحلیلی مناسبی برای تعدادی نقطه در فضا بدست می‌آورد. در یک شبکه عصبی، رفتار کلی شبکه، برآیند رفتارهای محلی نرون‌های متعدد می‌باشد. این ویژگی باعث می‌شود تا نرون‌ها در یک روند همکاری، خطاهای محلی یکدیگر را تصحیح کنند که این امر باعث افزایش قابلیت مقاوم بودن (تحمل پذیری خطا) سیستم می‌شود [۱۴].

۱-۴- تشابهات و انتظارات

با توجه به مسائل فوق، می‌توان گفت که با تمام اغراقها در مورد شبکه‌های عصبی مصنوعی، این شبکه‌ها اصلا سعی در حفظ پیچیدگی مغز ندارد.

حال این موضوع را تحت دو عنوان تشابهات و انتظارات بررسی می‌کنیم.

۱-۴-۱- تشابهات

۱- بلوکهای ساختاری در هر دو شبکه بیولوژیکی و مصنوعی، دستگاه‌های محاسباتی خیلی ساده‌ای هستند و علاوه بر این، نرون‌های مصنوعی از سادگی بیشتری برخوردار می‌باشند.

۲- ارتباطهای بین نرون‌ها، عملکرد شبکه را تعیین می‌کند.

^{۱۴} - Adaptable weight

^{۱۵} - Learning laws

^{۱۶} - Generalization

^{۱۷} - Interpolation

این ویژگی‌ها عبارتند از:

۱- قابلیت یادگیری

۲- پردازش اطلاعات به صورت متن

۳- قابلیت تعمیم

۴- پردازش موازی

۵- مقاوم بودن [۱۳].

۱-۵- تاریخچه شبکه‌های عصبی مصنوعی

پیش زمینه‌های شبکه‌های عصبی مصنوعی به اواخر قرون نوزدهم و اوایل قرن بیستم بر میگردد. گامهای اولیه در این زمینه توسط روان‌شناسان مشهوری به نام ویلیام جیمز (۱۹۸۰) برداشته شد. در این دوره، کارهای اساسی در فیزیک، روانشناسی و نروفیزیولوژی^{۱۸} توسط علمایی چون هرمان فون هلمهولتز^{۱۹}، ارنست ماخ^{۲۰} و ایوان پاولف^{۲۱} صورت پذیرفت. این کارهای اولیه عموماً بر تئوری‌های کلی یادگیری، بینایی و شرطی تاکید داشته‌اند و اصلاً به مدل‌های مشخص ریاضی عملکرد نرونها اشاره‌ای نداشته‌اند.

وارن مک کلوت^{۲۲} و والتر پیتس^{۲۳} (۱۹۴۳) برای اولین بار عملکرد مغز را توسط روابط ریاضی نشان دادند. دونالد هب^{۲۴} این مسیر را ادامه داد و سرانجام فرانک روزنبلات^{۲۵} و همکارانش (۱۹۵۸) شبکه پرسپترون^{۲۶} را معرفی کردند که این شبکه قادر به شناسایی الگوها از یکدیگر بود. برنارد ویدرو^{۲۷} (۱۹۶۰)

^{۱۸}=Neuro-physiology

^{۱۹}=Helmholtz

^{۲۰}=Ernst Mach

^{۲۱}Ivan Pavlov

^{۲۲}=McCulloch

^{۲۳}=Walter Pitts

^{۲۴}=Donald Hebb

^{۲۵}=Frank Rosenblatt

^{۲۶}=Perceptron

طرح روزنبلات را توسعه دادند و شبکه آدالاین^{۲۸} با قانون فراگیری جدید را ارائه داد.

هر دوی این شبکه‌ها، پرسپترون و آدالاین، دارای این محدودیت بودند که توانایی طبقه بندی الگوهایی را داشتند که به طور خطی از هم متمایز می شدند. ویدرو و روزنبلانت هر دو از این امر آگاه بودند. آنها توانستند شبکه‌های چند لایه را مطرح نمایند، لکن نتوانستند الگوریتمهای یادگیری شبکه‌های تک لایه را بهبود بخشند.

کایانلو^{۲۹} (۱۹۶۱) شبکه‌ای را عرضه کرد که شامل داده‌های متغیر با زمان بود. تئوکوهونن^{۳۰} و جیمز اندرسون^{۳۱} (۱۹۷۲) شبکه‌های جدیدی را عرضه کردند که به عنوان عناصر ذخیره ساز عمل می‌کرد. در همین دهه استفان گروسبرگ^{۳۲} روی شبکه‌های عصبی خودساز مانده^{۳۳} کار کرد. فعالیت در زمینه شبکه‌های عصبی در دهه ۶۰ قرن بیستم در قیاس با دهه ۸۰- به علت عدم بروز ایده‌های جدید و نبود کامپیوترهای سریع جهت پیاده سازی- کم‌رنگ می نمود. جان هاپفیلد^{۳۴} (۱۹۸۲) شبکه‌های برگشتی (پسخور)^{۳۵} را معرفی کرد و دیوید راملهارت^{۳۶} و جیمز مک کلند^{۳۷} الگوریتم پس انتشار خطا^{۳۸} را ارائه دادند که تولدی دوباره برای شبکه‌های عصبی به شمار می‌رود.

در سالهای اخیر شبکه‌های عصبی در دو جهت تئوری و عملی توسعه بسیاری داشته است و این روند رشد در دوره‌هایی بسیار سریع و در دوره‌هایی کند بوده است و همچنان ادامه دارد. در طی این توسعه، ساختارها و روشهای یادگیری جدید ارائه می‌شود [۱۳ و ۱۴].

^{۲۷} =Bernurd Widrow

^{۲۸} =ADALINE

^{۲۹} =Caianello

^{۳۰} =Teo Kohonen

^{۳۱} =James Anderson

^{۳۲} =Stephan Grossberg

^{۳۳} =Self-Organize

^{۳۴} =John Hopfield

^{۳۵} =Feedback

^{۳۶} =David Ramelhart

^{۳۷} =James Meland

^{۳۸} =Back Propagation

۱-۶- کاربرد شبکه‌های عصبی مصنوعی

با عنایت به اینکه شبکه‌های عصبی از دو ویژگی اساسی یادگیری یا نگاشت پذیری بر اساس ارائه داده‌های تجربی (قدرت و توانایی تعمیم پذیری) و ساختار پذیری موازی برخوردار می‌باشند، این شبکه‌ها برای مسائل کنترل، علی‌الخصوص سیستم‌های پیچیده که مدلسازی این سیستمها یا میسر نیست و یا به سختی انجام می‌شود، بسیار مناسب است.

نخستین کاربرد شبکه‌های عصبی در کنترل سیستمها توسط ویدرو^{۳۹} در سال ۱۹۶۳ ارائه شده است. در خلال سالهای ۱۹۷۰ تا ۱۹۸۰ شبکه‌های عصبی برای کنترل بلادرنگ بازوهای ربات مورد استفاده قرار گرفت. در خلال سالهای ۱۹۸۰ تا ۱۹۹۰، بسیاری دیگر از شبکه‌های عصبی استاتیکی و دینامیکی و معماری IC آنها پیشنهاد و پیاده‌سازی شدند. در همین راستا یادگیری تشدید و روندهای نقادی تطبیقی همراه با کاربردهای صنعتی مطرح گشت و شبکه‌های برگشتی (با فیدبک) همراه با کاربردهای وسیعشان برای مسائل مدلسازی و تخمین پارامترهای سیستم توسعه یافتند.

در حال حاضر شبکه‌های عصبی به طور وسیع در زمینه‌های مختلف کاربرد دارند. بخشی از این کاربردها عبارتند از: کنترل کیفیت، مخابرات، کشف جرم، بازشناسی صدا و دست خط، مسائلی مالی، بیمه، امور حمل و نقل، ساخت وسایل صنعتی و پزشکی، مسایل امنیتی، مدیریت، صنایع شیمیایی، معادن وغیره. در دهه گذشته استفاده از شبکه‌های عصبی مصنوعی در زمینه معدن و مکانیک سنگ افزایش یافته است که چندین مورد از کاربردهای آن در این زمینه‌ها در فصلهای بعد آورده شده است.

به طور خلاصه می‌توان جمع بندی زیر را از کاربرد شبکه‌های عصبی بیان نمود:

(۱) طبقه بندی، شناسایی و تشخیص الگو

(۲) پردازش سیگنال

^{۳۹} =Widrow

(۳) پیش‌بینی سری‌های زمانی

(۴) مدل‌سازی و کنترل

(۵) بهینه‌سازی

(۶) سیستم‌های خبره و فازی

(۷) مسائل مالی، بیمه، امنیتی، بازار بورس و وسایل سرگرم‌کننده

(۸) ساخت وسایل صنعتی، پزشکی و امور حمل و نقل

آنچه که شبکه‌های عصبی را در آینده محبوب‌تر خواهد نمود، سرعت بالای کامپیوترها و الگوریتم‌های یادگیری سریع‌تر می‌باشد که استفاده از شبکه‌های عصبی را در مسائل صنعتی با محاسبات زیاد یاری می‌نماید [۱۳].

۱-۷- ساختار شبکه عصبی

تمام شبکه‌های عصبی حداقل در سه مولفه اصلی مشترک هستند.

۱- نرون یا گره یا واحد پردازش^{۴۰} (PE)

۲- وزنهای ارتباطی

۳- لایه‌های مجزایی که شامل نرون‌ها هستند و توسط وزن‌ها به هم مرتبط می‌شوند.

نرون‌ها به عنوان واحدهای محاسباتی پایه، اساس عملکرد شبکه‌ها را تشکیل می‌دهند. شکل (۱-۳)

نرونی را با چند ورودی نشان می‌دهد. حاصل ضرب بردار ورودی (P) و ماتریس وزنی (W) و جمع آن با

جمله بایاس^{۴۱} (b) تشکیل ورودی خالص^{۴۲} (n) را برای تابع محرک (f) می‌دهد. خروجی تابع محرک،

میزان فعالیت نرون را مشخص می‌کند.

^{۴۰}=Processing Element

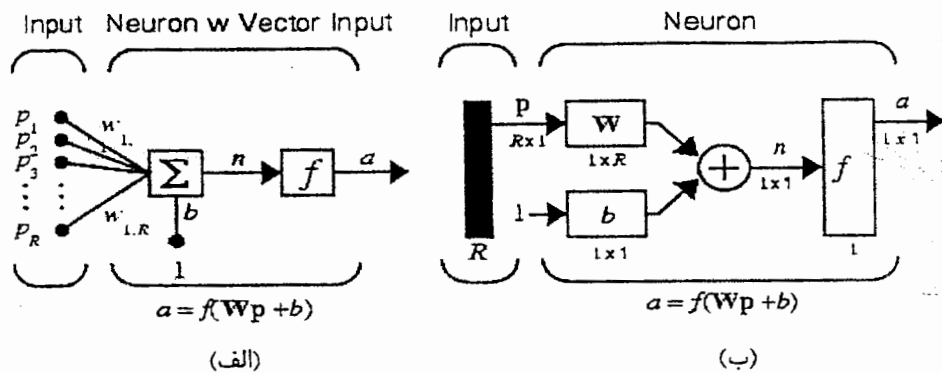
^{۴۱}=bias

^{۴۲}=Net input

$$n = \sum_{i=1}^R P_i W_{i1} + b = W.P + b, \quad act_1 = f_1(n)$$

$$P = [P_1, P_2, \dots, P_R]^T, \quad W = [W_{11}, W_{12}, \dots, W_{1R}] \quad (2-1)$$

(P_i) مولفه‌های بردار ورودی و (W_{ii}) مولفه‌های ماتریس وزن و (act_1) میزان فعالیت اولین نرون را نشان می‌دهند. لازم به ذکر است که اندیس اول در نمایش ماتریسی وزن به شماره خود نرون و اندیس دوم به مبدا سیگنال ورودی اشاره می‌کند. در این حالت چون تنها یک نرون داریم، ماتریس وزن W ، یک بردار سطری می‌باشد. بنابراین، ستونهای ماتریس وزن بیانگر تعداد ورودیها به یک نرون و سطرهاى آن بیانگر تعداد نروها می‌باشد. در واقع ستونها و سطرها به ترتیب ابتدا و انتهای یک خط ارتباطی را مشخص می‌کنند [۱۴].



شکل (۳-۱) الف: مدل یک نرون با چند ورودی ب: فرم خلاصه شده نرون با چند ورودی [۱۴]

در مورد عملکرد شبکه، جمع وزنی ورودی‌ها به هنگام عبور از تابع محرک با آستانه تابع مقایسه می‌شود، چنانچه این جمع وزنی از مقدار آستانه فراتر رود، نرون فعال می‌شود و اصطلاحاً "آتش" می‌کند و چنانچه این مقدار کمتر از آستانه باشد، نرون غیر فعال باقی می‌ماند و یا اصطلاحاً "آتش" نمی‌کند.

$$Sum_j = \sum_{i=1}^n w_{ji} p_i \quad (3-1)$$

(Sum_j) مجموع وزنی ورودی به زامین نرون می باشد.

$$act_j = f(sum_j) = \quad (4-1)$$

T مقدار آستانه تابع محرک و act_j میزان فعالیت زامین نرون می باشد.

با توجه به مساله وزن ها و مقدار آستانه به گونه ای محاسبه می شود و تغییر می یابد تا هدف مساله تامین گردد. معمولاً مقدار آستانه به سمت چپ رابطه انتقال می یابد و در واقع سطح آستانه صفر در نظر گرفته می شود.

$$act_j = f(sum_j) = \quad (5-1)$$

رابطه فوق را می توان به این صورت هم نوشت.

$$Sum_j = \sum_{i=1}^n w_{ji} p_i + w_{jb} \quad (6-1)$$

مقدار آستانه (T) را می توان به عنوان یک عنصر ورودی با مقدار ثابت $P_b = 1$ در نظر گرفت که وزن متناظر با آن (w_{jb}) معادل با منفی مقدار آستانه قرار می گیرد.

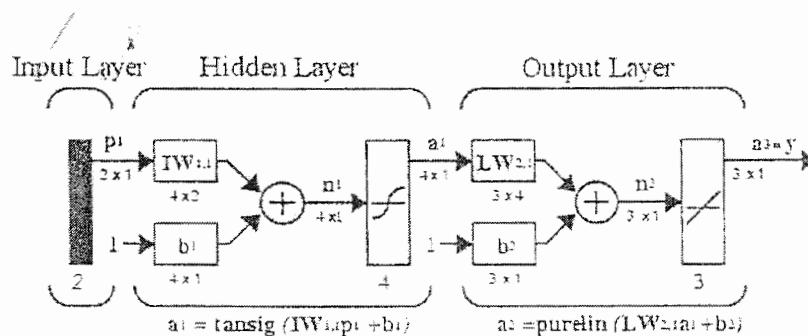
$$w_{jb} = -T \quad (7-1)$$

این مقدار بیان کننده مقدار بایاس می باشد.

$$b = w_{jb} P_b \quad (8-1)$$

در واقع مقدار خروجی یک نرون بستگی به جمع وزنی دارد. ممکن است که این جمع در یک قسمت بهینه منحنی تابع محرک نیفتد، بنابراین جهت اطمینان از این امر جمله بایاس، برای جابه‌جا کردن آستانه به چپ و راست در طول منحنی به این جمع اضافه می‌شود.

شبکه‌ها می‌توانند تک لایه و یا چند لایه (شکل ۴-۱) باشند. هر لایه شامل ماتریس وزن، جمع‌کننده‌ها، بردار بایاس، و تابع محرک می‌باشد. بردار ورودی (P) را می‌توان با عنوان لایه ورودی نام برد. این لایه را می‌توان شامل ماتریس W معادل با ماتریس واحد، بایاس صفر و تابع محرک خطی ($f(n) = n$) در نظر گرفت. در این وضعیت تعداد نرون‌های لایه ورودی برابر با تعداد عناصر بردار ورودی می‌باشد. لایه‌ای که خروجی آن خروجی نهایی شبکه است، لایه خروجی می‌نامند. تمامی لایه‌هایی که بین لایه ورودی و لایه خروجی قرار می‌گیرند، لایه پنهان نامیده می‌شوند. لازم به ذکر است که لایه‌های مختلف می‌توانند توابع محرک متفاوت داشته باشند.



شکل ۴-۱- شبکه چند لایه‌ای (اصلاح شده از راهنمای نرم افزار Matlab ۲۰۰۲) [۱۴]

شبکه باید این اختلاف را جبران کند. بهترین روش استفاده از تعریف خطای میانگین مربعات اصلاح شده به صورت زیر می‌باشد.

$$e_p = \frac{1}{2} \sum_{k=1}^L (d_{pk} - o_{pk})^2 \quad (9-1)$$

خطای e_p برای P امین الگو به صورت مربع اختلاف بین خروجی محاسبه شده توسط شبکه O_{pk} و خروجی مطلوب d_{pk} می باشد. هدف از آموزش شبکه به حداقل رساندن مقدار تابع خطا با تغییر در وزن ها به صورت زیر می باشد. برای سهولت کار علامت منفی مشتق ها حذف شده است.

$$\frac{\partial e_p}{\partial w_{kj}} = \frac{\partial e_p}{\partial Sum_{pk}} \frac{\partial Sum_{pk}}{\partial w_{kj}} \quad (10-1)$$

$$\frac{\partial Sum_{pk}}{\partial w_{kj}} = \frac{\partial}{\partial w_{kj}} \sum_j w_{kj} act_{pj} = act_{pj} \quad (11-1)$$

متغیر جدیدی به صورت زیر تعریف می شود.

$$\delta_{pk} = \frac{\partial e_p}{\partial Sum_{pk}} \quad (12-1)$$

با این متغیر جدید رابطه (10-1) به صورت زیر تبدیل می شود.

$$\frac{\partial e_p}{\partial w_{kj}} = \delta_{pk} act_{pj} \quad (13-1)$$

معادله (12-1) را می توان به صورت زیر بازنویسی نمود.

$$\frac{\partial e_p}{\partial Sum_{pk}} = \frac{\partial e_p}{\partial o_{pk}} \frac{\partial o_{pk}}{\partial Sum_{pk}} \quad (14-1)$$

$$\frac{\partial o_{pk}}{\partial Sum_{pk}} = \dot{f}_k (Sum_{pk}) \quad (15-1)$$

و همچنین

$$\frac{\partial e_p}{\partial o_{pk}} = (d_{pk} - o_{pk}) \quad (16-1)$$

با جایگذاری معادلات (15-1) و (16-1) در (12-1) معادله زیر حاصل می شود.

$$\delta_{pk} = (d_{pk} - o_{pk}) \dot{f}_k (Sum_{pk}) \quad (17-1)$$

جهت تصحیح وزن ها در خطوط ارتباطی بین لایه خروجی و لایه پنهان از رابطه حاصل از معادله فوق استفاده می شود [۱۴].

۸-۱- شبکه های پیشخور و پسخور


شبکه ها به صورت های مختلف دسته بندی می شوند. یکی از انواع این دسته بندی ها بر طبق جهت شارش اطلاعات می باشد که بر این اساس دو نوع شبکه وجود دارد.

۱-۸-۱- شبکه های پیشخور

در این شبکه ها، نرون ها، ورودی خود را تنها از لایه قبلی دریافت می کنند و خروجی خود را تنها به لایه بعدی منتقل می کنند. شکل (۴-۱) یک شبکه پیشخور را نشان می دهد.

۱-۸-۲- شبکه های پسخور یا برگشتی

مطابق شکل (۵-۱) در شبکه های پسخور حد اقل، خروجی یک نرون، به عنوان ورودی همان نرون یا نرون های همان لایه و یا لایه قبل استفاده می شود [۱۴].



شکل ۱-۵- شبکه پسخور یا برگشتی [۱۴]

۱-۹-دسته بندی شبکه ها براساس روش یادگیری

به پروسه یادگیری نیاز است، چون اطلاعات (ارتباط بین ورودی و خروجی) کاملاً مشخص نیستند. نوع دیگری از تقسیم بندی شبکه ها براساس نحوه یادگیری می باشد. بر این اساس شبکه ها به سه دسته تقسیم می شوند.

۱-۹-۱- شبکه های دارای یادگیری با ناظر^{۴۳}

در یادگیری با ناظر فرض بر این است که در هر مرحله از تکرار الگوریتم یادگیری جواب مطلوب سیستم یادگیرنده از قبل آماده است و به عبارتی الگوریتم یادگیری به جواب واقعی و مطلوب دسترسی دارد. در این روش یادگیری، الگوهای خروجی مطلوب با خروجی محاسبه شده توسط شبکه با عنوان خروجی واقعی^{۴۴}، مقایسه می شود و اختلاف بین آنها می بایست با تغییر پارامترهای شبکه (وزن و بایاس) جبران شود. نحوه تغییر پارامترهای شبکه توسط نوع الگوریتم آموزشی^{۴۵}، تعیین می گردد.

۱-۹-۲- شبکه های دارای یادگیری بدون ناظر^{۴۶}

در یادگیری بدون ناظر جواب مطلوب برای سیستم یادگیرنده موجود نیست. به عبارتی به خطای یادگیری جهت بهبود رفتار سیستم یادگیرنده دسترسی نداریم. چگونگی ارتباط بین نرون ها اعم از ارتباط داخلی بین نرون های یک لایه با نرونهای لایه های مختلف و نحوه یادگیری، نوع شبکه را مشخص می کند. به یادگیری بدون ناظر خود یادگیری^{۴۷} هم گویند.

^{۴۳} =Supervised Learning

^{۴۴} =Actual Output

^{۴۵} =Learning Algorithm

^{۴۶} =Unsupervised Learning

^{۴۷} =Self-Learning

باید توجه داشته باشیم که در این حالت فرد طراح یا معلم است که هدف و مقصد نهایی، یعنی چیزی را که باید به آن رسید مشخص می‌کند و به عبارتی یادگیری بدون معلم مفهوم نادرستی است که عموماً به جای یادگیری بدون ناظر مورد استفاده قرار می‌گیرد.

۱-۹-۳- یادگیری تشدید (تقویتی)^{۴۸}

یک اشکال یادگیری با ناظر این است که شبکه عصبی ممکن است بدون معلم نتواند مواضع جدیدی را که توسط مجموعه داده‌های جدید تجربی پوشانده نشده است یاد بگیرد. یادگیری از نوع تشدید این محدودیت را برطرف می‌کند. این نوع یادگیری به طور صورت On-line می‌گیرد، در حالی که یادگیری با ناظر را به دو صورت On-line و Off-line می‌توان انجام داد. در حالت Off-line می‌توان از یک سیستم محاسبات با در اختیار داشتن داده‌های یادگیری استفاده نمود و طراحی شبکه عصبی را به انجام رساند. پس از مرحله یادگیری و طراحی، شبکه عصبی به عنوان یک سیستم استاتیکی عمل می‌کند. اما در یادگیری On-line، شبکه عصبی همراه با خود سیستم یادگیر در حال انجام کار است و از این رو مثل یک سیستم دینامیکی عمل می‌کند.

بنابر این این الگوریتم نوعی از یادگیری با ناظر است که در آن به جای فراهم نمودن جواب واقعی، به شبکه عددی که نشانگر میزان عملکرد شبکه است ارائه می‌شود. این بدین معنی است که اگر شبکه عصبی پارامترهایش را به گونه‌ای تغییر داد که منجر به یک حالت مساعد شد، آنگاه تمایل سیستم یادگیر جهت تولید آن عمل خاص تقویت یا تشدید می‌شود، در غیر این صورت تمایل شبکه عصبی جهت تولید آن عمل خاص تضعیف می‌شود [۱۳].

۱-۱۰-۱- پارامترهای شبکه

پارامترهای زیر اثر مستقیم در نحوه عملکرد شبکه دارد. کاربر می‌تواند این پارامترها را کنترل کند.

^{۴۸} = Reinforcement Learning

۱- تعداد لایه‌ها

۲- تعداد نرونهای لایه پنهان

۳- تابع محرک

۴- مقدار دهی اولیه به وزنها و بایاس

۵- نرخ یادگیری و گشتاور^{۴۹}

۱-۱۰-۱- تعداد لایه‌ها

بیشاپ^{۵۰} (۱۹۹۵) نشان داد که یک شبکه با یک لایه پنهان که از تابع محرک سیگموئیدی استفاده می‌کند قادر به تقریب هر تابع پیوسته با تعداد معینی نرونی در لایه پنهان می‌باشد. لایه بیشتر تحقیقات نشان می‌دهد که یک لایه پنهان کافی است اما در بسیاری مواقع ممکن است اضافه کردن یک لایه پنهان دیگر باعث افزایش دقت و کاهش زمان یادگیری شود.

۱-۱۰-۲- تعداد نرونهای پنهان

تعداد نرونهای لایه پنهان، نقش بسیار مهمی در میزان دقت شبکه بازی می‌کند. بنابراین یافتن تعداد مناسب، اهمیت بسیاری دارد. محققین تلاشهای بسیاری در زمینه یافتن روشی برای انتخاب بهینه تعداد نرونهای لایه پنهان نمودند. برخی از آنها واسطه هندسی نرونهای ورودی و خروجی را به عنوان یک تعیین کننده خوب از تعداد نرونهای لایه پنهان در شبکه‌هایی که تعداد نرونهای خروجی در آنها کمتر از ورودی می‌باشد، پیشنهاد کردند. هخت - نیلسون^{۵۱} (۱۹۸۷) بیان کردند که برای شبکه‌ای با یک لایه پنهان، تعداد $(n+1)$ نرون در این لایه نیاز است که (n) تعداد نرونهای ورودی می‌باشد. اما هیچ یک از این

^{۴۹} - Momentum

^{۵۰} - Bishop

^{۵۱} - Hecht and Nielsen

پیشنهادات در مورد مسائل مختلف عمومیت ندارد و تعداد بهینه نرونهای لایه پنهان تنها از طریق آزمون و خطا قابل حصول می‌باشد.

۱-۱۰-۳- انتخاب نوع تابع محرک


در شبکه پس انتشار خطا، هر تابع مشتق‌پذیر و پیوسته‌ای که به طور یکنواخت افزایش یابد، می‌تواند به عنوان تابع محرک استفاده شود. معمولترین این توابع، سیگموئیدی، تانژانت هیپربولیک و خطی می‌باشند. انتخاب نوع تابع محرک به هدف مساله بستگی دارد. چنانچه شبکه یک مساله دسته‌بندی را حل می‌کند، بهتر است از تابع سیگموئیدی یا تانژانت هیپربولیک در لایه خروجی استفاده شود. اگر هدف از حل مساله، تخمین تابع می‌باشد بهتر است از تابع محرک غیر خطی مانند سیگموئیدی برای نرونهای لایه پنهان و از تابع خطی برای لایه خروجی استفاده شود. خطی بودن تابع لایه خروجی اجازه می‌دهد تا شبکه مقادیر خارج از یک گستره محدود را هم تولید کند.

۱-۱۰-۴- مقدار دهی اولیه وزنها و با یاس

انتخاب مقدار اولیه مناسب برای وزنها و با یاسها بسیار مهم است. چنانچه این وزنها خیلی بزرگ انتخاب شوند، توابع محرک سیگموئیدی سریعاً اشباع خواهند شد و احتمال گرفتار شدن شبکه در یک کمینه محلی^{۵۲} افزایش می‌یابد (شکل ۶-۱). با یک انتخاب صحیح برای مقادیر اولیه وزنها، می‌توان سرعت و دقت را در شبکه افزایش داد. بهتر است این انتخاب به گونه‌ای باشد تا ورودی خالص به زامین نرون لایه پنهان کمتر از البته نه خیلی کمتر از یک شود. این امر در صورتی محقق می‌شود که وزنها از رتبه $\frac{1}{K_j}$ باشند که K_j تعداد نرونهای ورودی است که زامین نرون لایه پنهان را تغذیه می‌کند. مقدار

^{۵۲} - Local minimum

مناسب اولیه برای بایاس و وزنها با آزمون و خطا حاصل می‌شود. مقدار بایاس اولیه برای لایه‌های مختلف می‌تواند متفاوت باشد. حضور بایاس باعث افزایش سرعت همگرایی در شبکه می‌شود.



شکل ۱-۶- کمینه های محلی و سراسری [۱۴]

۱-۱۰-۵- نرخ یادگیری و گشتاور

این دو کمیت میزان تغییر وزنها را کنترل می‌کند. انتخاب نرخ یادگیری بسیار مهم است و اندازه گامها را در راستای حصول به حداقل خطا تنظیم می‌کند. زمانی که تابع خطا نسبتاً تخت می‌باشد استفاده از نرخ آموزشی بزرگتر سودمند است. استفاده از نرخ آموزشی کوچک باعث طولانی‌تر شدن زمان همگرایی می‌شود. در روشهای آموزشی سریعتر که با اعمال تغییراتی در الگوریتم پس انتشار خطا حاصل شده است، نرخ یادگیری ثابت نیست و در خلال آموزش تغییر می‌کند.

گاهی اوقات شبکه به یک وضعیت پایدار دست می‌یابد ولی خروجی درستی ارائه نمی‌دهد. در واقع شبکه در یک کمینه محلی به تله افتاده است. جهت رهایی از این کمینه محلی و سوق به سمت کمینه سراسری^{۵۳} اضافه کردن کسری از تغییر وزن مرحله قبلی به عنوان گشتاور به معادله تنظیم ضرایب

^{۵۳} - Global Minimum

وزنی، سرعت همگرایی را نیز افزایش می‌دهد و احتمال گیر افتادن شبکه را در کمینه‌های محلی کاهش می‌دهد. گشتاور یک عدد ثابت مثبت $0 < \beta < 1$ می‌باشد اما این کمیت در در برخی از الگوریتم‌های آموزشی سریعتر متغیر، نسبت به زمان تعریف می‌شود.

$$w_{ji}(t+1) = w_{ji}(t) + \alpha \delta_{pj} x_{pi} + (\beta(w_{ji}(t) - w_{ji}(t-1))) \quad (18-1)$$

α : نرخ یادگیری

β : گشتاور

یک نرخ یادگیری کوچک می‌تواند با یک گشتاور بزرگتر جهت تسریع همگرایی استفاده شود و یک نرخ یادگیری بزرگتر معمولاً با یک گشتاور کوچکتر جهت اطمینان از پایداری شبکه می‌تواند همراه شود. مقادیر گشتاور و نرخ یادگیری اغلب توسط آزمون و خطا، انتخاب می‌شوند.

۱۱-۱- پیش پردازش و پس پردازش^{۵۴} داده‌ها

جهت افزایش کارایی شبکه غالباً از پیش و پس پردازش داده‌ها استفاده می‌شود. توابع محرک مورد استفاده در اغلب شبکه‌ها نیاز به قرار گرفتن ورودی‌هایشان در یک گستره محدود دارند. این توابع معمولاً در مقادیر کوچک و بزرگ مسطح می‌شوند و در دنباله‌هایشان دیگر به تغییر مقادیر ورودی حساس نیستند. به کار بردن روشهایی برای قرار دادن داده‌های ورودی در یک گستره محدوده مثلاً [۱-۱] نرمالیزه کردن مقادیر یا دوباره مقیاس‌بندی کردن می‌نامند که یکی از روشهای پیش پردازش می‌باشد. این عمل روشهای مختلفی دارد که به عنوان می‌توان تقسیم مقادیر به بزرگ‌ترین عدد آنها، تقسیم به نرم مقادیر ورودی اشاره کرد.

داده‌های ارائه شده به نرونهای ورودی ممکن است بر اساس نوع اندازه گیری دارای مقادیر بسیار متفاوت باشند و چنانچه آنها در یک گستره محدود قرار نگیرند امکان دارد که شبکه نسبت به مقادیر

^{۵۴} - Pre-Post processing

داده‌های یکی از نرون‌های ورودی حساستر شود حتی اگر بزرگی این مقادیر مربوط به واحد اندازه‌گیری باشد. از دیگر مزایای قرار دادن ورودیها در یک گستره محدود، جلوگیری از رشد زیاد وزن‌ها می‌باشد. این محدودیت، مدت زمان همگرایی شبکه و حصول کمینه خطا را کاهش می‌دهد.

داده‌های خروجی نیز غالباً جهت آموزش دادن به شبکه نرمالیزه می‌شوند و قبل از آنالیز نتایج به واحدهای اصلی برگردانده می‌شوند. متعاقباً وقتی خروجی‌ها به واحدهای قبلی برگردانده می‌شود خطا نیز افزایش خواهد یافت به ویژه وقتی که از مقیاس لگاریتمی برای آموزش استفاده می‌شود [۱۴].

۱-۱۲- تعمیم (عمومی سازی) شبکه

یکی از مواردی که در آموزش شبکه با آن مواجه می‌شویم. این است که چه وقت آموزش شبکه باید متوقف شود ممکن است ایده توقف آموزش وقتی که شبکه به یک کمینه محلی، دست یافت یا بعد از تعداد تکرارهای معین، خوب به نظر آید. اما گمن^{۵۵} و همکارانش (۱۹۹۲) نشان دادند که این مساله باعث می‌شود توزیع وزنی بدست آمده تنها روی نمونه‌های آموزشی به خوبی پاسخ می‌دهد اما وقتی نمونه‌های جدید به شبکه ارائه می‌شود، میزان خطا برای آنها افزایش می‌یابد. با روشهای تعمیم این معضل حل خواهد شد به منظور تعمیم شبکه سریهای آموزش به سه زیرشاخه تقسیم می‌شوند.

اولین زیرشاخه شامل سریهای آموزشی می‌باشد که جهت محاسبه خطا و تغییر وزن‌ها در شبکه استفاده می‌شود. دومین زیرشاخه تحت عنوان سری اعتبار سنجی از داده‌هایی استفاده می‌کند که در فرآیند آموزش استفاده نمی‌شود. این سری به عنوان سری مرجع استفاده می‌شود. وقتی که خطا برای سری مرجع برگردانده می‌شود، زیر شاخه سوم تحت عنوان سری تست اغلب متمایز از سری اعتبار سنجی^{۵۶} می‌باشد، این سری در آموزش استفاده نمی‌شود و تنها به عنوان معیاری برای مشخص کردن عملکرد شبکه می‌باشد، سری با توزیع وزنی تعیین شده می‌بایست به کمینه خطا دست یابد. در طی

^{۵۵} - Geman

^{۵۶} - Validation

فرآیندهای تست و اعتبار سنجی وزنها تغییر نمی‌کنند و این داده‌ها تنها یکبار طول شبکه را طی می‌کنند.

از مسائلی که تاثیر فراوان روی عملکرد بهینه شبکه دارد نحوه ارائه داده‌های ورودی و خروجی به شبکه و تعداد نمونه‌های تعمیم و آموزشی می‌باشد. به طور ایده آل در یک شبکه تعداد نمونه‌های آموزشی باید بیشتر از وزنه‌های ارتباطی باشد. بنابراین بردار ورودی بزرگتر، وزنه‌های ارتباطی بیشتر و نمونه‌های آموزشی بیشتری نیاز دارد. به پیشنهاد پولتون^{۵۷}، بهتر است نمونه‌های آموزش تقریباً ۱۰ برابر تعداد وزنها در شبکه باشد. باوم و هسلر^{۵۸} (۱۹۸۲) تعداد نمونه‌ها را برای نرونهای خطی با توجه به سطح دقت مطلوب تعیین کردند.

$$D = (1 - e)$$

که e مقدار خطای مطلوب شبکه می‌باشد. تعداد نمونه‌های آموزشی می‌تواند به صورت زیر محاسبه شود.

$$W/e = \text{تعداد نمونه‌ها}$$

W تعداد وزنه‌های ارتباطی در شبکه می‌باشد. این امر باعث می‌شود که نحوه ارائه بردارهای ورودی مورد توجه قرار گیرد. کاهش اندازه^{۵۹} این بردارها می‌تواند اثر بسیار مهمی روی دقت شبکه داشته باشد. البته چنانچه این کاهش به قیمت از دست دادن اطلاعات زیادی باشد، به جای افزایش دقت، کاهش دقت را در پی خواهد داشت. بنابراین موفقیت شبکه به درک ما از داده‌ها و نحوه ارائه آنها به شبکه با فشرده‌ترین حالت و هنوز غنی از اطلاعات بستگی دارد. اما چه تعداد از نمونه‌ها باید برای آموزش و چه تعداد برای تعمیم استفاده شوند. سولی^{۶۰} و همکاران (۱۹۸۷) دریافتند که چنانچه شبکه روی حدود ۳/۵ از الگوهای ورودی آموزش ببیند می‌تواند با موفقیت تعمیم را روی داده‌های باقی مانده انجام دهد [۱۴].

^{۵۷} - Poulton

^{۵۸} - Baum and Haussler

^{۵۹} - Size Reduction

^{۶۰} - Soulie

۱-۱۳- معایب شبکه‌های عصبی

علی‌رغم تمام مزایای جالب توجه شبکه عصبی، اشکالاتی نیز به این شبکه‌ها وارد است، که می‌توان به موارد زیر اشاره نمود:

۱- به طور کلی، شبکه‌های عصبی مصنوعی در درون یابی عملکرد خوبی دارند ولی دربرون یابی چندان قوی نیستند. آنها می‌توانند الگوهایی را که قبلاً دیده‌اند تشخیص دهند و الگوهای میانی را نیز که ندیده‌اند، در حیطه توانایی خود قرار دهند. ولی الگوهایی را که خارج از گستره الگوهای آموزش داده اولیه شبکه هستند را نمی‌توانند به خوبی طبقه‌بندی کنند، زیرا نمونه‌های چندانی را برای مقایسه در اختیار ندارند. به عبارت دیگر، اگر الگوهای تازه‌ای بین دو الگوی آشنا قرار گرفته باشند، شبکه آنها را به عنوان نمونه‌ای از الگوهای مهم‌تر، طبقه‌بندی می‌کند ولیکن چنانچه الگوهای جدید با هیچکدام از الگوهای قبلی که شبکه دیده‌است شباهت نداشته باشد، طبقه‌بندی به خوبی انجام نمی‌گیرد.

۲- هر چه حجم داده‌های آموزشی افزایش یابد، زمان آموزش شبکه نیز افزایش می‌یابد. علاوه بر این انتخاب داده‌های آموزشی مناسب، تاثیر مستقیم بر راندمان آموزشی شبکه دارد.

۳- تاکنون روش مشخصی برای تعیین ساختار بهینه شبکه، معرفی نشده است. به همین دلیل باید از روشهای سعی و خطا برای یافتن ساختار بهینه استفاده کرد [۱۶].

فصل دوم

تحلیل پایداری سیستم نگهداری تونل با استفاده از

شبکه عصبی مصنوعی

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

۲-۱- خلاصه

در این مبحث پایداری نگهداری تونل با استفاده از شبکه عصبی مصنوعی (ANN) پیش بینی شده است. داده ها از یک تونل راه آهن که جدیداً در تایوان به پایان رسیده است، برداشت شده است. در این منطقه نوع سنگ رسوبی است. برای آموزش و تست کردن شبکه پارامترهای مکانیک سنگی و ساختاری موثر بر پایداری نگهداری شبکه انتخاب شده است. همچنین برای نشان دادن اینکه ANN یک تحلیل تفکیک کننده را اجرا می کند یا نه، اعتبار سنجی انجام می شود و یک رگرسیون غیر خطی برای حالت پایداری نگهداری تونل به کار رفته است.

۲-۲- مقدمه

اطلاعات نقش اساسی را در مدیریت دوره زندگی پروژه ایفا می کنند. اطلاعات منبع اساسی و با ارزشی برای برنامه ریزی، طراحی، اجرا و کنترل کار می باشد. به دلیل نقش مهم اطلاعات، مطالعات زیادی بر روی مدل کردن اطلاعات معماری، مهندسی و ساخت انجام می شود. این مطالعات در ابتدا بر روی تولید و پردازش اطلاعات به منظور یک شکل کردن آن متمرکز می شود. هدف اصلی این کار ایجاد مکانیسم مدیریت موثر داده ها برای ذخیره کردن و اداره کردن تعداد زیادی از داده های تولید شده در طول عمر پروژه است. علاوه بر، مدیریت موثر اطلاعات، برای مدیریت برنده مفید است که اطلاعات با ارزش را از اطلاعات خام استخراج کند تا در شرایط بحرانی تصمیم گیری کند.

Datamining، به عنوان یک تکنولوژی اطلاعات رایج در به دست آوردن اطلاعات معتبر و نامعلوم از پایگاه های اطلاعاتی بزرگ به ما کمک می کند. این مقاله کاربرد تکنیک Datamining، شبکه

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

عصبی، جهت تعیین شرایط پایداری سیستم نگهداری تونل‌های سنگی با توجه به فاکتورهای مکانیک سنگی و فاکتورهای مربوط به اجرا را، شرح می‌دهد. این مطالعه توانایی Datamining را در دادن دیدگاهی برای انجام پروژه‌های جدید نشان می‌دهد در حالی که، در فنون رایج با موفقیت همراه نیستند.

در حال حاضر در کشور تایوان تعداد زیادی تونل در محیط سنگی در حال ساخته شدن است. روش اصلی که در تونل سازی در تایوان مورد استفاده قرار می‌گیرد، ناتم است. هدف اصلی NATM تعیین کردن و کنترل توسعه تنشهای سنگ و انحراف آن و اندر کنش آن با نگهداری و آستر بتنی و در نهایت تحمل بار به وسیله سنگهای اطراف است. سه روش مهم برای طراحی NATM وجود دارد: روش‌های تجربی، روش‌های مشاهده‌ای، روش‌های تحلیلی.

هر چند کاربرد این سه روش بستگی به محدودیت‌های مربوط به پیچیدگی سازندهای سنگی و پروسه ساختن تونل دارد.

طراحی بهینه سیستم نگهداری تونل را هنوز به دلیل کامل نبودن اطلاعات مکانیک سنگی و تاثیر روش اجرا روی پایداری سیستم نگهداری تونل نمی‌توان انجام داد. اخیراً، روشهای تحلیلی، مانند روش تحلیلی مکانیک سنگ برای تحلیل رفتار متقابل سنگ و سیستم نگهداری تحت شرایط مختلف سنگ و روشهای اجرای مختلف مورد استفاده قرار گرفته است. هرچند، در طی ساخت یک تونل سنگی، متغیرهای زیادی (مانند نوع سنگ، مقاومت سنگ، درزه‌ها و دیگر ناپیوستگی‌ها، تنشهای درون سنگ، اندازه و مقطع تونل، نوع و مقاومت نگهداری فوری، آستر بتنی دائمی، روش‌های اجرا) به صورت دینامیک بر پایداری سیستم نگهداری اثر می‌گذارد. فقط یک سیستم نگهداری استاتیک برای منطبق شدن بر همه جبهه کار تونل کافی نیست و باید تعدیل و تنظیم برای منطبق شدن بر شرایط جبهه کار تونل انجام شود.

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

در حقیقت سخت است که با استفاده از روشهای تحلیلی متداول رابطه بین پایداری نگهداری و پارامترهای ورودی (مانند کاراکترهای سنگ و برنامه ساختاری) تعیین شود. روش شبکه عصبی مصنوعی قادر است این ارتباط را تعیین کند. ANN رابطه بین نتایج خروجی (مانند حالت پایداری نگهداری) و متغیرهای ورودی عوامل (مانند مشخصات سنگ و فاکتورهای مربوط به ساخت) را تعیین می کند. اگر رابطه بین حالت پایداری نگهداری و عوامل مکانیکی سنگی و پارامترهای مربوط به ساخت به خوبی مشخص شود، می توان حالت پایداری سیستم نگهداری را با اطمینان بیشتر پیش بینی کرد. دلیل اولیه انتخاب ANN از بین سایر ابزارهای هوش مصنوعی توانایی آن در پیدا کردن اطلاعات با ارزش از داده های مثال می باشد.

بر عکس سیستم خبره، ANN، روش بدون فرضی است که از داده های قبلی یا مثالها آموزش می بیند و تخمین قابل قبولی را بدون استفاده از خبره گی یا قوانین مشخصی انجام می دهد.

این بخش نتایج تحقیقاتی درباره کاربرد ANN در پیش بینی پایداری سیستم نگهداری براساس مجموعه ای از اطلاعات مکانیک سنگی و اطلاعات مربوط به اجرا را توضیح می دهد.

ANN می تواند برای یاری کردن به مهندسان پروژه تونل برای تصمیم گیری درباره نگهداری تونل آموزش یابد و طراحی شود. مدل ANN که در این قسمت شرح داده شده است، می تواند حالت پایدار سیستم نگهداری با توجه به ورودی های (پارامترهای) مکانیک سنگی و پارامترهای مربوط به ساخت را پیش بینی کند و سپس یک سیستم نگهداری به روز (جدید) و مفید را برای فواصل منظم در طول فرآیند ساخت تونل ارائه دهد. در قسمت بعد به طور خلاصه NATM توضیح داده می شود، سپس الگوریتم ANN مورد بحث قرار می گیرد. سپس یک مدل پیش بینی پایداری سیستم نگهداری شرح داده می شود. سپس دقت روش شبکه عصبی و دو روش آماری مورد مطالعه قرار گرفته است. همچنین، یک تحلیل حساسیت انجام شده است که پارامترهای مکانیکی سنگی و پارامترهای مربوط به اجرا که

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

اهمیت بیشتری در پایداری نگهداری تونل دارند را مشخص می کند. نتیجه هم در پایان آورده شده است.

۲-۳- ناتم^۱ (طبقه بندی)

ناتم روش معمول مورد استفاده در ساختن تونل های سنگی است. طراحی تیپیک ناتم و جریان ناتم در شکل (۱-۲) توضیح داده شده است [۱۷].

اسم روش جدید تونل زنی اتریشی (NATM) اسم بی مسمایی می باشد، چونکه این روش، یک روش تونل زنی نیست بلکه یک راهکار برای تونل زنی می باشد که ترتیب و یکنواختی بسیار مناسبی دارد. NATM براساس فلسفه ساخت در حین پیشروی^۲ با تذکرات زیر استوار می باشد.

نه بسیار سخت، نه بسیار انعطاف پذیر

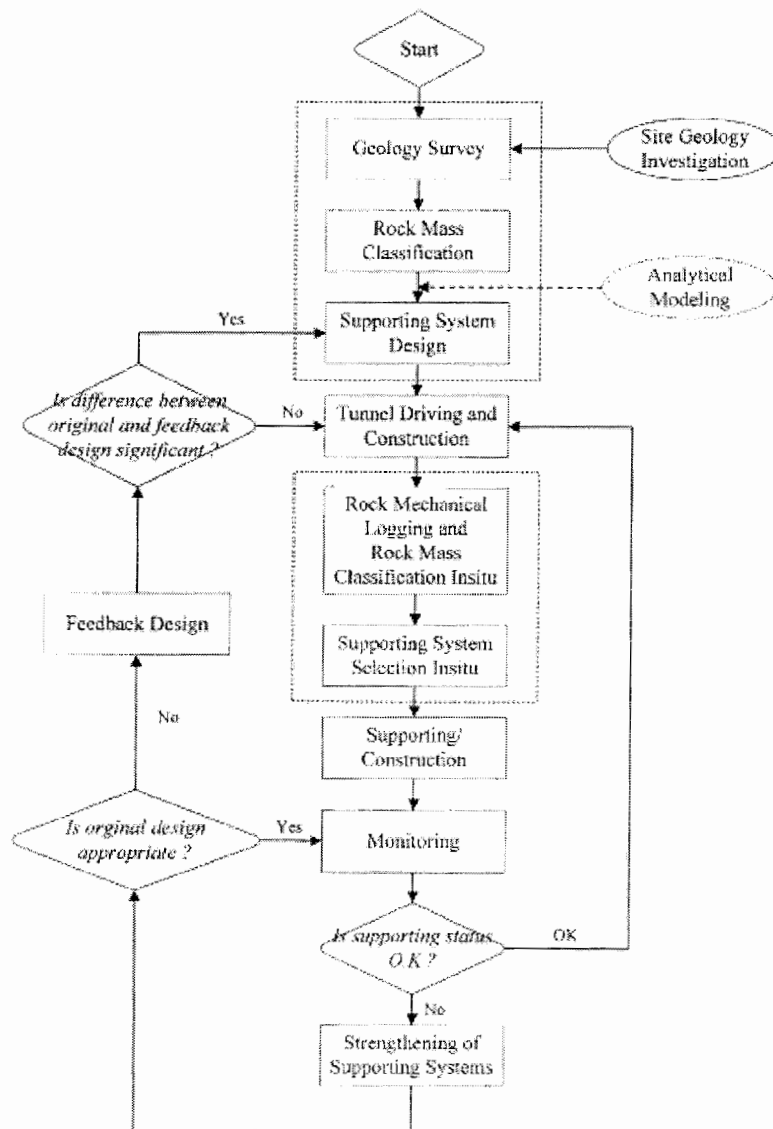
نه خیلی زود، نه خیلی دیر

NATM با آزادسازی کنترل شده تنش، تونل را پایدار می سازد. سنگ در بر گیرنده به همراه المان های نگهداری نصب شده، از یک سیستم تماما بارگذار به یک سازه خودنگهدار تبدیل می گردد، که از ایجاد سست شدگی نامطلوب که موجب از بین رفتن مقاومت ذاتی می شود، اجتناب می شود. با پیچ کاری منظم با به کارگیری شاتکریت، خود نگهداری با آزادسازی کنترل شده تنش همراه می شود. از یک طرف این سیستم، نگهداری فوری ایجاد می کند و از طرف دیگر انعطاف پذیری لازم تامین می شود تا تنش در هنگام تغییر شکل شعاعی، آزاد شود. بنابراین در سقف قوسی، گسترش تنش های برشی در پوشش شاتکریت به مقدار حداقل کاهش می یابد [۱۸].

^۱=New Astrain Tunneling Method

^۲=Build as you go

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی



شکل ۲-۱- روند اجرای NATM [۱۷]

اصول پایه ای NATM به صورت زیر شرح داده می شود:

۱- استفاده از توده سنگ.

۲- پوشش شاتکریت برای حفظ ظرفیت تحمل بار توده سنگ.

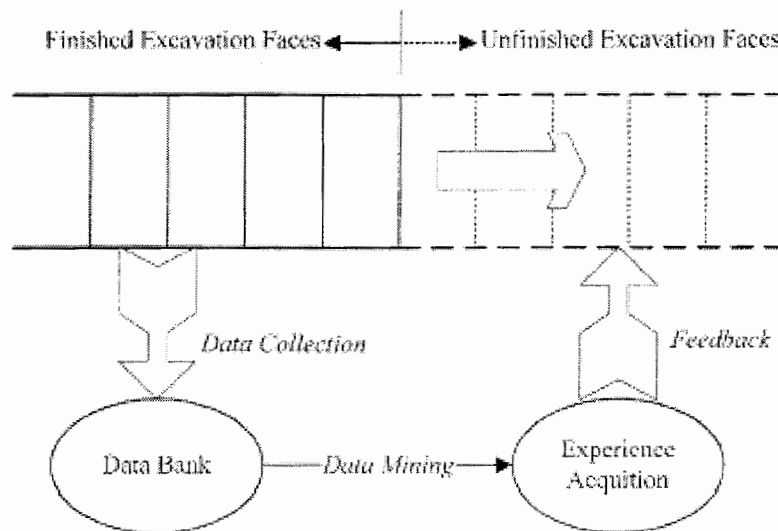
۳- رفتارنگاری تغییر شکلهای توده سنگ حفاری شده.

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

۴- کاربرد نگهداری های انعطاف پذیری و فعال.

۵- بستن کف به شکل حلقه نگهداری باربر به منظور کنترل تغییر شکل توده سنگ [۱۸].

ساختمان تونل، یک پروسه قابل تکرار است (شکل ۲-۲). با توجه به پارامترهای ساختاری خطی و تکراری، ساختمان تونل در طی پروسه جمع آوری داده، Datamining و Feed back بهبود می یابد. چندین روش مدرن مانند روشهای آماری و روش شبکه عصبی به جمع آوری اطلاعات مناسب از مجموعه داده ها کمک می کنند. در این مبحث، یک شبکه عصبی برای به دست آوردن اطلاعات درباره پایداری نگهداری از مجموعه داده های گزارشات روزانه کمک می کند. تمرکز اصلی شبکه عصبی در این مبحث آزمایش داده ها می باشد، تا رابطه بین داده های خروجی (حالت پایداری سیستم نگهداری) و مقادیر ورودی (پارامترهای مکانیک سنگی و ساختمانی) به دست آید. اگر وابستگی بین حالت پایداری سیستم نگهداری و پارامترهای مکانیک سنگی و ساختمانی پیدا شود، روش تونل زنی ناتم می تواند در حالت مناسب تر و اقتصادی تر انجام شود [۱۷].



شکل ۲-۲- پروسه تیپیک ساختمان تونل [۱۷]

۲-۴ - Datamining - شبکه عصبی

Datamining یک روش آموزش ماشین ، مانند روشهای دیگر فراگیری ، برای تولید کردن اطلاعات مناسب از نظم دادن و تحلیل داده های خام می باشد.

مراحل Datamining عبارت است از :

۱- تعیین هدف

۲- آماده سازی (تهیه) داده ها

۳- تغییر شکل داده ها

۴- Data mining

۵- تحلیل نتایج

۲-۵- تحلیل نتایج

چندین روش آموزش ماشین برای فراگیری اطلاعات در مهندسی تونل پیشنهاد شده است، تعدادی از آنها عبارت است از یادگیری سمبولیک، یادگیری بر اساس مثال و ANN. فاکتورهایی که بر روی کارایی یادگیری ماشین تاثیر می گذارند عبارتند از: قابل درک بودن اطلاعات، پیچیدگی داده ها و اطلاعات ورودی، توانایی فهمیدن داده های نویز دار و مانند آن. در اینجا رابطه بین پایداری نگهداری تونل و داده های ورودی (مثل مشخصات سنگ و روشهای ساخت) به طور شفاهی قابل درک نیست، بنابراین، ANN یک روش مناسب یادگیری ماشین در این حالت است.

ANN یک روش محاسباتی است که از سیستم مغز و اعصاب الهام گرفته است. ANN از شبکه بزرگ به هم پیوسته ای از محاسبه کننده ها (که در ANN نرون نامیده می شود) تشکیل شده است. دو خصوصیت ANN توانایی آن در عمل خود سازماندهی و یادگیری اتوماتیک است. ANN می تواند، به

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

طور مناسبی مساله سازگاری ورودی ها به خروجی ها بدون احتیاج به دلایل قوی را حل کند. ANN در حوزه های بسیاری از مهندسی عمران و معدن برای کمک به مهندسان پروژه استفاده می شود. به عنوان مثال، در زمینه های سازه، ژئو تکنیک، ساخت، هیدرولیک، غیره کاربرد دارد.

در این بخش از شبکه (BPNS) برای تحلیل رابطه بین پایداری سیستم نگهداری و خصوصیات مکانیکی سنگی و پارامترهای اجرایی استفاده می شود. الگوریتم BP یک روش کاهش گرادیان است که وزنه های اتصالات با استفاده از تخصص موازی خطا با توجه به وزنها به روز (اصلاح) می شود. بطور کلی BPNS یک شبکه عصبی است که بیشتر از بقیه شبکه ها مورد استفاده قرار گرفته است و برای مسایل دسته بندی، پیش بینی، کنترل سازگاری، شناسایی سیستم و غیره مورد استفاده قرار می گیرد

۲-۶- توصیف مطالعه موردی

داده ها برای این مبحث از تونل راه آهنی که جدیداً در غرب تایوان حفر شده است، گرفته شده است. قطر داخل تونل ۱۰/۸ m است. قسمت عمده سنگ این منطقه رسوبی است که شامل دو نوع اصلی از سنگ می شود. سنداستون که به طور متناوب سنداستون و شیل وجود دارند. RMR معمولاً از نوع (III) (۴۱-۶۰) و نوع (IV) (۲۱-۴۰) است. پیمانکار از روش تونل سازی NATM برای ساختن تونل استفاده کرده است. در طول تونل پس از حفاری قسمت بالا (head)، حفاری قسمت پایین (bench) انجام شده است. شاتکریت، مش سیمی، آرکهای فلزی و پیچ سنگ مهمترین سیستمهای نگهداری را تشکیل می دهند. سیستم های رفتار نگاری برای کنترل پایداری سیستم نگهداری مورد استفاده قرار گرفته است. براساس اطلاعات رفتار نگاری حالت پایداری سیستم نگهداری به سه دسته تقسیم می شود: مناسب، خطر دهنده، فعال (بد).

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

حدود این سه ناحیه به وسیله شرکت های مشاور تونل سازی تعریف می شود و معمولاً از نظریه های گریمستاند^۳ و بارتون^۴ و ساکورایی^۵ پیروی می کند.

در طی ساختن تونل، بازرسی از تونل برای کمک به شرح حالت سیستم نگهداری مورد استفاده قرار گرفته است. در مواقع وقوع رویدادهای غیر عادی، مانند ترک خوردن شاتکریت، پیچش یا جمع شدن آرکهای فلزی و شکستن پیچ سنگ، برای حل مشکل انجام یک سری عملیات لازم است. به این حالت حالت فعال (بد) برای حالت پایداری نگهداری گویند.

۲-۷- آماده کردن و انتقال داده ها

آماده سازی داده ها ابتدا شامل شناسایی تمام منابع اطلاعات و انتخاب داده ها برای کار Datamining است و سپس تغییر شکل داده ها انجام می شود تا برای تحلیل مورد توجه، مناسب باشد و شکل (فرمت) اطلاعات براساس الگوریتم تعیین می شود. در این مطالعه، داده های اصلی و اولیه شامل ۱۰۰۰ داده می شدند و تعدادی از داده ها به دلایل مبهم بودن و غیر کامل بودن و غیر قابل تطبیق بودن حالت داده ها (مانند قطره های مختلف تونل) حذف شدند. بعلاوه، به منظور داشتن پیش بینی درست تر از ANN، ایجاد یک توزیع یکنواخت مجموعه اطلاعات لازم است. با توجه به مسائل بالا تنها ۴۷۰ جفت داده برای تحلیل ANN باقی می ماند. داده های باقی مانده به دو گروه تقسیم می شود: RMR نوع III و RMR نوع IV و هر کدام به داده های آموزش و تست تقسیم می شوند. داده های تست شامل ۳۳٪ داده ها به صورت تصادفی می باشد. ۳۵۵ جفت داده برای آموزش و ۱۱۵ جفت داده برای تست در نظر گرفته شده اند (جدول ۱-۲).

^۳ = Grimstand

^۴ = Barton

^۵ = Sakurai

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

جدول ۱-۲- تعداد نمونه های آموزش و تست [۱۷]

Description	1	2	Total
RMR type	III	IV	III and IV
No. of training data	165	190	355
No. of testing data	55	60	115

تعداد پارامترهای مکانیکی سنگی و اجرایی که به عنوان ورودی شبکه استفاده می شوند، ۱۴ عدد هستند که عبارتند از: نوع سنگ، RQD، شرایط آبهای زیر زمینی، جدایش ها و جهت شیب ناپیوستگی ها، جدایش ناحیه ضعیف، ناحیه برش و گسل زده، تعداد ناپیوستگی ها، فاصله داری ناپیوستگی ها، جدایش ناپیوستگی ها، حالت ناپیوستگی ها، فاصله از جبهه کار پله ای، زمان نگهداری و نوع نگهداری. جزئیات تعریف پارامترهای مکانیک سنگی توسط بنیا و سکی ارائه شده است.

در این مطالعه، ناحیه برش و گسل زده تنها برای حالت RMR نوع IV وجود دارد. بنابراین ۱۳ ورودی برای RMR نوع III و ۱۴ ورودی برای RMR نوع IV وجود دارد.

نوع داده ها که شامل محدوده تغییرات واقعی و نظری آنهاست در جدول ۲ آورده شده است. مقادیر عددی به طور مستقیم از آزمایشهای مکانیک سنگی خوانده می شوند و RMR از گزارشهای روزانه و خلاصه کارهای اجرایی به دست می آید. داده های منطقی (logical) با توجه به تقسیم بندی منطقی داده ها تعریف می شوند. خروجی شبکه حالت پایداری سیستم نگهداری است که شامل سه حالت می شود. حالت ایمن، حالت اعلام خطر و حالت بد. داده ها با توجه به تابع زیر نرمالایز می شوند:

$$X_{new} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1-2)$$

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

که در این رابطه:

X_{new} = مقدار نرمالایز شده، X = مقدار اولیه، X_{max} = مقدار ماکزیمم در بین همه داده ها، X_{min} = مقدار

مینیمم در بین همه داده ها

جدول ۲-۲- شرح پارامترها ورودی و خروجی شبکه عصبی مصنوعی [۱۷]

Attribute	Input/output	Data type	Data range
Rock type	Input	Logic	1-8
RQD	Input	Numeric	30-60
Groundwater conditions	Input	Logic	7-10
Strike and dip orientations of discontinuities	Input	Numeric	- 5 to - 10
Weak zone separation	Input	Numeric	12-17
Faults and shear zones	Input	Logic	0-1
Number of discontinuities	Input	Numeric	0-2
Discontinuity separation	Input	Logic	1-3
Discontinuity length	Input	Logic	1-6
Discontinuity conditions	Input	Logic	1-24
Distance from driving face	Input	Numeric	Based upon daily reports
Distance from bench face	Input	Numeric	Based upon daily reports
Supporting timing	Input	Numeric	Based upon daily reports
Supporting types	Input	Logic	1-6
Support stability status	Output	Logic	1-3

مهمترین دلیل برای نرمالایز کردن این است که داده ها معمولا با واحدهای مختلف سنجیده می شوند. با نرمالایز کردن داده ها و بدون واحد کردن آنها، اثر قراردادی شباهت بین موضوعات برداشته می شود. به علاوه، با نرمالایز کردن داده ها، آموزش شبکه سریعتر انجام می شود.

۲-۸- Datamining - تحلیل شبکه عصبی

به منظور دستیابی به یک شبکه خوب، دو مساله معماری شبکه و پارامترها مهم اند. در این حالت، ما شکل شبکه عصبی را با تعداد لایه های میانی مختلف و تعداد گره ها در هر لایه تست کرده ایم و پارامترهای شبکه عصبی را با قوانین یادگیری متفاوت، تابع تبدیل متفاوت، نرخ یادگیری متفاوت، نرخ مومنتم متفاوت، مدل شبکه عصبی متفاوت، برای یافتن بهترین مقدار و شکل برای آنها تست کرده ایم. تعداد لایه های مخفی که برای تست استفاده شده اند به ترتیب ۰ و ۱ و ۲ و ۳ هستند.

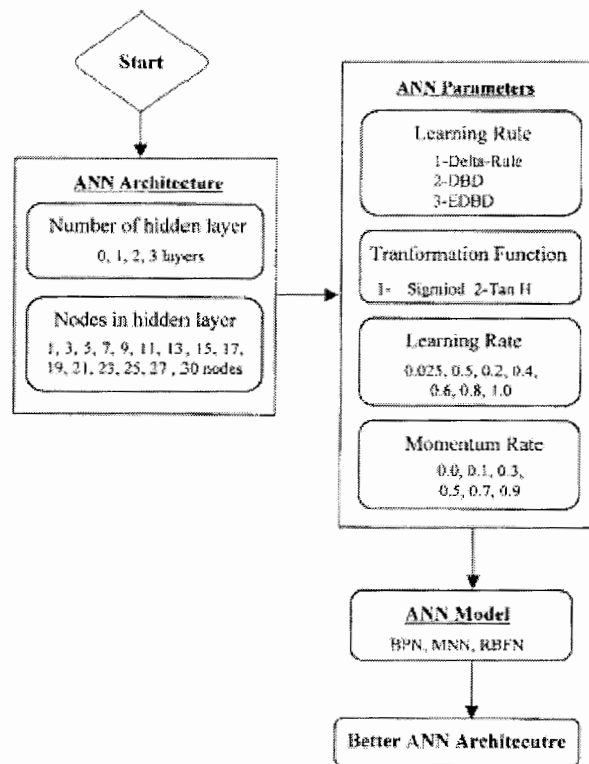
تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

تعداد گره ها در هر لایه مخفی به صورت تجربی و به صورت عددی، بین ۱ و ۳۰ است. قوانین یادگیری شبکه عبارتند از : قوانین دلتا (Δ) و دلتا بار ($\bar{\Delta}$) و دلتا بار توسعه یافته^۶. توابع تبدیل مورد استفاده تابع های سیگموئید و تانژانت هیپربولیک اند. نرخ یادگیری (η) یک فاکتور مهم است که پروسه آموزش شبکه را کنترل می کند. به طور کلی، نرخ یادگیری کوچک خطای الگوریتم یادگیری BP را کاهش می دهد، اما سبب کند شدن همگرایی می شود. هدف روش مومنتم به عنوان یک روش مکمل برای تعدیل وزنها در شبکه BPNS سرعت بخشیدن به همگرایی الگوریتم یادگیری BP است. ژاکوبز^۷ توضیح داده است که روش مومنتم به همگرایی سریع شبکه کمک می کند و همچنین در رسیدن به یک یادگیری کافی و واقعی کمک می کند. در روش مومنتم، نرخ مومنتم ثابت مثبتی است که کاربر انتخاب می کند. علاوه بر شبکه BPNS استاندارد، همچنین شبکه عصبی modular (MNN) که توسط Jacobs پیشنهاد شده است و شبکه با تابع شعاعی (RBFN) که توسط Leonard و همکارانش پیشنهاد شده است، برای پیدا کردن معماری بهتری از شبکه عصبی مورد استفاده قرار گرفته است.

پروسه شبکه عصبی در شکل (۲-۳) نشان داده شده است. چندین روش ارزیابی برای تکنیک یادگیری ماشین وجود دارد که شامل، جانشینی، بسط یافتن، cross-validation, boot strap است. روشی که در این مطالعه برای ارزیابی شبکه عصبی استفاده می شود روش hold out است.

^۶=Extended delta rule
^۷= Jacobs

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی



شکل ۲-۳- مراحل کار شبکه عصبی [۱۷]

در این روش داده ها بطور تصادفی به دو قسمت آموزش (۶۷٪ در این مطالعه) و تست (۳۳٪ در این مطالعه) تقسیم می شوند. تعیین اعتبار شبکه آموزش یافته با توجه به یکی یا بیشتر از اشاره کننده های (مشخص کننده های) خطا مانند میانگین قدر مطلق خطا (MAE)، مجذور میانگین خطا (MSE) و مجذور میانگین ریشه های خطا (RMS) است. در این مطالعه RMS برای ارزیابی شبکه عصبی مورد استفاده قرار گرفته است. RMS در معادله (۲-۲) تعریف شده است. RMS کوچکتر، باعث اجرای بهتر شبکه می شود. در این مطالعه، مقدار RMS برای انتخاب شکل بهتر شبکه مقدار RMS تست می باشد.

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

$$RMS = \frac{\sqrt{\sum_{i=1}^N (O_i - T_i)^2}}{N} \quad (2-2)$$

که در این رابطه:

T_i = مقدار هدف، O_i = مقدار پیش بینی شده و N = تعداد جفت‌های ورودی و خروجی

Neuralwork یک نرم افزار تجاری موجود است که برای آموزش شبکه عصبی مورد استفاده قرار گرفته است. اجرای شبکه بر روی یک کامپیوتر پنتیوم (II)(32MBRAM,200MHZ) انجام گرفته است. اجرای 600 هزار سیکل آموزش حدود 20 دقیقه طول کشیده است.

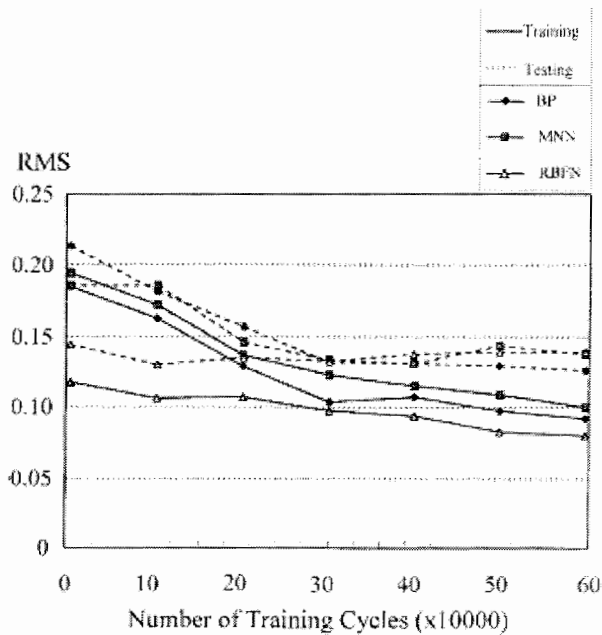
بعد از تعدادی آموزش، نتایج بهبود یافته شبکه عصبی در جدول (2-3) داده شده است. قسمتی از نتایج آزمایشی RMR نوع III در شکل‌های (2-4) تا (2-6) نشان داده شده است.

نتایج نهایی آزمایشها نشان می دهد که مدل BPN بهترین نتایج تست را در 600000 سیکل و در مقدار RMS برابر با 0/1123 و 0/1491 برای RMR های نوع III و IV دارا خواهد شد. برای RMR نوع III و IV یک لایه مخفی با 13 و 19 گره در لایه مخفی بهترین حالت است. قانون یادگیری و تابع تبدیل به ترتیب قانون دلتا و تابع سیگموئید هستند. نرخ یاد گیری و مومنتم هم به ترتیب 0/6 و 0/5 می باشند.

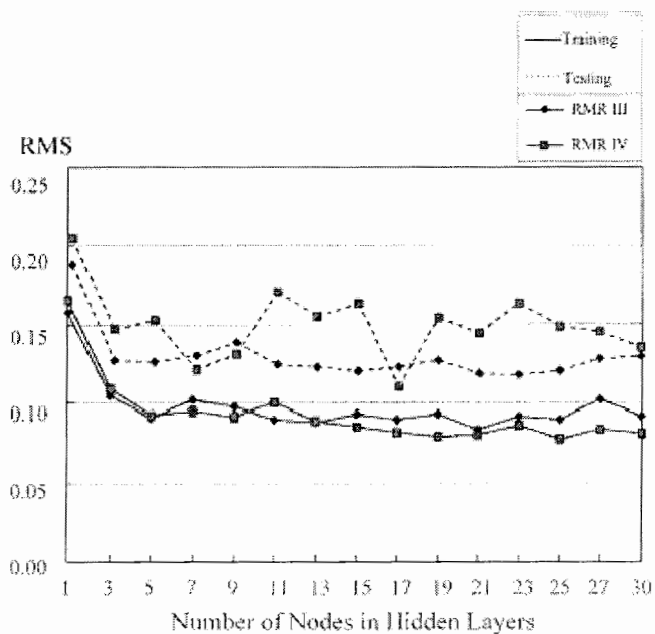
جدول 2-3- نتایج آموزش و تست شبکه عصبی [17]

Description	RMR III	RMR IV
Training/testing data set	165/55	190/60
Training RMS	0.0965	0.0937
Testing RMS	0.1123	0.1491
ANN architecture	BPN 13-13-1	BPN 14-17-1
Learning rule	Delta rule	Delta rule
Transformation function	Sigmoid	Sigmoid
Learning rate	0.6	0.6
Momentum rate	0.5	0.5
Training cycles	600,000	600,000

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی




شکل ۲-۴- خروجی شکل‌های مختلف شبکه عصبی (برای RMR(III)) [۱۷]



شکل ۲-۵- خروجی شبکه عصبی برای لایه های مخفی متفاوت [۱۷]

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی



شکل ۲-۶- خروجی شبکه عصبی برای قوانین آموزش متفاوت [۱۷]

۹-۲- تحلیل نتایج

به منظور تعیین مقبولیت پیش بینی شبکه عصبی، روش شبکه عصبی و روشهای آماری مورد مقایسه

قرار گرفته است. (جدول ۲-۴)

جدول ۲-۴- مقایسه نتایج شبکه عصبی و روش آماری [۱۷]

Model purpose	Problem type	Comparison	Validation
Analysis of Support Stability	Classification (logic output)	Discriminant analysis	Scattering diagram
		Non-linear regression	Hypothesis testing

داده های مورد استفاده در شبکه عصبی برای انجام یک تحلیل جدا کننده و برای تحلیل رگرسیون

غیر خطی (MRA) با فاکتورهای مکانیک سنگی و اجرایی به عنوان متغیرهای مستقل و حالت پایداری

نگهداری به عنوان متغیرهای وابسته مورد استفاده قرار گرفته است. نرم افزار SPSS به عنوان یک

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

نرم افزار آماری برای تحلیل رگرسیون و تحلیل جدا کننده مورد استفاده قرار گرفته است. چند تابع رگرسیون تست شد و رگرسیون غیر خطی مکعبی بهترین نتایج را داشت. (با مقدار همبستگی Pearson (R) برابر با ۰/۷۴ و ۰/۸۵ برای RMR نوع III و I). بنابراین، خروجی های تابع رگرسیون غیر خطی مکعبی برای مقایسه با ANN مورد استفاده قرار گرفت.

درصد درست بودن پیش بینی شبکه عصبی، تحلیل تفکیک کننده و رگرسیون غیر خطی مکعبی برای RMR های III و IV در جدول (۲-۵) شرح داده شده است.

در جدول (۲-۵) نشان داده شده است که شبکه عصبی بهترین حالت و MRA حالت میانی و تحلیل تفکیک کننده حالت ضعیف است. نمودار جدا کننده شکل های (۲-۷) و (۲-۸) خروجی ها از شبکه عصبی MRA را برای RMR های نوع III و IV نشان می دهد. شکل (۲-۷) مقدار درست پیش بینی را وقتی که دو تکنیک برای ارزیابی داده های آموزش هم واحد (یکسان) می شوند را شرح می دهد.

شکل (۲-۸) نتایج ارزیابی داده های تست را شرح می دهد. هر دو نتیجه نشان می دهد که شبکه عصبی بهتر از رگرسیون غیر خطی است. اهمیت خروجی های شبکه عصبی در این است که مقادیر پیش بینی شده ۱ و ۲ و ۳ است. این بدین معنی است که پیش بینی شبکه عصبی برای این حالت عالی است. خروجی های تابع رگرسیون غیر خطی مکعبی در ناحیه بزرگتری پخش می شود و این بدین معنی است که تابع رگرسیون غیر خطی مکعبی در این مطالعه حالت ضعیف تری است، مخصوصاً وقتی که حالت پایداری سیستم نگهداری یکی از دو حالت مناسب و یا فعال باشد.

برای RMR نوع III و IV میزان خطای پیش بینی شده و انحراف از معیار خطاها برای سه روش در جدول (۲-۶) نشان داده شده است. مقدار میانگین و همچنین میزان انحراف با توجه به شبکه عصبی کوچکتر از تحلیل جدا کننده و تابع رگرسیون مکعبی است. تست های فرضیه بیشتر برای ارزیابی سه تکنیک به کار می رود. یک فرضیه صفر: $H_0 = P_1 - P_2 > 0$ و یک فرضیه جذاب: $H_1 = P_1 - P_2 < 0$ به وجود می

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

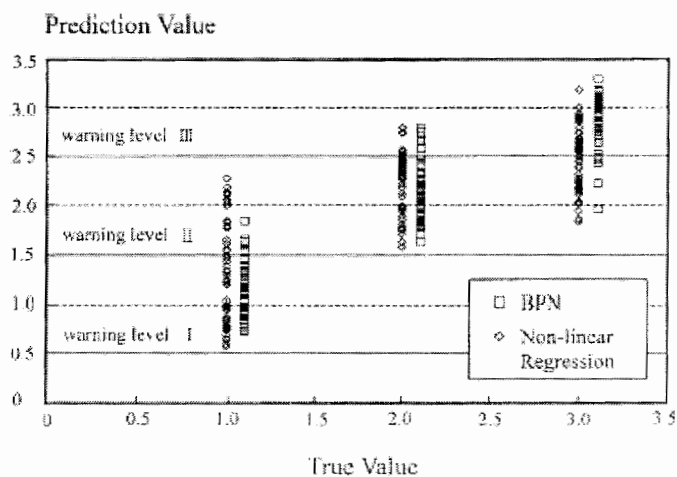
آید، که P_1, P_2 مقادیر میانگین خطای پیش بینی به روشهای آماری هستند. تابع تست فرضیه در معادله (۳-۲) آمده شده است، در جایی که $\hat{p} = (x_1 + x_2) / (n_1 + n_2)$ ، تعداد خطاهای پیش بینی و n_1, n_2 تعداد داده ها می باشند. مقدار α برای این حالت مقدار ۰.۵ و Z_{\dots} برابر با (۱/۶۴۵-) است. تا وقتی

که Z کوچکتر از Z_{\dots} است، فرض جالب $H_1 = P_1 - P_2 < 0$ قابل قبول است. (جدول ۲-۷)

جدول ۲-۵ درصد پیش بینی درست BPN و تحلیل تفکیک کننده و تابع رگرسیون [۱۷]

Evaluation method	RMR III		RMR IV	
	Training (165 data) [%]	Testing (55 data) [%]	Training (190 data) [%]	Testing (60 data) [%]
BPN	88.48	81.82	92.11	81.67
Discriminant analysis	62.42	65.45	60.00	68.33
Multiple regression analysis	67.27	50.91	76.84	66.67

شکل ۲-۷ نمودار تحلیل جداکننده BPN و رگرسیون مکعبی (داده های آموزش (RMR(III) [۱۷]



شکل ۲-۸ نمودار تحلیل جداکننده BPN و رگرسیون مکعبی (داده های تست (RMR(III) [۱۷]

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

جدول ۲-۶- میزان خطای پیش بینی شبکه عصبی و تحلیل آماری [۱۷]

RMR type	Description	Training data set		Testing data set	
		Mean	Standard deviation	Mean	Standard deviation
III	BPN	0.1152	0.02485	0.1818	0.05196
	Discriminant analysis	0.3758	0.03768	0.3455	0.06411
	Multiple regression	0.3273	0.00133	0.4909	0.00454
IV	BPN	0.0789	0.00038	0.1833	0.00250
	Discriminant analysis	0.4000	0.00126	0.3167	0.00361
	Multiple regression	0.2316	0.00094	0.3333	0.00370

جدول ۲-۷- تست فرضی BPN و تحلیل آماری [۱۷]

Description	III		IV	
	Training	Testing	Training	Testing
BPN vs. discriminant analysis	-5.5002	-1.9483	-7.3324	-1.6874
BPN vs. multiple regression	-4.6415	-3.4308	-4.1098	-1.8771

میانگین خطای پیش بینی شده با توجه به ANN کوچکتر از خطای تحلیل تفکیک کننده و تابع رگرسیون مکعبی است. نتیجه ای که به دست می آید به این صورت است: ظرفیت پیش بینی شبکه عصبی از لحاظ آماری نسبت به رگرسیون غیر خطی و تحلیل تفکیک کننده در این مبحث و برای این حالت بهتر است.

$$Z_0 = \frac{p_1 - p_2}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} < Z_\alpha \quad (3-2)$$

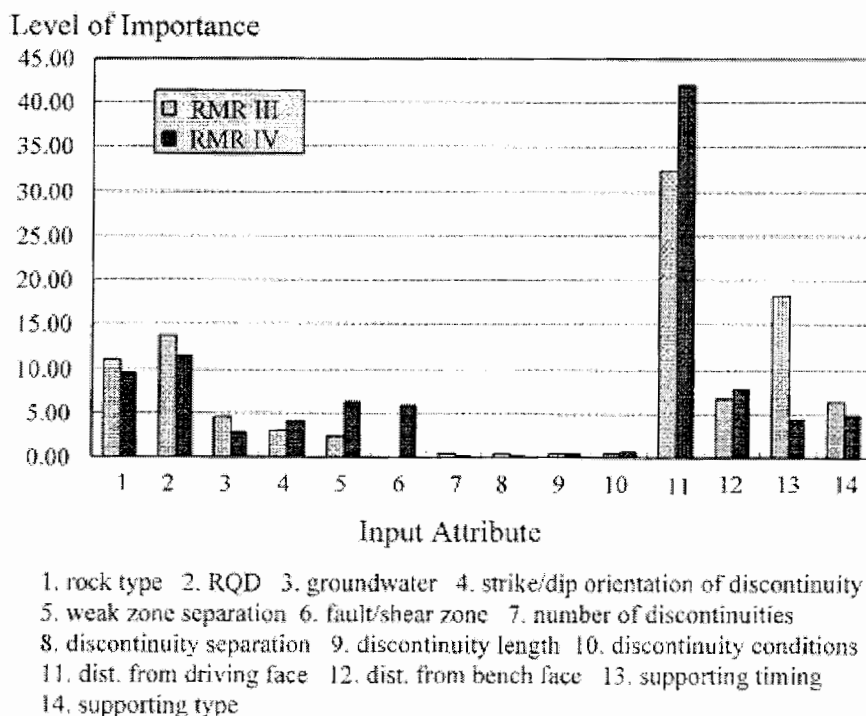
۲-۱۰- تحلیل حساسیت و بحث در مورد آن

بعد از کالیبره کردن و ارزیابی مدل شبکه عصبی، یک تحلیل حساسیت برای تخمین میزان اثر پارامترها ی مکانیک سنگی و اجرایی بر پایداری سیستم نگهداری انجام شده است. در اینجا مدول


تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

“explain” نرم افزار Neural work به منظور تحلیل حساسیت مورد استفاده قرار گرفت. نتایج در شکل (۹-۲) شرح داده شده است.

این شکل نشان می دهد که پارامترهای عمومی اجرایی اثر مهمی را بر پایداری سیستم نگهداری دارند، مخصوصا فاصله از جبهه کار که بیشترین اثر را دارد. به منظور ارزیابی نتایج شبکه عصبی، FLAC-۳D یک نرم افزار تحلیل عددی ژئوتکنیکی برای تحلیل تغییر شکل سیستم نگهداری مورد استفاده قرار گرفت و ترکیبات متفاوت از فاصله قسمت بالا (top heading) و طول پله ها تحلیل شد.



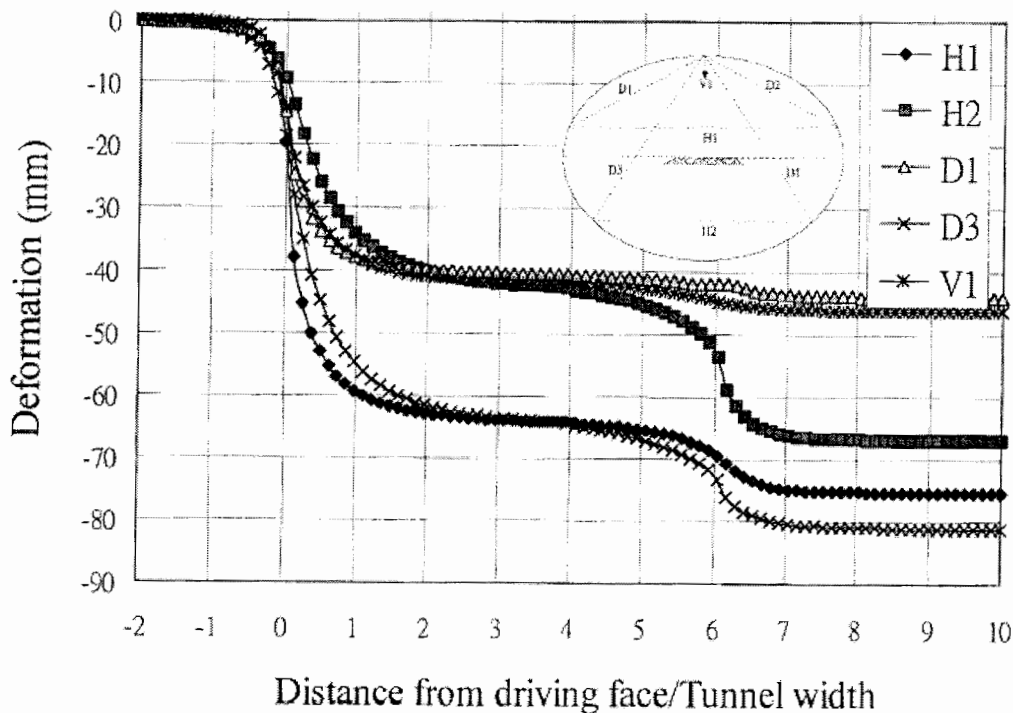
شکل ۹-۲- تحلیل حساسیت متغیرهای ورودی شبکه عصبی [۱۷]



شکل ۲-۱۰- مدل تحلیل ۳D-FLAC [۱۷]

یک ساختار مش بندی نرم افزار ۳D-FLAC برای حالت مورد مطالعه در این مطالعه در شکل (۲-۱۰) نشان داده شده است. با توجه به این تحلیل، می فهمیم که طول قسمت بالا برای مثال فاصله از جبهه کار در شکل (۲-۹) تاثیر بسیار زیادی بر تغییر شکل سیستم نگهداری دارند. Brown , Brady یافته های مشابهی را با توجه به تحلیل مکانیک سنگی ارائه کرده اند. تغییر شکلی که توسط سیستم رفتارنگاری محاسبه می شود، عموماً با توجه به اختلافات فاصله از دو طرف تونل (عرض تونل) در دو زمان به دست می آید. طول پله (برای مثال فاصله از پله جبهه کار در شکل ۲-۹) همچنین بر تغییر شکل اثر دارد. وقتی که طول پله کوتاه است، اثر حفاری قسمت پایین بر تغییر شکل، در زمان، مشابه حفاری قسمت بالا است. وقتی که طول پله زیاد باشد، اثر زمان بر حفاری قسمت پایین متفاوت از حفاری قسمت بالا است. (شکل ۲-۱۱)

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی



شکل ۲-۱۱- منحنی تغییر شکل - فاصله از جبهه کار تونل [۱۷]

پارامترهای دیگر اجرایی، مانند زمان نگهداری و نوع نگهداری نیز در یک درجه (حد) خاص بر پایداری سیستم نگهداری اثر دارند. مهمترین پارامترهای مکانیک سنگی که در این مطالعه بر سیستم نگهداری اثر می کنند، نوع سنگ و RQD هستند. برای RMR نوع IV، وجود ناحیه برشی و گسل زده مثل ناحیه ضعیف بر پایداری سیستم نگهداری در درجه های متفاوت اثر دارند.

مهندسين زمين شناسی و مهندسان پروژه در محل سایت مشورتهاي لازم را انجام دادند و معلوم شد که نوع سنگ، RQD، آب زیر زمینی، شرایط ناپیوستگی ها، ناحیه برشی و گسل زده، فاصله از جبهه کار، فاصله از قسمت پایین جبهه کار، زمان نگهداری، نوع نگهداری، پارامترهای مهم برای پایداری نگهداری ، با توجه به مشاهدات و تجربیات آنها است (جدول ۲-۸).

تحلیل پایداری سیستم نگهداری تونل با استفاده از شبکه عصبی مصنوعی

جدول ۲-۸- مقدار نسبت داده شده به حالت تست [۱۷]

Attribute	Back-propagation neural network	Experts' opinions
Rock type	<input type="radio"/>	<input type="radio"/>
RQD	<input type="radio"/>	<input type="radio"/>
Groundwater		<input type="radio"/>
Discontinuity orientation		
Discontinuity condition		<input type="radio"/>
Discontinuity separation		
Faults/shear zone	<input type="radio"/>	<input type="radio"/>
Distance from driving face	<input type="radio"/>	<input type="radio"/>
Distance from Bench face	<input type="radio"/>	<input type="radio"/>
Supporting timing	<input type="radio"/>	<input type="radio"/>
Supporting type	<input type="radio"/>	<input type="radio"/>

به دلیل عدم وجود آبهای زیرزمینی و وجود ناپیوستگی های بزرگ در این مطالعه، آبهای زیر زمینی و ناپیوستگی ها کمترین اثر را بر پایداری سیستم نگهداری دارند. برای پارامترهای دیگر مکانیک سنگی و اجرایی، مدل شبکه عصبی به نتیجه مشابهی می رسد. در این مورد، شبکه عصبی نشان می دهد که پارامترهای اجرایی تاثیر بیشتری از پارامترهای مکانیک سنگی دارند. این بدین معنی است که کیفیت اجرا اثر بیشتری نسبت به خصوصیات زمین شناسی بر پایداری سیستم نگهداری دارد. هر چند، تحلیل ابتدایی در این مبحث تنها یک رابطه ساده بین پایداری سیستم نگهداری و پارامترهای مکانیک سنگی و اجرایی برای سازند سنداستون را نشان می دهد. تحقیقات بیشتری نیاز می باشد برای این که بفهمیم شبکه عصبی برای انواع دیگر سنگ و سازند های متفاوت دیگر، مانند گرانیت و متامورفیک مناسب است یا نه.

۲-۱۱- نتیجه گیری

تخمین علت ناپایداری سیستم نگهداری تونل معمولاً با مقایسه با تجربیات قبلی که بیشتر بر تحلیل تفصیلی شرایط زمین شناسی و اجرایی استوار است انجام می شود. این مقاله پتانسیل شبکه عصبی را برای کار در تحلیل پایداری سیستم نگهداری نشان می دهد. این آزمایشات نشان می دهد که شبکه عصبی یک روش مناسب برای مدل کردن وابستگی پیچیده بین پایداری سیستم نگهداری و پارامترهای مکانیک سنگی و اجرایی است. تست اعتبار سنجی نشان می دهد که شبکه عصبی به طور واضحی نسبت به تابع رگرسیون چند گانه و تحلیل تفکیک کننده پایداری سیستم نگهداری تونل تحت حالت‌های مختلف تست و آموزش را با دقت بیشتری پیش بینی می کند. شبکه عصبی می تواند اطلاعات ارزشمندی را از داده های مورد مطالعه پیدا کند. برای فرآیندهای اجرایی تکرار پذیر مانند ساختن تونل، یادگیری شبکه عصبی انجام می شود و استخراج اطلاعات ارزشمند از داده های خام یک جبهه کار تمام شده انجام می شود و سپس این اطلاعات می تواند به یک جبهه کار جدید در حال حفر، بازگشت (fed back) داشته باشد. این کار بر روی داده ها و پروسه feed back، عملیات ساخت تونل‌های بعدی را بهبود می بخشد.

باید تحقیقات بیشتری در این زمینه باید انجام شود. در تحقیقات بعدی، انواع دیگر سنگ و سازنده های دیگر مانند سنگهای گرانیت و متامورفک، می توانند با شبکه عصبی بررسی شوند و رابطه بین پایداری سیستم نگهداری تونل و پارامترهای مکانیکی سنگی و ساختمانی تحلیل شود. بعلاوه، یکپارچه کردن (کامل کردن) شبکه عصبی و سیستم داده های تونل امکان پذیر است و برای استفاده مهندسی مشاور که پایداری سیستم نگهداری تونل را پیش بینی می کنند و برای مدیران پروژه که عملیات پروژه را مدیریت می کنند و برای کنترل کردن پروژه کاربردی (عملی) است [۱۷].

فصل سوم

کاربرد شبکهٔ عصبی برای پیش بینی خرج ویژه
و حداکثر سرعت ذره در آتشباری تونل

۳-۱- خلاصه

هدف اصلی این مطالعه به کار بردن شبکه عصبی مصنوعی برای تصمیم گیری درباره مقدار بهینه خرج ویژه و پیش بینی حداکثر سرعت ذره، با توجه به سری‌هایی از پارامترهای مشاهده شده و ورودی است. الگوی آتشباری مورد استفاده برش به صورت گوه ای است. موقعیت چال‌های آتشباری و الگوی آتشباری اغلب ثابت است. پارامترهای ورودی ۱۴ پارامتر زمین شناسی (مقدار شیب، جهت شیب، فاصله داری، جدایش، دوام دو دسته درزه، جهت تونل، مقاومت سنگ، RQD و RMR) و چهار پارامتر آتشباری‌اند (فاصله بین نقاط آتشباری و نقاط اندازه گیری، وزن خرج در هر تأخیر، طول چالزنی و کارایی آتشباری). داده‌ها برای کار شبکه عصبی در این مطالعه از یک تونل بزرگراه در حال ساخت در کره جمع شده است. اصلی‌ترین نوع سنگ در این محل گرانیت بیوتیتی است. یک مدل بهینه شبکه عصبی به وسیله آموزش داده‌های جمع آوری شده به دست آمده است. مدل آموزش یافته برای ارزیابی قابلیت پیش بینی مدل بهینه استفاده می شود. این نشان می دهد که مدل شبکه عصبی می تواند میزان خرج ویژه و حداکثر سرعت ذره را با توجه به پارامترهای انتخاب شده ورودی پیش بینی کند. مطالعات نشان می دهد که مدل شبکه عصبی، پیش بینی دقیق تری از حداکثر سرعت ذرات نسبت به معادله لرزش ناشی از آتشباری می دهد. به علاوه، فاکتور تسلط بین ورودی‌ها، می تواند با آنالیز اثر مقاومت نسبی به دست آید.

۳-۲- مقدمه

طراحی الگوی آتشباری در راندمان آتشباری، میزان آسیب به دیواره تونل، لرزش و نویزهایی که به واسطه آتشباری در تونل ایجاد می شوند مهم و مؤثر است. میزان حداکثر سرعت مجاز ذره

باتوجه به سازه های مجاور و خرج ویژه، بستگی به انتخاب الگوی بهینه آتشباری دارد. هرچند، در محل ساختن تونل در کره، عمل آتشباری با توجه به تجربیات مهندسان آتشباری انجام می شد. در نتیجه، مهندسان آتشباری وزن های متفاوتی را برای پارامترهای زمین شناسی که بر خرج ویژه و حداکثر سرعت ذره اثر می گذارند، تعیین می کنند.

خرج ویژه، که به صورت وزن ماده منفجره استفاده شده (به کیلوگرم) در حجم - واحد سنگ شکسته شده (به متر مکعب) تعریف می شود، با ریشه سوم فرکانس شکست رابطه عکس دارد (اسکوت^۱، ۱۹۹۶) و با شاخص قابلیت انفجار که از مجموع مقادیر شرح داده شده از توصیف توده سنگ، فاصله داری درزه ها، جهت داری دسته درزه ها، وزن مخصوص و سختی به دست می آید، رابطه مستقیم دارد (Lilly, ۱۹۸۶). وزن خرج در هر تأخیر برای کنترل لرزش ناشی از آتشباری که به وسیله عملیات آتشباری تحت سرعت مجاز ذرات تولید می شود، از معادلات لرزش ناشی از آتشباری که به صورت تجربی به دست آمده است، محاسبه می شود. مطالعات سیستماتیک که در ترکیبی از شرایط زمین شناسی و شرایط آتشباری برای تخمین خرج ویژه و پیش بینی حداکثر سرعت ذرات انجام می شود، به ندرت در کره دیده می شود. بنابراین، لازم است که پارامترهای زمین شناسی و شرایط آتشباری که در آتشباری تونل مشاهده می شود شناسایی شود و میزان اثر آنها هم شرح داده شود.

اخیراً، شبکه عصبی در مهندسی سنگ مورد استفاده قرار گرفته است. Huang (۱۹۹۸) و همکارانش کاربرد شبکه عصبی را در مهندسی سنگ با استفاده از چندین مطالعه موردی شرح داد و Meulenkamp و همکارانش (۱۹۹۹) شبکه عصبی را برای پیش بینی مقاومت فشاری نامحصور از سختی Equotip به کار برد. به طور ویژه ای، Eou-SenLeu و همکارانش (۱۹۹۸) کاربرد شبکه عصبی برای پیش بینی خرج ویژه برای آتشباری تونل به وسیله مشخصات دو دسته درزه اصلی (جهت شیب، شیب، فاصله داری، جدایش و استحکام)، مقاومت سنگ، RQD و RMR به عنوان

^۱=Scot


ورودی‌های شبکه عصبی را شرح داد. Yang (۱۹۹۷) همچنین درجه اهمیت پارامترهای موجود برای تحلیل پایداری بازکننده های زیر زمینی را با استفاده از شبکه عصبی و اثر مقاومت نسبی (RSE) بررسی کرد. در کره، همچنین، مطالعات در زمینه کاربرد شبکه عصبی به عنوان یک روش پیش بینی برای به دست آوردن خرج ویژه و حداکثر سرعت ذرات در اثر آتشباری تونل کم است. در این مطالعه، خطای ناشی از برداشت کننده های مختلف داده‌ها، با جمع کردن مستقیم داده‌ها از شرایط زمین شناسی در محل سایت تونل مذکور مینیمم شده است. در این مطالعه، امکان پذیری کاربرد شبکه عصبی برای پیش بینی خرج ویژه در عملیات آتشباری تونل و حداکثر سرعت ذرات ناشی از لرزش آتشباری مورد مطالعه قرار گرفته است. همچنین، پارامترهای مؤثر بر خرج ویژه و حداکثر سرعت ذرات در محل آتشباری یک تونل با استفاده از اصل RSE مورد بررسی قرار گرفته است.

۳-۳- آموزش شبکه عصبی و تصمیم گیری در مورد پارامترها

داده‌های مورد استفاده برای آموزش شبکه عصبی در این مطالعه به صورت مستقیم از یک بزرگراه در حال ساخت در کره به دست آمده است. عمده سنگ‌ها در این منطقه گرانیت بیوتیتی هوازده است. الگوی آتشباری مورد استفاده در این محل برش گوه ای است که در شکل (۳-۱) نشان داده شده است.

داده‌های مورد استفاده در این مطالعه از یک تونل در حال ساخت که موقعیت چال های آتشباری و الگوی آتشباری در آن ثابت است، جمع شده است و شرایط آتشباری پارامترهای ورودی شبکه می باشند. پارامترهای ورودی این مطالعه، براساس مطالعات قبلی انتخاب شده است. ۱۴ پارامتر ورودی برای پیش بینی خرج ویژه و ۱۸ پارامتر ورودی برای پیش بینی حداکثر سرعت ذره که توسط آتشباری تونل تولید می شود، استفاده می شوند.

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل



شکل ۳-۱- الگوی آتشباری استفاده شده در محل تونل [۱۹]

جدول (۳-۱) پارامترهای ورودی و خروجی را نشان می دهد. پارامترهای ورودی (A ~ F) برای پیش بینی خرج ویژه و (A ~ J) برای پیش بینی حداکثر سرعت ذره به کار می روند. برای آموزش شبکه عصبی، ۲۵ دسته داده برای پیش بینی خرج ویژه و ۲۷ دسته داده برای پیش بینی حداکثر سرعت ذره استفاده می شوند.

جدول ۳-۱- شرح پارامترهای ورودی و خروجی در شبکه عصبی [۱۹]

Parameter	Description	Data Type	Range (Unit)
Input	A. Tunnel orientation	Numeric	0 - 360
	B1. Major discontinuity dip direction	Numeric	0 - 360
	B2. dip	Numeric	0 - 90
	B3. spacing	Logic	1 - 5
	B4. separation	Logic	1 - 5
	B5. persistence	Logic	1 - 5
	C1. Secondary discontinuity dip direction	Numeric	0 - 360
	C2. dip	Numeric	0 - 90
	C3. spacing	Logic	1 - 5
	C4. separation	Logic	1 - 5
	C5. persistence	Logic	1 - 5
	D. Rock strength	Logic	1 - 5
	E. RQD	Logic	1 - 5
	F. RMR	Numeric	1 - 100
G. Drilling length	Numeric	(m)	
Output	H. Blasting efficiency	Numeric	(%)
	I. Charge weight per delay	Numeric	(kg)
	J. Distance between the blasting and measured point	Numeric	(m)
	Powder Factor	Numeric	(kg/m ³)
Peak Particle Velocity	Numeric	(cm/sec)	

شبکه عصبی با توجه به نوع الگوریتم های یادگیری، توپولوژی شبکه و داده های پذیرفته شده به انواع مختلف تقسیم می شود. با توجه به این طبقه بندی ها، در این مطالعه از یک پرسپترون چند لایه با الگوریتم یادگیری پس انتشار خطا و از تابع سیگموئید به عنوان تابع فعال سازی استفاده شده است. شبکه عصبی کارآیی یادگیری و قابلیت پیش بینی متفاوت دارد که بستگی به ثابت های یادگیری، از قبیل نرخ یادگیری، نرخ مومنتم، تعداد نرون ها در لایه ورودی و لایه خروجی و معماری لایه پنهان دارد. در طی دوره یادگیری شبکه عصبی، این پارامترها برای تصمیم گیری در مورد مدل بهینه برای پیش بینی خرج ویژه و حداکثر سرعت ذره در طی آتشباری تونل تغییر می کند تا به مدل بهینه برسد.

به عنوان نتیجه، مدل بهینه برای پیش بینی خرج ویژه، مدلی با نرخ یادگیری ۰/۹۵، نرخ مومنتم ۰/۹۵ و معماری شبکه به صورت ۱-۴-۴-۱۴ است. به علاوه، برای پیش بینی حداکثر سرعت ذره، مدل بهینه شبکه عصبی با نرخ یادگیری ۰/۹۵ و نرخ مومنتم ۰/۸ و معماری به صورت ۱-۵-۵-۱۸ است. معیار استفاده شده برای به دست آوردن مدل بهینه کمترین مقدار جذرمیانگین توان دوم (RMS) خطاهای پیش بینی مقدار و همچنین کمترین زمان یادگیری شبکه است.

۳-۴- ارزیابی مدل شبکه عصبی

قابلیت پیش بینی شبکه عصبی انتخاب شده برای خرج ویژه و سرعت ذره در آتشباری تونل با استفاده از داده هایی که برای آموزش شبکه استفاده نمی شود ارزیابی می شود و سرعت های پیش بینی شده به وسیله شبکه عصبی با نتایج معادلات لرنش ناشی از آتشباری مقایسه شده است.

جدول (۲-۳) داده های استفاده شده برای دسترسی به قابلیت پیش بینی شبکه عصبی بهینه (معماری ۱-۵-۵-۱۸ و نرخ یادگیری ۰/۹۵ و نرخ مومنتم ۰/۹۵) برای پیش بینی خرج ویژه در آتشباری تونل را نشان می دهد. جدول (۳-۳) نتایج مقایسه بین خرج ویژه پیش بینی شده با استفاده از مدل شبکه عصبی و مقدار سنجیده شده (واقعی) را نشان می دهد. مدل شبکه عصبی

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل

برای پیش بینی خرج ویژه نشان می دهد که RMS برای پیش بینی مقادیر، 0.433 kg/m^3 است.

این مقدار از RMS خطاها (یعنی 0.00737 kg/m^3)، برای داده های آموزش شبکه بزرگتر است.

جدول ۳-۲- داده های تست برای رسیدن به مدل بهینه برای پیش بینی خرج ویژه [۱۹]

Sample Number	S-11	S-12	S-13	S-14
Tunnel orientation	090	090	090	090
Major dip direction	259	086	081	257
discontinuity dip	82	86	88	87
spacing	2	2	3	2
separation	2	2	2	2
persistence	2	2	2	3
Secondary dip direction	346	005	357	340
discontinuity dip	77	73	77	78
spacing	1	2	2	1
separation	3	3	2	2
persistence	3	3	3	3
Rock strength	3	4	5	2
RQD	1	2	2	2
RMR	38	52	39	44

جدول ۳-۳- نتایج مقایسه بین مقادیر پیش بینی شده به وسیله شبکه عصبی و مقادیر واقعی [۱۹]

Sample Number	Powder Factor (kg/m^3)		Error	
	Measured value	Value predicted by ANN	Absolute Error (kg/m^3)	Relative Error (%)
S-11	0.94	0.89	0.05	5.32
S-12	0.98	0.94	0.04	4.08
S-13	0.83	0.78	0.05	6.02
S-14	0.87	0.90	-0.03	-3.45

علت این موضوع کم بودن داده های آموزش در مثل شبکه عصبی می باشد. هرچند، مقادیر

پیش بینی شده خطای مطلق میانگین 0.04 kg/m^3 و خطای نسبی میانگین 4.72% با توجه به

داده های واقعی دارند. خطای مطلق و خطای نسبی به صورت زیر تعریف می شود:

$$\text{خطای مطلق} = T_i - O_i \quad \dots\dots\dots (1-3)$$

$$\text{خطای نسبی} = T_i / O_i \quad \dots\dots\dots (2-3)$$

که در این رابطه T_i و O_i ، خروجی هدف استفاده شده در یادگیری شبکه عصبی (مقدار واقعی) و

خروجی یادگیری شبکه عصبی (مقدار پیش بینی شبکه) را بیان می کند.

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل

بنابراین، این اعتقاد ایجاد می شود که شبکه عصبی آموزش یافته تغییرات شرایط زمین شناسی را به صورت مطلوب می گیرد و یک قابلیت پیش بینی مطلوب را می دهد.

داده های آموزش مدل شبکه عصبی برای تعیین معادله لرزش ناشی از آتشباری استفاده می شوند. در ابتدا، در این حالت استفاده از فاصله مقیاس بندی شده ریشه دوم، ۵۰٪ معادله میانگین رگرسیون، معادله (۳-۳) است و ۹۵٪ معادله لرزش آتشباری است که در این طراحی آتشباری استفاده می شود و فاکتور ایمنی ارائه شده در معادله (۴-۳) به دست می آید:

$$V = 78.0 \cdot \left[\frac{D}{W^2} \right]^{-1/964} \quad (50\%)(R = 0.1887) \quad (3-3)$$

$$V = 1552/9 \left[\frac{D}{W^2} \right]^{-1/964} \quad (0.95\%)(R = 0.1887) \quad (4-3)$$

که در این رابطه V , D , W به ترتیب حداکثر سرعت ذره، فاصله بین نقطه آتشباری و نقطه اندازه گیری و وزن خرج در هر تأخیر را نشان می دهند.

نتایج تحلیل با استفاده از توان سوم فاصله مقیاس بندی شده (بین مقادیر) با استفاده از معادله ۵ و ۶ نشان داده شده است. معادله (۵-۳)، معادله رگرسیون میانگین ۵۰٪ است و معادله (۶-۳)، معادله لرزش آتشباری ۹۵٪ است.

$$V = 1544/8 \left[\frac{D}{W^3} \right]^{-2/42} \quad (50\%)(R = 0.1890) \quad (5-3)$$

$$V = 3045/6 \left[\frac{D}{W^3} \right]^{-2/42} \quad (0.95\%)(R = 0.1890) \quad (6-3)$$

داده های شرح داده شده در جدول (۴-۳) برای دسترسی به قابلیت پیش بینی شبکه عصبی بهینه (معماری : ۱-۵-۵-۱۸، نرخ یادگیری ۰/۹۵ و نرخ مومنتم ۰/۸۰) برای پیش بینی حداکثر

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل

سرعت ذرات در آتشباری تونل استفاده می شود. جدول (۳-۵) نتایج مقایسه بین مقدار پیش بینی شده توسط شبکه عصبی و مقدار اندازه گیری شده (واقعی) حداکثر سرعت ذرات را نشان می دهد. مدل شبکه عصبی نشان می دهد که RMS خطاها از مقادیر پیش بینی شده توسط شبکه در برابر مقادیر واقعی 0.0156 cm/sec است. این مقدار بزرگتر از RMS (برای مثال 0.00361 cm/sec) مشاهده شده با استفاده از داده‌های آموزش است. هرچند، مقدار RMS مقادیر به دست آمده به وسیله معادله لرزش آتشباری با (در مقایسه با) داده‌های آموزش 0.0150 cm/sec است.

جدول ۳-۴- داده های تست برای دسترسی به شبکه بهینه برای پیش بینی PPV [۱۹]

Sample Number	S-21	S-22	S-23	S-24
Tunnel orientation	090	090	090	090
Major dip direction	086	086	086	081
discontinuity dip	86	86	86	88
spacing	2	2	2	3
separation	2	2	2	2
persistence	2	2	2	2
Secondary dip direction	005	005	005	357
discontinuity dip	73	73	73	77
spacing	2	2	2	2
separation	3	3	3	2
persistence	3	3	3	3
Rock strength	4	4	4	5
RQD	2	2	2	2
RMR	52	52	52	56
Drilling length (m)	1.70	1.70	1.70	2.20
Blasting efficiency (%)	88.2	88.2	88.2	81.8
Charge weight per delay (kg)	2.56	2.56	2.56	3.20
Distance (m)	70.0	80.5	93.5	93.9

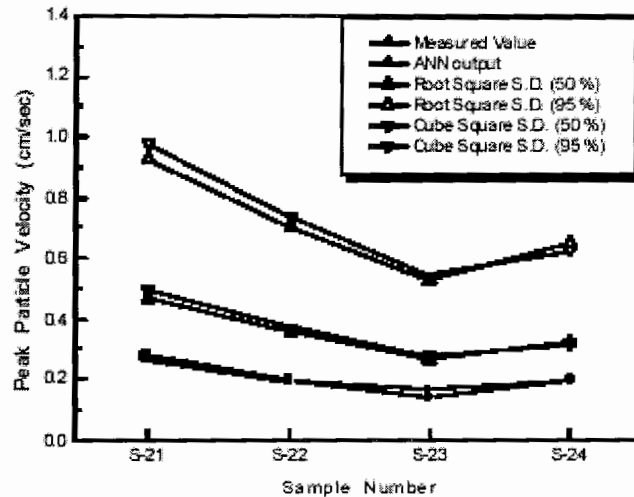
جدول ۳-۵- نتایج مقایسه بین مقادیر به دست آمده بوسیله شبکه عصبی و مقادیر واقعی حداکثر سرعت ذرات [۱۹]

Sample Number	Peak Particle Velocity (cm/sec)		Error	
	Measured value	Value predicted by ANN	Absolute Error (cm/sec)	Relative Error (%)
S-21	0.28	0.265	0.015	5.36
S-22	0.20	0.193	0.007	3.50
S-23	0.14	0.166	-0.026	-18.57
S-24	0.20	0.195	0.005	2.50

شکل (۳-۲) مقدار اندازه گیری شده و مقدار پیش بینی شده توسط شبکه عصبی و مقدار به دست آمده به وسیله معادله‌های لرزش آتشباری یعنی معادلات (۳-۳) و (۳-۶) را بیان می کند. این شکل نشان می دهد که مقدار پیش بینی شده از معادلات ۶۰٪ بیشتر از مقدار اندازه گیری شده

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل

(واقعی) است، که به این معنی است که معادلات نمی تواند به طور کافی شرایط زمین شناسی را منعکس کند.



شکل ۳-۲- مقایسه بین مقادیر پیش بینی شده و مقادیر واقعی PPV [۱۹]

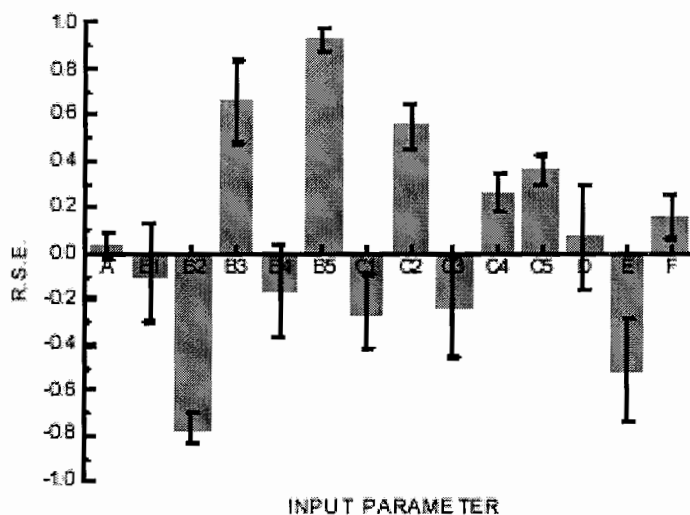
بنابراین، پیش بینی سرعت با استفاده از شبکه عصبی از روش‌هایی که از معادلات لرزش آتشباری استفاده می کنند دقیق تر است یعنی، نتایج تحلیل رگرسیون با استفاده از داده‌های اندازه گیری شده که تنها شرایط زمین شناسی محلی را منعکس می کند، به دلیل حداکثر سرعت ذرات بستگی به شرایط زمین شناسی دارد.

۳-۵- اثر مقاومت (استحکام) نسبی

اثر مقاومت نسبی (RSE) مقدار مؤثر بودن مقادیر متفاوت ورودی بر یکی از مقادیر خروجی را بیان می کند. وقتی که مقدار RSE بزرگ تر می شود اثر بر خروجی‌ها بیشتر می شود و هر RSE نشان می دهد که ورودی‌ها چگونه بر خروجی‌ها اثر می گذارند. اگر خروجی‌ها وابستگی با ورودی‌ها نداشته باشند، مقدار RSE، صفر می شود و وقتی که مقدار مثبت است، اثر مثبت بر خروجی‌ها دارد و وقتی که مقدار منفی باشد، اثر منفی بر خروجی‌ها دارد (یانگ و همکارانش، ۱۹۹۸).

شکل (۳-۳)، مقدار میانگین RSE برای هر ورودی برای داده‌های آموزشی که برای پیش بینی خرج ویژه در آتشباری تونل استفاده می شوند را نشان می دهد.

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل



شکل ۳-۳- مقدار میانگین RSE هر پارامتر ورودی برای داده های آموزش [۱۹]

در شکل، طول خط کشیده شده بالای هر ستون واریانس مقادیر RSE را شرح می دهد. بنابراین، در این حالت تونل، یک سلسله مراتب از پارامترهای ورودی روی خرج ویژه ملاحظه می شود :

۱- دوام ناپیوستگی های اصلی (B5)، شیب (B2) و فاصله داری ها (B2).

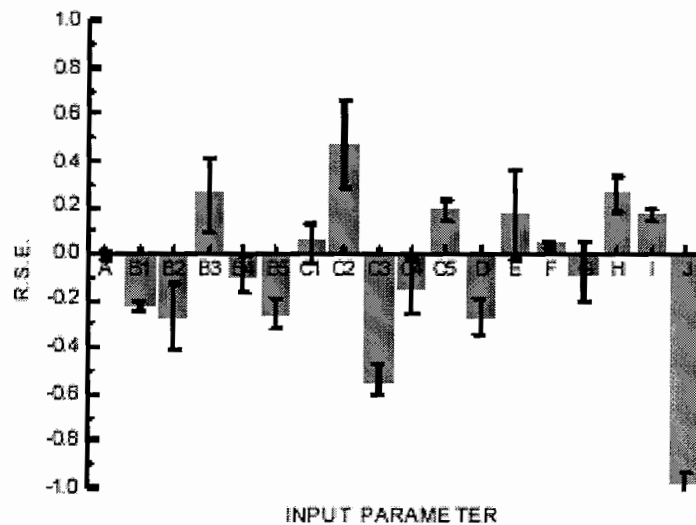
۲- RQD (E)، شیب ناپیوستگی های ثانویه (C2).

۳- دوام ناپیوستگی های ثانویه (C5)، جدایش (C4)، جهت شیب (C1)، فاصله داری (C2).

۴- RMR (F)، جدایش ناپیوستگی های ثانویه (B4)، جهت شیب (B1) و جهت تونل (A).

در حالتی که داده های آموزش یافته برای پیش بینی حداکثر سرعت ذرات در آتشباری تونل استفاده می شوند، مقدار میانگین RSE برای هر پارامتر ورودی در شکل (۳-۴) نشان داده شده است.

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل



شکل ۳-۴- مقدار میانگین برای هر پارامتر ورودی برای داده های آموزش [۱۹]

در این شکل، نشان داده می شود که فاصله بین نقاط آتشباری و نقاط اندازه گیری (J) یک فاکتور بسیار موثر حداکثر سرعت ذرات در بین ۱۶ پارامتر ورودی است. با توجه به اینکه فاصله داری ناپیوستگی ثانویه (C۳) و شیب (C۲)، شیب ناپیوستگی اصلی (B۲) و دوام سنگ (D)، بر حداکثر سرعت ذرات اثر دارند، واریانس پارامترها زیاد است. جهت گیری تونل (A) و RMR (F)، اثر کمتری نسبت به پارامترهای ورودی دیگر دارند.


اجرای عملیات آتشباری تونل در محدوده ای که برای سرعت ذرات اجازه داده شده است و برای ماکزیمم کردن راندمان آتشباری مهم است. بنابراین، لازم است که پارامترهای ورودی که بر حداکثر سرعت ذره که توسط لرزش آتشباری در راندمان های مختلف آتشباری تولید می شود اثر می گذارند، مورد بررسی قرار گیرند.

برای داده های آتشباری با راندمان بالا (داده های شماره ۱ و ۲ و ۵ و ۶) و گروه ضعیف (داده های شماره ۱۵ و ۱۹ و ۲۰) در طی آموزش داده ها برای شبکه عصبی، نتایج تحلیل RSE آزمایش شده اند. وقتی که راندمان آتشباری، یعنی نسبت مقدار واقعی به مقدار طراحی شده بیشتر از ۹۵٪ باشد، داده ها متعلق به گروه آتشباری با راندمان بالا است. از سوی دیگر، وقتی که راندمان آتشباری کمتر

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل

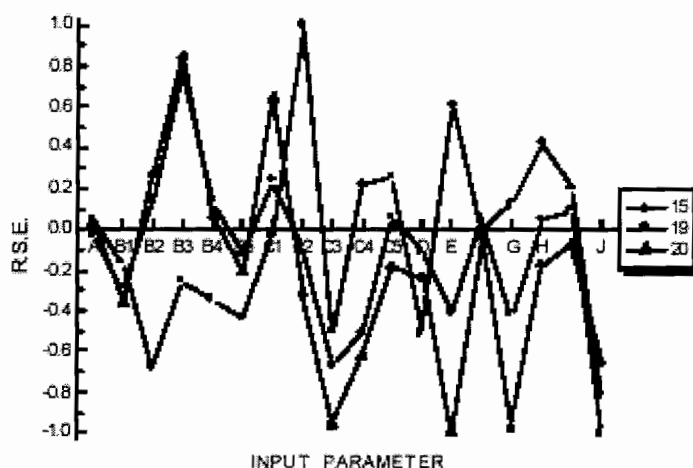
از ۸۰٪ است، داده متعلق به گروه با راندمان آتشباری ضعیف است. شکل (۳-۵) مقدار RSE گروه آتشباری با راندمان خوب و شکل (۳-۶) مقادیر گروه ضعیف را نشان می دهد.

شکل (۳-۶) نشان می دهد که به طور مستقل از راندمان آتشباری، فاصله بین نقاط آتشباری و نقاط اندازه گیری (J) اثر منفی بیشتری بر حداکثر سرعت ذرات در پارامترهای ورودی ملاحظه شده دارد. این به این معنی است که فاصله بیشتر باعث حداکثر سرعت کمتر برای ذره می شود. هم داده های گروه آتشباری با راندمان پائین و هم داده های گروه آتشباری با راندمان بالا منحنی مشابه هم می دهد که به وسیله مقدار RSE هر پارامتر ورودی لینک می شود. هرچند، واریانس مقدار RSE در آتشباری با راندمان بالا کمتر از آتشباری با راندمان پائین است. این نشان می دهد که تغییرپذیری پارامترهای ورودی که واریانس بزرگتری از مقادیر RSE دارند، اثر بیشتری بر سرعت وقتی که راندمان آتشباری کم باشد، دارند.



شکل ۳-۵- مقدار RSE برای آتشباری با راندمان بالا [۱۹]

کاربرد شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره در آتشباری تونل



شکل ۳-۶- مقدار RSE برای آتشباری با راندمان پایین [۱۹]

۳-۶- نتیجه گیری

در این مطالعه، شرایط زمین شناسی و آتشباری به طور مستقیم در ساختمان تونل اندازه گیری شده است و به منظور امکان به کار گیری شبکه عصبی برای پیش بینی خرج ویژه و حداکثر سرعت ذره مورد بررسی قرار گرفته است. پارامترهای مؤثر بر خرج ویژه و حداکثر سرعت ذره در آتشباری تونل به وسیله اصل RSE مورد مطالعه قرار گرفته است. نتیجه این مطالعه به این صورت است :

۱- مدل شبکه عصبی ساخته شده برای پیش بینی خرج ویژه، نشان می دهد که خطای RMS مقادیر پیش بینی شده در مقابل مقادیر واقعی 0.0433 kg/m^3 است. این مقدار بزرگتر از خطای RMS به دست آمده با استفاده از داده‌های آموزش است. هرچند، مقادیر پیش بینی شده فقط میانگین خطای مربوط برابر 4.72% داده‌های سنجیده شده (واقعی) دارد. بنابراین، این نتیجه می دهد که شبکه عصبی آموزش یافته قابلیت پیش بینی مناسبی در شرایط متغیر زمین شناسی دارد.

۲- مدل شبکه عصبی برای پیش بینی حداکثر سرعت ذرات نشان می دهد که خطای RMS مقادیر پیش بینی شده در مقابل مقادیر واقعی برابر با 0.156 cm/sec است. این مقدار بزرگتر از خطای RMS مشاهده شده با استفاده از داده‌ها آموزشی است. هرچند، خطای مربوط کمتر از 5% است و خطای RMS مقادیر پیش بینی شده با استفاده از معادلات لرزش ناشی از آتشباری با داده‌های

آموزشی 150 cm/sec است. بنابراین، پیش بینی سرعت با استفاده از شبکه عصبی دقیق تر از روش های با استفاده از معادله لرزش ناشی از آتشیاری است، یعنی، نتایج تحلیل رگرسیون با استفاده از داده های اندازه گیری شده (واقعی)، شرایط زمین شناسی محلی را منعکس می کند، به دلیل اینکه حداکثر سرعت ذرات توسط شرایط مختلف زمین شناسی تحت تأثیر قرار می گیرد.

۳- خرج ویژه در آتشیاری تونل توسط مشخصات ناپیوستگی های اصلی (یعنی، جهت شیب، شیب، فاصله داری و دوام) و RQD از بین ۱۴ پارامتر زمین شناسی که در این مطالعه مشاهده می شود تحت تأثیر قرار می گیرد.

۴- فاصله بین نقطه آتشیاری و نقطه اندازه گیری بیشترین اثر را در بین ۱۸ پارامتر ورودی بر روی حداکثر سرعت ذرات دارد و اگرچه فاصله داری و شیب ناپیوستگی های ثانویه، شیب ناپیوستگی های اصلی و مقاومت سنگ بر روی حداکثر سرعت ذرات اثر دارند، اما واریانس پارامترها بزرگ است. جهت گیری تونل و RMR، فاکتورهای دارای اهمیت کمتری نسبت به پارامترهای ورودی دیگر هستند [۱۹].

فصل چهارم

پیش بینی نشست زمین بر اثر معدن کاری زیر

زمینی با استفاده از شبکه عصبی مصنوعی

۴-۱- خلاصه

در کنار پیش بینی تجربی گزینه‌های دیگر مثل روش‌های توابع تأثیر و مدل‌های مکانیکی و روش شبکه عصبی مصنوعی می‌تواند برای پیش بینی نشست زمین استفاده شوند. در این مطالعه، یک شبکه عصبی پیشخور چند لایه مورد استفاده قرار گرفته است. آموزش و تست شبکه عصبی با توجه به داده‌های موجود انجام شده است. متغیرهای ورودی، پارامترهای استخراجی و مختصات نقاط مورد نظر می‌باشد و متغیرهای خروجی داده‌های نشست زمین را شرح می‌دهند.

بعد از اینکه شبکه عصبی به طور موفق آموزش داده شد و در قسمت جداگانه‌ای تست گردید، میزان فرورفتگی سطح زمین در بالای پروژه استخراج توسط شبکه عصبی پیش بینی گردید. قابلیت کاربرد شبکه عصبی مصنوعی برای پیش بینی نشست زمین در مدل‌های مختلف نشست مورد بررسی قرار گرفت و افق‌های مختلف استخراج واقعی به دست آمد و در افق‌هایی از داده‌ها در یک پروفیل سطحی در معدن ذغال ولنجه^۱ محک زده شد.

۴-۲- مقدمه

معدن کاری زیر زمینی سبب ایجاد یک شکل فرو رفتگی در سطح زمین می‌شود. پیش بینی نتیجه معدن کاری یک کار مهم برای معدن کاری است. اطلاعات درباره فعالیت سطح زمین که توسط معدن کاری ایجاد می‌شود و پیش بینی نشست زمین که امکان جبران کافی آن وجود ندارد، اثر مستقیمی بر نتایج اقتصادی معدن کاری دارد. پیش بینی دقیق و واقعی در کنار فاکتورهای دیگر، تأثیر زیادی بر چگونگی استراتژی معدنکاری دارد. با توجه به پارامترهای زیادی که بر رفتار سنگ در بالای فضای حفر شده تأثیر دارند، پیش بینی نتیجه معدنکاری یک کار لازم

^۱=Velenje

است. تصمیم گیری درباره همه این پارامترها کار سختی است و تصمیم گیری درباره میزان اثر آنها کار مشکل تری است.

جابجایی سطح زمین باعث آسیب در زمینه‌های مختلف بر روی زمین می شود بنابراین، هدف نقشه برداران معدن در این قرن تخمین اثر معدن کاری زیر زمینی بر ساختمان‌ها، سیستم حمل و نقل و سطح زمین در بالای معادن می باشد. آنها شروع به سنجیدن جابجایی نقاط در معادن و در سطح زمین کردند تا قادر به کنترل نشست و کم کردن زیان‌های ناشی از استخراج باشند. آنها برنامه رفتارنگاری جابجایی‌ها و توسعه روش‌های پیش بینی نشست زمین را در معادن خاص شروع کردند (Kratzsch, ۱۹۸۳) و چندین روش پیش بینی نشست ایجاد شد.

اولین روشی که برای پیش بینی نشست زمین استفاده شد، روش پیش بینی تجربی بود. این روش‌ها مبتنی بر ارتباط بین داده‌ها و نتایج مربوط به آنها با پارامترهای هندسی محل استخراج شده است (ارتفاع و عمق محل استخراج شده یا ضخامت و عمق لایه‌ها، مثل کیفیت استخراج و موقعیت لبه‌های (گوشه‌های) محل استخراج شده و غیره). وقتی که این روش‌ها در سطح خاصی سنجیده می شود، پارامترها به طور مستقیم با آن ناحیه رابطه دارند و نتایج تنها برای آن ناحیه اعتبار دارند. مثال برای آن روش‌ها عبارت است از: روش زاویه تقاطع^۲، روش روسی^۳، روش لهستانی^۴، روش مجارستانی^۵ و روش منحنی پروفیل برنامه ریزی شده^۶ و روش یکی کردن شبکه‌ها^۷ مثل مدل پیش بینی در معدن ذغال و لنجه.

مدل پیش بینی با توجه به تابع تأثیر، دومین گروه از روش‌های پیش بینی را تشکیل می دهد. تابع تأثیر برای توصیف میزان موثر بودن بخش اصلی استخراج شده، بر نشست زمین به کار می رود.

^۲ =The method of the angle of intersection

^۳ =Russian

^۴ =Polish

^۵ =Hungarian

^۶ =The programmed profile curve method

^۷ =Methods of the integration grid

این گروه از پیش بینی‌ها بر پایه هفت فرضیه می باشد که حساب کردن و کاربردی کردن روش را ساده می کند.

طرز کار این روش انتخاب تابع تأثیر برای هر معدن است و سپس درباره ضریبی که مطمئن می سازد که منحنی نشست زمین شبیه شکل نشست در طبیعت است تصمیم گیری می کند. این روش ساده و مؤثر است، اما محاسبه ضریب در معادله تابع تأثیر سخت است و در طبیعت نشست زمین توسط پدیده‌های زمین شناسی و ژئومکانیکی بسیاری تحت تأثیر قرار می گیرد.

سومین گروه از روش‌های پیش بینی شامل روش‌های مدل پیش بینی^۸ می شود. حدود این روش در مدل‌های ریاضی - فیزیکی^۹ است. رفتار سقف و توسعه نشست با توجه به قوانین مکانیک حساب می شود. مدل‌های الاستیک و پلاستیک نشست متعلق به این گروه از مدل‌های پیش بینی هستند. وقتی که از این مدل‌ها استفاده می کنیم، مسأله معمولاً با روش‌های عددی^{۱۰} حل می شود مانند روش‌های المان محدود^{۱۱}، المان متفاوت^{۱۲} و المان‌های مرزی^{۱۳}.

یک گزینه علاوه بر روش‌های بالا، پیش بینی نشست زمین با استفاده از شبکه عصبی مصنوعی است. مزیت مهم این روش پیش بینی نشست این است که احتیاج به دانستن حالت‌های زمین شناسی و ژئومکانیکی در شیب‌های بالای استخراج نیست. هرچند، احتیاج است که به داده‌های استخراج و داده‌های جابجایی نقاط در سطح زمین یا داده‌هایی که سبب نشست می شوند و داده‌های ناشی از استخراج دسترسی داشته باشیم. به دست آوردن این داده‌ها بسیار ساده‌تر از به دست آوردن همه داده‌های مؤثر لازم برای روش‌های قبلی ذکر شده برای پیش بینی نشست است.

^۸ = Model prediction method

^۹ = Mathematical-physical method

^{۱۰} = Numerical methods

^{۱۱} = Finit element method

^{۱۲} = Finit difference method

^{۱۳} = Boundary element method

۳-۴- مثال‌های عددی

نتایج پیش بینی نشست زمین با استفاده از شبکه عصبی با نتایج حاصل از روش اتفاقی (دارای تغییر در مواقع مختلف) پیش بینی نشست و مدل یک شکل پیش بینی برای معدن ذغال Velenje مقایسه شده است. سرانجام، کارآیی روش شبکه عصبی با توجه به نتایج واقعی سنجش نشست ناشی از معدن کاری زیر زمینی در معدن ذغال ولنجه کنترل شده است.

شبکه عصبی با استفاده از جفت‌های ورودی - خروجی داده‌های آموزشی به وسیله قانون دلتا^{۱۴} آموزش داده شده است. تکرار تا وقتی انجام می شود که خطا در همه جفت‌های ورودی و خروجی بیشتر از ۵٪ باشد. میزان خطا برابر با تفاوت مقدار واقعی و مقدار به دست آمده با توجه به شبکه عصبی است.

موفقیت آموزش شبکه عصبی با توجه به داده‌های تست با δ تفاوت، بین مقادیر واقعی نشست و مقادیر ملاحظه شده با توجه به شبکه عصبی ارزیابی می شود. برای دستیابی به این قضایا، موارد زیر استفاده می شود:

- مینیمم مقدار تفاوت‌ها $\delta_{\min} = \min_i \delta_i$

- ماکزیمم مقدار تفاوت‌ها $\delta_{\max} = \max_i \delta_i$

- میزان متوسط تفاوت‌ها $\bar{\delta} = \sum_i \delta_i / N_{i-o}$

- میزان انحراف از معیار برابر است با: $S = \sqrt{\left(\sum_i \delta_i - \bar{\delta} \right)^2 / (N_{i-o} - 1)}$

- میزان میانگین واریانس برابر است با: $d = \sum_i |\delta_i - \bar{\delta}| / N_{i-o}$

که در این رابطه N_{i-o} تعداد زوج‌های ورودی - خروجی است.

^{۱۴} = Delta rule

در طی تحقیقات اولیه (مقدماتی)، مقایسه بین روش منحنی پروفیل برنامه ریزی شده و تخمین روش شبکه عصبی انجام می شود. تحقیقات اولیه این نتایج را می دهد: اول اینکه، استفاده از شبکه عصبی برای طولها و عمقهای متفاوت استخراج، ممکن (مناسب) است. به علاوه، شایسته است که از یک شبکه بندی از دادههای جفتی ورودی و خروجی استفاده شود. شبکهها می توانند حتی با یک لایه مخفی از نرونها آموزش یابند و نتایج در صورت وجود سه لایه مخفی و یا بیشتر ضعیفتر است. در این مطالعه حالت بهینه هندسه شبکه، شبکه با دو لایه مخفی است که هر کدام شامل ۴۰ نرون می شوند.

شیب نشست در بالای فضای استخراج شده با استفاده از مدل اتفاقی نشست پیش بینی می شود. با هم جهت کردن این نقاط و محاسبه مسائل مربوط به نشست زمین، جفتهای ورودی - خروجی از دادههای آموزش و تست شکل می گیرند.

با توجه به مختصات x و y نقاط سطح زمین تحت نشست، دادههای ورودی شامل عرض، طول، عمق و ارتفاع فضای استخراج شده است. دادههای خروجی شامل نشست محاسبه شده و یا مقدار Z نقاط سطح زمین است. برای آماده کردن دادههای آموزش شبکه، هشت اندازه متفاوت از استخراج (جدول ۴-۱) استفاده شد. آنها در سه عمق مختلف قرار داشتند ($400m, 350m, 300m$) و ارتفاعهای متفاوت استخراج ($6m, 5m, 4m$) داشتند. نشست زمین در شبکه های مربعی با اضلاع مساوی در 11×11 نقطه توضیح داده شده است.

جدول ۴-۱ - مقدار عرض W و طول استخراج L در پروسه آموزش [۲۰]

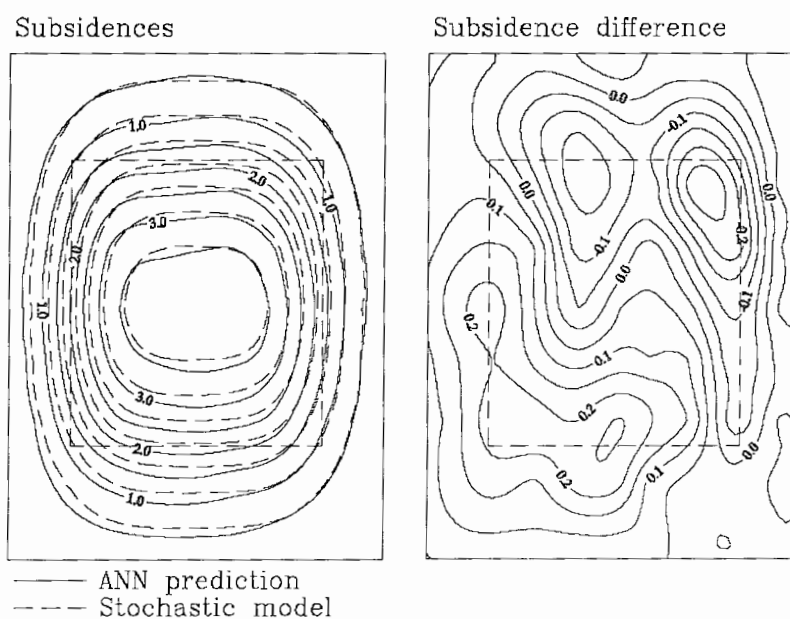
W (m)	200	200	250	300	300	350	400	400
L (m)	400	500	450	400	500	450	400	500

در دادههای آموزش $N_{i=0} = 8 \times 3 \times 3 \times 11 \times 11 = 8712$ جفت دادههای ورودی و خروجی وجود دارد. وقتی که نشست زمین محاسبه می شود، پارامترهای دیگر استخراج برای استخراجهای


مختلف یکسان است (زاویه شیب صفر درجه است، فاکتور نشست ۱ است، زاویه مؤثر در جهت شیب ۷۰ درجه است و در جهت گسل‌ها ۵۵ درجه است، محدوده نشت برای لبه نشست فاصله کف و سقف است و در جهت جدایش‌ها برابر با ۰.۱٪ ماکزیمم نشست است).

با توجه به تجربیات قبلی، شبکه عصبی با دو لایه مخفی و با ۴۰ نرون در هر لایه انتخاب شد. بنابراین هندسه شبکه ۱-۴۰-۴۰-۶ است. تعداد $1 \times 40 + 40 \times 40 + 40 \times 6 = 1880$ اتصال بین نرون‌ها وجود دارد و همان مقدار وزن که شبکه لازم دارد در مرحله آموزش تعریف شده است. همچنین، $40 + 40 \times 1 = 81$ مقدار برای آستانه تعیین شده است.

تست شبکه آموزش یافته برای مثال‌های متفاوت از استخراج‌ها انجام شد. شکل (۲-۴) نتایج پیش بینی نشست را که برای استخراج با عرض ۳۰۰m و طول ۴۰۰m و با ارتفاع استخراج ۴m و عمق متوسط ۳۲۵m می باشد، نشان می دهد. در این مطالعه، ریاضی تست عبارت است از $d = 0.065m$ و $S = 0.093m$ و $\bar{\delta} = 0.039m$ ، $\delta_{max} = 0.250m$ ، $\delta_{min} = -0.283m$ و درجه همبستگی $r = 0.997$ (شکل ۳-۴).



شکل ۲-۴- نشست مشاهده شده با استفاده از شبکه عصبی و روش stochastic [۲۰]



شکل ۴-۳- گراف همبستگی شبکه عصبی - مدل stochastic [۲۰]

علاوه بر پارامترهای قبلی ذکر شده، زاویه شیب هم به پارامترهای مؤثر بر نشست اضافه شده است. همه حفاریات مورد بحث برای سه زاویه شیب صفر درجه (همیشه حساب شد) و ۱۰ درجه و ۲۰ درجه محاسبه شده است. اگر نشست زمین به یک شبکه با 11×11 نقطه منتقل شود، در مجموعه داده‌های آموزش $N_{i=0} = 8712 \times 3 = 26136$ جفت داده ورودی-خروجی وجود دارد. با توجه به تعداد زیاد داده‌های ورودی و خروجی، تصمیم گیری با توجه به شبکه بندی برای نشست انجام نمی شود، بلکه نشست نقاط از پروفیل انتخاب شده انجام می شود. پروفیل انتخاب شده در شکل (۴-۴) نمایش داده می شود. پروفیل انتخاب شده (اصلی) شامل ۱۱ نقاط شبکه: از نقطه شبکه شماره ۶ تا نقطه شبکه شماره ۱۶ است. در پروفیل ارائه شده برای نشست $N_{i=0} = 11 \times 8 \times 3 \times 3 \times 3 = 2376$ جفت ورودی - خروجی برای داده‌های آموزش وجود دارد.

وقتی که مقادیر زاویه شیب برای Levelهای مختلف (حفاریات شیب دار) وجود داشته باشد، یک نرون زاویه شیبی که به داده‌های ورودی اضافه می شود را شرح می دهد. بنابراین ۷ نرون در لایه ورودی وجود دارد و هندسه شبکه عصبی به صورت ۷-۴۰-۴۰-۱ است.


تست کردن شبکه عصبی آموزش دیده در چندین پروفیل شکل می گیرد. شکل (۴-۵) نتایج تست استخراج‌ها با عرض ۲۰۰ m و طول ۴۵۰ m و ارتفاع استخراج ۵/۵ m و عمق استخراج ۳۲۵ m

پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی مصنوعی

و زاویه شیب صفر درجه (حالت اول) و نتایج استخراج‌ها با عرض ۴۵۰ m و طول ۴۵۰ m و ارتفاع استخراج ۵/۵m و عمق استخراج ۳۷۵ m و زاویه استخراج ۱۵ درجه (حالت دوم) را نشان می دهد. پارامترهای آماری این تست‌ها در جدول (۲-۴) نشان داده شده است.



جدول ۲-۴- مقایسه بین میزان تخمین زده شده توسط شبکه عصبی و نشست واقعی [۲۰]

	δ_{min} (m)	δ_{max} (m)	δ (m)	s (m)	d (m)
First case	-0.181	0.349	0.049	0.160	0.126
Second case	-0.182	0.222	0.006	0.121	0.100



شکل ۴-۴- پروفیل اصلی برای نمایش و ارزیابی نشست [۲۰]

پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی مصنوعی



شکل ۴-۵- نشست پروفیل اصلی به دست آمده از شبکه عصبی و روش stochastic [۲۰]

۴-۴- مقایسه با مدل پیش بینی یکسان (یک شکل) برای معدن ذغال ولنجه

پیش بینی نشست شیب در بالای سطح استخراج با استفاده از شبکه عصبی با استفاده از نشست ملاحظه شده به وسیله یک مدل پیش بینی یک شکل از معدن ذغال ولنجه ادامه یافت.

برای آموزش شبکه عصبی، ۳۳ افق از جنوبی ترین قسمت استخراج شده پرلوگ^۱ در معدن ذغال ولنجه با پارامترهای زیر استفاده شد (شکل ۴-۶) ارتفاعهای افق ها یا نامشان از ET.k.+۱۰۰ تا ET.K.-۶۵/D.

- عرض افق ها از ۶۲ m تا ۱۴۱ m.

- طول افق ها از ۸۲ m تا ۸۵۳ m.

- عمق متوسط افق ها از ۲۶۰ m تا ۴۲۵ m.

- زاویه شیب افق ها برابر با صفر درجه است.


- ارتفاع حفریات از ۸ m تا ۱۳/۹ m است.

- فاکتور نشست برابر ۰/۸۶.

- میانگین زاویه باقیمانده از زاویه اصطکاک داخلی برابر با ۲۳ درجه.

پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی مصنوعی

در معدن ذغال و لنجه افق ها با $ET.k.+h$ نامگذاری می شوند، که h برابر با ارتفاع از سطح دریا به متر است. ناحیه تحت تأثیر حفریات تمام سطوح، توسط یک شبکه از نقاط پوشیده شده است. در این نقاط، میزان نشست که با توجه به هر سطح (تراز) خاص ایجاد می شود محاسبه شده است. در کنار مختصات، داده های ورودی شامل طول و عرض افق، چرخش از محورهای اصلی افق ها در سیستم مختصات، ارتفاع حفریات در افق، در فاکتور نشست ضرب شده و مختصات x و y مراکز و عمق ترازها می باشد.



شکل ۴-۶- استخراج های آموزش و تست و نقاط پروفیل در معدن ذغال و لنجه [۲۰]

هندسه شبکه عصبی به صورت ۱-۴۰-۴۰-۹ است. بنابراین، ۹ نرون در لایه ورودی و ۲ لایه میانی که در هر لایه ۴۰ نرون وجود دارد و یک نرون در لایه خروجی وجود دارد. وقتی که نشست توسط شبکه ها نشان داده می شود، سطح تأثیر از یک شبکه ۲۰×۲۰ نقطه تشکیل می شود. چون تعداد افق های مورد استفاده ۳۳ عدد می باشد، شبکه انتخاب شده شامل ۱۳۲۰۰ جفت ورودی - خروجی در داده های آموزش می شود. چون تعداد جفت های ورودی - خروجی زیاد است، ما تعداد آنها را با برداشتن تعدادی به صورت رندوم از آنها کاهش می دهیم. بنابراین ۶۰٪ داده ها یا ۷۹۸۹ جفت داده برای آموزش باقی می ماند.

برای تست کردن شبکه عصبی، ما از تراز ET.K.-۸۰/A از جنوبی ترین ناحیه استخراج پرلوگ با پارامترهای زیر استفاده می کنیم: (در شکل (۴-۶) تراز تست علامت گذاری شده است).

- عرض تراز برابر با ۱۰۱ m.

- طول تراز برابر با ۷۹۴ m.

- عمق متوسط تراز ۴۴۰ m.


- زاویه شیب تراز صفر درجه.

- فاکتور نشست ۰/۸۶.

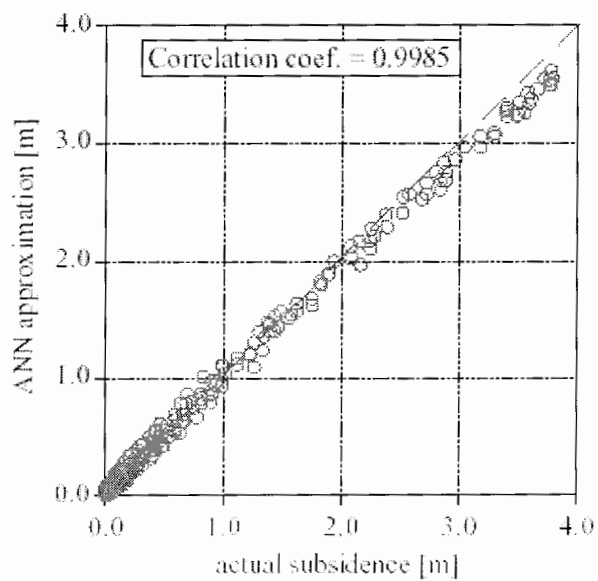
- متوسط زاویه باقیمانده از اصطکاک داخلی ۲۳ درجه.

نتایج تست در شکل (۴-۷) نشان داده شده است.

شکل نشان می دهد که نشست پیش بینی شده برای یک قسمت بزرگ، شبیه یکی از قسمت هایی است که توسط شبکه عصبی محاسبه شده است. در این مطالعه، پارامترهای آماری داده های تست عبارت است از: $\delta_{\min} = -0.300\text{ m}$ ، $\delta_{\max} = 0.180\text{ m}$ ، $\bar{\delta} = -0.004\text{ m}$ و $S = 0.071$ و $d = 0.44\text{ m}$ و درجه همبستگی $r = 0.998$ (شکل (۴-۸) را ببینید).



شکل ۴-۷- نتایج تست در سطح ET.K.-۸۰/A [۲۰]



شکل ۴-۸- گراف همبستگی مدل پیش بینی شبکه عصبی برای معدن ذغال ولنجه [۲۰]

سرانجام، نشست شیب در بالای تراز استخراج شده با استفاده از داده‌های تهیه شده از نقشه برداری معدن ذغال ولنجه پیش بینی شده است. داده‌ها به دو گروه می‌تواند تقسیم شود :

نخستین مجموعه شامل داده‌های متعلق به نقاط در پروفیل انتخاب شده است، که توسط گوه آهنی پایدار می‌شود (شکل ۴-۶) که شامل موقعیت مختصات نقاط، سن ترازها و بلندی ترازها از نقاط است. داده‌ها برای ۳۷ نقطه که در ۴ پروفیل‌اند، می‌باشند.

دومین مجموعه شامل داده‌های متعلق به افق‌ها است (شکل ۴-۶) که عبارتند از : نام افق‌ها، شرح ارتفاع آنها، مختصات گوشه‌ها و نقاط شکستگی ترازها، ارتفاع استخراج ترازها و فاکتور نشست، جهت استخراج در تراز و زمان اولین و آخرین روز استخراج در تراز. ما از داده‌های ۳۳ تراز از جنوبی‌ترین ناحیه استخراج پرلوگ در معدن ذغال ولنجه استفاده می‌کنیم که در طی سال‌های ۱۹۷۳ تا ۱۹۹۷ استخراج شده است. داده‌های موجود به ما اجازه می‌دهد تا جفت‌های ورودی و خروجی از داده‌های آموزش و تست را شکل دهیم.

با توجه به مختصات گوشه‌ها و نقاط شکستگی گوشه‌های ترازها، ترازهای مستطیلی (چهارگوش) به همان طریق ترازهای چهارگوش جدید حساب می‌کند که سطح چهارگوش‌ها مشابه حالت واقعی یکی از آنها است و آنها را با حالت ترازهای واقعی تا حد ممکن سازگار می‌کند. یک انتقال با توجه به شکل مختلف ترازها لازم است که از حالت چهارگوش با قاعده که با ۴ نقطه بالای شکل توسط ۲۲ نقطه ایجاد می‌شود انجام شود. از طرف نقاله گوشه، مختصات شکل چهارگوش انتقال یافته ترازها، طول و عرض ترازها، چرخش‌های محورهای تراز اصلی در سیستم مختصات و مختصات X و Y مرکز ترازها، محاسبه می‌شود. پارامترهای ذکر شده از ترازها اولین ۵ متغیر ورودی لازم برای آموزش و تست شبکه عصبی را تشکیل می‌دهند. ششمین متغیر ورودی ارتفاع استخراج هر تراز ضربدر فاکتور نشست است. برای مقدار فاکتور نشست مقدار ۰/۸۶ را فرض می‌کنیم. هفتمین متغیر ورودی عمق هر تراز است که با توجه به بلندی هر تراز محاسبه می‌شود، فرض می‌شود که ارتفاع سطح زمین از سطح دریا ۳۶۰ متر است.

با توجه به تحلیل ترازهای استخراج، این نتیجه قطعی می شود که در همه سالها نشست هر نقطه از سطح به وسیله دو تراز تحت تأثیر قرار می گیرد. این یافته‌ها شکل فایل داده‌ها با جفت‌های ورودی و خروجی را برای آموزش و تست دیکته می کند. اینها به همین طریق ترکیب می شوند که دو تراز بر نشست نقاط مربوط به هر تراز اثر می گذارند. وقتی که هر تراز با هفت پارامتر شرح داده می شود، هر جفت ورودی و خروجی شامل ۱۷ متغیر است. ۱۶ متغیر اول مربوط به داده‌های ورودی‌اند. ۷ متغیر اول مربوط به اولین تراز مؤثر است و ۷ متغیر دوم مربوط به دومین تراز مؤثر است و ۱۵ و ۱۶ امین متغیرهای ورودی برای مختصات X و Y نقاط پروفیل انتخاب شده سطح است. ۱۷ امین متغیر داده‌های خروجی را بیان می کند: نشست نقطه تراز از پروفیل انتخاب شده در سطح در یک سال معین.

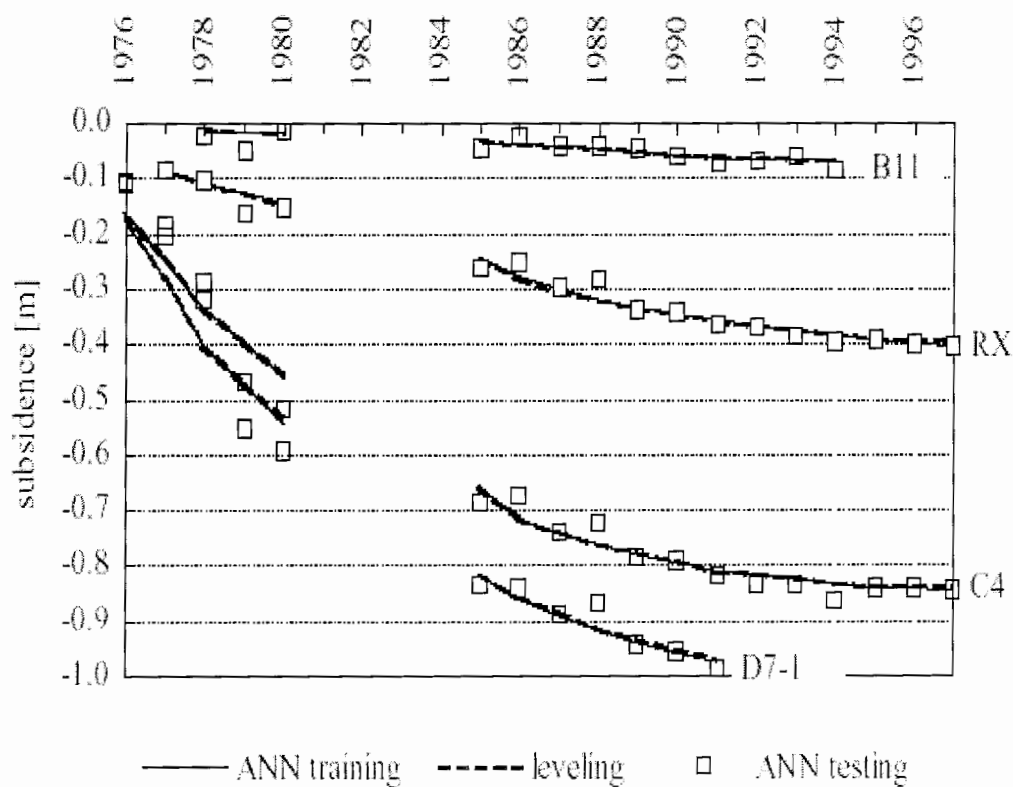
هندسه شبکه عصبی به صورت ۱-۴۰-۴۰-۱۶ است، در جایی که تعداد نرون‌ها در لایه ورودی وابسته به تعداد متغیرهای ورودی است و یک نرون در لایه خروجی داده خروجی را بیان می کند. هر کدام از دو لایه مخفی شامل ۴۰ نرون است.

آموزش و تست شبکه عصبی به تدریج انجام می شود. ابتدا شبکه عصبی با توجه به داده‌های ۵ سال از استخراج‌ها آموزش می یابد (از ۱۹۷۴ تا ۱۹۷۸). سپس شبکه عصبی آموزش یافته با داده‌های سال ششم تست می شود (۱۹۷۹). پیش بینی مشاهده شده از نشست نقاط با نتایج ترازها مقایسه می شود (نتایج در سال ۱۹۷۹ مشاهده می شود) (نتایج واقعی) و میزان موفقیت آموزش شبکه به دست می آید. سپس شبکه عصبی برای داده‌های ۶ سال اول استخراج (از سال ۱۹۷۴ تا ۱۹۷۹) آموزش می بیند و نشست در سال هفتم (۱۹۸۰) پیش بینی می شود و با مقادیر به دست آمده از سال ۱۹۸۰ (واقعی) تست می شود. این روال برای همه دوره‌ها برای هر کدام از داده‌ها در ترازها تکرار می شود. در مثال بعدی آموزش، تراز استخراج مورد استفاده از $ET.k=100$ تا $ET.k=65/D$ است و پیش بینی برای تراز $ET.k=80/A$ تست می شود. نتایج تست در شکل (۴-۹) نشان داده شده است.

پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی مصنوعی

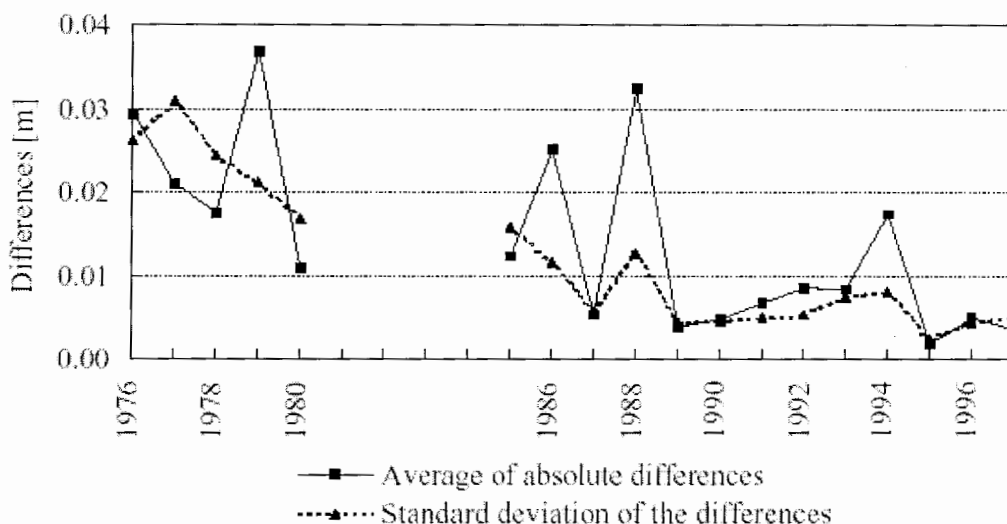
در طی سال‌های ۱۹۸۱ تا ۱۹۸۴ که ۳ یا ۴ تراز وجود داشتند که نقاط نشست را تحت تأثیر قرار می دادند، داده‌های روی ترازها و ترازبندی در این زمان در پروسه آموزش شبکه دیده نمی شود.

شکل (۹-۴) و (۱۰-۴) نشان می دهد که پیش بینی نشست نقاط زمین با استفاده از شبکه عصبی با پذیرفتن اینکه در سال‌های ۱۹۷۹، ۱۹۸۶، ۱۹۸۸ و ۱۹۹۴ که یک مقدار انحراف از مقدار اصلی با توجه به شبکه عصبی می تواند گزارش شود، به طور کامل رضایت بخش است.



شکل ۹-۴- نشست نقاط انتخاب شده از پروفیل [۲۰]

پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی مصنوعی



شکل ۴-۱۰- تفاوت بین پیش بینی شبکه عصبی و مقدار واقعی [۲۰]

دلیل این اختلاف عبارت است از :

- در سال ۱۹۷۹، نقاط سطح به وسیله تراز استخراج شده $ET.k.+60$ که در سال ۱۹۷۸ استخراج شده بود تحت تأثیر قرار گرفت و این تراز در قسمت غرب همه ترازهای استخراج شده قرار داشت.

- در سال ۱۹۸۶ و ۱۹۸۸، نقاط بر روی سطح به وسیله ترازهای استخراج شده در شرقی ترین قسمت جنوبی ترین محل استخراج بر لوگ تحت تأثیر قرار گرفتند و به وسیله آنها همه ترازها در غربی ترین قسمت استخراج شد.

- در سال ۱۹۹۴، تراز $ET.k.-45/B$ سبب آشفتگی در آموزش شبکه عصبی شد، آن در سال ۱۹۹۳ حفر شد که مرکز تراز در غربی ترین قسمت از ترازها قرار داشت.

همه محاسبات و ۴ نقطه پروفیل توضیح داده شده به ما اجازه می دهد که نتیجه گیری کنیم که تا وقتی که نتایج پیش بینی نشست نقاط شبیه به داده های ترازها است آموزش شبکه عصبی موفق است. بیشترین مقدار اختلاف بین نتایج محاسبه شده به وسیله شبکه عصبی آموزش دیده و داده های واقعی ترازها در نقطه X_1 در سال ۱۹۹۷ بود که حدود 34mm بود که کمتر از 10% نشست بود و نشست نهایی در نقطه X_1 383mm بود. درجه همبستگی 0.9980 در فاز آموزش و 0.9873 در فاز تست بود.

پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی مصنوعی

۴-۵- نتیجه گیری

این پروژه به پیش بینی نشست زمین بر اثر معدن کاری زیر زمینی با استفاده از شبکه عصبی منتهی می شود که موضوع تازه‌ای است و جدیدتر از روش‌های تجربی پیش بینی، روش‌های پیش بینی براساس تابع تأثیر و روش مدل پیش بینی است. در این تحقیق از شبکه عصبی پیشخور چند لایه استفاده می کند. کاربرد شبکه عصبی برای پیش بینی نشست زمین در ابتدا در مدل‌های مختلف چک شد (مدل پیش بینی نشست براساس روش منحنی پروفیل برنامه ریزی شده، روش اتفاقی و مدل پیش بینی یک شکل (همسان) برای معدن ذغال ولنجه).

در پایان نتیجه گرفته شد که شبکه عصبی با دو لایه مخفی با ۴۰ نرون در هر لایه نتایج رضایت بخشی می دهد. این ثابت کرد که موفقیت پیش بینی بستگی به حالت شرح دادن نشست ندارد. انحراف کمی بین مقدار پیش بینی شده و مقدار واقعی وقتی که نشست در شبکه ای از نقاط یا با نقاط توزیع شده در پروفیل‌ها ملاحظه می شود دیده می شود. میزان کاربردی بودن شبکه عصبی در یک حالت واقعی در تراز استخراج شده و در تراز داده‌ها در نقاط پروفیل سطح در معدن ذغال ولنجه نشان داده شده است. نتایج مشاهده شده توسط شبکه عصبی ربطی به حالت‌های زمین شناسی و ژئومکانیکی سقف ندارد. این البته یک امتیاز است و همچنین سخت است که در مورد پارامترهای مؤثر بر نشست تصمیم گیری کنیم و حتی سخت‌تر از آن تصمیم گیری درباره میزان اهمیت اثر آن است [۲۰].

فصل پنجم

کاربرد شبکه عصبی در طراحی تجربی
حفاری‌های زیر زمینی

۵-۱- خلاصه

یک روش تجربی برای طراحی نگهداری‌ها در ورودی‌های زیر زمینی با به کار بردن شبکه عصبی، یک پایگاه اطلاعات وسیع از داده‌ها، در این مقاله به کار رفته است. برنامه براینسل^۱ برای تحلیل انتخاب شده است و داده‌ها از ۲۹۲ موقعیت مورد مطالعه از ۶ معدن در کانادا به دست آمده است که رنج وسیعی از (RMR)ها و ابعاد دهانه‌ها را در بر می‌گیرد. داده‌های ورودی شامل، تقسیم بندی نوع سنگ‌ها و هندسه (ابعاد) باز کننده‌ها و خروجی برنامه، پایداری باز کننده‌ها است. شبکه عصبی که با آموزش داده‌ها ایجاد می‌شود برای پیش بینی پایداری در ۳۴۲ نقطه شبکه بین RMR و دهانه آنها مورد استفاده قرار گرفته است. نمودار طراحی دهانه‌ها با توجه به تحلیل به دست آمده و باعث بهبود در روش‌های تجربی برای تشخیص به پایداری حفاری‌های زیر زمینی شده است و پایگاه اطلاعات مورد استفاده برای آموزش شبکه در پیوست آمده است.

۵-۲- طراحی دهانه

معادن دارای ورودی احتیاج به محیط کاری با درجه پایداری بیشتر نسبت به معادن بدون ورودی دارند، که درجه پایداری بیشتری را برای این معادن می‌طلبند. در معادن بدون ورودی مثل معادن با کارگاه‌های باز، مقداری سست شدگی و جدا شدگی در سطح قابل قبول است. در روش‌های با ورودی مانند کندن و پر کردن، باید مقدار بیشتری از پایداری وجود داشته باشد که می‌تواند با افزایش نگهداری‌ها و یا کاهش دهانه به وجود آید. حداکثر فضای بدون نگهداری در زیر زمین بستگی به

^۱ =Braincel

فاکتورهای زیادی دارد که عبارتند از : خصوصیات توده سنگ، تنش برجا و شکل ساختار به وجود آمده (توسط حفاری‌ها) در توده سنگ.

ناپایداری سقف وقتی اتفاق می افتد که ابعاد فضاها بزرگ‌تر از ابعاد بحرانی فضاها می شود و تنش محیطی هم بیشتر از حالت بحرانی باشد. یک رابطه بین خواص توده سنگ و محیط اطراف و حداکثر دهانه پایدار بدون نگهداری وجود دارد.

دو محدودیت در طراحی دهانه ها برای طراحی‌های معدنی وجود دارد که در ساختارهای عمرانی زیرزمینی وجود ندارد. اول اینکه، طبیعت ورودی معدنی طوری است که کارگرها در معرض حفاریهای آتشی شده جدید قرار می گیرند. نگهداری در سقف به کار می رود و سپس آتشیاری ماده معدنی بعد از چند روز یا هفته انجام می شود. دوم، معادن سودآور معمولاً احتیاج به حداکثر استخراج ماده معدنی دارند که می تواند با افزایش دهانه باز کننده‌ها بهبود یابد. لزوم پایداری کوتاه مدت فضاها به همراه اقتصاد معدن محدودیتهایی در طراحی اعمال می کنند که در فضاهای زیرزمینی عمرانی اینگونه نیست. تعدادی از روشهای تجربی طراحی دهانه پیش از این توسط long، Bieniawski, Barton, Merritel و دیگران انجام شده است. این روشها، با استثناء نمودار دهانه بحرانی لانگ^۱ برای فضاهای زیرزمینی در کارهای مهندسی عمران که معمولاً پایداری در مدت طولانی نیاز دارند، ارائه شده اند. تعدادی از این روشها برای معادن استفاده شده است، هرچند که، به جز در روش نمودر بحرانی، آنها فاقد پایگاه اطلاعات تجربی بودند تا این روشها را در محیط های معدنی قابل اعتماد و اقتصادی نماید.

۵-۳- گراف دهانه بحرانی لانگ

این گراف توسط اکثر معدنکاران کانادایی برای روش کندن و پر کردن پذیرفته شده است. این گراف برای طراحی اولیه دهانه اولیه کارگاه کندن و پر کردن استفاده می شود و محورهای نمودارش RMR در برابر دهانه است. هرچند، دو نقطه ضعف در اینجا وجود دارد. اول اینکه، یک روش تحلیل

^۱=Langs critical span graph

آماری برای استنتاج گراف مورد استفاده قرار گرفته است و بزرگترین عیب روشهای آماری از جمله تحلیل رگرسیون آن است که آن فقط بر پیش بینی مقادیر میانگین مبتنی است. داده‌های معدنی عموماً به صورت پراکنده‌اند (حول میانگین نیستند). بنابراین، استفاده از تحلیل های آماری باعث می شود که اکثر تخمینها بالاتر یا پایین‌تر از مقدار واقعی و معمول باشد. دوم اینکه، گراف منحصراً بر پایه ۱۷۲ مطالعه موردی از یک معدن (معدنی در کانادا) است و یک روش تجربی باید بر پایه دامنه وسیعی از شرایط زمین و محیط باشد تا کاربردی شود و روشی مانند حالت بالا که در یک معدن کار شده از لحاظ کاربردی بودن در جاهای دیگر محدودیت دارد. با توجه به این مسائل، پایگاه اطلاعاتی مورد استفاده قرار گرفته و قسمتی از تحقیقات در زیر گزارش شده است.

در این روش از طبقه بندی RMR، برای تعیین خصوصیات توده سنگ استفاده می شود. فاکتور جهت درزه‌ها در اینجا به طور مستقیم به کار نمی رود. اگر درزه‌ها دارای شیبی بین ۰ تا ۳۰ درجه باشند، یا درزه‌ها وشکافهای باز با شیب بین ۰ تا ۶۰ درجه وجود داشته باشند، مقدار ۱۰ را از RMR کم می کنیم. این تصحیح مثل تصحیح اولیه RMR برای جهت داری است. هر چند، این مقدار مستقل از امتداد درزه‌ها نسبت به امتداد باز کننده‌ها می باشد. این روش برای حالتی که در سقف بازکننده‌ها تنش کم و یا بدون تنش باشد مورد استفاده قرار می گیرد. کار بعدی که پیشنهاد شده است این است که می توان در مناطق با تنش بالا ۲۰ را از RMR کم کرد. داده‌های این مقاله شامل حالتهایی با تنش بالا و یا حالت انفجاری نمی شود.

گراف حالت تجربی دارد و محدودیت‌های بسیاری برای کار کردن با این روش وجود دارد. تعدادی از محدودیت‌ها در به کارگیری این تکنیکها وجود دارد عبارتند از :

- ۱- دهانه قطر بزرگترین دایره‌ای است که می توان بین پایه‌ها و مرزهای کارگاه‌ها در سقف کارگاه‌ها ایجاد کرد. پایداری پایه‌ها برای طراحی قابل اعتماد دهانه ضروری است.
- ۲- سقف کارگاه‌ها باید نگهداری موضعی داشته باشد.

۳- در شرایطی که تنش‌های بالا بر پایداری تاثیر دارند، قابلیت اعتماد کمی وجود دارد.

۴- سقف کارگاه^۱ افقی است.

۵- منظور از اصطلاح پایدار، پایداری کوتاه مدت (تقریباً ۳ ماه) می باشد.


۶- قبل از این که این روش طراحی به طور مطمئن مورد استفاده قرار گیرد، گوه‌های جدا شده را باید به طرز مناسبی نگهداری کرد.

گراف بحرانی شامل دو خط مستقیم می شود که RMR را در مقابل دهانه به سه ناحیه تقسیم می کند (پایدار، دارای پتانسیل ناپایداری، ناپایدار) که در شکل (۵-۱) نشان داده شده است. خطوط براساس داده‌های RMR در دامنه ۸۰-۶۰، برآزش شده‌اند، اما در خارج از این محدوده، انحراف قابل توجه دیده می شود. برای رسیدن به طراحی بهتر و واقعی‌تر مطالعه بیشتری با استفاده از شبکه عصبی مصنوعی با اضافه کردن داده‌های ۶ معدن متفاوت انجام شده است.

۴-۵- طراحی دهانه‌ها با استفاده از شبکه عصبی مصنوعی

بینیواسکی یک رابطه بین دهانه، RMR و زمان پایداری را نشان داده است. دهانه بزرگتر به ازای هر RMR، زمان پایداری کمتری را می دهد. در این مطالعه اکثر داده‌ها از کارگاه‌های معدن کندن و پر کردن، در جایی که کارگاه‌ها ۱۲ ماه یا بیشتر پایدارند، می باشد. در این مطالعه حفاریات پایدار را حفاریات با سه ماه پایداری می باشند. پایداری حفاریات یکی از سه حالت پایدار، دارای پتانسیل ناپایداری، ناپایدار می باشد.

^۱=Back



شکل ۵-۱- گراف بحرانی دهانه [۲۱]

۵-۴-۱- حفاری پایدار

باید دارای سه حالت باشد:

- ۱- ریزش کنترل نشده زمین وجود نداشته باشد.
- ۲- جابجایی قابل توجه سقف که ممکن است بر پایداری اثر بگذارد وجود نداشته باشد.
- ۳- نگهداری غیرعادی مثل میل مهارها وجود نداشته باشد (الگویی از بولت‌ها ممکن است برای کنترل افتادن سطوح به کار رود).

۵-۴-۲- حفاری دارای پتانسیل ناپایدار

یکی از این موارد باید به کار رود:

- ۱- گسل / برش‌هایی با جهاتی که گوه‌هایی را در سقف به وجود می‌آورند. (پتانسیل گوه‌ای را به وجود می‌آورند).
- ۲- نگهداری ویژه زمین برای پیشگیری از ریزش زمین نصب شود.
- ۳- ابزاربندی‌ها جابجایی پیوسته در سقف را نشان دهند.

۴- میزان شکستگی ها و پوپ^۱ ها به طور متناوب افزایش یابد که نشانه جابجایی زمین است.

۵-۴-۳- حفاری ناپایدار

یکی از این دو مورد باید اتفاق بیفتد :

۱- ریزش غیر قابل کنترل ایجاد شده باشد یعنی

(a) ریزش زمین معمولاً باعث شکست در سیستم نگهداری شود، یا در حالت بدون نگهداری، گسترش مقدار شکست در حدی باشد که اگر نگهداری نصب شود باعث صدمه زدن به آن شود.

۲- کارگاه‌ها ناپایدار باشد و شکست با وجود نگهداری شدید زمین اتفاق افتد.

این سه کلاس پایداری برای تحلیل با شبکه عصبی به کار رفته است.

۵-۵- پایگاه اطلاعات برای تحلیل توسط شبکه عصبی

داده‌هایی که برای مطالعه جمع شده‌اند شامل داده‌های شش معدن در کانادا است. داده‌های فوق شامل ۲۹۲ داده می باشند. منابع برداشت داده‌ها در جدول (۵-۱) نشان داده شده است. هر مطالعه موردی شامل اطلاعاتی از شرایط توده سنگ، است که شامل RMR و دهانه و پایداری باز کننده ها می شود. این داده‌ها در پیوست آورده شده است.

جدول ۵-۱- منابع مطالعه موردی [۲۱]

Mine	Number of data cases			
	Total	Stable	Potentially unstable	Unstable
Detour Lake mine, 1994	172	94	37	41
Detour Lake mine, 1999	22	10	0	12
Photo Lake mine	6	0	6	0
Olympias mine	13	4	1	8
Brunswick Mining	17	5	3	9
Mussel White mine	46	35	10	1
Snip Operations	16	12	2	2
Summary	292	160	59	73

^۱ =Pop

مقدار RMR بین ۲۴ تا ۸۷ و دهانه از ۲ تا ۴۱ متر برای ۲۹۲ حالت تغییر می کند. ۶۳٪ RMRها بین ۶۰ تا ۸۰ است. اندازه دهانه ها در ۹۶٪ حالتها بین ۲/۳ تا ۲۶ متر است. افراد تخمین زننده RMRها متفاوت‌اند. این باعث متغیر بودن و کم دقت بودن داده‌های ورودی می شود، هر چند، در این مطالعه موردی، در مقدار تخمین بعد دهانه ، این مقدار خطا کمتر از 1^m است که این، توالرانس طراحی گرافیکی است. قابلیت تغییر در تخمین RMR می تواند مناسب تر باشد و بستگی به تجربه مهندسی برداشت کننده داده‌ها دارد. برای افراد با تجربه قابلیت تغییر مقادیر $RMR_{۷۶}$ تخمین زده شده بین $\pm 10\%$ درصد است. در همه موارد بهترین حدس و یا میانگین مقدار RMRها برای تحلیل مورد استفاده قرار می گیرد.

۵-۶- طراحی دهانه توسط شبکه عصبی مصنوعی

در این مطالعه برنامه شبکه عصبی براینسل استفاده شد. براینسل یک شبیه سازی کامپیوتری شبکه عصبی است که احتیاج به نرم افزار MS Excel دارد. یک محیط قدرتمند و انعطاف پذیر Excel میزان ظرفیت شبکه عصبی را بسیار بالا می برد. شبکه عصبی براینسل مراحل زیر را در بر دارد:

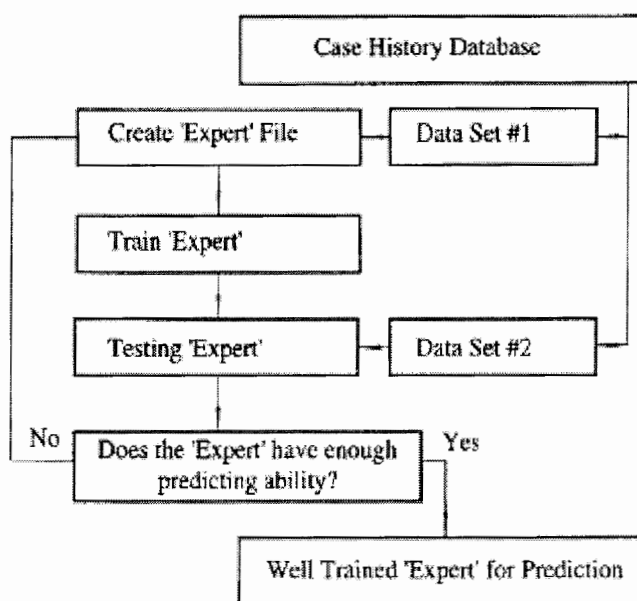
- پردازش داده‌ها و نصب کردن مساله برای براینسل.
- تعریف کردن داده‌ها برای آموزش و تست کردن.
- درست کردن فایل "Expert" که شامل تنظیم کردن ساختارها و پارامترهای کنترل کننده آموزش می شود.

۴- آموزش Expert بر روی داده‌های آموزشی.


۵- تست کردن پیش بینی و شبکه با توجه به داده‌های تست.

۶- استفاده از Expert به طور کامل آموزش یافته برای پیش بینی کردن.

شکل (۲-۵) یک فلوجارت از چگونگی کار شبکه عصبی را نشان می دهد. داده‌های ورودی ۲۹۲ حالت شامل RMR، Q و دهانه می باشد. چگونگی حالت پایداری حفاری‌ها، خروجی برنامه اند. شکل (۳-۵) ساختار پروسه شبکه عصبی را شرح می دهد. پایداری به صورت شماره (۱ و ۲ و ۳) بیان می شود که به ترتیب نشانگر حالت پایدار، دارای پتانسیل ناپایداری و ناپایدار است. داده‌ها در ابتدا به دو قسمت داده‌های آموزش و تست تقسیم می شوند. داده‌های آموزش شامل ۶۰٪ داده‌ها و داده‌های تست شامل ۴۰٪ داده‌ها می شود.



شکل ۲-۵- فلوجارت شبکه عصبی [۲۱]

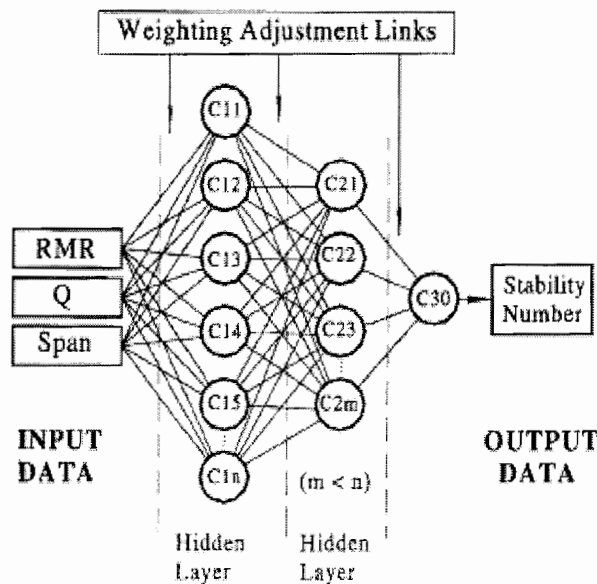


شکل ۳-۵- ساختار پروسه شبکه عصبی [۲۱]

بعد از آموزش دادن، تست کردن و تعدیل کردن و رسیدن به ظرفیت پیش بینی رضایت بخش در دامنه داده های آموزش، همه داده‌ها برای آموزش Expert با استفاده از داده‌های مشابه آموزش استفاده می شود. بهترین Expert آموزش شبکه عصبی سپس برای پیش بینی در یک شبکه، 19×18 (۳۴۲ نقطه) مورد استفاده قرار می گیرد. به طور اتوماتیک یک ساختار داخلی از شبکه عصبی را با اختصاص دادن وزن‌ها بین ورودی‌ها و خروجی‌ها ایجاد می کند. این ساختار به طور دستی شکل می گیرد. شکل (۴-۵) ساختار داخلی شبکه عصبی را شرح می دهد.

برنامه براینسل بسیاری از مراحل آموزش را نشان می دهد. پیکربندی دینامیک و داخلی شبکه عصبی کنترل می شود و به وسیله برنامه ایجاد می شود. هرچند، بسیاری از پارامترها می تواند به صورت دستی برای کمک به آموزش Expert براینسل ایجاد شود.

تعدادی از پارامترهای مورد استفاده شامل، میزان خطای قابل قبول، نرخ آموزش، دامنه وزن اولیه، تقویت کننده خطای خروج از مرکز^۱ و فاکتور خروج از مرکز^۲ می باشد.



شکل ۴-۵- تشریح ساختار داخلی شبکه عصبی [۲۱]

^۱ = Outlier error cap multiplier
^۲ = Outlier factor

۵-۷- خطای قابل قبول

مسائل مختلف دقت‌های مختلفی را لازم دارند. Expert انتظار می‌رود که دقیق باشد، اما آنقدر دقیق نیست که داده‌های آموزش را به خاطر بسپارد. این باعث ضعیف عمل کردن در شرایط جدید می‌شود. میزان خطا برای Expert میانگین خطای هر رکورد است. خطا برای هر رکورد خاص از رابطه زیر محاسبه می‌شود:

$$\text{خطا} = \frac{1}{4} \times \left| \frac{\text{داده خروجی شبکه (واقعی)} - \text{داده خروجی واقعی}}{\text{انحراف معیار داده‌های واقعی}} \right|$$

درصد خطا میزان متوسط اختلاف از انحراف معیار خروجی‌ها است. این خطا برای به دست آوردن درست دقت 'Expert' کافی نیست. دقت 'Expert' می‌تواند تنها با تست کردن داده‌های ورودی وقتی که برای این مطالعه خیلی پراکنده‌اند، تعیین شود، بنابراین، رسیدن به درصد خطای پائین بسیار سخت است. در کارهای مختلف میزان کمترین خطا ۱۲٪ است. ایجاد 'Expert' در داده‌های تست خطای آموزش مناسبی را لازم دارد.

۵-۸- پارامترهای آموزش

نرخ آموزش فاکتوری است که به شبکه در تنظیم وزن‌های خود کمک می‌کند. این نرخ برای مینیمم کردن اثر هر کدام از رکوردها بر پروسه آموزش طراحی می‌شود. برای مثال، اگر شبکه عصبی نتایجی را برای رکوردها به دست آورد که میزان تطبیق یافتن داده‌ها را کاهش دهد، شبکه به طور قابل توجهی وزن آن داده‌ها را کاهش می‌دهد.

وزن اتصالات که شبکه عصبی برای هر ورودی تعیین می‌کند مهم است و اهمیت آن با مقادیر ضرایب ریاضی بیان می‌شود. نرخ آموزش مانع تغییرات مورد نظر می‌شود و به شبکه نیروی وارد می‌کند تا تغییرات کمتر باشد. نرخ آموزش بین ۰ تا ۱ است. نرخ کوچک‌تر، بیشتر مانع شبکه

می شود. نرخ کوچک‌تر آموزش بهتر است، اما می تواند زمان کلی آموزش را زیاد کند یا در این مطالعه موردی، مقدار زیادتری از داده‌های ورودی لازم است (یعنی راندمان کمتر اما دقت بیشتر). نرخ آموزش بالاتر باعث آموزش سریع‌تر شبکه می شود، اما ممکن است بهترین راه حل را ندهد (یعنی راندمان بیشتر و دقت کمتر).

وزن های اولیه، دامنه مقادیری است که شبکه عصبی اعداد تصادفی را به صورت وزن اتصالات به کار خواهد برد. outlier error cap multiplier یک روش برای کاهش دادن اثر داده‌های خروجی بر روی داده‌ها است. Cap خطا، خطا را در الگو محدود می کند. خطای رأس میانگین خطا برای آخرین سیکل از تمام داده ها است.

اگر خطای یک قسمت بیشتر از سیکل قبلی باشد، آن را کاهش می دهد تا به مقدار میانگین نزدیک شود. ¹Ecm به کاربر اجازه می دهد در حالتی که خطای بزرگ‌تری پذیرفته است رأس را افزایش دهد. فاکتور outlier ضربی است که نشان می دهد که چقدر باید شبکه به آن قسمت که برای یادگیری مزاحمت ایجاد می کند توجه کند (یعنی حالتی که خطا در یک حالت خاص بزرگ‌تر از میانگین کل خطاهای آموزش باشد). در حالت عمومی، شبکه عصبی حالت‌های غیر معمولی را در حل مسأله نادیده می گیرد. فاکتور outlier به کاربر اجازه می دهد که وزن‌ها را تنظیم کند و به Expert بگوید که کجاها توجه بیشتری کند. مقدار از ۰ تا ۱ تغییر می کند. صفر معنی می دهد که کار بیشتری از حالت نرمال لازم نیست و ۱ معنی می دهد که توجه بیشتری از حالت نرمال لازم است. برای مثال، مقدار ۰/۱ به براینسل می آموزد که ۱۰٪ رکوردها با خطای بیشتر از مقدار میانگین را در نظر نگیرد. این تصویر برای تحلیل داده‌ها در جایی که داده‌های مکانیک سنگی ممکن است با توجه به کم تجربگی یا شرایط زمین شناسی پیچیده دقت کافی را نداشته باشد، بسیار مهم است.

¹ =Error cap multiplier

۹-۵- بحث در نتایج طراحی شبکه عصبی


شبکه‌ای که به خوبی آموزش دیده است و رضایت بخش است، بعد از یک سری از آموزش‌های شبکه عصبی و دوره تست به وجود می‌آید که از ترکیب روش‌های ممکن مختلف استفاده می‌کند. در این مطالعه برای پیش بینی از یک شبکه 18×19 که RMR های از ۵ تا ۱۰۰ و دهانه‌ها از $2/5$ تا ۴۵ متر با فواصل $m \ 2/5$ را می‌پوشاند، استفاده شده است. نتایج مطابق شکل (۵-۵) در یک نمودار RMR در مقابل دهانه کشیده شده است و خطوط تراز آن در شکل (۶-۵) نشان داده شده است.

حتی در جاهایی که مطالعه موردی با دهانه بزرگ و RMR کوچک وجود نداشته باشد، شبکه عصبی خطوط تراز را با توجه به روند پایداری جامعه کل مطالعه های موردی استنتاج کرده است. اگر تحلیل شبکه عصبی به سطحی با توجه به اکثریت مطالعه های موردی محدود شود، نتایج کنتور چندان تغییر نمی‌کند. سطوح با داده‌های مطالعه موردی محدود با خطوط پراکنده‌ای در گراف طراحی دهانه مشخص شده است. کنتور شبکه عصبی در شکل (۶-۵) نشان داده شده است. قسمت متراکم کنتورها مقادیر بین ۱ تا ۳ است، که ناحیه انتقال بین ناحیه پایدار و ناپایدار، با توجه به شماره‌های از قبل تعیین شده برای پایداری می‌باشد. شبکه عصبی به ورودی‌های مختلف با توجه به اهمیت مطالعات اهمیت متفاوتی می‌دهد. این می‌تواند باعث شود که شبکه عصبی مقادیر پایداری بزرگ‌تر از ۳ یا کوچک‌تر از ۱ بدهد. مقادیر بزرگ‌تر از ۳ می‌تواند حالت ناپایدار و مقادیر کوچک‌تر از ۱ می‌تواند حالت پایدار را نشان دهد. این مطالعه موردی به صورت کنتور در شکل (۶-۵) نشان داده شده است.

خطوط در منطقه متراکم مرتبط با منطقه دارای پتانسیل ناپایداری و حالت ناپایدار است. بر طبق کاتاکوری که از قبل برای پایداری تعریف شده است و پیش بینی شبکه عصبی ناحیه انتقال بین دو ناحیه دارای مقادیر بین ۱ و ۳ است. شکل (۶-۵) نشان می‌دهد که در مقادیر کنتور زیر ۱ حالت


کاربرد شبکه عصبی در طراحی تجربی حفاری‌های زیر زمینی

ناپایدار و در مقادیر کنتور بالای ۳ حالت پایدار وجود ندارد. بسیاری از حالت‌های پایدار، دارای پتانسیل ناپایداری و ناپایدار، بین مقادیر کنتور ۱/۲ و ۲ همگرا شده است. بیشترین همگرایی (هم مرکزی) داده‌ها در ۱/۶ است. با توجه به شبکه عصبی یک گراف جدیدی برای طراحی دهانه ورودی‌ها در حفاری‌های زیر زمینی طراحی شده است.



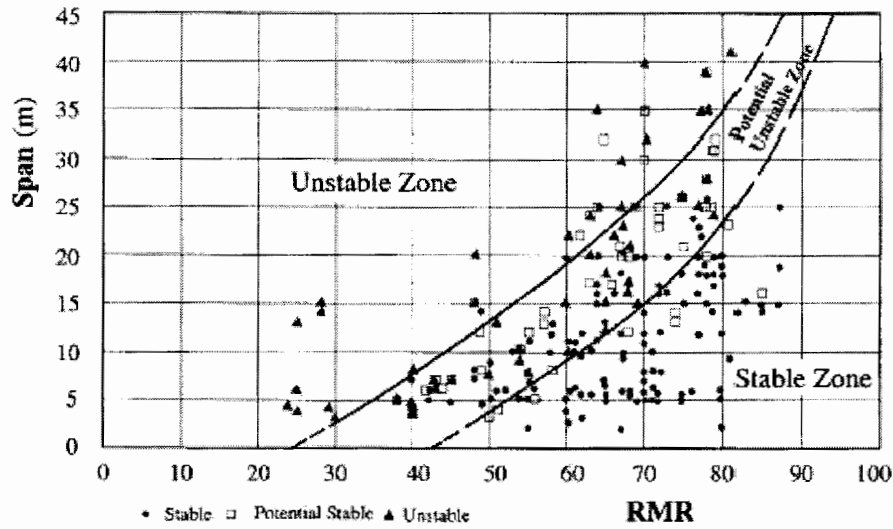
شکل ۵-۵- نتایج پیش بینی شبکه عصبی [۲۱]

گراف طراحی شده از مقادیر کنتور ۱ به عنوان مرز بین منطقه پایدار و دارای پتانسیل ناپایداری و از مقدار کنتور ۲/۵ به عنوان مرز بین منطقه ناپایدار و دارای پتانسیل ناپایداری استفاده می کند. خط کنتور ۱ به عنوان یک تقسیم مهم بین منطقه پایدار و دارای پتانسیل ناپایداری می باشد زیرا در این ناحیه حالت غیر پایدار وجود ندارد. خط کنتور ۲/۵ در ابتدا برای تقسیم ناحیه ناپایدار و دارای پتانسیل ناپایداری با توجه به قضاوت‌های مهندسی انتخاب می شود. خط کنتور ۳ هم می تواند برای این مرز انتخاب شود، اما احساس می شود که مقدار ۲/۵ ناحیه ناپایدار را با ضمانت بهتری انتخاب می کند.




شکل ۵-۶- نقشه کنتور با استفاده از داده های مورد مطالعه [۲۱]

طراحی گراف جدید برای دهانه با توجه به داده‌ها در شکل (۵-۷) نشان داده شده است. به علاوه، یک احتمال پایداری با توجه به نتایج شبکه عصبی محاسبه شده است (شکل ۵-۸). شکل (۵-۸) درجه پایداری مربوط به RMR و دهانه را نشان می‌دهد. احتمال ۹۹٪ مربوط به خط ۱ کنتور شبکه عصبی، مرز بین ناحیه پایدار و دارای پتانسیل ناپایداری را نشان می‌دهد. ۱٪ احتمال پایداری برای خط کنتور ۳ شبکه عصبی وجود دارد. احتمال قابل قبولی برای پایداری در اینجا وجود ندارد. میزان نزدیکی به واقعیت تکنیک طراحی تجربی فوق الذکر بستگی به تجربه کاربر و میزان پیچیدگی محیط زمین شناسی دارد.



شکل ۵-۷- گراف نهایی طراحی دهانه با توجه به داده های مورد مطالعه [۲۱]



شکل ۵-۸- تصمیم گیری شبکه عصبی در مورد احتمال پایداری [۲۱]

روش شبکه عصبی که برای طراحی گراف دهانه به کار رفت تنها روش قابل قبول موجود نیست. یک روش جالب برای تحلیل داده‌های بزرگ برای تکنیک گراف پایداری Mathews روش منطقی رگرسیون است. داده‌های مورد مطالعه در این بخش در پیوست آمده است که افراد دیگر می‌توانند با روش‌های دیگر بر روی آن کار کنند.

یک امتیاز روش شبکه عصبی این است که اثر داده‌هایی که با توجه به اهمیت داده‌های ورودی منطبق نمی‌شوند را کاهش می‌دهد. به علت عدم قطعیت داده‌های وابسته به شرایط زمین شناسی یک مدل تجربی ساده که بر روی طبقه بندی سنگ‌ها می‌باشد نمی‌تواند میزان پایداری را با دقت کافی در تمام شرایط بدهد.


گسل‌ها و تغییرات سنگ شناسی که ممکن است توسط مهندس به خوبی تشخیص داده نشود می‌تواند سبب این شود که پیش بینی یک مدل طراحی تجربی ساده تا حدی قابل قبول نباشد. یکی از مزایای شبکه عصبی این است که قادر به کاهش اثر داده‌های خاص از نظر زمین شناسی (داده‌هایی که مشکل دارد) بر روی پیش بینی می‌باشد.

۵-۱۰- نتیجه

مقایسه‌ای بین طراحی دهانه با توجه به شبکه عصبی و گراف بحرانی دهانه در شکل (۵-۹) نشان داده شده است. گراف بحرانی دهانه در ناحیه RMR بین ۵۰-۸۰ بسیار درست عمل می‌کند اما در مقادیر غیر آن به علت محدودیت داده‌ها ضعیف عمل می‌کند.

طراحی دهانه با توجه به شبکه عصبی مسأله را با اضافه کردن داده‌های بیشتر از معادن مختلف و با استفاده از روش سخت تری برای تحلیل داده‌ها قابل حل می‌کند. شبکه عصبی که داده‌های زیاد داشته باشد، دقت طراحی را در ناحیه RMR کمتر از ۵۰ و بیشتر از ۸۰ بالا می‌برد. گراف نهایی طراحی دهانه همبستگی قابل قبولی را با گراف زمان ایستایی بیناوسکی (برای زمانی ایستادن ۶ ماه) و طراحی نگهداری تونل بارتون نشان می‌دهد. این مقایسه مطلوب پیشنهاد می‌دهد که طراحی سقف جبهه کار برای ورودی‌های معادن قابل قبول است.

روش طراحی دهانه با شبکه عصبی پیشرفت محسوسی را نسبت به روش‌های طراحی تجربی قبلی نشان می‌دهد. شبکه عصبی تحلیل و تفسیر داده‌ها را برای طراحی بهبود می‌بخشد. منحنی طراحی تطبیق خوبی با داده‌ها را نشان می‌دهد.



شکل ۵-۹- مقایسه بین گراف های بحرانی بعد دهانه [۲۱]

تشابه داده‌های شرایط مورد مطالعه و کاربرد داده‌های ۶ معدن، کار انجام شده را برای صنعت معدن کاری نسبت به روش‌های تجربی قبلی مورد استفاده واقع بینانه‌تر (نزدیک‌تر به واقعیت) می‌کند. مثل اکثر روش‌های تجربی در مکانیک سنگ، این روش هم بستگی به تجربه افراد مشغول به کار و پیچیدگی محیط زمین شناسی دارد [۲۱].

پیوست ۱- داده های مطالعات موردی [۲۱]

Case no.	RMR, %	Span, m	Stability
1	85	15	S
2	87	25	S
3	67	20	P
4	77	16	S
5	78	19	S
6	78	28	P
7	51	13	U
8	67	9	S
9	50	9	S
10	85	15	S
11	87	15	S
12	73	20	S
13	63	20	U
14	78	19	S
15	78	28	P
16	50	9	S
17	73	20	S
18	85	15	S
19	42	5	S
20	73	20	S
21	63	20	U
22	77	18	S
23	62	12	S
24	49	8	P
25	52	6	S
26	73	20	S
27	77	25	S
28	42	6	S
29	77	20	S
30	67	23	U
31	58	10	S
32	78	20	S
33	78	39	P
34	49	12	P
35	61	10	S
36	42	6	P
37	48	15	U
38	48	15	S
39	68	20	P
40	70	11	S
41	68	21	U
42	76	24	S
43	38	5	P
44	78	35	P
45	58	13	S
46	77	22	S
47	87	19	S
48	85	14	S
49	77	20	S
50	63	17	S
51	78	18	S
52	78	28	S
53	87	15	S
54	85	16	P
55	63	17	P
56	77	12	S
57	67	2	S
58	55	5	S
59	50	5	S
60	72	16	S
61	53	10	S
62	48	8	S
63	48	20	U
64	25	13	U
65	48	15	U
66	60	22	U
67	28	14	U
68	28	15	U

S = stable, P = potentially unstable, U = unstable

کاربرد شبکه عصبی در طراحی تجربی حفاری‌های زیر زمینی

Case no.	RMR, %	Span, m	Stability	Case no.	RMR, %	Span, m	Stability
69	66	22	U	137	76	24	S
70	55	12	P	138	38	5	U
71	69	25	S	139	38	5	P
72	69	20	S	140	65	5	S
73	64	16	S	141	78	35	P
74	70	20	S	142	79	20	S
75	77	23	S	143	77	16	S
76	58	10	S	144	69	15	U
77	78	20	S	145	64	17	S
78	78	39	P	146	45	7	U
79	80	12	S	147	45	7	P
80	66	17	P	148	69	25	P
81	48	7	S	149	77	12	S
82	64	35	P	150	63	24	U
83	83	15	S	151	63	24	P
84	63	24	U	152	75	26	U
85	63	24	P	153	54	10	P
86	43	7	U	154	75	5	S
87	43	7	P	155	63	24	P
88	56	5	U	156	63	24	P
89	64	15	S	157	81	9	S
90	80	6	S	158	54	10	U
91	80	12	S	159	54	10	P
92	66	17	P	160	70	5	S
93	79	18	S	161	25	3.5	U
94	40	7	S	162	35	3.5	U
95	79	25	S	163	33	3.5	U
96	64	25	S	164	71	10	S
97	77	35	P	165	72	5	P
98	67	9	S	166	65	8	S
99	67	25	U	167	63	7	S
100	80	19	S	168	24	4.3	U
101	79	18	S	169	40	4	U
102	40	7	S	170	56	5	P
103	79	25	S	171	69	25	P
104	77	20	S	172	78	18	S
105	60	5	S	173	79	17	S
106	67	25	U	174	65	18	U
107	43	6	U	175	65	18	P
108	25	6	U	176	75	21	P
109	80	18	S	177	45	7	U
110	80	20	S	178	45	7	P
111	73	25	S	179	80	20	S
112	55	7	S	180	81	23	P
113	77	25	S	181	78	15	S
114	77	35	S	182	63	24	U
115	77	25	U	183	63	24	P
116	79	14	S	184	75	26	P
117	78	26	S	185	79	24	P
118	38	5	S	186	78	15	S
119	77	20	S	187	72	23	S
120	67	25	U	188	72	25	S
121	70	11	S	189	79	32	S
122	82	14	S	190	79	31	S
123	68	21	U	191	72	24	S
124	38	5	U	192	25	3.5	U
125	78	25	S	193	25	3.5	U
126	78	35	P	194	25	3.5	U
127	30	3	U	195	40	4	S
128	40	4.6	U	196	25	3.5	U
129	50	7.6	U	197	50	3.5	U
130	55	11	S	198	62	9.5	S
131	55	7.9	U	199	62	5.5	S
132	55	7.9	S	200	64	11	S
133	68	20	P	201	65	13	S
134	70	11	S	202	65	5.6	S
135	67	18	S	203	67	6	S
136	68	16	U	204	67	10	S

S = stable, P = potentially unstable, U = unstable

S = stable, P = potentially unstable, U = unstable

کاربرد شبکه عصبی در طراحی تجربی حفاری‌های زیر زمینی

Case no.	RMR, %	Span, m	Stability	Case no.	RMR, %	Span, m	Stability
205	67	12	S	273	72	8	S
206	67	9	S	274	72	12	S
207	60	10	U	275	74	13	S
208	60	8	U	276	74	14	S
209	60	15	U	277	75	18	S
210	63	10	S	278	49	14	S
211	65	6.4	S	279	60	11	S
212	65	15	U	280	55	2	S
213	65	7	S	281	50	3	P
214	65	12	U	282	70	6	S
215	65	15	U	283	51	3.8	P
216	70	5	S	284	68	17	U
217	72	17	S	285	70	12	S
218	73	16	S	286	70	11	S
219	73	10	U	287	80	2	S
220	73	8	U	288	56	6	S
221	75	15	S	289	58	8	S
222	80	5	S	290	60	6	S
223	79	25	S	291	61	5.9	S
224	72	5	S	292	61	11	S
225	75	5.4	S				
226	76	6	S				
227	80	6.1	S				
228	57	13	S				
229	57	14	S				
230	58	12	S				
231	64	20	S				
232	60	20	S				
233	66	16	S				
234	67	21	S				
235	44	6	P				
236	62	22	P				
237	64	25	P				
238	67	30	U				
239	60	2.5	S				
240	60	2.5	S				
241	62	3	S				
242	54	9	U				
243	54	5	S				
244	60	3.8	S				
245	29	4	U				
246	40	4.2	U				
247	40	8	U				
248	45	4.8	S				
249	49	4.4	S				
250	51	6	S				
251	78	15	U				
252	70	20	S				
253	70	30	P				
254	65	32	P				
255	70	32	U				
256	70	35	P				
257	70	40	U				
258	81	41	U				
259	56	5.9	S				
260	63	5.5	S				
261	68	5.5	S				
262	69	5	S				
263	68	6	S				
264	68	12	S				
265	70	6	S				
266	70	7	S				
267	70	8	S				
268	70	14	S				
269	71	5	S				
270	71	6.2	S				
271	71	8	S				
272	72	5.5	S				

S = stable, P = potentially unstable, U = unstable

S = stable, P = potentially unstable, U = unstable

فصل ششم

طبقه بندی (دسته بندی) مواد توسط حفاری

۶-۱- خلاصه

معادن ذغال زیرزمینی یکی از خطرناک ترین شغلها است. در سالهای متمادی تلاشهای بسیاری برای انجام تحقیق درباره روشهای توصیف سقف و کف معادن برای بهبود محیط و شرایط معدن کاری انجام شده است. این تحقیق استفاده از شبکه عصبی برای طبقه بندی لایه های سنگی با توجه به پارامترهای حفاری سقف را بررسی می کند. این مبحث روش کار را شرح می دهد، که با توجه به نتایج تجربیات حفاری که در آزمایشگاه با استفاده از بلوک تست مرسوم ریزش بتن تولید می شود، پنج لایه از بلوک تست با استفاده از شبکه آموزش دیده، با خطای کمتر از ۵٪ طبقه بندی گردیده است.

۶-۲- مقدمه

معادن ذغال زیرزمینی یکی از خطرناکترین شغلها است. شکستن سیستم نگهداری در هر سال ۴۰۰ مجروح و ۱۰ کشته را در بر می گیرد. یکی از روشهای افزایش پایداری معادن حفاری و پیچ کردن سقف ضعیف معادن پس از برداشتن یک لایه از ذغال است. کنترل زمین معدن در دهه های اخیر مورد مطالعه قرار گرفته است. هنوز هم مشکلات پایداری معدن، مانند ریزش سقف و پرتاب سنگ ادامه دارد که باعث مصدوم و کشته شدن مردم در هر سال می شود. بیشتر از نصف مرگ و میرهای اخیر در معادن در زیر سقف نگهداری شده انجام گرفته است.

معدن کاران اطلاعات در مورد سنگ شناسی سنگهای در بر گیرنده لایه ذغال را محدود می کنند. اگر بتوان به اطلاعات سنگ شناسی محلی همراه با جزئیات دست یافت، معادن بهتر می توانند به پیچ های سقف موثر دسترسی پیدا کنند، خطرهای محلی به معدن کاران اطلاع داده می شود، کنترل زمین افزایش می یابد و بنابراین، سلامت معدن بسیار بهبود می یابد. در طی سالها


تلاشهای بسیاری برای پیدا کردن روشهای مشخص کردن لایه های معدن به منظور بهبود بخشیدن سلامتی معدن انجام شده است.

این فصل استفاده از پارامترهای فیزیکی حفاری بولت سقف مانند نیروهای گشتاوری، فشار محوری، سرعت چرخش و نرخ نفوذ را برای آموزش شبکه برای طبقه بندی سنگ بررسی می کند. در قسمت دوم درباره زمینه مناسب معدن ذغال بحث می کند، مساله را شرح می دهد و تحقیقات را مرور می کند. در قسمت سوم توضیحات جزئی از روشی که اطلاعات حفاری برای طبقه بندی مواد استفاده می کند، بیان می شود و قسمت چهارم آزمایشها و نتایج را شرح می دهد. سپس آخرین تست آزمایشی و نتایج شرح داده می شود. سرانجام، طرح تحقیقات آینده در قسمت پنجم آورده شده است.

۳-۶- پیش زمینه

معمولی ترین روش به دست آوردن اطلاعات سنگ شناسی قبل از آغاز معدن کاری، حفاری اکتشافی قبل از معدن کاری است. هر چند، این کار، گران است و در نتیجه در فواصل زیاد صورت می گیرد. اطلاعات مغزه ها اطلاعات محدودی را درباره سنگ بستر و لایه های در بر گیرنده با دقت محدود می دهد. مغزه های حفاری، آنومالیهای زمین شناسی محلی را که خطرها را برای معدن کاران مطرح می کند با خطا نشان می دهد. به علاوه، پروسه معدن کاری به طور مداوم حالتیهای ساختاری معدن را تغییر می دهد. سلامت عمومی معدن می تواند با رفتار سنجی حالتیهای ساختمانی محلی با پیشرفت معدنکاری افزایش یابد. شکل (۶-۱) یک مقطع از معدن ذغال را نشان می دهد.

یک خطر موجود، شکست یا لایه لایه شدن سقف لایه هایی است که نمی توانند وزنشان را تحمل کنند. اغلب، لایه های ضعیف نمی توانند تنش های تولید شده توسط روباره زیاد را تحمل کنند و در نتیجه، سقف و کف جابجا می شوند و کناره ها متورم می شوند و ورودی معدن کوچک می شود.



شکل ۶-۱- یک مقطع از معدن ذغال [۲۲]

معمولی ترین تکنیکهای کشف خطر که در طبیعت فعال اند عبارتند از : اکتنسونومترها و حس کردن تغییرات سیگنالها که اتفاقات قریب الوقوع را پیش بینی می کند. اغلب، تجربه کارگران معدن بهترین کشف کننده خطرات (اتفاقات) است، زیرا آنها با احساس و صدای ماشینها زندگی می کنند (مسائل را می توانند درک و احساس کنند). اما، کارگران معدن از همه وسائل کشف خطر آسیب پذیر ترند و همچنین موفقیت کمی برای وسایل سنجش حالتها بر جای محلی زمین مانند نفوذ راداری به زمین، سنسورهای آلتراسونیک و پیچهای سقف ابزار بندی شده وجود دارد.

در مقابل، تحقیقات گران قیمتی در همه انواع حفاری دقیق وجود دارد. این تحقیقات بینش ارزشمندی در تحلیل حفاریها بوجود می آورد. رامیرز^۱ و ترونهیل^۲ یک دوره چاپ شده ارائه کردند که حفاریهایی را نشان می داد که از تحلیل طیف مختلف نیروهای حفاری و یک تکنیک ترکیب سنسورها برای ترکیب داده ها استفاده می کرد و گزارش دادند که در حالتها مختلف، نیروی برش، وابسته به تناوب قطعه قطعه شدن تراشه ها است که بستگی به خصوصیات فیزیکی ماده دارد. کابور لاسوس از تکنیکهای آموزش برای مربوط ساختن نیروی محوری و گشتاوری حفاری که در طی

^۱ =Ramirez

^۲ =Thornhill

حفاری با اندازه گیری ضخامت قسمت داخلی قسمت حفاری کننده به دست می آید، برای پیش بینی شکست و برای پیش گیری آسیب به قسمت حفاری کننده استفاده می کند.

تنها چند گروه درباره استفاده از هوش حفاری برای کارهای معدنی و ساختمانی با استفاده از حفاری چرخشی تحقیق کردند. لیگتون همچنین از حفاری چرخشی ابزار بندی شده چالهای انفجار برای مرتبط کردن میزان گشایش حفاریها و لایه با متغیر های حفاری، برای طراحی آتشیاری معدن روباز استفاده کرد. آنها قادر به کشف ارتباط تجربی بین نیروی محوری حفاری و نرخ نفوذ با میزان مقاومت مواد در برابر شکست هستند. اسکوبل همچنین از رفتار نگاری حفاری برای تشخیص دادن مرزهای سنگ ذغال در معدن ذغال روباز (سطحی) با استفاده از حفاری چرخشی چالهای انفجار استفاده کرد. آنها انرژی مخصوص حفاری (SED)^۲ (تخمین انرژی چرخشی و خطی با استفاده از حفاری) را حساب کردند و آن را با مقاومت لایه ها مقایسه کردند و آن را شرح دادند.

کینگ و سینگر داده های حفاری معدن ذغال را با استفاده از تکنیک یادگیری تفسیر کردند. آنها از آموزش با ناظر برای طبقه بندی داده های حفاری سقف معادن ذغال زیر زمینی به گروهها استفاده کردند و سپس از طبقه بندی انجام شده برای آموزش شبکه عصبی به داده های دیگر حفاری استفاده کردند.

به طور مشابه، UTT، از شبکه عصبی برای تقسیم بندی سنگها با توجه به SED استفاده کرد. کار آنها مقادیر نرم، متوسط و سفت (سخت) را با اطلاعات حفاری می دهد که معدنکاران می توانند وقتیکه از پیچها برای سقف معدن استفاده می کنند از لایه های ضعیف آگاه شوند. کینگ و سینگر و UTT یک روش را برای توصیف لایه های معدن ذغال انتخاب کردند، اما آنها فرض کردند که کار آنها از این تحقیق متفاوت است. هردو کاتاکوری از لایه ها بوسیله مقاومت مربوط به پارامترهای حفاری تخمین زده شد. هر گروه نتایج مثبتی دارد، اما در ابتدا، برای حالتی که دو لایه اختلاف زیادی در مقاومت فشاری دارند هستند.

^۲ = Specific energy of drilling

بسیاری از محققان، از SED به عنوان راهی برای توصیف لایه ها استفاده می کنند. اگر کسی بخواهد مقاومت مربوط بین لایه ها و حالت‌های زمین شناسی دیگر را تخمین بزند این قابل قبول است. هر چند، SED بستگی به این دارد که سنگ به چه خوبی به صورت ریزه در زمین است. استفاده از SED برای تخمین مقاومت نسبی بین مواد، اگر حالت حفاری ثابت نباشد ممکن است به نتایج مناسبی نرسد. اگر حالت حفاری ثابت نباشد بعلاوه ، به تنهایی نمی تواند فرق بین مواد را تشخیص دهد، زیرا حالت‌هایی وجود دارد که مواد با مقاومت‌های متفاوت، مقاومت‌های مشابهی را نشان می دهند (ذغال و شیل در رنج مقاومت فشاری نزدیکی (مشابهی) هستند) یا لایه ها دارای مقاومت مشابه اند (مانند حالتی که مواد در نرخ‌های مختلف برای مواد شکسته و یا حفاری می شوند). با تفاوت بین مواد، همراه با تخمین پارامترهای فیزیکی بر جا ، یک شخص میتواند مواد را در درجه اطمینان بالاتر طبقه بندی کند


۶-۴- روش کار

در این تحقیق، ما قصد داریم که از داده های یک ابزاربندی حفاری معدن برای طبقه بندی موادی که به صورت تیپیک در اطراف یک لایه ذغال پیدا می شوند، استفاده کنیم. برای این کار باید یک معدن بدون احتیاج به کارگران معدن که طبقه بندی را انجام دهند و صرفنظر از حفاری، اپراتور یا حالت‌های محلی وجود داشته باشد. این فکر با این حقیقت که جواب حفاری مرتبط (وابسته) با اطلاعات حفاری مواد است، مهیج تر می شود. برای مثال، محققان تایید می کنند که خصوصیات مواد مانند ساینده‌گی، سختی و مقاومت به طور مستقیم بر پروسه حفاری اثر می گذارد.

خصوصیات فیزیکی مواد شامل خصوصیات مکانیکی (مانند مقاومت، سختی، ساینده‌گی و تخلخل)، خصوصیات الکتریکی و ساختارهای مولکولی است. خصوصیات فیزیکی می تواند اثر داشته باشد و یا اثر فعل و انفعالات ذرات سنگ را نشان دهند. برای مثال، دو ماده می توانند مقاومت فشاری یکسان داشته باشند و احتیاج به انرژی حفاری مشابه ای داشته باشند و ذرات دستگاه حفاری را در

سرعت‌های متفاوت می‌فرسایند. خصوصیات یک ماده معمولاً توسط حالت‌های بر جا مثل محدوده فشار، دما، مقدار رطوبت، گازهایش و پروسه معدنکاری خودش تحت تاثیر قرار می‌گیرد. پروسه حفاری با مدل فیزیکی پیچیده می‌شود. متغیرهای زیادی وجود دارند که پروسه حفاری را تحت تاثیر قرار می‌دهند. فاکتورهایی که بر حفاری اثر می‌کنند، از حفر، مواد و محیطی که حفاری در آن انجام می‌شود ناشی می‌شوند. متغیرهایی مثل میزان مستقیم بودن (بدون انحراف بودن) حفاری، هندسه ذرات حفاری و فرساینده‌گی آنها، روش پاشیدن آب و موقعیت ماشین می‌تواند بر چگونگی حفاری و فعل و انفعالات ذرات سنگ اثر کند. این متغیرها معمولاً بین حفاریها و اپراتورها متفاوت است.

ملاحظه می‌شود که با توجه به همه متغیرهای زمین‌شناسی، محیط زیستی و مکانیکی موجود، کیفیت حفاری یک مقدار واقعی بزرگ و داده چند متغیری می‌شود. اغلب، رابطه پیچیده بین این متغیرهای دینامیکی به درستی فهمیده نمی‌شود. به این دلایل، این عمل حفاری کاندیدای مناسبی برای یادگیری ماشین است. آخرین تحقیقات از این روش پیشنهاد می‌کند که شبکه عصبی یک الگوریتم یادگیری مناسب برای استفاده است. شبکه عصبی از لایه‌هایی از گره‌های متصل، همچنانکه در شکل (۶-۲) نشان داده شده است تشکیل شده است.



شکل ۶-۲- نمونه ای از یک شبکه عصبی [۲۲]

مقادیر سنسورها ی حفاری ورودی های شبکه می باشند و مشخصات ماده (که به شکل باینری نشان داده شده است) خروجی ها هستند. هر گره به وسیله مقدار ثابت واقعی یا وزنها به همه گره ها در لایه بعد وصل می شود. تعداد لایه های مخفی و گره ها در لایه، پیچیدگی شبکه و تابع بیان کننده آن را تعیین می کند. هدف آموزش شبکه مینیمم کردن خطای طبقه بندی مواد است. بنابراین، آموزش یک پروسه است : ورودیها را در شبکه گسترش می دهد، خطای بین خروجی شبکه و مقدار واقعی (هدف) را حساب می کند و وزنها را با گسترش به سمت عقب خطا تعدیل می کند. این سیکل تا رسیدن به مقدار مینیمم خطا یا رسیدن به مقدار تکرار تعیین شده ادامه می یابد. برای کمک به شبکه عصبی برای استفاده از وابستگی پیچیده بین همه متغیرها، تعداد سنسورها با افزودن سنسورهای مجازی افزایش می یابد. این سنسورها، سنسور فیزیکی نیستند، اما تابعی از سنسورهای حفاری اند. آنها می توانند رابطه پیچیده بین رفتارهای حفاری و خصوصیات ماده را بیان کنند. اطلاعات حاصل از سنسورهای مجازی، پارامتر دیگر حفاری است و متغیر دیگری برای استفاده توسط شبکه عصبی است. قسمت بعدی یک کار که شامل جمع کردن داده های واقعی معدن ذغال و داده های آزمایشگاهی، پایدار کردن داده های واقعی و مجازی، آموزش شبکه عصبی برای طبقه بندی مواد حفاری شده و ارزیابی نتایج طبقه بندی است را بیان می کند.


۶-۵-آزمایشها

۶-۵-۱- دستگاه های آزمایشی

دستگاه حفاری شامل، قسمت قابل حمل و نقل، پاور^۴ هیدرولیکی، آب سرد کننده ذغال معدن که با سنسورها ابزار بندی شده است، سخت افزار فراگیری (استفاده از) داده و کامپیوتر لپ تاپ (شکل ۶-۳ را ببینید) است. سخت افزار الکترونیکی که از حفار ایزوله شده است، می تواند در محیط معدنی واقعی عمل کند. قسمت فراگیری داده در یک جعبه عایق آب قرار دارد، با یک کابل که به سنسورها

^۴ =Power

متصل است و کابل دیگری که به لپ تاپ وصل است که ممکن است که چندین فوت دورتر از محل حفاری باشد. پارامترهای حفاری که ثبت می شوند عبارتند از : نیروی گشتاوری، فشار محوری، سرعت چرخش، فشار هیدرولیکی و موقعیت (حالت) حفاری. شش محور با دقت بالا، که با سنسور نیرو-گشتاور کوپل شده است در خطی بین موتور حفاری و اتاقک حفاری وصل می شود.



شکل ۶-۳- دستگاه حفاری آزمایشگاه [۲۲]

فشار هیدرولیکی موتورهای چرخشی و فشار محوری در قسمت ورودی و خروجی ثبت می شود. دلیل این کار دسترسی به امکان پذیری سنجش فشار محوری و مقدار گشتاور از سنسورهای ارزان تر برای سیستم واقعی جهان است. سرعت چرخش با استفاده از سنسورهای مغناطیسی و دهانه ها با چهار قسمت مغناطیسی که به گیره های حفاری چرخشی پیوست شده است سنجیده می شود. با استفاده از مقادیر آزمایشگاهی مقادیر سنسورها در نرخ ثابتی به دست می آید و میزان نرخ نفوذ حفاری به صورت Offline، با استفاده از موقعیت ذرات حفاری که در زمانهای ثابت مراحل خوانده می شود، محاسبه می گردد.

آزمایشگاه حفاری ما شامل یک قاب قابل سازگاری برای ساپورت حفاری در لایه های بلوک بتنی است. حفاری به صورت عمودی توسط کابل ها حمایت می شود. وقتی که یک چال حفاری می شود، دکل حفاری بین قاب فلزی و بلوک بتنی تست گسترده می شود. در حالی که فراگیری داده توسط

کامپیوتر کنترل می شود، جابجایی خطی و چرخشی حفاری به صورت دستی کنترل می گردد. در جائیکه یک مقدار هیدرولیکی محدود کننده برای ماکزیمم نگهداشتن نرخ جریان استفاده می شود، مقدار فشار محوری موتور به طور کامل، باز(نامحدود) نگاه داشته می شود. اگر هدف ثابت نگهداشتن نرخ نفوذ باشد مقدار چرخشی به طور کامل نامحدود نگه داشته می شود، اما جریان کنترل نمی شود. برای اینکه تا حد ممکن چال حفاری تمیز نگه داشته شود، آب با حداکثر جریان در زمان حفاری جریان می یابد.

۶-۶- جمع آوری داده ها و پردازش

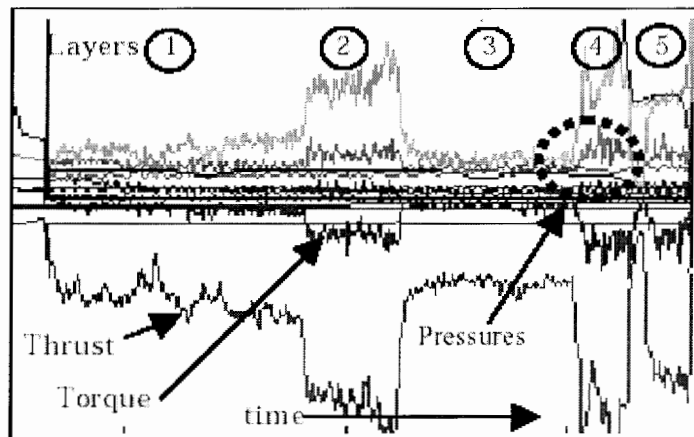
اطلاعات از ۴۰ چال که در حدود ۳ فوت در یک بلوک بتنی ضخیم تست حفر گردید، جمع آوری شده است. بلوک ۳×۳×۳ که ۸۰۰۰ پوند می باشد شامل ۵ لایه بتنی با مقاومت های متفاوت و مواد متفاوت است. هر قسمت بتنها تحت آزمایش مقاومت فشاری تک محوری قرار می گیرد. پارامترهای فیزیکی هر لایه در جدول (۶-۱) آمده است. چالها در بلوک بتنی تست در یک الگوی نامنظم حفر شده است.

جدول ۶-۱- پارامترهای بلوک بتنی تست [۲۲]

Layer	1	2	3	4	5
Concrete Mix	Grout	Lime stone	Fly-ash	H.E.S	H.E.S
Comp. Str. (psi)	1,900	5,600	1,300	4,500	4,300
Thick-ness (in)	11	5	9	4	7

همچنین حدود ۳۰ چال در معدن ذغال براكتون در پترزبورگ حفر شد و مقادیر آنها ثبت گردید. به طور متوسط حدود ۹۰ ثانیه برای حفر یک چال در بلوک بتنی تست وقت صرف می شود. هر فایل داده ها شامل ۶۰۰۰ تا ۱۰۰۰۰ نقطه داده است که هر کدام از داده های واقعی ۷ سنسور به دست آمده اند که داده ها شامل مقادیر، نیرو و گشتاور از سنسور نیرو - گشتاور، فشار هیدرولیکی در فشار

محوری و ورودی و خروجی موتور چرخشی، موقعیت حفاری و سرعت چرخش است. شکل (۴-۶) یک مثال از سنسورهای گیرنده داده ها در جایی که هر چال در طی ۵ لایه بتنی حفر می شود است. سنسورهای حفاری که در این آزمایش استفاده می شود مربوط به مرحله بعد از پردازش هستند. خروجی پتانسیل سنج با نشان دهنده ظرفیت (محدود کننده ظرفیت) فیلتر می شود، مادامیکه سنسور نیرو-گشتاور از فیلتر عبور جریان کم استفاده می کند. قسمت پالس مغناطیسی برای سرعت چرخش از فیلتر نرم افزاری استفاده می کند.



شکل ۴-۶-مقدار ثبت شده توسط سنسور ها برای یک چال حفر شده [۲۲]

بعد از حساب کردن نرخ نفوذ حفاری، هر فایل داده حفاری به مقدار ۱٪ (۱٪ داده هایش) تحت نمونه گیری قرار می گیرد (یک شکل از فایل تحت نمونه گیری، وقتیکه با فایل منشا خود مقایسه می شود قابل قبول تر است). این فایل با انتخاب نقاط مربوط به داده ها از بخشهای تمیز هر ماده و خارج شدن از ناحیه حمل و نقل (گذر) ماده یا نقطه شروع و یا پایانی حفاری بیشتر مورد پردازش قرار می گیرد. فایل تمیز شده بین ۵۰۰ تا ۱۵۰۰ نقطه داده است که شامل یک قسمت از مقادیر به دست آمده از سنسور برای هر ماده که در آن چال خاص حفاری می شود، است. هر کدام از فایلها به وسیله دست نامگذاری می شود و نرمالایز می شود. سرانجام، هر بخش از داده ها به یک نقطه در فضای N

بعدی مربوط می شود (نسبت داده می شود)، جایگاه N تعداد فیلد ها است. فیلد های یک نقطه داده، برای مثال میانگین نیروی محوری در بخش حفاری است و N برای هر آزمایش متفاوت است.

۶-۷- آموزش و تست شبکه عصبی

ماز الگوریتم پس انتشار خطای نت لیز^۵ با دو لایه پیشخور استفاده می کنیم. داده ها به داده های باینری برای آموزش و تست شبکه عصبی معکوس می شود و سپس دوباره به اعداد صحیح بر می گردد تا با استفاده از بهترین برنامه N بعدی طبقه بندی شوند.

آزمایشات فوق برای تصمیم گیری درباره طبقه بندی داده های حفاری بلوک بتنی به ۵ ماده و انجام تحلیل حساسیت برای پارامترهای حفاری طراحی شده است. یک شبکه عصبی بدون لایه میانی طراحی شد و نتایج ضعیفی داد که به طور متوسط ۸۰٪ خطای طبقه بندی داشت که معلوم می کرد که رابطه بین داده های سنسورهای حفاری غیر خطی است. شبکه های بعدی دارای ۴ لایه پنهان بود و در یک رنج از تکرارها آموزش داده شد.

در این کار از چند خاصیت به عنوان داده های ورودی به شبکه عصبی استفاده شده است (جدول ۶-۲). که شامل داده های به دست آمده از سنسورهای فیزیکی (واقعی) (با P نامگذاری می شود) و سنسورهای مجازی (با V نامگذاری می گردد) می شود. به منظور جلوگیری از نوعی از یادگیری شبکه که تنها با توجه به موقعیت حفاری، (تا وقتیکه هر چال در بلوک بتنی تست مشابه حفر می شود) طبقه بندی می کند، موقعیت ذرات حفاری به عنوان یک ورودی برای شبکه عصبی استفاده نمی شود.

فایل داده های ۱۴ چال حفاری برای آزمایشها استفاده می شود. داده ها به صورت رندوم ۱۱ فایل برای آموزش و ۳ فایل باقیمانده برای تست به کار می روند. هر کدام از آزمایشها با ۱۰۰ داده برای تست و آموزش در شبکه عصبی شروع می شود. میانگین نرخ خطای تست، از نرخ خطای تست ۱۰۰

^۵ =Netlabs

واحد داده محاسبه می شود. این برای رنج مقادیر پارامتر تعداد تکرارها، تکرار می شود و تعداد تکرار با کمترین میانگین نرخ خطا گزارش می شود.

جدول ۶-۲- توزیع استفاده شده در آزمایش [۲۲]

Attributes	Experiment											
	1	2	3	4	5	6	7	8	9	10	11	12
Mean												
Thrust (p)	■	■		■	■	■			■			
Torque (p)	■		■		■					■		
RPM (p)	■	■	■	■		■	■	■			■	
Penetration (p)	■	■	■	■	■		■	■				■
Rotary In (p)	■						■	■				
Rotary Out (p)	■						■	■				
Thrust In (p)	■						■	■				
Thrust Out (p)	■						■	■				
Thrust Diff. (v)							■	■				
Rotary Diff. (v)							■	■				
Std. Dev.												
Thrust (v)	■											
Torque (v)	■											
Penetration (v)	■							■				
Thrust Diff. (v)							■	■				
Rotary Diff. (v)							■	■				

۶-۸- نتایج آزمایش

میانگین نرخ خطا برای آزمایش و طبقه بندی نرخ خطا بوسیله ماده، در جدول (۶-۳) نشان داده شده است.


آزمایش ۱ از همه مقادیر سنسورهای فیزیکی - فشار محوری، گشتاور، سرعت چرخش، نرخ نفوذ و فشار ورودی موتور مانند تعداد سنسورهای مجازی در خواص آن استفاده می کند. این حالت دارای کمترین میانگین نرخ خطای طبقه بندی از بین ۱۲ آزمایش با ۴/۵٪ خطا است. این نتایج نشان

می دهد که شبکه عصبی می تواند ۵ ماده را طبقه بندی کند و همچنین می تواند مقادیری را ایجاد کند که بتوان از آنها برای مقایسه نتایج آزمایشها استفاده کرد.

جدول ۶-۳- نرخ خطا به وسیله مواد برای هر آزمایش [۲۲]


<i>Experiment</i>	<i>Error Rates by Material (%)</i>					<i>Avg</i>
	<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>	
1	0	0	1.5	15.1	5.8	4.5
2	4.2	4.1	13.9	33.3	27.5	15.2
3	48.9	21.3	60.5	83.6	84.4	59.8
4	12.7	6.8	32.2	11.1	48.6	22.3
5	0.2	0.9	9.9	25.8	37.1	14.8
6	0.1	0.8	6.3	29.8	32.3	13.8
7	44.8	31.7	63.2	61.7	68.3	54.0
8	0.0	14.5	5.8	34.7	66.7	24.3
9	14.0	8.6	8.6	87.2	91.8	42.0
10	57.6	16.2	43.4	93.9	90.5	60.3
11	76.8	62.6	63.8	86.0	97.2	77.3
12	54.8	47.7	77.2	92.3	97.1	73.8

شکل (۵-۶) نرخ خطای طبقه بندی را برای رنج داده نشان می دهد. افزایش تعداد تکرارها دقت طبقه بندی را افزایش می دهد تا وقتی که به ۹۰ تکرار برسد، در اینجا رشد میزان دقت متوقف می شود. ماده ۵ دارای بیشترین نرخ خطا است. این مساله برای تمام آزمایشها که در آینده توضیح داده می شود درست است.



شکل ۶-۵- نرخ خطای طبقه بندی برای رنج داده ها [۲۲]

شکل (۶-۶) در پایین شکلی از اغتشاش ماتریس شبکه است. ماتریس اغتشاش یک سنجش برای میزان خوبی طبقه بندی است و جایی را که طبقه بندی خوب انجام شده است نشان می دهد. محور افقی طبقه بندی برای داده های آزمایش اول است. محور عمودی درصد کلاس ماده را که واقعا آنگونه است، بیان می کند. برای مثال مواد ۱ و ۲ به صورت کامل و ۱۰۰٪ طبقه بندی شدند. ماده ۳ مثل ماده ۴ در ۱۰٪ از زمانها به خوبی طبقه بندی نشد.



شکل ۶-۶- ماتریس اغتشاش آزمایش [۲۲]

هدف آزمایشهای ۲ تا ۶ ارزیابی پارامترهای کلاس حفاری، نیروی محوری، گشتاور، نرخ چرخش و نرخ نفوذ است. نرخ خطای طبقه بندی شبکه برای آزمایشهای ۲ تا ۶ در جدول (۶-۳) نشان داده شده است. آزمایش ۲ از همه ۴ پارامتر حفاری استفاده می کند، در صورتیکه در ۴ آزمایش بعد، نیروی محوری، گشتاور rpm، و نرخ نفوذ یکی در هر زمان برداشته می شود. برداشتن سرعت چرخش

یا نرخ نفوذ سبب می شود که خطای طبقه بندی به صورت ملایم زیاد شود. برداشتن فشار محوری حفاری سبب آسیب رساندن به توانایی شبکه در طبقه بندی مواد می شود. این ممکن است که به این دلیل باشد که نرخ چرخش و نرخ نفوذ در مقایسه با فشار محوری و گشتاور ثابت اند، بنابراین این دو پارامتر در طبقه بندی مواد بحرانی تراند.

در آزمایشهای ۷ و ۸ مقادیر سنسورهای نیرو - گشتار با دقت بالا، توسط مقادیر سنسورهای گذرنده فشار ارزانتر که در ورودی و خروجی موتورهای الکتریکی نصب شده است جایگزین می شود. آزمایش ۷ به یک نرخ طبقه بندی ضعیف، با ۵۴٪ خطا می رسد. در آزمایش ۸ شبکه عصبی با استفاده از داده های ۵ سنسور مجازی اضافه شده آموزش می بیند و میانگین نرخ خطا ۲۴٪ می شود، که تقریباً نصف مقدار آزمایش ۷ است. این مساله پیشنهاد داد که سنسورهای مجازی اضافه شده به سنسور ها می تواند استفاده از سنسورهای فشار ارزان تر و بزرگ تر به جای سنسورهای کرنش سنجش ظریف و گران برای طبقه بندی سنگ سقف معدن را آسان تر (ممکن تر) کند.

تنها یک پارامتر حفاری (نیرو، گشتاور، سرعت چرخش و نرخ نفوذ) برای آموزش شبکه در آزمایشهای ۹ تا ۱۲ استفاده می شود. آموزش شبکه تنها با نیروی محوری حفاری، نرخ کمتری را تولید می کند. این نتایج با نتایج آزمایش سوم که نشان می داد که از بین ۴ پارامتر برداشتن نیروی محوری حفاری پارامتر مهمتری در طبقه بندی مواد ۱ و ۲ و ۳ است و چهار پارامتر حفاری - فشار محوری، گشتاور، سرعت چرخش و نرخ نفوذ - به نظر می رسد که به طور برابر در طبقه بندی مواد ۴ و ۵ ضعیف اند. این همچنین ثابت می کند که احتمالاً پارامترهای دیگری برای حفاری وجود دارد که بهتر می تواند این دو ماده را مشخص کند.

آزمایشهای ۱ و ۷ و ۸ نشان می دهد که انحراف معیار پارامترهای حفاری در افزایش درجه دقت در طبقه بندی مواد بتنی تست مفید است. یک نتیجه می تواند این باشد که رنج سایز در ترکیب بتن و تمرکز توده، سبب می شود لرزش حفاری متفاوت از مواد دیگر باشد. این اثر در فایل‌های بزرگتر و

نمونه گیری نشده بهتر بیان می شود و ممکن است تغییرات در لرزش، در زمان، در یک مسیر معلوم، حتی مفیدتر باشد. آزمایشهای ۷ و ۸ همچنین به طور قوی پیشنهاد می دهند که سنسورهای مجازی مفیدند و دقت طبقه بندی مواد مشابه را بهبود می بخشند.

۶-۹- کارهای آینده

در آزمایشی که در این مقاله بیان شد، فایل داده که برای آموزش و تست شبکه عصبی استفاده شد، بسیار کوچک شد و به چندین نقطه رسید. این به شبکه داده های بسیار تمیزی را می داد که شبکه را با آن آموزش دهند. مرحله بعد تست کردن شبکه در مجموعه داده های بزرگتر است. این بدین معنی است که برای مجموعه داده های بزرگتر ما احتیاج به استفاده از سنسورهای مجازی اضافه شده داریم. این آزمایش همچنین از یک ساختار شبکه (شکل شبکه) استفاده می کند و به تابع خطا یا الگوریتم مورد استفاده برای میزان کردن وزنها تنوع نمی بخشد. آزمایش بعدی برای انتخاب مدل به کار می رود، که بهترین شکل شبکه و الگوریتم آموزش می تواند قبل از سنسورهای مجازی اکتشافی به دست آید. آزمایشات بعدی بر روی طبقه بندی همراه با داده های نویزی حفاری و دانستن رابطه بین حفاری و ماده، تمرکز می کند. تحقیقات آینده همچنین شامل طبقه بندی مواد با استفاده از داده های جمع شده از معدن ذغال است [۲۲].

فصل هفتم

کاربرد شبکهٔ عصبی مصنوعی در طبقه بندی

قابلیت انفجار تودهٔ سنگ

۷-۱- خلاصه

در این فصل با ملاحظه کارها در مهندسی سنگ، تلاشی برای به کار بردن شبکه عصبی مصنوعی (ANNS) به عنوان یک روش برای طبقه بندی قابلیت آتشباری توده سنگ انجام شده است و یک گروه از داده های مربوط به قابلیت آتشباری برای آموزش و تست شبکه عصبی به کار می رود. تکنیک مدل طبقه بندی براساس شبکه عصبی برای طبقه بندی قابلیت انفجار شبکه عصبی به کار می رود. مدل بهتر برای طبقه بندی قابلیت انفجار توده سنگ ایجاد می شود و پس از آموزش و بهینه سازی شبکه عصبی شرح داده می شود. مدل شبکه عصبی به دست آمده مؤثر است و در هنگامی که نتایج طبقه بندی قابلیت آتشباری توده سنگ به دست می آید، مدل پایدار و قابل تطبیق است. از این مطالعه نتیجه گیری می شود که طبقه بندی قابلیت انفجار توده سنگ با توجه به شبکه عصبی مصنوعی، می تواند به خوبی به وسیله الگوریتم آموزش و یادگیری و با توجه به مجموعه جامعی از داده ها توسعه یابد و درجه اهمیت هر فاکتور مؤثر می تواند به طور مستقیم از وزن های مختلف آن به دست آید.

۷-۲- مقدمه

طراحی و پروسه مهندسی آتشباری سنگ بستگی به نتایج طبقه بندی توده سنگ دارد. واضح است که روش های مختلفی می تواند برای ترتیب های متفاوت توده سنگ به کار رود. این مهم است که راه قابل قبول و قابل تکراری برای طبقه بندی قابلیت آتشباری توده سنگ به دست آوریم. توده سنگ، به عنوان یک حالت (شی) نامعین، یک موضوع مهندسی وسیع (جامع) است که مشخصات آن به وسیله نقشه (طرح) ساختاری و ساختار توده سنگ کنترل می شود. حالت های محیط اطراف توده

سنگ و شرایط زمین شناسی، اثر معینی بر آتشباری سنگ دارند. روش‌های تجاری طبقه بندی توده سنگ، تنها بر روی خود سنگ تمرکز می کنند و از فهرست‌های جداگانه ای که مشخصات مهندسی آتشباری در آن وجود ندارد، اما مشخصات توده سنگ در آن وجود دارد استفاده می کند. در حقیقت، بسیاری از فاکتورها ممکن است رفتار آتشباری سنگ را در کنار خصوصیات توده سنگ تحت تأثیر قرار دهد. آشکار است که کنترل همه فاکتورها که بر رفتار مهندسی آتشباری سنگ اثر می گذارند بسیار سخت و یا حتی غیرممکن است. یک روش قابل قبول برای طبقه بندی آتشباری، که موضوعش مستقیماً مهندسی آتشباری سنگ است، نه تنها تعیین مشخصات توده سنگ است، بلکه پیش بینی کیفیت مهندسی آتشباری می باشد. شبکه عصبی مصنوعی در این مبحث برای طبقه بندی قابلیت آتشباری توده سنگ مورد بحث قرار گرفته است. این روش در یک مورد تمرینی از مهندسی آتشباری سنگ، برای طبقه بندی قابلیت آتشباری توده سنگ به کار رفته است.

۷-۳- پارامترهای طبقه بندی قابلیت آتشباری و شبکه عصبی

۷-۳-۱- پارامترهای طبقه بندی قابلیت آتشباری توده سنگ

خردایش آتشباری سنگ عموماً در طی ترک‌ها، ریز ترک‌ها و لایه‌های نرم انجام می گیرد. پارامترهای خردایش به وسیله ساختار زمین شناسی توده سنگ تعیین می شود. تکرار عملیات آتشباری ثابت می کند که مشخصات توده سنگ اثر بیشتری نسبت به خود انفجار بر نتایج آتشباری سنگ دارد.

فاکتورهایی که خصوصیات آتشباری سنگ را تحت تأثیر قرار می دهند می توانند به سه گروه تقسیم شوند. ساختار توده سنگ، مقاومت سنگ و مشخصات خردایش. به طور نرمال، ساختار توده سنگ، آتشباری سنگ را بیشتر از مشخصات خود سنگ تحت تأثیر قرار می دهد. میزان چگالی قسمت نرم به طور قابل ملاحظه‌ای نتایج آتشباری سنگ را تحت تأثیر قرار می دهد.

مقاومت قسمت نرم کمتر از آن قسمت از سنگ است که توده سنگ می تواند به صورت بلوک سنگی قبل از آتشباری بریده می شود. وقتی که آتشباری در توده سنگی که شامل قسمت نرم متراکم است انجام می شود، فشار انفجار می تواند به آسانی به طرفی که انرژی خردشدگی کمتری لازم دارد، فرار کند. در این مبحث، طول و فاصله ترکها برای بیان کردن مشخصات ساختار توده سنگ استفاده می شود.

مقاومت سنگ درجه سختی آتشباری را معین می کند. آشکار است که سنگ نرم شکستن آسان تری نسبت به سنگ سخت دارد. پارامترهای مقاومت شامل مقاومت فشاری، مقاومت کششی، مقاومت برشی و مدول الاستیسیته می شود. برای آتشباری سنگ، مقاومت فشاری دینامیک و مدول الاستیک دینامیک پارامترهای مهم برای شرح دادن کاراکترهای دینامیک مقاومت سنگ است.

مشخصات خردایش سنگ می تواند توسط توزیع آتشباری در بلوک شرح داده شود. به طور ویژه، تقاضا برای توزیع خردایش وقتی که تجهیزات کار و حمل و نقل مختلف مورد استفاده قرار می گیرد، متفاوت است. به این طریق، ما همچنین می توانیم بگوییم که درجه سختی عملیات آتشباری متفاوت است. درصد بلوکهای دارای عدم کیفیت لازم و میانگین اندازه خردایش در اینجا برای شرح دادن مشخصات خردایش سنگ استفاده می شود.

۷-۴- طریقه محاسبه شبکه عصبی مصنوعی

طریقه محاسبه طبقه بندی قابلیت آتشباری توده سنگ با معادله زیر صورت می گیرد :

$$K = \{L, S, R_{cd}, E_d, P_c, d_{cp}\}$$

شش پارامتر ورودی که ساختار توده سنگ، مقاومت سنگ و خصوصیات خردایش را شرح می دهند برای آموزش شبکه استفاده می شود.

L: طول نهایی شکستها در بلوک $2 \times 2 m^2$.

S : میانگین فاصله شکست‌ها در بلوک $2 \times 2 m^2$.

R_{cd} : مقاومت فشاری دینامیک سنگ.

E_d : مدول الاستیک دینامیک سنگ.

P_c : درصد بلوک‌های فاقد کیفیت.

d_{cf} : اندازه میانگین خردایش.

پارامتر خروجی شبکه K است که ترتیب طبقه بندی قابلیت آتشباری توده سنگ است. این داده‌ها برای طراحی یک شبکه عصبی برای ارزیابی طبقه بندی قابلیت آتشباری توده سنگ استفاده می‌شود. در این مطالعه یک شبکه BP که شش ورودی و پنج لایه پنهان و یک خروجی دارد، استفاده شده است. ساختار و فاکتورهای شبکه نهایی به وسیله زمان‌ها یا ترکیبات بهینه به دست می‌آید. شکل‌های دیگر شبکه‌ها این میزان موفقیت در آموزش و تولید شبکه را نشان نمی‌دهد.

۷-۵- مثال و تست

۷-۵-۱- داده‌های شبکه عصبی

با توجه به داده‌ها، مطالعه بر روی طبقه بندی قابلیت آتشباری توده سنگ انجام شد. ۸۸ داده که حالت‌های مختلف آتشباری را بیان می‌کنند، برای ساختار فضای برداری شبکه استفاده می‌شوند. که ۴۴ داده برای آموزش، ۲۲ داده برای اعتبار سنجی و ۲۲ داده برای تست به صورت رندوم انتخاب شده‌اند.

L و S در یک بلوک $2 \times 2 m^2$ در قسمت میانی آتشباری سنجیده می‌شود. R_{cd} و E_d از آزمایش فشار شکافت هاپکینسون^۱ به دست می‌آید و P_c و d_{cp} به وسیله مقایسه ظاهری (چشمی) عکس استاندارد شده به دست می‌آید.

^۱ = Split Hopkinson pressure

یک مجموعه داده گسترش یافته که چندین ورودی را ترکیب می کند، می تواند برای شبکه با وفق پذیری پیچیده استفاده شود. در چنین زمانی دقت طبقه بندی قابلیت آتشباری توده سنگ بهبود می یابد.

۷-۶- نتایج تست

داده های آموزش و اعتبارسنجی برای آموزش و اعتبارسنجی شبکه عصبی استفاده می شوند. ساختار و فاکتورهای شبکه ها وقتی که میزان مینیمم میانگین مجذور خطا (MSE) پس از زمان های ترکیب بهینه، رضایت بخش می شود به دست می آیند. داده های تست به عنوان بردار کیفیت برای تست کردن ظرفیت عمومیت بخشیدن شبکه بهینه استفاده می شود. تعدادی از نتایج طبقه بندی قابلیت آتشباری توده سنگ در جدول (۶-۱) نشان داده شده است. تفاوت بین مقدار واقعی و تست K کمتر از ۱۰٪ است و این نتایج قابل قبول است.

جدول ۶-۱- نتایج طبقه بندی قابلیت آتشباری سنگ با استفاده از شبکه عصبی مصنوعی [۲۳]

$L(m)$	$S(cm)$	$R_{cd}(Mpa)$	$E_d(Gpa)$	$P_c(\%)$	$d_{ip}(mm)$	K(real)	K(testing)
۸,۸۹	۶۳,۳۴	۲۳۵,۰۰	۶۴,۰۰	۰,۵۶	۳۵۲,۰۰	۳	۲,۹۹
۷,۴۳	۷۳,۰۰	۲۳۵,۰۰	۶۴,۰۰	۰,۲۳	۲۳۴,۰۰	۳	۳,۰۵
۹,۱۲	۲۴,۰۰	۱۳۵,۰۰	۴۴,۰۰	۰,۴۶	۱۹۸,۰۰	۱	۱,۱۰
۹,۸۹	۱۱,۳۴	۱۳۵,۰۰	۴۴,۰۰	۰,۳۹	۲۰۰,۰۰	۱	۱,۰۵
۶,۵۴	۶۷,۰۰	۲۲۹,۰۰	۷۸,۰۰	۰,۴۵	۲۸۳,۰۰	۳	۳,۰۸
۵,۹۸	۷۳,۰۰	۲۴۰,۰۰	۷۸,۰۰	۰,۲۳	۲۵۲,۰۰	۳	۳,۰۱

وزن های پارامترهای ورودی مختلف در شبکه در جدول (۶-۲) لیست شده است.

جدول ۶-۲- وزن ورودی های مختلف در شبکه [۲۳]

	$L(m)$	$S(cm)$	$R_{cd}(Mpa)$	$E_d(Gpa)$	$P_c(\%)$	$d_{ep}(mm)$
PE _۱	۳,۶۲	۱۵,۷۰	-۴,۰۸	-۶,۷۷	۸,۰۶	۱,۸۷
PE _۲	-۶,۶۸	۴,۸۰	۳,۹۳	۳,۲۱	۴,۵۶	۲,۵۵
PE _۳	-۳,۶۶	۸,۲۱	۱,۴۷	-۷,۰۰	۵,۳۶	۱,۷۳
PE _۴	-۰,۸۰	-۸,۶۷	-۶,۱۴	-۰,۰۵	۷,۲۲	-۹,۴۲
PE _۵	-۰,۹۲	۱,۱۲	-۰,۰۰	۰,۳۹	-۰,۶۱	-۱,۲۲

این مسأله دریافت می شود که ساختار توده سنگ، که معمولاً فاکتور مهم مؤثر در نتایج آتشباری سنگ است، به طور مقایسه‌ای وزن کمتری از فاکتورهای دیگر دارد. طول و فاصله شکست‌ها که ساختار توده سنگ و درصد بلوک بی کیفیت و اندازه میانگین خردایش را بیان می کند، نتایج مهمی را در طبقه بندی قابلیت آتشباری توده سنگ در بر دارد.

۷-۷- نتیجه گیری

مدل شبکه عصبی به طور موفق در این مبحث برای طبقه بندی قابلیت آتشباری توده سنگ ایجاد می شود. شبکه مدل، ساختار پیشخور دارد و بر مبنای یادگیری BP است. بردار ورودی شامل شش خصوصیت ساختار توده سنگ، مقاومت سنگ و درجه خردایش آتشباری است. خروجی شبکه یک بردار تنهایی است که ترتیب طبقه بندی قابلیت آتشباری توده سنگ را نشان می دهد.

شبکه عصبی مصنوعی روش جدیدی است که برای طبقه بندی قابلیت آتشباری توده سنگ استفاده می شود. به دلیل انعطاف پذیری و عمومیت این روش، خطای یک داده نمونه تأثیر کمی در نتایج نهایی دارد. آموزش شبکه، تست شبکه و تولیدات، سریع و واقعی و دارای کارایی بالا هستند.

این روش آسان است و می تواند به طور مناسبی در مهندسی آتشباری سنگ استفاده شود [۲۳].

- 1- Serkan Yilmaz , Cem Diemircioglu , Serhat Akin- 2002 – Application of artificial neural network to optimum bit selection – Elsevier science
- 2- Xia Yuanyou , Xia Yanming , Zhu Ruigeng – 1997 – An engineering geology evaluation method based on an artificial neural network – Elsevier science
- 3- Liquan Ren , Zhiye Zhao – 2002 –An optimal neural network and concretet strenght modeling - Published by Elsevier science
- 4- Y.yang , Q.zhang – 1998- The application of neural network to rock engineering systems(RES) – Published by pergamon science
- 5- C.y.kim , G.j.bae , S.w.hang , C.h.park ,H.k.moon , H.s.shin - 2001 – Neural network based prediction of ground surface settlements due to tunneling - Published by Elsevier science
- 6-J.H.Deng, C.F.Lee – 2000 – Displacement back analysis for a a steep slop at the three Gorges project site – International journal of rock mechanics & mining sciencesSS
- 7- I.K.Kapageridis – 2002 – Artificial neural network technology in mining and environmental - Mining planing and equipment selection
- ۸- مهدی یاوری، سعید مهدوری – ۱۳۸۳ - پیش بینی نرخ نفوذ با استفاده از شبکه عصبی مصنوعی - کنفرانس مهندسی معدن ایران، دانشگاه تربیت مدرس
- ۹- حسین کاظمی – ۱۳۸۱ - معرفی شبکه های عصبی مصنوعی به عنوان تکنیک تخمین ذخیره - سومین کنفرانس داتشجویی مهندسی معدن، دانشگاه صنعتی امیر کبیر
- ۱۰- سهراب ظهره بند – ۱۳۸۱ - تخمین خصوصیات مخزنی توسط شبکه های عصبی مصنوعی در مهندسی نفت - سومین کنفرانس داتشجویی مهندسی معدن، دانشگاه صنعتی امیر کبیر

- ۱۱- مجتبی صدیق عربانی -۱۳۸۱- تخمین تخلخل از روی نگارهای چاه با استفاده از شبکه های عصبی مصنوعی - سومین کنفرانس دانشجویی مهندسی معدن، دانشگاه صنعتی امیر کبیر
- ۱۲- مهدی تدینی، احمدرضا عربانی، مجید نبی بید هندی - ۱۳۸۱ - تعیین نفوذپذیری سنگ مخزن میدان نفتی پارسی با استفاده از شبکه های عصبی مصنوعی - کنفرانس مهندسی معدن ایران، دانشگاه تربیت مدرس
- ۱۳- محمد باقر منهاج - ۱۳۸۱ - مبانی شبکه های عصبی (جلد اول و دوم) - مرکز نشر دانشگاه صنعتی امیر کبیر
- ۱۴- فاطمه طهماسبی - ۱۳۸۳ - مدل سازی معکوس دوبعدی داده های مگنوتلوریک با استفاده از شبکه های عصبی مصنوعی - پایان نامه کارشناسی ارشد، دانشگاه صنعتی شاهرود، دانشکده معدن و ژئوفیزیک
- ۱۵- محمود البرزی - ۱۳۸۰ - آشنایی با شبکه های عصبی مصنوعی - موسسه انتشارات علمی دانشگاه صنعتی شریف
- ۱۶- الهام بخشی - ۱۳۸۲ - شبیه سازی نمودار شاخص فتوالکتریک با شبکه های عصبی مصنوعی - پایان نامه کارشناسی ارشد، دانشگاه صنعتی شاهرود، دانشکده معدن و ژئوفیزیک
- 17- Sou-Sen Leu, Chee-Nan Chen, Shiu-Lin Chang – 2000 – Data mining for tunnel support stability: neural network approach – Elsevier Science
- ۱۸- رسول اجل لوئیان، سید داود محمدی - ۱۳۸۲ - رده بندی توده سنگ (روشی کاربردی در مهندسی عمران) - انتشارات فن آوران
- 19- Yonghun Jong and Chungin Lee – 2002 – Application of Neural networks to prediction of powder factor and peak particle velocity in tunnel blasting – International society of explosive engineers

- 20- Tomaz Ambrozic, Goran Turk – 2002 – Prediction of subsidence due to underground mining by artificial neural networks – Elsevier science
- 21- J.Wang, D.Milne and R.Pakalnis- 2002 – Application of a neural network in the empirical design of underground excavation spans – Paper published in Trans, The Institution of Mining and Metallurgy 2002.
- 22- Diana Labelle, John Bares, Illah Nourbakhsh – Material classification by drilling – Robotics institute of Carnegie Mellon university
- 23- Jiang Han, Xu weiya, Xie shouyi – Artificial neural network method of rock mass blastability classification – Research institute of Geotechnical engineering of Hohai university
- ۲۴- علی کاوه، عباس ایران منش – ۱۳۷۸ – شبکه های عصبی مصنوعی در بهینه سازی سازه ها – چاپخانه مرکز تحقیقات ساختمان و مسکن
- ۲۵- ارشیا گرامی زادگان ۱۳۸۲ – معکوس سازی دوبعدی داده های ژئوالکتریکی با استفاده از شبکه های عصبی مصنوعی – پایان نامه کارشناسی ارشد، دانشگاه صنعتی شاهرود، دانشکده معدن و ژئوفیزیک
- 26- Abhijits, Pandya, Robert.macy – 1996- Pattern recognition with neural network in C++ - Newyork: IEE press
- 27- Mario Alvarez Grima – 2000 – Neuro-Fuzzy modeling in engineering geology – Balkema, Rotterdam