






دانشکده مهندسی معدن، نفت و ژئوفیزیک

رشته مهندسی معدن، گرایش مکانیک سنگ

پایان نامه مقطع کارشناسی ارشد

پیش بینی عمر دیسک کاتر TBM در سنگ سخت به روش شبکه عصبی-مطالعه

موردی تونل انتقال آب اوما اويا

نگارنده:

حمیدرضا مرادی

استاد راهنما:

دکتر شکراله زارع

شهریور ۱۴۰۰

تقدیم به

خدای راسبی شاکرم که از روی کرم، پدر و مادری خداکار نصیبم ساخته

تا در سایه درخت پربار وجودشان بیایم و از ریشه آن ما شاخ و برگ گیرم و زیر سایه وجودشان در راه کسب علم و دانش تلاش نمایم.

با تمام عشق حاصل آموخته‌ایم را به پدر و مادر عزیزم تقدیم می‌کنم که مهر آسمانی‌شان آرام‌بخش آلام زمینی‌ام است و هر چه بگویم قطره‌ای از دریای بی‌کران مهربانی‌شان را

پاس نتوانم بگویم.

سپاسگزاری

از استاد ارجمندم جناب آقای دکتر شکراله زارع که به عنوان استاد راهنما در مراحل مختلف این پایان نامه

همواره با صبر و کثرت روئی بنده را راهنمایی و بار بنمودهای شان مرا تا پایان مسیر همراهی کردند و قدردانی می‌نمایم.

همچنین از آقای مهندس کریمی بابت بخاری و رهنمودهای شان در مسیر پایان نامه شکر و قدردانی می‌کنم.

در پایان از اساتید و همه دوستانی که مراد این تحقیق یاری رسانند شکر و قدردانی می‌نمایم.

تعمدنامه

اینجانب **حمیدرضا مرادی** دانشجوی دوره کارشناسی ارشد رشته مهندسی معدن-گرایش مکانیک سنگ دانشکده مهندسی معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود نویسنده پایان نامه پیش‌بینی عمر دیسک کاتر TBM در سنگ سخت به روش شبکه عصبی-مطالعه موردی تونل انتقال آب اوما اويا تحت راهنمایی دکتر شکراله زارع متعهد می‌شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است.

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

با توجه به هزینه‌های ناشی از سایش ابزار حفاری در پروژه‌های تونل‌سازی، نیاز روزافزون به ارائه مدلی جامع و کاربردی برای تخمین و پیش‌بینی نرخ سایش بیش از پیش احساس شده است. محققان زیادی به دنبال اهمیت موضوع ساینده‌گی و تأثیر آن بر راندمان و زمان حفاری، سعی نموده‌اند تا با استفاده از مدل‌های تجربی و نیمه تئوری به تخمین و پیش‌بینی نرخ سایش بپردازند. با توجه به این که این مدل‌ها در شرایط زمین‌شناسی خاص توسعه یافته‌اند و همچنین تأثیرگذاری همه پارامترهای مؤثر بر نرخ سایش در این مدل‌ها در نظر گرفته نشده است، قابل تعمیم به تمامی شرایط زمین‌شناسی نیستند. کاستی‌های این روش‌ها از یک سو و رشد شاخه علم در زمینه‌های هوش مصنوعی و شبکه عصبی از سوی دیگر، محققین را به استفاده و بررسی کاربرد این روش نسبت به روش‌های پیشین سوق داده است. شبکه‌های عصبی در زمانی که ارتباط بین پارامترهای ورودی و خروجی یک کمیت مشخص نباشد ایده خوبی برای مدل‌سازی به شمار می‌رود. در این پژوهش به بررسی تأثیر پارامترهای سنگ و ماشین بر مدل‌های پیش‌بینی عمر دیسک‌کاتر (Gehering و NTNTU، CSM) پرداخته شده است. نتایج حاصل نشان از تأثیرگذاری متفاوت هر یک از این پارامترها بر مدل‌های سایش دیسک‌کاتر دارد که نشان‌دهنده اهمیت انتخاب مدلی مناسب با توجه به شرایط زمین‌شناسی منطقه است. در ادامه با استفاده از روش شبکه عصبی به ارائه مدلی برای تخمین و پیش‌بینی عمر دیسک‌کاتر و مقایسه‌ی آن با سایر مدل‌های متداول پیش‌بینی عمر دیسک‌کاتر پرداخته شده است. پس از تعیین پارامترهای مؤثر بر نرخ سایش و ایجاد ساختار مناسب شبکه عصبی به پیش‌بینی نرخ سایش در تونل‌های انتقال آب اوما اوایا و کرمان پرداخته شده است. با توجه به ضریب تعیین بالای ۰/۶ و میانگین خطای به‌دست‌آمده برای مدل شبکه عصبی و مقایسه‌ی آن با روش‌های NTNTU، CSM و Gehering نشان از کارایی مناسب شبکه عصبی در پیش‌بینی میزان نرخ سایش دیسک‌کاتر در تونل‌هایی با کلاس ساینده‌گی بالا دارد. اما در تونل‌های با کلاس ساینده‌گی کم نیازمند بررسی بیشتری است.

کلمات کلیدی: نرخ سایش، شبکه عصبی، دیسک کاتر، مدل‌سازی.

فهرست مطالب

صفحه	عنوان
------	-------

فصل اول: کلیات

۲	۱-۱- مقدمه
۲	۱-۲- تعریف مسئله
۴	۱-۳- ضرورت انجام تحقیق
۵	۱-۴- روش تحقیق

فصل دوم: پیشینه پژوهش

۸	۲-۱- مقدمه
۸	۲-۲- تعریف ساینده گی
۱۱	۲-۲-۱- عوامل موثر بر ساینده گی
۱۳	۲-۳- آزمایش های سایش ابزار

صفحه	عنوان
۱۳	۲-۳-۱- سختی ویکرز
۱۶	۲-۳-۲- آزمون سرشار
۱۷	۲-۳-۳- آزمون سایش (AV,AVS) NTNU
۱۹	۲-۴-۱- مدل های تخمین عمر ابزار
۱۹	۲-۴-۱- مدل کسینک
۱۹	۲-۴-۲- محاسبه عمر مفید دیسک کاتر به روش (NTNU)
۲۱	۲-۴-۳- محاسبه عمر مفید دیسک کاتر به روش (CSM)
۲۲	۲-۴-۴- مدل فنزئال
۲۲	۲-۴-۵- مدل میدل و بکاران
۲۳	۲-۴-۶- مدل فرخ و بکاران
۲۳	۲-۴-۷- مدل لنو و بکاران
۲۴	۲-۴-۸- مدل تجربی ارائه شده توسط حسن پور

۲-۴-۹-۱ مدل سان و بهکاران ۲۴

۲-۴-۱۰-۱ مدل کرمی و بهکاران ۲۶

۲-۵-۱ مقایسه‌ی بین مدل‌های پیش‌بینی عمر دیسک کاتر ۲۷

۲-۶-۱ جمع‌بندی ۳۰

فصل سوم: بررسی تاثیر پارامترهای سنک و ماشین بر عمر دیسک کاتر

۳-۱-۱ مقدمه ۳۴

۳-۲-۱ بررسی تاثیر پارامترهای سنک و ماشین بر عمر دیسک کاتر ۳۴

۳-۲-۱-۱ تاثیر نرخ نفوذ ۳۵

۳-۲-۲-۱ تاثیر مقاومت فشاری تک محوره (UCS) ۳۷

۳-۲-۳-۱ تاثیر شاخص ساینده‌ی (شاخص عمر دیسک کاتر) ۳۸

۳-۲-۴-۱ تاثیر تعداد دیسک کاتر (N) ۳۹

۳-۳-۱ جمع‌بندی ۴۰

فصل چهارم: مبانی شبکه‌های عصبی

۴-۱- مقدمه	۴۲
۴-۲- معرفی شبکه عصبی	۴۲
۴-۳- اجزای تحلیلی شبکه عصبی	۴۳
۴-۳-۱- توابع فعال‌ساز	۴۵
۴-۴- روش‌های شبکه عصبی	۴۷
۴-۴-۱- شبکه‌های پیشخور	۴۷
۴-۴-۲- الگوریتم یادگیری پس انتشار خطا (Back Propagation)	۴۸
۴-۴-۳- پرسپترون چندلایه یا MLP	۵۰
۴-۴-۴- شبکه‌های عصبی شعاعی یا RBF	۵۰
۴-۴-۵- ماشین‌های بردار پشتیبان یا SVM	۵۱
۴-۵- کاربردهای شبکه‌های عصبی مصنوعی	۵۱

عنوان	صفحه
-------	------

۴-۶- کاربرد شبکه عصبی در مکانیک سنگ	۵۲
۴-۷- معایب شبکه های عصبی	۵۵
۴-۸- جمع بندی	۵۶

فصل پنجم: پیش بینی عمر دیسک کاتر با استفاده از شبکه عصبی

۵-۱- مقدمه	۵۸
۵-۲- منطقه مورد مطالعه	۵۹
۵-۲-۱- مطالعات زمین شناسی	۶۰
۵-۲-۲- اطلاعات آماری داده های ثبت شده ماشین حار	۶۳
۵-۴- پیش بینی عمر دیسک کاتر با شبکه عصبی مصنوعی	۶۵
۵-۴-۱- ایجاد ساختار مناسب شبکه عصبی مصنوعی	۶۵
۵-۵- مقایسه بین مدل شبکه عصبی با سایر مدل های سایش	۷۵
۵-۶- توسعه مدل شبکه عصبی برای استفاده در شرایط لیتولوژی متفاوت	۷۷

صفحه	عنوان
------	-------

۷۸ ۵-۶-۱- آنالیز حساسیت

۸۲ ۵-۶-۲- اعتبار سنجی مدل ایجاد شده

۸۸ ۵-۷- ساختار شبکه عصبی $۸*۹*۷*۱$

۹۰ ۵-۸- جمع بندی

فصل ششم: نتیجه گیری و پیشنهادات

۹۴ ۶-۱- نتیجه گیری

۹۶ ۶-۲- پیشنهادات

۹۷ منابع

فهرست شکل‌ها

صفحه	عنوان
۹	شکل ۱-۲: سایش میث از حد بر روی کد حفاریک TBM (Nilsen et al., 2007).....
۱۰	شکل ۲-۲: کاننرم سایش نرمال (Farrokhi et al., 2018).....
۱۰	شکل ۳-۲: توزیع انواع سایش دیسک کاتر در تونلی واقع در هنگ کنگ (Ciamei et al., 2011; Farrokhi et al., 2018).....
۱۱	شکل ۴-۲: متداولترین نوع سایش دیسک کاتر (عکس مرتضی کرمی در تونل انتقال آب اوماوایا) (Karami et al., 2021).....
۱۲	شکل ۵-۲: عوامل مرتبط با زمین شناسی در ساینده‌گی (Thruo., 1997).....
۱۲	شکل ۶-۲: پارامترهای موثر بر سایش ابزار و عملکرد حفاری (Thuro et al., 2009).....
۱۴	شکل ۷-۲: نمای شماتیک از مون سختی ویکرز (خداپرستی، ۱۳۹۰).....
۱۶	شکل ۸-۲: ساختار دستگاه آزمون سرشار بر طبق (West, 1989) به همراه خراش‌هایی بر روی یک نمونه سنگ (Thruo et al., 2009).....
۱۷	شکل ۹-۲: مقادیر اندیس سایش سرشار برای سنگ‌های مختلف (Plinninger et al., 2008).....
۱۸	شکل ۱۰-۲: اصول کلی آزمایش‌های سایش NTNU (Dahl et al., 2012).....
۱۸	شکل ۱۱-۲: توزیع مقادیر ثبت شده در پایگاه داده NTNU (Dahl et al., 2012).....
۲۰	شکل ۱۲-۲: پارامترهای محاسباتی مورد نیاز برای مدل‌های پیش‌بینی عمر دیسک کاتر (Bruland., 1998a).....
۲۶	شکل ۱۳-۲: منحنی منطبق بر CAL و RAI (Sun et al., 2019).....
۲۷	شکل ۱۴-۲: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده میزان عمر دیسک کاتر با استفاده از مدل‌های مختلف (Karami et al., 2021).....
۲۸	شکل ۱۵-۲: مقایسه‌ی بین مدل‌های سایش دیسک کاتر در کلاس‌های ساینده‌گی متفاوت (Karami et al., 2021).....
۳۰	شکل ۱۶-۲: پیش‌بینی عمر دیسک کاتر در پروژه انتقال کابل نخ‌چوب با استفاده از مدل‌های مختلف (Farrokhi et al., 2018).....

- شکل ۳-۱: تغییرات متوسط عمردیسک کاتر بر اساس نرخ نفوذ ۳۶
- شکل ۳-۲: رابطی بین نرخ نفوذ و نیروی کله حصار در مقاومت های متفاوت ننگ (Frenzell et al., 2008) ۳۶
- شکل ۳-۳: رابطی بین متوسط عمردیسک کاتر و مقاومت فشاری تک محوره ۳۷
- شکل ۳-۴: رابطی بین نرخ سایش CAI و CLI با متوسط عمردیسک کاتر ۳۸
- شکل ۳-۵: رابطی بین تعداد دیسک کاتر با متوسط عمردیسک کاتر ۳۹
- شکل ۴-۱: ساختار نورو ۴۴
- شکل ۴-۲: معروفترین توابع فعال ساز (Demuth & Beal., 2012) ۴۵
- شکل ۴-۳: ساختار شبکه عصبی به صورت شتیک (افشاری و بکاران، ۱۳۹۱) ۴۶
- شکل ۴-۴: مقایسه بین مقادیر پیش بینی شده و مقادیر واقعی (Grima et al., 2000; Yagiz et al., 2009) (یاوری و بکاران، ۱۳۸۶) ۵۴
- شکل ۵-۱: موقعیت پروژه و تونل انتقال آب اوماوایا (Pourhashemi et al., 2021) ۵۹
- شکل ۵-۲: واحد های نسبی موجود در موقعیت پروژه (Pourhashemi et al., 2021) ۶۰
- شکل ۵-۳: توزیع واحد های زمین شناسی در امتداد محور تونل (Pourhashemi et al., 2021) ۶۱
- شکل ۵-۴: نمایش مقادیر واقعی در مقابل مقادیر پیش بینی شده میزان سایش: الف) برای مجموعه داده های آموزش ب) برای مجموعه داده های ارزیابی ۷۰
- شکل ۵-۵: نمایش مقادیر واقعی در مقابل مقادیر پیش بینی شده میزان سایش: الف) برای مجموعه داده های آزمون ب) فراوانی در هر باند ۷۰
- شکل ۵-۶: نمایش مقادیر واقعی در مقابل مقادیر پیش بینی شده میزان سایش برای مجموعه ی داده های آزمون جدید ۷۱
- شکل ۵-۷: ساختار شبکه عصبی سه لایه با چهار نورو در لایه میانی ۷۲
- شکل ۵-۸: نتایج آنالیز حساسیت داده های ورودی بر تابع هدف ۷۴
- شکل ۵-۹: مقایسه مدل های بررسی نرخ سایش ۷۶

- شکل ۵-۱۰: میانگین اختلاف مقادیر پیش بینی شده نرخ سایش با مقادیر واقعی نرخ سایش ۷۶
- شکل ۵-۱۱: نمایش مقادیر واقعی در مقابل مقادیر پیش بینی شده نرخ سایش: الف) برای مجموعه داده های آموزشی ب) برای مجموعه داده های ارزیابی ۷۸
- شکل ۵-۱۲: نمایش مقادیر واقعی در مقابل مقادیر پیش بینی شده میزان سایش برای مجموعه ی داده های آزمون ۷۸
- شکل ۵-۱۳: یک شبکه پسترون چند لایه فرضی ۷۹
- شکل ۵-۱۴: نتایج آنالیز حساسیت داده های ورودی بر تابع هدف ۸۲
- شکل ۵-۱۵: مقایسه مدل های بررسی نرخ سایش ۸۴
- شکل ۵-۱۶: میانگین اختلاف مقادیر پیش بینی شده نرخ سایش با مقادیر واقعی نرخ سایش ۸۵
- شکل ۵-۱۷: مقایسه مدل های بررسی نرخ سایش در تونل انتقال آب کرمان ۸۷
- شکل ۵-۱۸: میانگین اختلاف مقادیر پیش بینی شده نرخ سایش با مقادیر واقعی نرخ سایش در تونل انتقال آب کرمان ۸۷
- شکل ۵-۱۹: نای کلی از ساختار شبکه عصبی ۸۸
- شکل ۵-۲۰: ماتریس ضرایب شبکه عصبی ۸۹
- شکل ۵-۲۱: نحوه به کارگیری ورودی های شبکه برای استفاده در رابطه ی ۵-۲۴ ۸۹

فهرست جداول

صفحه	عنوان
۱۳	جدول ۱-۲: پارامترهای تاثیرگذار ماشین حفاری و توده سنگ در فرآیند سایش دیسک کاتر (Bruland.,1998a)
۱۵	جدول ۲-۲: عدد سختی ویکرز (VHN) برای کانی های مختلف (Bruland.,1998b)
۱۵	جدول ۲-۳: محاسبه عدد سختی ویکرز برای یک نمونه سنگ از جنس کائیس (Bruland.,1998b)
۱۸	جدول ۲-۶: طبقه بندی معادیر AV و AVS (Dahl et al.,2012)
۲۳	جدول ۲-۷: تعیین وزن مخصوص دیسک با استفاده از مدل کیرینگ و میدل
۲۸	جدول ۲-۸: طبقه بندی کلاس های ساینده (Karami et al.,2021)
۳۵	جدول ۳-۱: پارامترهای ورودی برای آنالیز عمر دیسک کاتر
۵۲	جدول ۴-۱: کاربرد های شبکه عصبی در علوم مختلف
۶۲	جدول ۵-۱: مشخصات واحد های زمین شناسی موجود در طول تونل (FARAB.,2016)
۶۳	جدول ۵-۲: خلاصه نتایج درصد کانی های تشکیل دهنده هر واحد زمین شناسی (FARAB.,2016)
۶۳	جدول ۵-۳: مشخصات مربوط به تونل و ماشین حفر
۶۴	جدول ۵-۴: اطلاعات آماری داده های ثبت شده در منطقه مورد مطالعه
۶۷	جدول ۵-۵: خلاصه برخی از نتایج به دست آمده برای ایجاد ساختار مناسب شبکه
۶۸	جدول ۵-۶: کدگذاری هر نوع سنگ
۶۹	جدول ۵-۷: تعریف باندهای خطا
۷۰	جدول ۵-۸: ارزیابی کارایی شبکه با تغییر تعداد نورون های لایه میانی

- جدول ۵-۹: وزن های اتصالی بین نورون های لایه های مختلف شبکه عصبی ۷۲
- جدول ۵-۱۰: نحوه محاسبه حاصلضرب وزن های W_{Kj} و W_{ji} ۷۳
- جدول ۵-۱۱: نحوه محاسبه حاصلضرب وزن های W_{Kj} و W_{ji} ۷۳
- جدول ۵-۱۲: آنالیز حساسیت داده های ورودی بر تابع هدف ۷۴
- جدول ۵-۱۳: نتایج حاصل برای نرخ سایش با استفاده از مدل های مختلف ۷۵
- جدول ۵-۱۴: آنالیز حساسیت داده های ورودی بر تابع هدف ۸۲
- جدول ۵-۱۵: نتایج حاصل برای نرخ سایش با استفاده از مدل های مختلف ۸۴
- جدول ۵-۱۶: مشخصات واحد های زمین شناسی موجود و پارامتر های عملیاتی ماشین حفر ۸۵
- جدول ۵-۱۷: نتایج حاصل برای نرخ سایش با استفاده از مدل های مختلف ۸۶
- جدول ۶-۱: خلاصه نتایج مقایسه ی بین شبکه عصبی و سایر مدل های سایش ۹۵

فصل اول

کلیات

۱-۱- مقدمه

نیاز به ابزار و ماشین آلات حفاری با توجه به توسعه روزافزون نیازهای جوامع بشری به فضاهای زیر زمینی از جمله تونل‌های راه، انتقال آب، بارگیری مواد معدنی و غیره به سرعت در حال گسترش است. یکی از عواملی که عدم پیش‌بینی به موقع آن می‌تواند هزینه‌های هنگفتی را بر پروژه‌های حفاری تونل تحمیل کند موضوع ساینده‌گی سنگ بر روی دیسک‌کاترهای ماشین حفار است که عدم پیش‌بینی مناسب آن می‌تواند سبب وقفه زیاد در اجرای پروژه، آسیب جدی به کله حفار و در نتیجه افزایش هزینه و کاهش راندمان عملیات حفاری تونل شود به گونه‌ای که تخمین عمر دیسک‌کاتر به یکی از مهم‌ترین دغدغه‌ها و چالش‌های اخیر پژوهشگران صنعت تونل سازی تبدیل شده است. پژوهش‌های مختلفی توسط محققان در این زمینه انجام شده است که نتایج این پژوهش‌ها ارائه مدل‌های تجربی و ریاضی برای پیش‌بینی میزان نرخ سایش بوده است. از آن جایی که این مدل‌ها در شرایط زمین‌شناسی خاص توسعه یافته‌اند استفاده از این مدل‌ها دارای محدودیت بوده است و نیاز به داشتن اطلاعات صحیح و کامل از شرایط زمین‌شناسی منطقه دارد. در این تحقیق به مدل‌سازی و تخمین عمر دیسک‌کاتر با استفاده از شبکه عصبی پرداخته شده است. با در نظر گرفتن پارامترهای مؤثر سنگ و ماشین بر نرخ سایش به عنوان ورودی‌های شبکه عصبی به بررسی و کاربرد این روش برای مدل‌سازی پرداخته شده است.

۱-۲- تعریف مسئله

سایش دیسک‌کاتر و جایگزینی دیسک‌کاترهای فرسوده بسیار زمان‌بر بوده به نحوی که بر روی طراحی و برنامه‌ریزی پروژه تأثیر می‌گذارد. نرخ مصرف دیسک سهم عمده‌ای را در بهره‌وری کل پروژه و نیز افزایش هزینه‌ها ایفا می‌کند، از آن جایی که امکان بازرسی مکرر به ابزار برشی در ماشین‌های حفر تونل وجود ندارد، مخاطرات سایش فلزات و هزینه‌های ناشی از تعمیر و نگهداری آن‌ها به تناسب افزایش پیدا می‌کند؛ بنابراین

با توجه به مطالب بیان شده تعیین هرچه دقیق‌تر عمر مفید ابزار برش در موفقیت پروژه بسیار مؤثر می‌باشد (برزگری و ارومیه، ۱۳۹۴).

عمر دیسک کاتر به عوامل متعددی بستگی دارد که برخی از آن‌ها عبارت‌اند از: قطر دیسک، جنس سنگ، درصد کوارتز سنگ‌های مسیر، مشخصات درزه داری توده سنگ، فاصله‌داری دیسک، سرعت کاتر هد، نیروهای فشاری، فناوری به‌کاررفته در ایجاد شکل ابزار برش و نوع فولاد، ارتفاع روباره تونل و غیره. در صورت پیش‌بینی قابل قبول از نرخ سایش ابزار، تخمین قابل اطمینانی از زمان و بودجه لازم جهت انجام پروژه می‌تواند صورت پذیرد. با توجه به اهمیت پیش‌بینی نرخ سایش ابزار در عملیات تونل‌سازی هم‌زمان با ساخت TBM همواره محققانی به دنبال یافتن روشی برای پیش‌بینی مقدار آن بوده‌اند و تاکنون روش‌های تئوری و تجربی نیز ارائه شده است. روش تجربی بر مبنای ارتباط عملی و مشاهداتی بین پارامترهای زمین و ماشین برقرار است و به واسطه برازش بین خصوصیات سنگ و پارامترهای ماشین با نرخ سایش به‌دست آمده است. مزیت روش‌های تجربی این است که به طور طبیعی تمام تأثیرات ناشی از زمین و ماشین را در نظر می‌گیرند، اما با این حال رشد فناوری و ارائه‌ی ماشین‌هایی با قابلیت‌های متفاوت استفاده از این روش‌ها را محدود می‌سازد.

با این وجود، به دلیل اینکه مدل‌های ارائه شده در یک حالت خاص از شرایط زمین پیشنهاد شده‌اند، قابل تعمیم به تمام شرایط نیستند. در سال‌های اخیر از روش شبکه‌های عصبی مصنوعی به عنوان ابزاری جدید جهت پیش‌بینی نرخ نفوذ^۱ و نرخ پیشروی^۲ و غیره استفاده شده است. شبکه‌های عصبی مصنوعی^۳ با الهام از ساختار مغز و عملکرد موازی آن به وجود آمده است و به مدل‌های ریاضی محض نیازی ندارد، بلکه همانند انسان تجربه کسب کرده و سپس نتیجه این تجربیات را تعمیم می‌دهد. در مواردی که رابطه مشخصی میان پارامترهای ورودی و خروجی وجود نداشته و ارتباط میان آن‌ها توسط روش‌های مرسوم قابل شناسایی نیست،

^۱ Penetration rate (PR)

^۲ Advance rate (AR)

^۳ Artificial neural network

استفاده از روش شبکه‌های عصبی مصنوعی به سبب عدم نیاز به فرمول‌بندی و پویا بودن شبکه و همچنین امکان لحاظ کردن اثر پارامترهای مؤثر بیشتر، ایده خوبی برای تخمین و مدل‌سازی به شمار می‌رود.

روش‌های شبکه عصبی برای حل مسئله سه مرحله را طی می‌کنند، الف) آموزش، ب) ارزیابی و ج) اجرا. آموزش فرایندی است که طی آن الگوریتم می‌آموزد تا الگوی موجود در ورودی‌ها را (که به صورت مجموعه داده است) بشناسد، برای این منظور هر الگوریتم از مجموعه‌ای از قوانین یادگیری که نحوه یادگیری را تعریف می‌کنند، استفاده می‌کند. ارزیابی، توانایی الگوریتم است برای ارائه جواب قابل قبول در قبال ورودی‌هایی که در مجموعه آموزشی نبوده‌اند. استفاده از شبکه برای انجام عملکردی که به آن منظور طراحی شده است را اجرا می‌گویند (منهاج، ۱۳۹۱).

در این تحقیق با استفاده از روش شبکه عصبی مدلی مناسب جهت پیش‌بینی نرخ سایش دستگاه‌های حفاری مکانیزه در سنگ‌های سخت ارائه می‌شود و میزان دقت آن‌ها با روش‌های متداول مقایسه شده و میزان توانایی این روش و روش‌های مرسوم مورد ارزیابی قرار می‌گیرد.

۱-۳- ضرورت انجام تحقیق

تخمین قابل اطمینان میزان سایش ابزار، یکی از نیازهای اساسی در حفاری مکانیزه است. نتایج مطالعات نشان داده است که روش‌های موجود در ارزیابی سایش ابزار به مدل‌های تجربی و نیمه تئوری محدود شده است. مدل‌های مذکور، با توجه به عدم امکان ارزیابی سایش ابزار در شرایط مشابه برجا و بررسی تأثیر پارامترهای مختلف در سایش ابزار، دارای محدودیت فراوانی می‌باشند؛ لذا انجام تحقیقات برای ارائه مدلی جدید با قابلیت ارزیابی سایش ابزار در شرایط نسبی مشابه شرایط عملی حفاری مکانیزه هدف این تحقیق به شمار می‌رود.

با توجه به مشکلات موجود در مدل‌های پیشین و همچنین خطای بالای مقادیر پیش‌بینی شده توسط مدل‌های موجود و همچنین نبود مدلی که امکان پیش‌بینی نرخ سایش را در زمین‌های ناهمگن داشته باشد

نیاز به مدلی با ساختار ساده و کاربرد فراوان احساس می‌شد. در این تحقیق انتظار می‌رود با استفاده از روش شبکه عصبی معایب مدل‌های دیگر را تا حدودی برطرف کرد و میزان خطا را کاهش داد.

۱-۴- روش تحقیق

در این تحقیق ابتدا به مرور مطالعات گذشته پرداخته و برجسته‌ترین مدل‌هایی که تاکنون برای پیش‌بینی عمر دیسک کاتر ارائه شده است معرفی و مورد بحث قرار می‌گیرد سپس با کمک روش شبکه عصبی مدلی برای پیش‌بینی عمر دیسک کاتر ارائه خواهد شد، برای انجام این منظور به جمع‌آوری داده برای تربیت شبکه عصبی نیاز است، داده‌های موردنیاز با استفاده از روش‌هایی مانند استفاده از داده‌ها و آمارهای موجود، انجام آزمایش یا با استفاده از نرم‌افزارهای موجود تولید می‌گردد البته با توجه به محدودیت در انجام آزمایش و عدم دسترسی به مکان مورد مطالعه در این تحقیق از داده‌های ثبت شده استفاده شده است. تعیین تمامی پارامترهای مرتبط که بر پیش‌بینی عمر دیسک کاتر مؤثرند بسیار مشکل و پیچیده است، برخی پارامترها مستقل و برخی دیگر تأثیر فراوانی بر خروجی شبکه دارند. در صورتی که پارامترهای ورودی به درستی انتخاب شوند، با در اختیار داشتن اطلاعات لازم برای آموزش شبکه و استفاده از الگوریتم آموزشی مناسب، شبکه، روابط بین ورودی‌ها و خروجی‌ها را به‌خوبی فرامی‌گیرد و همچنین ارائه نتایج توسط این شبکه‌ها به سرعت انجام می‌گیرد. پارامترهایی که برای پیش‌بینی عمر دیسک کاتر در نظر گرفته شده است از میان پارامترهای قطر دیسک، جنس سنگ، درصد کوارتز سنگ‌های مسیر، مشخصات درزه داری توده سنگ، فاصله‌داری دیسک، سرعت کاترهد، نیروهای فشاری، فناوری به‌کاررفته در ایجاد شکل ابزار برش و نوع فولاد، ارتفاع روباره تونل، نرخ نفوذ و غیره بوده است. به‌منظور مدل‌سازی پیش‌بینی عمر دیسک کاتر با استفاده از شبکه عصبی در اولین گام داده‌ها به سه بخش داده‌های آموزشی^۴، آزمون^۵ و اعتبارسنجی^۶ تقسیم می‌شود، ۱۵ درصد داده‌ها به صورت

^۴ Training

^۵ Test

^۶ Validation

تصادفی انتخاب و در مجموعه داده‌های آزمون قرار گرفته، ۱۵ درصد داده‌ها در مجموعه داده‌های اعتبارسنجی و ۷۰ درصد داده‌ها نیز برای آموزش شبکه برای مدل‌سازی به کار گرفته شده است. پس از مدل‌سازی میزان حساسیت مدل نسبت به پارامترهای ورودی سنجیده و پارامترها با اثر کمتر حذف و پارامتر با تأثیر بیشتر جایگزین خواهد شد و همچنین نتایج مدل با نتایج واقعی مقایسه خواهد شد. در این تحقیق با استفاده از زبان برنامه‌نویسی متلب سعی شده است پارامترهای مؤثر بر نرخ سایش دیسک با بیشترین تأثیر انتخاب و مدلی مبتنی بر شبکه عصبی برای پیش‌بینی عمر دیسک ارائه شده است. برای آموزش شبکه از الگوریتم لونیبرگ مارکوات که سریع‌ترین پاسخ در بین الگوریتم‌ها دارد استفاده شده است.

فصل دوم

پیشینه پژوهش

۲-۱- مقدمه

در صورت پیش‌بینی قابل قبول از نرخ سایش ابزار، تخمین قابل اطمینانی از زمان و بودجه لازم جهت انجام پروژه می‌تواند صورت پذیرد. با توجه به اهمیت پیش‌بینی نرخ سایش ابزار در عملیات تونل‌سازی هم‌زمان با ساخت TBM همواره محققانی به دنبال یافتن روشی برای پیش‌بینی مقدار آن بوده‌اند و تاکنون روش‌های تئوری و تجربی نیز ارائه شده است. روش تجربی بر مبنای ارتباط عملی و مشاهداتی بین پارامترهای زمین و ماشین برقرار است و به واسطه برآزش بین خصوصیات سنگ و پارامترهای ماشین با نرخ سایش به‌دست‌آمده است. در این فصل ابتدا به تعریف موضوع ساینده‌گی و عوامل مؤثر بر آن پرداخته سپس به معرفی مدل‌های معروف تخمین نرخ سایش ابزار و در نهایت به مقایسه این مدل‌ها پرداخته شده است.

۲-۲- تعریف ساینده‌گی

سایش به‌صورت ازدست‌رفتن مداوم مواد از سطح یک جسم جامد در اثر کنش‌های مکانیکی مابین دو جسم تعریف می‌شود (آمون و همکاران، ۱۳۹۴). حسن‌پور و رستمی ساینده‌گی را به عنوان یکی از ویژگی‌های زمین دانسته که سبب سایش و خوردگی ابزار و قطعات ماشین شده است (حسن‌پور و رستمی، ۱۳۸۹). به‌منظور تشریح این بحث ضروری است اصطلاحات سایش اولیه^۷ و سایش ثانویه^۸ معرفی شود. سایش اولیه در اثر تماس و کنش بین سنگ و مصالح سنگی با دیسک‌کاتر به وجود می‌آید و انتظار سایش ابزار و سطوح حفاری مانند مته‌ها، کاترهای حلقه‌ای، اسکریپرها (ابزار خراشنده) و باکت‌ها (ابزار خارج کردن مواد) و ... وجود دارد که برای حفاری طراحی شده‌اند و نیاز به تعویض در فواصل مناسب دارند.

سایش ثانویه، یک سایش برنامه‌ریزی نشده است که توسط طراحان و تولیدکنندگان TBM پیش‌بینی نشده است و مستقیماً به علت برش سنگ بوجود نیامده است و زمانی رخ می‌دهد که سایش اولیه بیش از حد در ابزار برشی که در بالا توصیف شد ایجاد شود مانند سایش صفحه کله‌حفار و ساختار طراحی شده برای

^۷ Primary wear

^۸ Secondary wear

نگهداری و یا تکیه‌گاه ابزار در مکان‌هایی مانند میله‌های داخل کاترهد (چرخ پره‌ها) و غیره است. (Wittke et al., 2007; Herrenknecht & Frenzel., 2005). در شکل ۱-۲ نمونه‌ای از سایش اولیه دیسک با مکانیزم‌های متفاوت و سایش ثانویه نشان داده شده است.




شکل ۱-۲: سایش بیش از حد بر روی کله حفار یک TBM (Nilsen et al., 2007).

رایج‌ترین نوع سایش اولیه، سایش نرمال^۹ است که به عنوان کاهش یکنواخت قطر دیسک تعریف می‌شود. به دلیل سایش نرمال، عرض نوک دیسک افزایش می‌یابد و در نتیجه، فشار وارد شده به سنگ توسط دیسک کاتر کاهش می‌یابد (شکل ۲-۲). نتایج منفی فرسودگی دیسک کاتر می‌تواند در نهایت بر سرعت تونل زنی و در نتیجه هزینه تونل زدن تأثیر بگذارد. معمولاً سایش نرمال مکانیسم غالب برای الگوی سایش دیسک-کاتر با سهم بیش از ۸۰ درصد است (Yang et al., 2018; Ciamei & Grandori., 2011). در شکل ۳-۲ نمونه‌ای از آن نشان داده شده است. همچنین مواردی از آسیب غیر عادی^{۱۰} بر روی دیسک کاترها وجود دارد که شامل خرابی یا تاقان، نشت روغن، شکستن حلقه کاتر و بریدگی می‌شود (شکل ۴-۲). در حین بازرسی روزانه، در


^۹ Normal wear

^{۱۰} Abnormal Wear

صورت تشخیص آسیب غیرعادی، دیسک کاتر اغلب بلافاصله تعویض می‌شود (Zhang et al., 2017; Zhao et al., 2007).



شکل ۲-۲: مکانیزم سایش نرمال (Farrokh et al., 2018)



شکل ۲-۳: توزیع انواع سایش دیسک کاتر در تونلی واقع در هنگ کنگ (Ciamei & Grandori., 2011; Farrokh et al., 2018)




شکل ۲-۴: متداول ترین نوع سایش دیسک کاتر (الف) سایش نرمال (ب) ترک خوردگی حلقه (ج) شکستن حلقه (د) ساییدگی یک طرفه (عکس مرتضی کرمی در تونل انتقال آب اوما اوپا) (Karami et al., 2021)

۲-۲-۱- عوامل مؤثر بر سایندهی

علی‌رغم دارا بودن روش‌ها و شاخص‌های مختلف ارزیابی سایش، مفهوم پیش‌بینی سایش دیسک کاتر هنوز کار دشواری است. دلیل اصلی این امر عدم تجربه عملی کافی در استفاده از این روش‌ها برای پیش‌بینی سایش دیسک کاتر است (Farrokh & kim., 2018). سایش دیسک کاتر به عوامل متعددی از جمله شرایط سنگ و زمین‌شناسی و از سوی دیگر به خصوصیات ماشین‌آلات مورد استفاده بستگی دارد (Thuro et al., 2009). در اشکال ۲-۵ و ۲-۶ و جدول ۲-۱ به جزئیات بیشتری در مورد هر یک از عوامل مربوط به سایندهی پرداخته شده است. در شکل ۲-۵ به پارامترهای کانی، سنگ و توده سنگ اشاره شده است اما در شکل ۲-۶ علاوه بر این پارامترها به جنس ابزار و تجهیزات ماشین اشاره شده است.



شکل ۲-۵: عوامل مرتبط با زمین‌شناسی در ساینده‌گی (Thruo.,1997)



شکل ۲-۶: پارامترهای موثر بر سایش ابزار و عملکرد حفاری (Thuro et al.,2009)

جدول ۱-۲: پارامترهای تأثیرگذار ماشین حفاری و توده سنگ در فرایند سایش دیسک کاتر (Bruland.,1998a)

پارامترهای ماشین	پارامترهای توده سنگ
شکل و قطر کله حفار	میزان کانی‌های ساینده
قطر دیسک کاتر	شاخص عمر کاتر (CLI)
سرعت چرخش کله حفار	
تعداد دیسک کاتر	
نرخ نفوذ	
نوع و کیفیت دیسک کاتر	

۲-۳- آزمایش‌های سایش ابزار

از آن جایی که برخی از مدل‌های تخمین عمر ابزار با استفاده از آزمون‌های آزمایشگاهی به تخمین عمر ابزار پرداخته‌اند ابتدا به معرفی این آزمون‌ها پرداخته شده است و سپس به بیان و معرفی این مدل‌ها اقدام خواهد شد. به منظور برآورد میزان ساینده‌گی سنگ، اغلب از روش‌های آزمون ویکرز^{۱۱} (عدد سختی ویکرز)، آزمون سرشار^{۱۲} (شاخص سرشار) و آزمون سایش NTNU (مقادیر سایش AV، AVS) استفاده می‌شود.

۲-۳-۱- سختی ویکرز

به عنوان سختی کانی‌ها (در برابر فرورفتگی) تعریف می‌شود و عدد سختی ویکرز (VHN) را ارائه می‌دهد. عدد سختی ویکرز، نسبت بار اعمال شده برای ایجاد فرورفتگی (گرم و یا کیلوگرم نیرو) تقسیم بر سطح تماس تحت تأثیر (میلیمتر مربع) تعریف می‌شود. گوه ویکرز یک هرم الماسی با قاعده مربعی است که زاویه بین اضلاع متقابل آن ۱۳۶ درجه است، طوری که یک فرورفتگی کامل به صورت یک مربع با قطرهای مساوی دیده می‌شود (شکل ۲-۷) (Thruo.,1997; Hashemnejad et al.,2016; Moradizadeh et al.,2016).


عدد سختی ویکرز با استفاده از رابطه زیر محاسبه می‌شود:

^{۱۱} Vickers hardness

^{۱۲} Cerchar abrasivity index(CAI)

$$HV = 2P \sin(\alpha/2) / d^2 \quad (۱-۲)$$

که در آن P نیرو بر حسب کیلوگرم نیرو، d طول میانگین قطرها بر حسب میلیمتر، و α زاویه بین وجوه مقابل هرم الماسی بر حسب درجه می باشد



شکل ۲-۷: نمای شماتیک از مون سختی ویکرز (خداپرستی، ۱۳۹۰)

عدد سختی ویکرز معیاری برای سنجش درجه ساینده‌گی کانی‌ها است. با توجه به اعداد مربوط به سختی کانی‌های مختلف و درصد هر کانی در ترکیب سنگ، عدد سختی ویکرز مربوط به سنگ به دست می‌آید. برای فهم بیشتر این موضوع، اعداد مربوط به سختی کانی‌های مختلف در جدول ۲-۲ ارائه شده است و در جدول ۳-۲ نیز نمونه‌ای از محاسبه عدد سختی ویکرز، برای یک نمونه سنگ از جنس گنایس ارائه شده است.

جدول ۲-۲: عدد سختی ویکرز (VHN) برای کانی های مختلف (Bruland.,1998b)


کانی	عدد VHN (kg/mm ²)	کانی	عدد VHN (kg/mm ²)
کرنوم	۲۳۰۰	پیروتیت	۳۱۰
کوارتز	۱۰۶۰	فلوئوریت	۲۶۵
گارت	۱۰۶۰	پنتلاندیت	۲۲۰
هماتیت	۹۲۵	اسفالریت	۲۰۰
پیریت	۸۰۰	کلکوپیریت	۱۹۵
پلاژیوکلاز	۸۰۰	سریانیت	۱۷۵
دیوپسید	۸۰۰	انیدریت	۱۶۰
مگنتیت	۷۳۰	کلکسیت	۱۲۵
ارتوکلاز	۷۳۰	بیوتیت	۱۱۰
اوژیت	۶۴۰	گالن	۸۵
ایلمنیت	۶۲۵	کلکوسیت	۶۵
ارتوپیروکسن	۶۰۰	کلریت	۵۰
هورنبلند	۶۰۰	ژپس	۵۰
کرومیت	۶۰۰	تالک	۲۰
آپاتیت	۵۵۰	هالیت	۱۷
دولومیت	۳۶۵	سیلویت	۱۰

جدول ۲-۳: محاسبه عدد سختی ویکرز برای یک نمونه سنگ از جنس گنایس (Bruland.,1998b)

کانی	درصد	سختی کانی (VHN)	نسبت از سختی کل
کوارتز	۳۰	۱۰۶۰	۳۱۸
پلاژیوکلاز	۶۳	۸۰۰	۵۰۴
آمفیبول	۲	۶۰۰	۱۲
بیوتیت	۵	۱۱۰	۶
عدد سختی سنگ			۸۴۰


۲-۳-۲- آزمون سرشار

آزمون سرشار از معمول‌ترین روش‌های اندازه‌گیری سایش در آزمایشگاه است که در دهه ۱۹۸۰ در فرانسه ابداع شد و وست^{۱۳} در سال ۱۹۸۹ اصلاحاتی بر روی این دستگاه انجام داد. این آزمون توسط خراشیدن سطح تازه سنگ به طول یک سانتیمتر به وسیله نوک تیز پین (میله) از جنس آلیاژ حرارت دیده فولادی با سختی ۵۴ تا ۵۶ راکول و مقاومت کششی ۲۰۰۰ انجام می‌شود. اندیس سایش سرشار (CAI) به عنوان قطر متوسط نوک ساییده شده پین فولادی برحسب دهم میلی‌متر محاسبه می‌شود که در زیر میکروسکوپ دارای خط‌کشی مدرج خوانده می‌شود (شکل ۲-۸). مقدار اندیس سایش سرشار بین کمتر از ۰,۵ برای سنگ‌های نرم (مانند شیل و سنگ آهک) تا بیشتر از ۵ برای سنگ‌های سخت (مانند کوارتزیت) متغیر است (شکل ۲-۹).



شکل ۲-۸: ساختار دستگاه آزمون سرشار بر طبق (West, 1989) به همراه خراشهایی بر روی یک نمونه سنگ (Thruo et al., 2009)

^{۱۳} West



شکل ۲-۹: مقادیر اندیس سایش سرشار برای سنگ‌های مختلف (Plinninger et al., 2008)


۲-۳-۳- آزمون سایش NTNU (AV, AVS)

این روش برای تخمین قابلیت حفاری سنگ‌ها با حفاری ضربه‌ای در آزمایشگاه زمین‌شناسی مهندسی مؤسسه فناوری نروژی NTNU در اوایل دهه ۱۹۶۰ توسعه یافت. طرح شماتیک انجام آزمایش ساینده سنگ خرد شده با دانه‌های کوچکتر از ۱ میلی‌متر در شکل ۲-۱۰ نشان داده شده است.


AV: میانگین کاهش وزن بر حسب میلی‌گرم دو یا چهار مته از جنس تنگستن کاربرد بعد از ۵ دقیقه یعنی ۱۰۰ دور چرخش دستگاه NTNU با پودر سنگ ریزتر از ۱ میلی‌متر است.

AVS: میانگین کاهش وزن قطعه فولادی از جنس ابزار حفاری در مدت‌زمان ۱ دقیقه یعنی ۲۰ دور چرخش آزمایش NTNU با پودر سنگ ریزتر از ۱ میلی‌متر است.

از ۲۶۲۱ مقدار ثبت شده در پایگاه NTNU/SINTEF، کمترین و بیشترین مقادیر سایش تنگستن کاربرد به صورت صفر برای سنگ آهک و ۱۱۶ کوارتزیت می‌باشد و برای فولاد نیز به صورت صفر برای سنگ آهک و ۶۸/۵ برای کوارتزیت می‌باشد. محدوده اندازه‌گیری‌ها و توزیع نتایج آزمون‌های ثبت شده در این پایگاه داده در شکل ۲-۱۱ و جدول ۲-۶ نشان داده شده است.



شکل ۲-۱۰: اصول کلی آزمایش‌های سایش NTNU (Dahl et al., 2012)



شکل ۲-۱۱: توزیع مقادیر ثبت شده در پایگاه داده NTNU (Dahl et al., 2012)

جدول ۲-۶: طبقه‌بندی مقادیر AV و AVS (Dahl et al., 2012)

گروه - سایش تنگستن کاربید	AV(mg)	AVS(mg)	فراوانی تجمعی
شدیدا زیاد	≥ 58	≥ 44	۹۵-۱۰۰
بسیار زیاد	۴۲-۵۷,۹	۳۶-۴۴	۸۵-۹۵
زیاد	۲۸-۴۱,۹	۲۶-۳۵,۹	۶۵-۸۵
متوسط	۱۱-۲۷,۹	۱۳-۲۵,۹	۳۵-۶۵
کم	۴-۱۰,۹	۴-۱۲,۹	۱۵-۳۵
خیلی کم	۱,۱-۳,۹	۱,۱-۳,۹	۵-۱۵
شدیدا کم	≤ 1	≤ 1	۰-۵

۲-۴- مدل‌های تخمین عمر ابزار

چندین مدل برای پیش‌بینی عمر دیسک‌کاتر در حین تونل زنی TBM پیشنهاد شده است. روش‌های موجود شامل معادلات تجربی حاصل از تحلیل رگرسیون و رویکرد نیمه تئوری است. مدل‌های تجربی و نیمه تئوری شامل معادلات زیر است:

۲-۴-۱- مدل گیرینگ

معادلات تجربی بر اساس مشاهده همبستگی بین شرایط کار و عملکرد دیسک‌کاتر ایجاد شده است. گیرینگ^{۱۴} در سال ۱۹۹۵، با استفاده از تجزیه تحلیل داده‌ها از پروژه‌های مختلف به معرفی رابطه تجربی برای تخمین سایش دیسک بر اساس اندیس شاخص سرشار پرداخته است، رابطه بین CAI و کاهش وزن دیسک کاتر مطابق رابطه‌ی ۲-۲ پیشنهاد شده است (Gehering, 1995).

تخمین عمر دیسک‌کاتر	پارامترهای محاسباتی
(۲-۲) $H_f = (\Delta G \times PR \times D^2) / (4 \times \bar{D} \times v_s \times N)$	(۳-۲) $v_s = 0.74CAI^{1.93}$ $\bar{D} = 0.6D$ $\Delta G = 3700gr$

در این روابط H_f بیانگر عمر دیسک‌کاتر بر حسب مترمکعب بر کاتر، CAI شاخص سرشار بر حسب دهم میلیمتر، D قطر کله حفار بر حسب متر، $\bar{D}$ فاکتور تصحیح قطر کله حفار، ΔG ماکزیمم سایش دیسک کاتر بر حسب گرم و PR نرخ نفوذ بر حسب میلیمتر بر دور چرخش است.

۲-۴-۲- محاسبه عمر مفید دیسک کاترها به روش (NTNU)

برولند^{۱۵} در سال ۱۹۹۸، بر پایه نتایج به‌دست‌آمده از کارهای مطالعاتی و آماری بر روی داده‌های حاصل از کارگاه‌های تونل‌سازی (شامل بیش از ۳۵ کارگاه و بیش از ۲۵۰ کیلومتر تونل) در نروژ و دیگر


^{۱۴} Gehering

^{۱۵} Bruland


کشورها، مدل‌هایی جهت برآورد پارامترهای مؤثر در زمان و هزینه‌های تونل‌سازی ارائه نموده است. بر مبنای این مطالعات، خصوصیات توده سنگ و پارامترهای ماشین حفاری که در فرایند سایش دیسک کاتر در سنگ‌های سخت مؤثر است را معرفی و مدل NTNU را برای تخمین عمر دیسک کاتر ارائه نموده است و همچنین نحوه برآورد و محاسبه اندیس عمر کاتر (CLI) مورد بحث قرار داده است (Bruland.,1998a). در رابطه ی ۲-۴ تخمین عمر دیسک کاتر نشان داده شده است و با استفاده از رابطه ی ۲-۵ و شکل ۲-۱۲ پارامترهای موردنیاز برای تخمین عمر دیسک مورد محاسبه قرار گرفته است.

$$H_f = \frac{\pi \times D^2}{4} \cdot \frac{H_0 K_D K_Q K_{RPM} K_N}{N} \times PR \times RPM \cdot \frac{60}{1000} \quad (۴-۲)$$


$$k_N = \frac{N_{TBM}}{N_0}, k_{rpm} = \frac{50}{D \cdot rpm} \quad (۵-۲)$$




ب) مقادیر H_0 برای ابزار برش



الف) مقادیر k_q برای سنگ های مختلف



د) تعداد دیسک‌های نرمال



ج) مقادیر K_D برای انواع کله حفار

شکل ۲-۱۲: پارامترهای محاسباتی موردنیاز برای مدل‌های پیش‌بینی عمر دیسک کاتر (Bruland.,1998a)

در روابط ۴-۲ و ۵-۲، پارامتر H_f بیانگر عمر دیسک کاتر برحسب مترمکعب بر کاتر است، پارامتر H_0 بیانگر میانگین استاندارد عمر ابزار بر حسب ساعت می‌باشد که با استفاده از شاخص عمر کاتر (CLI) و قطر دیسک کاتر بر اساس شکل ۱۲-۲ (ب) مورد محاسبه قرار می‌گیرد، K_D فاکتور تصحیح قطر کله حفار است که بر اساس شکل ۱۲-۲ (ج) مورد محاسبه قرار می‌گیرد، K_Q فاکتور تصحیح مواد ساینده است که با توجه به محتوای کوارتز و جنس سنگ بر اساس شکل ۱۲-۲ (الف) مورد محاسبه قرار می‌گیرد، K_{rpm} فاکتور تصحیح سرعت چرخش کله حفار است که بر اساس رابطه ۵-۲ مورد محاسبه قرار می‌گیرد، N_0 فاکتور تصحیح تعداد دیسک کاتر است که بر اساس شکل ۱۲-۲ (د) با استفاده از قطر کله حفار و قطر دیسک کاتر مورد محاسبه قرار می‌گیرد، N تعداد دیسک کاتر، PR نرخ نفوذ بر حسب میلیمتر بر دور چرخش و RPM سرعت چرخش کله حفار بر حسب دور بر دقیقه و D قطر دیسک کاتر است.

شاخص عمر کاتر (CLI) بیانگر عملکرد شاخص سیورزجی (SJ) و شاخص های ساینده‌گی NTNU (AV و AVS) است که بر اساس رابطه ۶-۲ محاسبه می‌شود. شاخص سیورزجی بر اساس آزمون سیورزجی که توسط سیورز در دهه ۱۹۵۰ توسعه یافته است محاسبه می‌شود. سیورزجی به عنوان مقدار میانگین عمق سوراخ ایجاد شده پس از ۲۰۰ چرخش یک مته ۵/۸ میلیمتری بر حسب ۰/۱ میلیمتر، تعریف می‌شود (همزبان و همکاران، ۱۳۹۱).

$$CLI = 13.84 \left(\frac{SJ}{AVS} \right)^{0.3847} \quad (۶-۲)$$

۲-۴-۳- محاسبه عمر مفید دیسک کاترها به روش (CSM)

رستمی در سال ۱۹۹۷، با استفاده از آزمون شاخص سرشار مدل CSM را که برگرفته از مدل ریاضی تخمین نرخ نفوذ کالج معدن کلرادو می‌باشد را برای تخمین عمر دیسک ارائه داده است. این مدل بر اساس مسافت خطی طی شده بر روی سنگ توسط دیسک و واکنش سنگ در برابر نیروی اعمال شده توسعه یافته

است (Rostami.,1997). نحوه محاسبه‌ی عمر دیسک کاتر و پارامترهای محاسباتی ورودی مدل به ترتیب در رابطه‌ی ۷-۲ و ۸-۲ نشان داده شده است.

پارامترهای محاسباتی	تخمین عمر دیسک کاتر
(۸-۲)	(۷-۲)
$U_c = \frac{CL \times \bar{K}}{\bar{S}_r}, CL = \frac{2057}{CAI} \cdot \frac{d_m}{432}, \bar{S}_r = \frac{0.6 \times \pi \times D}{1000}$ $k \cong 0.67$	$H_f = \frac{\pi \times D^2}{4N} \cdot U_c \times PR$

در روابط ۷-۲ و ۸-۲، H_f بیانگر عمر دیسک کاتر بر حسب مترمکعب بر کاتر، N تعداد دیسک کاتر، D قطر کله حفار بر حسب متر، PR نرخ نفوذ بر حسب میلی متر بر دور چرخش، CAI اندیس سایش سرشار، d_m قطر دیسک کاتر بر حسب میلی متر است.

۲-۴-۴- مدل فرنزال

فرنزل^{۱۶} در سال ۲۰۱۱، داده‌های تفصیلی مربوط به ۷ پروژه تونل سازی که شامل طول بیش از ۱۲۷ کیلومتر و مشخصات بیش از ۱۲۰۰۰ دیسک کاترهای جایگزین شده می‌باشد را در یک پایگاه داده جمع‌آوری کرده است. تجزیه و تحلیل مفصلی برای توصیف حالت‌های خرابی و الگوهای سایش برش‌های دیسک انجام داده که بر اساس آن یک مدل تجربی بر اساس شاخص سرشار و عمر ابزار برش را ارائه داده است. در رابطه‌ی ۹-۲ نحوه محاسبه‌ی عمر ابزار برش نشان داده شده است (Frenzell.,2011).

$$H_f = \frac{1026}{CAI} \quad (۹-۲)$$

۲-۴-۵- مدل میدل و همکاران

میدل^{۱۷} و همکاران در سال ۲۰۰۸ با توجه به پیشرفت تکنولوژی تولید آلیاژ، به به‌روزرسانی مدل گیرینگ (۱۹۹۵) پرداخته است. در جدول ۷-۲ میزان تغییر وزن مخصوص دیسک بر حسب گرم نسبت به مدل

^{۱۶} Frenzel

^{۱۷} Maidl

گیرینگ نشان داده شده است (Maidl et al., 2009). سایر پارامترهای محاسباتی و عمر دیسک کاتر به مانند مدل گیرینگ مورد محاسبه قرار می گیرد.

جدول ۷-۲: تعیین وزن مخصوص دیسک با استفاده از مدل گیرینگ و میدل

مدل	وزن مخصوص دیسک (v_s)
گیرینگ	$v_s = 0.74CAI^{1.93}$
میدل و همکاران	$v_s = 0.65CAI^{1.93}$

۶-۴-۲- مدل فرخ و همکاران

فرخ و همکاران (۲۰۱۲) مجموعه ای از نمودارها را به عنوان تابعی از نوع سنگ، خواص و شاخص های ساینده برای تخمین عمر دیسک به عنوان حجم سنگ حفر شده در هر دور چرخش تهیه کرده است. رابطه ی ۸-۲ نحوه تخمین عمر دیسک کاتر را نشان خواهد داد (Farrokh et al., 2013). در رابطه ی ۱۰-۲، d_i قطر دیسک بر حسب اینچ، p نرخ نفوذ بر حسب متر بر ساعت و N تعداد دیسک کاتر است.

$$H_f = \frac{1577 \times d_i \times P \times D}{CAI \times RPM \times N} \quad (۱۰-۲)$$

۲-۴-۷- مدل لئو و همکاران

لئو و همکاران در سال ۲۰۱۷، به معرفی مدل تجربی برای تخمین عمر ابزار برش بر اساس رابطه ی خطی بین اندیس شاخص سرشار (CAI) و مقاومت فشاری تک محوره (UCS) پرداخته است. این مدل بر اساس تجزیه و تحلیل آماری داده های به دست آمده از پروژه تونل انتقال آب در چین برای سنگ های گرانیتی و TBM هایی با دیسک هایی با قطر ۲۰ اینچ مناسب می باشد (Liu et al., 2013). در رابطه ی ۱۱-۲ میزان عمر دیسک کاتر محاسبه شده است.

$$E_f = a.CAI + b.UCS + c \quad (۱۱-۲)$$

۲-۴-۸- مدل تجربی ارائه شده توسط حسن پور

در این مدل از شاخص ABI (شاخص ساینده‌گی) به عنوان پارامتر زمین‌شناسی ورودی اصلی به مدل استفاده شده است. بر اساس تجارب به‌دست‌آمده از پروژه‌ها و داده‌های حاصل و انجام آنالیزهای آماری معادلات زیر برای تخمین متوسط طول عمر دیسک کاتر و مصرف دیسک کاتر ارائه شده است که در سال ۲۰۱۴ برای سنگ‌های مافیک (mafic) و اذرآواری (pyroclastic) ارائه شده است و در سال ۲۰۱۸ برای سنگ‌های رسوبی و متامورفیک ارائه شده است (Hassanpour et al., 2014).

$$ABI = VHNR * \left(\frac{ucs}{100} \right) \quad (۱۲-۲)$$

$$H_f = -940.1 \ln(ABI) + 6939.4 \quad (۱۳-۲)$$

$$w_f(\text{cutter}/m) = \frac{\pi D^2}{4H_f} \quad (۱۴-۲)$$

در این روابط H_f طول عمر دیسک کاتر (m^3/cutter)، w_f مصرف لحظه ای دیسک کاتر (cutter/m)، D قطر تونل و ABI شاخص ساینده‌گی سنگ می‌باشد. برای بهره‌گیری از این مدل ابتدا مقادیر عدد سختی ویکرز ($VHNR$) برای گونه‌های مختلف زمین‌شناسی مهندسی مسیر تونل تعیین و سپس با استفاده از روابط بالا w_f ، ABI و H_f برآورد گردد.

۲-۴-۹- مدل سان و همکاران

بر اساس اصول کار TBM، دیسک‌کاترهای آزمایشی به اندازه ۰/۱ دیسک‌کاترهای واقعی تقسیم می‌شوند و یک مدل دستگاه تست سایش کامپوزیت تولید شده است. علاوه بر این، داده‌های مهندسی از پروژه بین هان جی وی به عنوان نمونه‌ای برای ایجاد مدل پیش‌بینی سایش دیسک کاتر جمع‌آوری شده است، نتایج

حاصله نشان می‌دهد که این مدل می‌تواند برای آزمایش سایش دیسک کاترهای کوچک و پیش‌بینی طول عمر دیسک کاتر مورد استفاده قرار گیرد.

به‌منظور بررسی میزان ساییدگی سنگ‌ها با مقادیر مختلف CAI، با استفاده از مدل آزمایشی تست‌های سایش گرانیات، ماسه سنگ، دیوریت، سنگ آهک و سنگ‌های پروژه بین هان جی وی انجام شده است. مقادیر اندیس سایش سرشار مطابق جدول ۲-۱۰ برای نمونه‌های مختلف آورده شده است، با استفاده از آزمایش سرووکنترل ATT-IGG میزان وزن از دست رفته ابزار محاسبه شده است و با تحلیل آماری رابطه‌ی بین شاخص سرشار و وزن ازدست‌رفته دیسک به‌دست‌آمده است. رابطه‌ی بین وزن ازدست‌رفته دیسک با شاخص سرشار بر اساس تحلیل آماری مطابق رابطه‌ی ۲-۱۵ است (Sun et al., 2019).

$$W = 0.7845 \times CAI^2 \quad (2-15)$$

با این وجود، پیش‌بینی میزان سایش فقط توسط CAI نادرست است. اثرات مقاومت فشاری تک محوره ^{۱۸} (UCS)، مقاومت کششی ^{۱۹} (BTS) و محتوای معادل کوارتز ^{۲۰} (EQC) باید همزمان در نظر گرفته شود. با توجه به این، تأثیر UCS و EQC همزمان بررسی شده است. با توجه به مرجع (Prieto 2012)، محصول EQC و UCS از سنگ اندیس سایش سنگ (RAI) است، رابطه‌ی ۲-۱۶ بیان‌کننده این امر است.


$$RAI = UCS \times EQC \quad (2-16)$$

۲۷ گروه نمونه سنگ از محل ساخت تونل انحرافی در کوه‌های Qinling، یک تونل راه‌آهن در گوانگ‌ژو و یک تونل انحرافی در شمال شرقی چین گرفته شد. طبق بررسی‌های انجام شده منحنی رابطه بین CAI و RAI همانطور که در شکل ۲-۱۳ نشان داده شده است.

^{۱۸} Uniaxial Compressive Strength

^{۱۹} Brazilian tensile strength

^{۲۰} Equivalent quartz content



شکل ۲-۱۳: منحنی منطبق بر CAI و RAI (Sun et al., 2019)


همان‌طور که از شکل ۲-۱۳ دیده می‌شود، شاخص سایشی سنگ CAI رابطه لگاریتمی مثبت با RAI دارد و دو شاخص بسیار همبسته هستند، ضریب همبستگی ۰/۹۵۶ است. یعنی می‌توان گفت که مدل پیش‌بینی نه تنها تأثیر CAI را در نظر می‌گیرد، بلکه در واقع تأثیر جامع CAI، UCS، EQC، BTS و غیره را در نظر می‌گیرد (Sun et al., 2019).

۲-۴-۱۰- مدل کرمی و همکاران

کرمی و همکاران در سال ۲۰۲۱ بر اساس تجزیه و تحلیل داده‌های تونل انتقال آب کرمان به معرفی مدل تجربی با استفاده از پارامترهای شاخص سرشار، مقاومت تراکمی توده سنگ و فاکتور خردشدگی کل برای ارزیابی میزان سایش دیسک کاتر پرداخته است. از مزایای این مدل نسبت به مدل‌های دیگر می‌توان به در نظر گرفتن هم‌زمان پارامترهای سنگ (شاخص سرشار) و توده سنگ (مقاومت تراکمی توده سنگ و فاکتور خردشدگی کل) برای پیش‌بینی عمر دیسک کاتر اشاره کرد در حالی که سایر مدل‌ها بر مبنای ویژگی‌های سنگ بکر گسترش یافته است. مقدار پیش‌بینی عمر دیسک کاتر با استفاده از این مدل در رابطه‌ی ۲-۱۷ نشان داده شده

است. شکل ۲-۱۴ صحت مدل تجربی ارائه شده را نشان می‌دهد همانطور که در شکل مشخص است ضریب تعیین به دست آمده برای این مدل برابر با ۰/۸ است که در مقایسه با سایر مدل‌ها عملکرد بهتری داشته است (Karami et al., 2021).

$$H_f = 963 \times \frac{K_{s-tot}^{0.32}}{UCS_{rm}^{0.15} \times CAI^{0.20}} \quad (2-17)$$



شکل ۲-۱۴: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده میزان عمر دیسک کاتر با استفاده از مدل‌های مختلف (Karami et al., 2021)


۲-۵- مقایسه‌ی بین مدل‌های پیش‌بینی عمر دیسک کاتر

حسن‌پور در سال ۲۰۱۵ بر اساس داده‌های ۱۰ سال تونل سازی مکانیزه در ایران ساینده‌ی سنگ را بر اساس عمر دیسک کاتر (H_f) از بسیار ساینده به غیر ساینده طبقه‌بندی کرد (Hassanpour et al., 2015). فرخ و کیم (۲۰۱۸) محدوده $UCSi$ ، CAI ، EQC و CLI را برای هر کلاس سایش تعیین کردند (Farrokh & kim., 2018)، کرمی و همکاران در سال ۲۰۲۰ با استفاده از طبقه‌بندی ساینده‌ی توده سنگ به مقایسه مدل‌های سایش دیسک در هر کلاس ساینده‌ی پرداخته است. طبقه‌بندی کلاس‌های ساینده‌ی و محدوده تغییرات

پارامترهای ورودی مدل‌های سایش در هر کلاس در جدول ۸-۲ ارائه شده است. شکل ۱۵-۲ نتیجه مقایسه‌ی بین مدل‌های سایش را نشان می‌دهد (Karami et al., 2021).

جدول ۸-۲: طبقه‌بندی کلاس‌های ساینده‌گی (Karami et al., 2021)

کلاس ساینده‌گی سنگ	کلاس سایش دیسک	H_f	UCS	CAI	EQC(%)	CLI
شدیدا ساینده	شدیدا زیاد	< 100	۲۰۰-۲۵۰	۴-۶	۷۵-۱۰۰	۳۵-۷۵
ساینده‌گی زیاد	خیلی زیاد	۱۰۰-۵۰۰	۱۵۰-۲۰۰	۲-۴	۳۵-۷۵	۱۵-۳۴
ساینده‌گی متوسط	زیاد	۵۰۰-۱۰۰۰	۱۰۰-۱۵۰	۱-۲	۲۰-۳۵	۸-۱۴,۹
ساینده‌گی کم	نرمال	۱۰۰۰-۲۰۰۰	۵۰-۱۰۰	۰,۵-۱	۱۰-۲۰	۶-۷,۹
ساینده‌گی خیلی کم	کم	۲۰۰۰-۲۵۰۰	۲۵-۵۰	۰,۳-۰,۵	۵-۱۰	۵-۵,۹
غیر ساینده	بدون سایش	> 2500	< 25	۰-۰,۳	۰-۵	۰-۵




شکل ۱۵-۲: مقایسه‌ی بین مدل‌های سایش دیسک‌کاتر در کلاس‌های ساینده‌گی متفاوت (Karami et al., 2021)

با توجه به شکل ۱۵-۲، در سنگ‌های کمی ساینده تغییرات زیادی را بین مدل‌های پیش‌بینی عمر دیسک‌کاتر نشان می‌دهد. با این حال، با افزایش کلاس ساینده‌گی سنگ، این پراکندگی کاهش می‌یابد و نتایج عمر پیش‌بینی شده دیسک‌کاتر با استفاده از مدل‌های تجربی تمایل به همگرایی دارد (Karami et al., 2021).

شکل ۲-۱۵ نشان می‌دهد که در سنگ‌های کمی ساینده، مدل پیش‌بینی باید بادقت انتخاب شود زیرا محدوده مقادیر پیش‌بینی شده بسیار وسیع است به‌طوری‌که حداکثر عمر دیسک‌کاتر می‌تواند از ۲۸۰۰ مترمکعب برکاتر تا ۱۰۰ مترمکعب برکاتر متفاوت باشد. با افزایش کلاس‌های ساینده‌گی، عمر پیش‌بینی شده در مدل‌های گیرینگ (۱۹۹۵)، میدل و همکاران (۲۰۰۸) به سرعت کاهش می‌یابد، زیرا این مدل‌ها با شاخص سایش سرشار رابطه معکوس دارند؛ بنابراین، می‌توان این مدل‌ها را محافظه‌کارانه و دست‌کم گرفته شده پیش‌بینی عمر دیسک‌کاتر در نظر گرفت. در میان مدل‌های موجود، مدل فرخ و همکاران (۲۰۱۳)، رستمی و همکاران (۲۰۰۵) و فرنزل (۲۰۰۵) روندی را نشان می‌دهند که در آن با افزایش کلاس ساینده‌گی، کلاس سایش برش دیسک نیز افزایش می‌یابد. به نظر می‌رسد این یک رفتار منطقی برای مدلی است که در آن افزایش یا کاهش تدریجی ساینده‌گی سنگ در عمر پیش‌بینی شده دیسک‌کاتر منعکس می‌شود. به نظر می‌رسد برولند (۱۹۹۸) محافظه‌کارترین مدل است و به طور مداوم عمر دیسک‌کاتر کمتری نسبت به سایر مدل‌ها برای دیسک‌کاتر در شرایط متفاوت پیش‌بینی می‌کند (Karami et al., 2021).

فرخ و همکاران در سال ۲۰۱۸ به پیش‌بینی عمر دیسک‌کاتر با استفاده از داده‌های تونل انتقال کابل سنگاپور برای مدل‌های مختلف پرداخته است که نتایج آن در شکل ۲-۱۶ نشان داده شده است. همانطور که در شکل ۲-۱۶ نشان داده شده است، نتایج مدل‌های مختلف تنوع گسترده‌ای برای پیش‌بینی عمر دیسک‌کاتر را نشان داده است (Farrokh et al., 2018). بنابراین استفاده از هر کدام از مدل‌ها نیازمند دقت زیاد و تجزیه تحلیل فراوان مطابق شرایط زمین‌شناسی است.



شکل ۲-۱۶: پیش‌بینی عمر دیسک کاتر در پروژه انتقال کابل سنگاپور با استفاده از مدل‌های مختلف (Farrokh et al., 2018)

۲-۶- جمع‌بندی

علی‌رغم این واقعیت که در عملیات حفاری تونل با استفاده از ماشین‌های حفاری تونل TBM نمی‌توان یک ارزیابی دقیق از ریسک‌های قطعی استفاده از این ماشین‌آلات داشت، این شیوه حفاری تونل به طور فزاینده‌ای در سال‌های اخیر رایج شده است. یکی از این ریسک‌ها که به راحتی توسط مهندسان و پیمانکاران نادیده گرفته می‌شود، اثر سایش زمین بر هزینه‌ها و برنامه زمان‌بندی یک پروژه معین است. اثرات کاتردهای ساییده شده و آسیب دیده ماشین‌های حفاری تونل در صدها پروژه تونل در سراسر جهان مشاهده شده است. ارائه پیش‌بینی‌های قابل اعتماد و صحیح در مورد ساییده شدن کاتر، پیشرفت حفاری و هزینه‌های مربوطه در حال تبدیل شدن به موضوعی کلیدی برای تولیدکنندگان ماشین‌آلات حفاری و پیمان کارانی است که با بهره‌برداری از سیستم‌های حفاری مکانیکی در معدن، تونل و سازه‌های زیر زمینی سروکار دارند. پارامترهای معرف و قابل اعتماد توصیف خصوصیات مختلف سنگ، همراه با خصوصیات توده سنگ، به‌طور قطع ورودی‌های اصلی برای دسترسی به معتبرترین برآوردهای مربوط به هزینه‌ها را تشکیل می‌دهند.

مدل‌های پیش‌بینی عمر دیسک‌کاتر، با بررسی همبستگی و روابط میان آزمون‌های آزمایشگاهی و داده‌های زمین‌شناسی برجا با داده‌های به‌دست‌آمده از پروژه‌های تونل‌سازی توسعه یافته‌اند. این مدل‌ها به طور پیوسته و با در دسترس قرارگرفتن داده‌های حاصل از پروژه‌های تونل‌زنی جدید مورد بازنگری قرار گرفته و به‌روزرسانی می‌شوند.

با توجه به این موضوع که مدل‌های پیش‌بینی عمر دیسک‌کاتر در شرایط زمین‌شناسی خاص مورد استفاده قرار گرفته‌اند برای استفاده از این مدل‌ها بایستی دقت لازم را به عمل آورد، کرمی ۲۰۲۰ و فرخ ۲۰۱۸ تفاوت معناداری را در پیش‌بینی عمر دیسک‌کاتر توسط مدل‌های مختلف را نشان داده‌اند.

فصل سوم

بررسی تأثیر پارامترهای سنگ و ماشین بر عمر دیسک کاتر

۳-۱- مقدمه

از میان مدل‌های متنوع ارائه شده برای پیش‌بینی عمر دیسک‌کاتر مدل‌های CSM، NTNU و Gehering بیشترین کاربرد را در میان سایر مدل‌های موجود دارند. با در نظر گرفتن این موضوع و همچنین دانستن این که پارامترهای ماشین و سنگ بر میزان عمر دیسک‌کاتر به نحوی مؤثر می‌باشند به بررسی ارتباط میان این پارامترها بر مدل‌های مذکور انجام شده است. در این بخش به بررسی تأثیر نرخ نفوذ، مقاومت فشاری تک‌محوره و شاخص ساینده‌گی در مدل‌های Gehering، CSM و NTNU پرداخته شده است.

۳-۲- بررسی تأثیر پارامترهای سنگ و ماشین بر عمر دیسک‌کاتر


عمر دیسک‌کاتر تا حد زیادی تحت تأثیر نرخ نفوذ و شاخص سایش است و نرخ نفوذ تابع مقاومت فشاری تک‌محوره سنگ و نیروی اعمال شده توسط کله حفار مرتبط است (Rostami., 1997). در این بررسی از مقادیر جدول ۳-۱ برای آنالیز و تجزیه تحلیل عمر دیسک‌کاتر پرداخته خواهد شد، همان‌طور که مشاهده می‌شود مقادیر UCS و CLI و CAI در یک محدوده مشخص تغییر می‌کند تا تأثیر آن بر عمر دیسک‌کاتر مشخص شود.

جدول ۳-۱: پارامترهای ورودی برای آنالیز عمر دیسک کاتر

نوع سنگ	گنایس	پارامترهای توده سنگ
UCS (Mpa)	۸۰-۲۰۰ (۱۲۰)	
درصد کوارتز	۱۵٪	
تخلخل	۶٪	
DRI	۲۷-۵۰	
تعداد دسته درزه	۲	
CAI	۱/۵ - ۷/۵ (۴/۱)	
CLI	۶-۲۸ (۸)	
ΔG (gr)	۳۷۰۰	پارامترهای ماشین
قطر ماشین حفاری (m)	۴/۳	
تعداد دیسک کاترها	۲۷	
سرعت چرخش کله حفار (rpm)	۴,۵	
نیروی پیشران (KN/cutter)	۳۰۰	
نرخ نفوذ (mm/rev)	۴-۱۸ (۷/۵)	
قطر دیسک کاتر (mm)	۴۳۲	


۳-۲-۱- تأثیر نرخ نفوذ

معادلات عمر دیسک کاتر حاکم بر هر یک از مدل‌ها بیانگر آن است که عمر ابزار برش به طور خطی متناسب با نرخ نفوذ تغییر می‌کند. شکل ۳-۱ تغییرات عمر دیسک کاتر را با افزایش نرخ نفوذ نشان می‌دهد همان‌طور که از شکل به دست می‌آید عمق نفوذ از ۴ به ۱۸ میلی‌متر افزایش یافته است.



شکل ۳-۱: تغییرات متوسط عمر دیسک کاتر بر اساس نرخ نفوذ


مدل‌های Gehring و CSM تقریباً نتایج یکسانی دارند اما در مدل NTNU سرعت رشد عمر دیسک کاتر کمی پایین تر از مدل‌های دیگر است. همانطور که مشاهده می‌شود با افزایش نرخ نفوذ متوسط عمر ابزار افزایش می‌یابد اما بایستی توجه داشت که عمق نفوذ بهینه باشد یعنی عمق نفوذ بیش از حد لرزش TBM را افزایش داده که خود می‌تواند عامل خرابی دیسک کاتر باشد و زمان تعویض دیسک کاتر را کاهش دهد. شکل ۳-۲ رابطه‌ی بین میزان نیروی کله‌حفار و نرخ نفوذ را در مقاومت‌های متفاوت نشان می‌دهد (Frenzell et al., 2008).



شکل ۳-۲: رابطه‌ی بین نرخ نفوذ و نیروی کله‌حفار در مقاومت‌های متفاوت سنگ (Frenzell et al., 2008)

۳-۲-۲- تأثیر مقاومت فشاری تک محوره (UCS)

در معادلات مربوط به عمر دیسک کاتر از خصوصیات مرتبط به مقاومت سنگ به عنوان متغیر ورودی استفاده نمی‌شود، اما معادلات پیش‌بینی نرخ نفوذ مدرسه معدن کلرادو (CSM) و گیرینگ (Gehring) هر دو بیانگر عملکرد مقاومت فشاری تک‌محوره هستند. اما در مدل NTNU مقاومت فشاری به عنوان متغیر مستقیم در تخمین نرخ نفوذ مورد استفاده قرار نمی‌گیرد بلکه به طور غیرمستقیم از طریق شاخص DRI مورد استفاده قرار می‌گیرد. شکل ۳-۳ بیانگر رابطه‌ی بین مقاومت فشاری و عمر دیسک کاتر با استفاده از نرخ نفوذ که در سه مدل نشان داده شده است. مقاومت فشاری تک‌محوره از ۸۰ مگاپاسکال به ۲۰۰ مگاپاسکال تغییر یافته است، حداکثر نیرو ۳۰۰ کیلونیوتن و حداکثر عمق نفوذ ۲۸ میلی‌متر می‌باشد.




شکل ۳-۳: رابطه‌ی بین متوسط عمر دیسک کاتر و مقاومت فشاری تک‌محوره

در ۲ مدل CSM و Gehring با افزایش مقاومت فشاری تک‌محوره عمر دیسک کاتر کاهش می‌یابد، مدل CSM با تغییر در مقاومت فشاری بیشترین تغییر را در طول عمر دیسک کاتر نشان می‌دهد، مدل NTNU در مقایسه با دو مدل دیگر با تغییر در مقاومت فشاری تفاوت معناداری را در طول عمر دیسک کاتر نشان

نمی‌دهد. در مدل NTNU مقاومت فشاری به عنوان متغیر مستقیم در تخمین نرخ نفوذ مورد استفاده قرار نمی‌گیرد بلکه به طور غیرمستقیم از طریق شاخص DRI و اندازه آن مورد استفاده قرار می‌گیرد.

۳-۲-۳- تأثیر شاخص ساینده‌گی (شاخص عمر دیسک کاتر)

در مدل Gehring و مدل CSM از اندیس سایش سرشار (CAI) برای تخمین عمر ابزار استفاده می‌شود اما در مدل NTNU از اندیس عمر کاتر (CLI) برای بیان این امر استفاده می‌شود. شکل ۳-۴ بیانگر رابطه‌ی بین متوسط عمر دیسک کاتر و شاخص‌های CAI و CLI می‌باشد بایستی توجه داشت که بین این دو شاخص ارتباطی وجود ندارد.




شکل ۳-۴: رابطه‌ی بین نرخ سایش CAI و CLI با متوسط عمر دیسک کاتر

متوسط عمر کاتر در مدل‌های Gehring و CSM با تغییر مقدار CAI از $\frac{1}{5}$ به $\frac{7}{5}$ تخمین زده شده و در مدل NTNU با تغییر در مقدار CLI از ۶ به ۳۰ این امر انجام شده است بایستی توجه داشت که عمق نفوذ $\frac{7}{5}$ میلی‌متر در نظر گرفته شده است. در مدل Gehring و CSM وقتی مقدار CAI از ۴ به بالا می‌رود تفاوت چشمگیری در عمر ابزار ایجاد نمی‌شود اما کمتر از این مقدار تفاوت بزرگی را نشان می‌دهد بنابراین انتخاب مدل تأثیر زیادی در تخمین عمر ابزار ایجاد می‌کند.

۳-۲-۴- تأثیر تعداد دیسک کاتر (N)

در مدل Gehring و مدل CSM از تعداد دیسک کاتر به طور مستقیم (N) برای تخمین عمر ابزار استفاده می‌شود اما در مدل NTNU علاوه بر تعداد دیسک کاتر از فاکتور تصحیح فاصله داری دیسک کاتر (K_N) برای بیان این امر استفاده می‌شود. شکل ۳-۵ بیانگر رابطه‌ی بین متوسط عمر دیسک کاتر و تعداد دیسک کاتر است.



شکل ۳-۵: رابطه‌ی بین تعداد دیسک کاتر با متوسط عمر دیسک کاتر

همانطور که در شکل مشخص است با افزایش تعداد دیسک کاتر در مدل‌های CSM و Gehring متوسط عمر دیسک کاتر کاهش می‌یابد و تقریباً نتایج یکسانی دارد، در مدل NTNU به دلیل اینکه علاوه بر تعداد دیسک کاتر، فاکتور تصحیح فاصله داری دیسک کاتر نیز در عمر ابزار نقش دارد. با توجه به رابطه‌ی مدل NTNU برای تخمین عمر دیسک کاتر، با افزایش تعداد دیسک کاتر همواره نسبت فاکتور تصحیح فاصله داری دیسک کاتر بر تعداد دیسک کاتر ($\frac{K_N}{N_{tbm}}$) عدد ثابتی است، بنابراین افزایش تعداد دیسک کاتر تاثیری بر عمر دیسک کاتر ندارد. بایستی توجه داشت که نرخ نفوذ ثابت و برابر با ۷/۵ میلی‌متر در نظر گرفته شده است.

۳-۳- جمع‌بندی

از میان مدل‌های متنوع ارائه شده برای پیش‌بینی عمر دیسک‌کاتر مدل‌های CSM، NTNU و Gehering بیشترین کاربرد را در میان سایر مدل‌های موجود دارند. با در نظر گرفتن این موضوع و همچنین دانستن این که پارامترهای ماشین و سنگ بر میزان عمر دیسک‌کاتر به نحوی مؤثر می‌باشند به بررسی ارتباط میان این پارامترها بر مدل‌های مذکور پرداخته شده است.

با بررسی انجام‌گرفته مشخص شده است که با افزایش نرخ نفوذ متوسط عمر دیسک‌کاتر برای هر یک از این ۳ مدل افزایش‌یافته است و با افزایش CAI و UCS میزان متوسط عمر دیسک‌کاتر در مدل‌های Gehering و CSM کاهش‌یافته اما در مدل NTNU به‌جای اندیس سایش سرشار از اندیس عمر کاتر CLI استفاده می‌شود که با افزایش آن عمر دیسک‌کاتر نیز افزایش‌یافته است و از آن جایی که در برآورد میزان سایش UCS به عنوان پارامتر مستقل از نرخ نفوذ در نظر گرفته می‌شود تغییرات آن تأثیری بر میزان سایش در مدل NTNU ندارد.

با توجه به توسعه مدل‌های تخمین عمر ابزار بر اساس شرایط زمین‌شناسی و تأثیرگذاری متفاوت هر یک از پارامترهای ورودی مدل‌های تخمین عمر ابزار، بایستی در انتخاب و کاربرد هر یک از مدل‌های تخمین عمر ابزار دقت لازم را به عمل آورد تا با تعیین مدل و تخمین مناسب عمر ابزار به راندمان بالاتری در عملیات حفاری تونل و کاهش هزینه و اتلاف وقت دست‌یافت.

فصل چهارم

مبانی شبکه عصبی و کاربردهای آن

۴-۱- مقدمه

با وجود اینکه مدل‌های تجربی و ریاضی زیادی برای پیش‌بینی نرخ سایش وجود دارد اما به دلیل اینکه مدل‌های ارائه شده در یک حالت خاص از شرایط زمین‌شناسی پیشنهاد شده‌اند، قابل تعمیم به تمام شرایط نیستند. در سال‌های اخیر از روش شبکه‌های عصبی مصنوعی به عنوان ابزاری جدید جهت پیش‌بینی نرخ نفوذ و نرخ پیشروی و غیره استفاده شده است. پویا بودن شبکه عصبی و عدم نیاز به فرمول‌بندی و روابط ریاضی محض سبب شده است محققین حوزه‌های مختلف برای مواردی که ارتباط بین کمیت‌های ورودی‌ها و خروجی‌ها قابل تشخیص نیست از این روش برای تخمین و مدل‌سازی استفاده کنند. در صورت در دسترس بودن داده‌های گسترده و تعیین ساختار مناسب برای شبکه، این روش قادر خواهد بود بادقت لازم و خطای مناسب به تخمین و مدل‌سازی بپردازد. در این فصل به معرفی و نحوه چگونگی تعیین ساختار شبکه عصبی، مزایا و معایب استفاده از این روش برای مدل‌سازی پرداخته شده است.

۴-۲- معرفی شبکه عصبی

به اذعان بسیاری از دانشمندان، پیچیده‌ترین و ناشناخته‌ترین سیستم جهان که مورد مطالعه قرار گرفته است مغز انسان است. پیچیدگی این سیستم نه به علت ابعاد و تعداد اجزای سازنده آن بلکه بیش‌تر به اتصال‌های فراوان موجود میان اجزای آن بازمی‌گردد. این همان ویژگی است که مغز انسان را از سایر سیستم‌ها متمایز می‌سازد. همه فرایندهایی که در بدن اتفاق می‌افتد چه فرایندهای خودآگاه و چه فرایندهای ناخودآگاه، همگی تحت مدیریت مغز هستند. به علت پیچیدگی برخی از این فرایندها هیچ رایانه یا ابررایانه‌ای نمی‌تواند در جهان به پردازش و تحلیل آن بپردازد. با این وجود، تحقیقات انجام شده نشان می‌دهد که سرعت عملکرد واحدهای سازنده مغز انسان، حدود یک میلیون بار کندتر از ترانزیستورهای مورد استفاده در تراشه‌های سیلیکونی CPU رایانه هستند. علت سرعت و قدرت پردازش بسیار بالای واحدهای سازنده مغز انسان، به ارتباط‌های بسیار انبوه بین این واحدها بازمی‌گردد و در صورت نبود این لینک‌های ارتباطی، سرعت و قدرت

پردازش مغز انسان هم به‌مانند یک سیستم معمولی کاهش می‌یافت. این ویژگی ممتاز در عملکرد مغز انسان در حل انواع مختلف مسائل، سبب شده است تا شبیه‌سازی مغز انسان و قابلیت‌های آن به یکی از مهم‌ترین آرمان‌ها و دغدغه‌های معماران سخت‌افزار و نرم‌افزار تبدیل شود. در واقع اگر روزی بتوان (که البته ظاهراً خیلی هم دور نیست) رایانه‌ای در حد و اندازه‌های مغز انسان بسازیم، قطعاً یک انقلاب بزرگ در صنعت، علم و در نتیجه زندگی انسان‌ها، رخ خواهد داد. مهندسين و متخصصين علوم رایانه، از چند دهه گذشته در راستای شبیه‌سازی عملکرد مغز انسان برای حل مسائل، کارهای پژوهشی بسیاری را انجام داده‌اند که نتایج کار آن‌ها، در شاخه‌ای از علم هوش مصنوعی و در زیرشاخه هوش محاسباتی تحت عنوان موضوع «شبکه‌های عصبی مصنوعی» یا Artificial Neural Networks (به اختصار: ANNs) طبقه‌بندی شده است. مدل‌های ریاضی و نرم‌افزاری متعددی با الهام گرفتن از عملکرد مغز انسان در مبحث شبکه‌های عصبی پیشنهاد شده‌اند که برای حل گستره وسیعی از مسائل حوزه‌های مختلف اعم از مسائل علمی، مهندسی و کاربردی و غیره کاربرد دارند.

۴-۳- اجزای تحلیلی شبکه عصبی

۱. ورودی^{۲۱} و خروجی‌ها^{۲۲}: ورودی‌ها به عنوان یک یا چند متغیر مستقل به شکل ارقام و اعداد به شبکه عصبی وارد شده و پس از انجام تحلیل و پردازش‌های خاص به یک یا چند متغیر وابسته خروجی تبدیل می‌شوند.

۲. نورون‌ها^{۲۳}: کوچک‌ترین واحد پردازش اطلاعات و مهم‌ترین جزء سیستم عصبی مصنوعی که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد نورون‌ها هستند. نورون‌ها به سه دسته نرون‌های لایه ورودی، لایه خروجی و لایه میانی (پنهان) تقسیم می‌شوند. هر نورون، ورودی و خروجی مخصوص دارد بدین صورت که داده‌های ورودی از طریق نورون‌های ورودی دریافت می‌شود و به نورون‌های لایه میانی و خروجی منتقل

^{۲۱} Inputs

^{۲۲} Outputs


^{۲۳} Neurons

می‌شود، در این نورون‌ها عملیات جبری بر روی اطلاعات ورودی انجام‌گرفته و نتیجه به صورت یک ورودی جدید به نورون لایه بعدی منتقل می‌شود بنابراین نورون‌های ورودی وظیفه دریافت اطلاعات ورودی و نورون‌های میانی و خروجی به عنوان مرکز پردازش و توزیع اطلاعات عمل می‌کند.

۳. وزن‌ها: با توجه به ارزش متفاوت هریک از متغیرهای ورودی شبکه، اعداد تصادفی قبل از لایه خروجی توسط شبکه تولید و به هریک از این متغیرهای ورودی اختصاص می‌یابد، این وزن‌ها در یک سیکل کاری شبکه تصحیح می‌شوند تا ارزش هر یک از متغیرهای ورودی به بهترین نحو بر شبکه اعمال شود.

شکل ۴-۱ ساختار یک نورون تک ورودی را نشان می‌دهد که در آن متغیر p ورودی نورون و متغیر a

خروجی نرون است.



شکل ۴-۱: ساختار نورون

خروجی نورون از رابطه (۴-۱) به دست می‌آید.

$$a=f(wp+b) \quad (۴-۱)$$

در رابطه‌ی ۴-۱ تابع فعال‌ساز f ،^{۲۴} w و b به ترتیب نشان‌دهنده وزن^{۲۵} و بایاس^{۲۶} نورون می‌باشند. طراح

با انتخاب تابع فعال‌ساز و نوع الگوریتم یادگیری اقدام به تنظیم پارامترهای w و b می‌کند. درحقیقت یادگیری

به این معنی است که w و b آن‌قدر تغییر می‌کند که رابطه بین ورودی و خروجی نورون، مطابق با یک هدف

^{۲۴} Activation function


^{۲۵} Weight

^{۲۶} Bias

خاص باشد. معمولاً یک نورون، دارای چندین ورودی است که حتی نورون با تعداد ورودی‌های زیاد نیز نمی‌تواند به‌تنهایی برای حل مسائل به کار رود؛ بنابراین برای حل این موضوع از اجتماع نورون‌ها به عنوان یک‌لایه استفاده می‌شود. مشابه با شبکه‌های عصبی بیولوژیکی، شبکه‌های عصبی مصنوعی از طریق اتصال نورون‌ها، از راه‌های متفاوت می‌توانند سازماندهی شوند و شبکه‌های عصبی با ساختارهای مختلفی تولید نمایند (منهاج، ۱۳۹۱؛ یآوری و همکاران، ۱۳۸۶؛ افتخاری و همکاران، ۱۳۹۱)


۴-۳-۱- توابع فعال‌ساز

نورون‌ها می‌توانند جهت تولید خروجی مناسب از توابع فعال‌ساز متفاوتی استفاده کنند که از رایج‌ترین آن‌ها می‌توان به توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع فعال‌ساز خطی اشاره کرد (شکل ۴-۲).



شکل ۴-۲: معروف‌ترین توابع فعال‌ساز (Demuth & Beal., 2012)

ساختار شبکه عصبی شکل (۴-۳) از یک‌لایه ورودی، یک یا چندلایه میانی (پنهان) و یک‌لایه خروجی تشکیل شده است که در لایه ورودی، پارامترهای تأثیرگذار بر کمیت موردنظر برای پیش‌بینی را به عنوان لایه ورودی در نظر می‌گیرند و در لایه خروجی پارامترهایی که توسط شبکه عصبی پیش‌بینی می‌شود قرار می‌گیرد اما لایه پنهان به عنوان رابط بین لایه ورودی و خروجی در نظر گرفته می‌شود که تعداد لایه‌های آن با توجه به مسئله موردنظر متفاوت است.



شکل ۳-۴: ساختار شبکه عصبی به صورت شماتیک (افتخاری و همکاران، ۱۳۹۱)

از آن جایی که توابع انتقال نمی‌توانند بین مقادیر خیلی بزرگ تمایز قائل شوند توصیه شده است که قبل از عملیات شبیه‌سازی، داده‌ها در دامنه صفر و یک تغییر مقیاس داده شوند به‌عنوان مثال تشخیص مقادیر بزرگ مثل ۲۰۰۰۰ و ۸۰۰۰۰ برای تابع انتقال سیگموئید بسیار مشکل است اما به‌راحتی می‌تواند بین ۱ و ۲ تمایز قائل شود از طرفی دیگر این کار باعث کمک به آموزش شبکه می‌شود زیرا تمامی ورودی‌ها و خروجی‌های تمام لایه‌ها در دامنه صفر و یک قرار می‌گیرد که این کار موجب سهولت و سادگی در فرایند انجام کار می‌شود. برای شبیه‌سازی و تخمین مسئله، شبکه عصبی سه مرحله آموزش، ارزیابی و اجرا را طی می‌کند. در طی فرایند آموزش، شبکه عصبی سعی می‌کند تا الگوی موجود بین ورودی‌های شبکه (مجموعه داده‌های آموزشی^{۲۷}) را از طریق قوانین و الگوریتم‌های یادگیری^{۲۸} که نحوه یادگیری را تعریف می‌کنند بشناسد. ارزیابی، توانایی شبکه برای ارائه جواب قابل قبول در قبال ورودی‌هایی است که در مجموعه داده‌های آموزشی نبوده‌اند. استفاده از شبکه برای انجام عملکردی که به آن منظور طراحی شده است را اجرا می‌گویند. در طی فرایند

^{۲۷} Training Data

^{۲۸} Training Algorithm

آموزش شبکه، وزن‌های داخلی شبکه عصبی که بر روی هر یک از متغیرهای ورودی شبکه اعمال می‌شود آن قدر تغییر می‌کنند تا به وضعیت مناسب برسند. پس از اتمام آموزش، داده‌های مجموعه اعتبارسنجی به شبکه ورودی داده می‌شود و پاسخ‌های شبکه با مقادیر واقعی کمیت مورد تخمین، مقایسه می‌شود هرچه این دو سری داده (واقعی و تخمینی) بیشتر به هم شبیه باشند قدرت تعمیم شبکه بیش‌تر خواهد بود. برای ارزیابی اختلاف دو سری داده، معمولاً از دو آماره، ضریب همبستگی و میانگین قدرمطلق خطا استفاده می‌شود. کاربرد دیگر مجموعه اعتبارسنجی در قطع زودرس آموزش است. بدین ترتیب که تا قبل از اینکه آموزش تا آخرین مرحله ادامه یابد در مرحله‌ای که خطای مجموعه اعتبارسنجی به حداقل می‌رسد آموزش متوقف می‌شود. از پرکاربردترین شبکه‌های مورد استفاده در تخمین و پیش‌بینی استفاده از شبکه‌های پیشرو^{۲۹} با قانون پس-انتشارخطا^{۳۰} می‌باشد (منهاج، ۱۳۹۱؛ یآوری و همکاران، ۱۳۸۶؛ افتخاری و همکاران، ۱۳۹۱).

۴-۴- روش‌های شبکه عصبی

مدل‌های محاسباتی مختلف که هرکدام از وجه خاصی از مغز انسان الهام گرفته‌اند تحت عنوان کلی شبکه‌های عصبی مصنوعی معرفی شده‌اند که هرکدام برای دسته‌ای از کاربردها قابل استفاده هستند. این مدل‌ها، دارای یک ساختار ریاضی و یک سری پیچ‌های تنظیم است که البته می‌توان به صورت گرافیکی هم آن را نمایش داد. این ساختار کلی، توسط یک الگوریتم یادگیری با تنظیم پارامتر وزن و بایاس به صورت بهینه سعی می‌کند بتواند رفتار مناسبی را از خود نشان دهد. از آن جایی که هرکدام از شبکه‌های عصبی تنها بخشی از قابلیت یادگیری مغز انسان را هدف قرار داده‌اند دارای رویکرد کاملاً متفاوت هستند. در ادامه به معرفی انواع مختلف شبکه‌های عصبی پرداخته شده است که مطالعه آن در ایجاد یک آشنایی اولیه بسیار مؤثر خواهد بود.

۴-۴-۱- شبکه‌های پیشخور

^{۲۹} Feedforward Neural Network

^{۳۰} Back Propagation

اولین و ساده‌ترین نوع یک شبکه عصبی مصنوعی، شبکه عصبی پیشخور (به انگلیسی: Feedforward Neural Network) می‌باشد. در این شبکه‌ها اطلاعات روبه‌جلو و در یک مسیر حرکت می‌کند و به نورون لایه قبل باز نمی‌گردد. در این شبکه‌ها به علت عدم وجود حلقه، خروجی هر لایه بر همان لایه تأثیر ندارد، به عبارت دیگر اطلاعات از گره‌های (نورون) ورودی وارد شده و با گذر از لایه‌های پنهان (میانی) به سمت نورون‌های خروجی می‌روند. شبکه‌های چند لایه با یک تابع انتقال غیرخطی، به شبکه اجازه می‌دهد که توانایی یادگیری رابطه خطی و غیرخطی را بین ورودی‌ها و خروجی‌ها داشته باشد. لایه خروجی خطی به شبکه این امکان را می‌دهد که خروجی خارج از محدوده $+1$ و -1 داشته باشد. ساده‌ترین نوع شبکه پیشخور، شبکه‌های پرسپترون چند لایه هستند (منهاج، ۱۳۹۱؛ یآوری و همکاران، ۱۳۸۶؛ افتخاری و همکاران، ۱۳۹۱).

۴-۴-۲- الگوریتم یادگیری پس انتشار خطا (Back Propagation)

الگوریتم پس انتشار بر قانون یادگیری اصلاح خطا مبتنی است و جزو الگوریتم‌های یادگیری با ناظر است. بدین ترتیب ساختار شبکه‌های پیش‌خور با این الگوریتم تکمیل می‌شود. فرایند این الگوریتم به صورت رفت و برگشت است. در مسیر رفت، ورودی به شبکه اعمال شده و خروجی ایجاد می‌شود. در مسیر برگشت مطابق با قانون اصلاح خطا پارامترهای شبکه تغییر کرده و اصلاح می‌شوند. این الگوریتم جزو الگوریتم‌های یادگیری با ناظر است. چون توزیع اخیر، در خلاف مسیر ارتباطات وزنی صورت می‌پذیرد، کلمه پس انتشار خطا جهت توضیح اصلاح رفتاری شبکه انتخاب شده است. پارامترهای شبکه (وزن‌ها و بایاس) طوری تنظیم می‌شوند که پاسخ واقعی شبکه به سمت پاسخ مطلوب نزدیک‌تر باشد (منهاج، ۱۳۹۱؛ افتخاری و همکاران، ۱۳۹۱).

مراحل آموزش به کمک الگوریتم پس انتشار خطا عبارت‌اند از (الف) - اختصاص دادن ماتریس وزن تصادفی به هر یک از نورون‌ها (ب) - انتخاب بردار ورودی و خروجی متناسب با آن (پ) - محاسبه خروجی هر یک از نورون‌ها در هر لایه و در نتیجه محاسبه خروجی نورون‌ها در لایه خروجی (ت) - بهنگام سازی وزن‌ها به روش انتشار خطای شبکه به لایه‌های قبل (خطا عبارت است از اختلاف بین مقدار واقعی و خروجی محاسبه

شده توسط شبکه). (ث) - ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص‌های تعریف شده مانند میانگین مربعات خطا^{۳۱} (MSE)، جذر میانگین مربعات خطا^{۳۲} (RMSE) و خطای متوسط (MAE^{۳۳}) سرانجام برگشت به قسمت پ یا پایان آموزش.

$$MSE(y, y') = \frac{\sum_{i=1}^n (y_i - y')^2}{n} \quad (۲-۴)$$

$$RMSE(y, y') = \sqrt{\frac{\sum_{i=1}^n (y_i - y')^2}{n}} \quad (۳-۴)$$

$$MAE(y, y') = \frac{\sum_{i=1}^n |y_i - y'|}{n} \quad (۴-۴)$$

۴-۴-۲-۱- روش‌های آموزش در شبکه‌های عصبی پس انتشار خطا

با توجه به پیچیدگی مسئله، تعداد داده‌های مجموعه آموزش، مقدار خطای مجاز، تعداد وزن‌ها و بایاس، تعیین اینکه کدام الگوریتم برای آموزش شبکه مناسب‌تر و سریع‌تر است کار سخت و دشواری است. الگوریتم‌های آموزشی متفاوتی جهت آموزش شبکه‌های عصبی وجود دارد این روش‌ها عبارت‌اند از:

۱- الگوریتم مومنتوم^{۳۴}

همانطور که در رابطه‌ی ۴-۵ مشخص است در این الگوریتم، قانون تغییر وزن‌ها را می‌توان به نحوی در نظر گرفت که تغییر وزن در تکرار n تا حدی به اندازه تغییر وزن در تکرار قبلی بستگی داشته باشد که در آن مقدار ممنتوم به صورت $1 > \alpha > 0$ - است.

$$\Delta W_{ji}(n) = \eta \delta_j X_{ji} + \alpha \Delta W_{ji}(n-1) \quad (۵-۴)$$

۲- الگوریتم لوببرگ - مارکوارت (LM)^{۳۵}

^{۳۱} Mean square error

^{۳۲} Root Mean Square Error

^{۳۳} mean absolute error

^{۳۴} Momentum algorithm

^{۳۵} Levenberg marquardt

این الگوریتم بر مبنای ماتریس هیسن است که برای افزایش سرعت یادگیری و کمینه‌سازی سطح خطای موجود شبکه عصبی طراحی شده است و برای شبکه‌های عصبی با پارامترهای ورودی کمتر از ۱۰۰ به دلیل همگرایی سریع‌تر در آموزش شبکه برای استفاده در تحقیق حاضر انتخاب شده است.

۳- الگوریتم گرادیان نزولی (CG)^{۳۶}

الگوریتم استاندارد گرادیان نزولی فقط از تقریب محلی شیب سطح کارآمدی در تعیین بهترین جهت حرکت وزن‌ها برای رسیدن به کمترین خطا، استفاده می‌کند. این روش معمولاً از مشتقات دوم و یا تقریبی از آن‌ها برای تصحیح وزن‌ها استفاده می‌نماید (منهاج، ۱۳۹۱؛ ارباب، ۱۳۹۲).

۴-۴-۳- پرسپترون چندلایه یا MLP

یکی از پایه‌ای‌ترین و مشهورترین مدل‌های عصبی موجود که به شبیه‌سازی عملکرد انتقالی مغز انسان می‌پردازد، مدل پرسپترون چندلایه^{۳۷} یا Multi-Layer Perceptron (به اختصار MLP) است. در این شبکه، بیش‌تر توانایی رفتار شبکه‌ای مغز انسان و انتشار سیگنال در آن مد نظر بوده است و از این رو، به این نوع شبکه‌ها شبکه‌های پیش‌خور (Feedforward Networks) نیز گفته می‌شود. این نوع از شبکه عصبی مصنوعی، از خروجی‌های لایه ورودی، به عنوان ورودی‌های لایه بعدی استفاده می‌شود، این کار به همین شکل ادامه پیدا می‌کند تا زمانی که، پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه میانی به عنوان ورودی‌های لایه خروجی مورد استفاده قرار می‌گیرد. شبکه‌های پرسپترون چند لایه حاوی مجموعه‌ای از وزن‌ها و بایاس هستند که باید برای آموزش و یادگیری شبکه عصبی تنظیم شوند. شبکه‌های عصبی پرسپترون، از توانایی مناسبی برای ایجاد یک خروجی مشخص متناظر با پارامترهای ورودی را دارند. استفاده از این شبکه برای حل مسائل ساده طبقه بندی بسیار مناسب است (منهاج، ۱۳۹۱؛ ارباب، ۱۳۹۲).

۴-۴-۴- شبکه‌های عصبی شعاعی یا RBF

^{۳۶} Gradient Descent

^{۳۷} Multi-Layer Perceptron (MLP)

نوع دیگری از شبکه‌های عصبی که از طریق توابع شعاعی یا Radial Basis Functions به اختصار (RBF) به مدل‌سازی می‌پردازند، شبکه‌های عصبی شعاعی^{۳۸} می‌گویند. ساختار کلی شبکه‌های عصبی RBF، در مقایسه با شبکه‌های MLP تفاوت چندانی با هم ندارند و تنها نوع پردازشی که نورون‌ها بر روی کمیت‌های ورودی‌شان انجام می‌دهند، متفاوت است. با این حال، کارتنظیم شبکه‌های RBF به دلیل تمرکز نورون‌ها بر محدوده عملکردی خاص راحت‌تر خواهد بود از این رو غالباً دارای فرایند یادگیری و آماده‌سازی سریع‌تری هستند.

۴-۵-۴- ماشین‌های بردار پشتیبان یا SVM

در شبکه‌های عصبی MLP و RBF، غالباً توجه بر بهبود ساختار شبکه عصبی است، به نحوی که خطای تخمین و میزان اشتباه‌های شبکه عصبی کمینه شود. اما در نوع خاصی از شبکه عصبی، موسوم به ماشین بردار پشتیبان^{۳۹} یا Support Vector Machine به اختصار (SVM)، صرفاً بر روی کاهش ریسک عملیاتی مربوط به عدم عملکرد صحیح، تمرکز می‌شود. ساختار یک شبکه SVM، اشتراکات زیادی با شبکه عصبی MLP دارد و تفاوت اصلی آن عملاً در شیوه یادگیری است.

۴-۵-۴- کاربردهای شبکه‌های عصبی مصنوعی

امروزه استفاده از سیستم‌های هوشمند از جمله شبکه عصبی با توجه به نیاز اکثر رشته‌های دانشگاهی به تحلیل، پیش‌بینی، مدل‌سازی، تخمین، ساخت و غیره به‌شدت در حال افزایش است به گونه‌ای که می‌توان این ابزارها را در ردیف عملیات پایه ریاضی و به عنوان ابزارهای عمومی و مشترک برای تمامی رشته‌ها، طبقه‌بندی کرد. در ادامه فهرستی مختصر از کاربرد شبکه عصبی مصنوعی در جدول ۴-۱ نشان داده شده است.

^{۳۸}Radial Basis Functions(RBF)

^{۳۹}Support Vector Machine(SVM)

جدول ۴-۱: کاربردهای شبکه عصبی در علوم مختلف

کاربرد	زمینه کلی
• طبقه‌بندی اسناد و اطلاعات در شبکه‌های کامپیوتری و اینترنت • توسعه نرم‌افزارهای نظارتی و نرم‌افزارهای آنتی‌ویروس	علوم کامپیوتر
• مهندسی معکوس و مدل‌سازی سیستم‌ها • پیش‌بینی مصرف بار الکتریکی • عیب‌یابی سیستم‌های صنعتی و فنی • طراحی انواع سیستم‌های کنترل • طراحی و بهینه‌سازی سیستم‌های فنی و مهندسی • تصمیم‌گیری بهینه در پروژه‌های مهندسی	علوم فنی و مهندسی
• پیش‌بینی نتایج آزمایش‌ها • ارزیابی و تخمین صحت فرضیه‌ها و نظریه‌ها • مدل‌سازی پدیده‌های فیزیکی پیچیده	علوم پایه و نجوم
• مدل‌سازی فرایندهای زیست-پزشکی • تشخیص بیماری‌ها با توجه به نتایج آزمایش پزشکی و تصویربرداری • پیش‌بینی نتایج درمان و عمل جراحی • پیاده‌سازی ادوات و الگوهای درمانی اختصاصی بیمار	علوم پزشکی

۴-۶- کاربرد شبکه عصبی در مکانیک سنگ

شبکه‌های عصبی مصنوعی با توجه به عدم نیاز به فرمول بندی و مدل‌های ریاضی محض در مواردی که ارتباط بین پارامترهای ورودی و خروجی مشخص نباشد ایده‌ی مناسبی برای تخمین و مدل‌سازی به شمار می‌رود. در واقع با استفاده از قابلیت‌های شبکه‌ی عصبی می‌توان راه‌های کم هزینه‌تر و آسانتر و نتایج دقیقتری را پیش روی مهندسین، قرارداد. برای پیش‌بینی یک کمیت با استفاده از شبکه‌ی عصبی نیاز به سابقه‌ای از آن کمیت و پارامترهای موثر بر آن است تا بتوان پس از ساخت شبکه‌ای مناسب، از آن به منظور پیش‌بینی کمیت مورد نظر بهره گرفت. بیشترین کاربرد شبکه‌های عصبی در مهندسی مکانیک سنگ مربوط به تخمین و تقریب می‌باشد که از این میان می‌توان به موارد زیر اشاره کرد.


- تخمین پارامترهای ژئومکانیکی سنگ‌ها

- پیش‌بینی و تخمین مقدار نشست زمین در اثر حفرتونل و فضا‌های زیرزمینی
- تعیین نرخ نفوذ، ضریب بهره‌وری و غیره دستگاه‌های حفر مکانیزه تونل و فضا‌های زیرزمینی
- تخمین ضریب اطمینان در پایداری سطوح شیب‌دار
- تخمین ضریب اطمینان در پایداری سطوح شیب‌دار
- تخمین ضریب اطمینان در پایداری سطوح شیب‌دار
- تعیین رفتار مکانیکی سنگ‌ها در شرایط مختلف


و بسیاری از موارد دیگر که نتایج رضایت بخشی از آن‌ها به‌دست‌آمده است. مجموعه تحقیقات موفق انجام شده نوید استفاده بیشتر این شبکه‌ها را در آینده مهندسی مکانیک سنگ می‌دهد. نتایج به‌دست‌آمده از بررسی تعدادی از تحقیقات انجام شده، به این قرار است که شبکه‌های عصبی عملکردی مناسب‌تر از آنالیزهای آماری و روابط تجربی ارائه شده دارند به طوری که علاوه بر دامنه کاربرد وسیع‌تر، خطای کمتری را در تخمین پارامترها نتیجه می‌دهد. علاوه‌برآن شبکه‌های عصبی از قدرت تعمیم‌پذیری بیشتری نسبت به روابط تجربی برخوردارند.

افتخاری و همکاران با استفاده از اطلاعات تونل بلند زاگرس به تحلیل پارامترهای گشتاور و نیروی پیشران با استفاده از شبکه‌ی عصبی و تأثیر آن بر نرخ نفوذ ماشین TBM پرداختند. نتایج تحلیل‌ها نشان داده است که نیروی پیشران و گشتاور در یک محدوده‌ی بهینه، سبب افزایش نرخ نفوذ شده است و برای رسیدن به نرخ نفوذ بیشینه مطابق نتایج، می‌توان از زوج نیروی محوری پیشران و گشتاور بهینه استفاده کرد (افتخاری و همکاران، ۱۳۹۱). از مطالعات دیگر می‌توان به مطالعات گریما و همکاران، مهدوی و یآوری، یاگیز و همکاران، اشاره کرد نتایج حاصل از این مطالعات نشان می‌دهد که مدل شبکه عصبی نسبت به روش‌های مرسوم از جایگاه مناسب‌تری برخوردار است، نتایج در شکل ۴-۴ نشان‌داده شده است (Grima et al., 2000; Yagiz et al., 2009) (یآوری و همکاران، ۱۳۸۶). فتح‌آبادی و همکاران به پیش‌بینی میزان نشست تونل خط هفت مترو تهران با استفاده از شبکه عصبی پرداخته است (فتح‌آبادی و همکاران، ۱۳۹۱)، نجاتی و


همکاران به پیش‌بینی ضریب بهره‌وری TBM با استفاده از شبکه عصبی پرداخته است که نتایج حاصله از کارایی مناسب این روش برای تخمین ضریب بهره‌وری با ضریب تعیین $0/95$ حکایت دارد (نجاتی و همکاران، ۱۳۸۹)؛ بنابراین استفاده از روش‌های نوین شبکه‌ی عصبی در تحلیل عملکرد ماشین‌های حفاری و سازه‌های زیر زمینی جایگاه ویژه‌ای را در بین مهندسين این حوزه کسب کرده است.




ب



الف



د



ج

شکل ۴-۴: مقایسه‌ی بین مقادیر پیش‌بینی شده و مقادیر واقعی (الف) مدل گریما و همکاران (ب) مدل مهدوی و یآوری و مقایسه با مدل گراهام (ج) مدل یاگیز و همکاران - شبکه عصبی (د) مدل یاگیز و همکاران - مدل رگرسیون چندمتغیره (یآوری و همکاران، ۱۳۸۶). (Grima et al., 2000; Yagiz et al., 2009)

۴-۷- معایب شبکه‌های عصبی

از معایب شبکه‌های عصبی می‌توان به عدم وجود قانون مشخص در تعیین تعداد لایه‌ها و تعداد نورون‌های میانی اشاره کرد. کم بودن نورون‌های لایه‌ی میانی شبکه سبب عدم شناسایی نگاشت غیرخطی بین ورودی و خروجی می‌شود. زیاد شدن نورون‌های لایه‌ی میانی نیز سبب افزایش پارامترهای تنظیم شونده‌ی شبکه شده و در نتیجه شبکه برای یادگیری نیاز به کمیت‌های ورودی زیادی در مجموعه‌ی آموزشی دارد تا بتواند اوزان خود را تنظیم کند، همچنین سبب افزایش احتمال بیش برآزشی در شبکه می‌شود. تعیین این مقادیر با استفاده از آزمون و خطا مشخص خواهد شد. با این وجود، تعدادی از محققان بر اساس تجربیات خود روش‌ها و محدودیت‌هایی را برای تعداد نورون‌ها در لایه‌ی میانی بیان کرده‌اند. به عنوان نمونه برکه پیشنهاد کرده است که تعداد نورون‌ها در لایه‌ی میانی عددی بین میانگین و مجموع نورون‌های لایه‌های ورودی و خروجی باشد. هیچت - نیلسن و کادیل نیز پیشنهاد کرده‌اند که حد بالایی تعداد نورون در لایه‌ی میانی در یک شبکه با یک لایه‌ی میانی $2I+1$ است که I تعداد ورودی شبکه است. از دیگر معایب شبکه عصبی می‌توان به نیاز دسترسی به داده‌های وسیعی از پارامترهای ورودی و خروجی برای آموزش مناسب شبکه اشاره کرد. معایب این گونه شبکه‌ها از دیدگاه منهای عبارت‌اند از:

- ۱- قواعد یا دستور مشخصی برای طراحی شبکه جهت یک کاربرد اختیاری وجود ندارد.
- ۲- دقت شبکه به اندازه مجموعه آموزش بستگی دارد.
- ۳- آموزش شبکه ممکن است مشکل یا حتی غیرممکن باشد.
- ۴- پیش‌بینی عملکرد آینده شبکه (عمومیت یافتن آن) به سادگی امکان‌پذیر نیست.
- ۵- در مورد مسائل مدل‌سازی، نمی‌توان صرفاً با استفاده از شبکه عصبی به فیزیک مسئله پی برد (منهای، ۱۳۹۱؛ ارباب، ۱۳۹۲؛ افتخاری و همکاران، ۱۳۹۱).

۴-۸- جمع‌بندی

ویژگی‌های شبکه عصبی سبب شده است محققین حوزه‌های مختلف برای مواردی که ارتباط بین کمیت‌های ورودی‌ها و خروجی‌ها قابل تشخیص نیست از این روش برای تخمین و مدل‌سازی استفاده کنند. در صورت در دسترس بودن داده‌های گسترده و تعیین ساختار مناسب برای شبکه، این روش قادر خواهد بود بادقت لازم و خطای مناسب به تخمین و مدل‌سازی بپردازد.

فصل پنجم

پیش‌بینی عمر دیسک کاتر با استفاده از شبکه عصبی

۵-۱- مقدمه


سایش دیسک کاتر و جایگزینی دیسک کاترهای فرسوده بسیار زمان بر و پرهزینه بوده به نحوی که بر روی طراحی و برنامه ریزی پروژه تأثیر می گذارد. نرخ مصرف دیسک سهم عمده‌ای را در بهره‌وری کل پروژه و نیز افزایش هزینه‌ها ایفا می کند. بنا بر مسائل بیان شده بدیهی است، تعیین هرچه دقیق تر عمر مفید ابزار برش در موفقیت پروژه بسیار مؤثر می باشد. با توجه به اهمیت تخمین نرخ سایش ابزار در عملیات تونل سازی هم زمان با ساخت و پی شرفت تکنولوژی طراحی ماشین های حفار (TBM) همواره محققانی به دنبال یافتن روشی برای تخمین و پیش بینی مقدار آن بوده اند و تاکنون مدل هایی شامل روابط تجربی حاصل از تحلیل رگرسیون و مدل های نیمه تئوری برای حل مسئله ارائه شده است. روش تجربی بر مبنای ارتباط عملی و مشاهداتی بین شرایط کار و عملکرد دیسک کاتر توسعه یافته است و به واسطه برازش بین خصوصیات سنگ و پارامترهای ماشین با نرخ سایش به دست آمده است. روش های نیمه تئوری بر اساس تئوری انرژی اصطکاک و یا آنالیز نیروهای عملکرد دیسک کاتر گسترش یافته است. مزیت مدل های تجربی این است که به طور طبیعی تمام تأثیرات ناشی از زمین و ماشین را در نظر می گیرند، اما با این حال، رشد فناوری و ارائه های ماشین هایی با قابلیت های متفاوت، استفاده از این روش ها را محدود می سازد. تاکنون چندین مدل برای پیش بینی عملکرد دیسک کاتر در حین تونل زنی TBM پیشنهاد شده است. مدل های تجربی شامل مدل گیرینگ (Gehering)، مدل برولند (NTNU)، مدل لئو و همکاران (Liu et al) و مدل های نیمه تئوری شامل مدل مدرسه معدن کلرادو (CSM) و مدل ونگ و همکاران (Wang et al) و غیره می باشد.

با این وجود، به دلیل اینکه مدل های ارائه شده در یک حالت خاص از شرایط زمین پیشنهاد شده اند، قابل تعمیم به تمام شرایط نیستند. در سال های اخیر از روش شبکه های عصبی مصنوعی به عنوان ابزاری جدید جهت پیش بینی نرخ نفوذ و نرخ پیشروی و غیره استفاده شده است. شبکه های عصبی مصنوعی با الهام از ساختار مغز و عملکرد موازی آن به وجود آمده است. پویا بودن شبکه عصبی و عدم نیاز به فرمول بندی و روابط ریاضی محض سبب شده است محققین حوزه های مختلف برای مواردی که ارتباط بین کمیت های

ورودی و خروجی قابل تشخیص نیست از این روش برای تخمین و مدل سازی استفاده کنند. در این تحقیق با استفاده از بانک اطلاعاتی جمع آوری شده از تونل انتقال آب اوما اويا واقع در کشور سریلانکا ابتدا با استفاده از روش های رگرسیون ساده و چندگانه به بیان ارتباط بین پارامترهای زمین و ماشین با نرخ سایش پرداخته سپس با استفاده از شبکه عصبی مدلی مناسب جهت پیش بینی نرخ سایش دستگاه های حفاری مکانیزه در سنگ های سخت ارائه شده است و میزان دقت آن ها با روش های متداول مقایسه شده و میزان توانایی این روش و روش های مرسوم مورد ارزیابی قرار گرفته است.

۵-۲- منطقه مورد مطالعه

طرح چندمنظوره اوما اويا (uma oya) با هدف انتقال آب، آبیاری اراضی پایین دست و تولید برق در محدوده جنوب شرقی منطقه بادولا (Badulla) از توابع استان اووا (Uva) به فاصله حدود ۲۰۰ کیلومتری پایتخت تجاری کشور سریلانکا تعریف شده است، این پروژه به منظور انتقال سالانه ۱۴۵ میلیون مترمکعب آب با هدف آبیاری و ایجاد ۷۰۰ متر هد آب، با هدف تولید برق به ظرفیت تولید ۱۲۰ مگاوات در حال ساخت است. موقعیت مکانی پروژه و تونل انتقال آب اوما اويا در شکل ۵-۱ نشان داده شده است (FARAB, 2016).



شکل ۵-۱: موقعیت پروژه و تونل انتقال آب اوما اويا (Pourhashemi et al., 2021)

۵-۲-۱- مطالعات زمین‌شناسی

پی‌جویی‌های زمین‌شناسی شامل برداشت‌های سطحی، حفر ۱۳ گمانه به طول مجموع ۳۵۲۰ متر، انجام آزمون‌های آزمایشگاهی و مطالعات دفتری برای تفسیر نتایج بوده است. عمده جنس سنگ در مطالعات شامل موارد زیر بوده و برخی از واحدهای زمین‌شناسی مسیر در شکل ۵-۲ نشان داده شده است (Pourhashemi et al., 2021; Hassanpour, 2014 FARAB., 2016).

۱. کندالیت یا گنایس کوارتز فلدسپاتیک به همراه گارنت و بیوتیت (pmgga & pmgqf).

۲. گنایس سخت شارنوکییتی (pmgk).

۳. کوارتزیت (Pmq).


۴. مرمر/کالک گنایس (Pmc).



شکل ۵-۲: واحدهای سنگی موجود در موقعیت پروژه (Pourhashemi et al., 2021)

توزیع واحدهای سنگی به شدت ناهمگن است، تغییرات در مقیاس متر و حتی در فواصل چند ده متر می‌توانند دیده شوند. ضخامت زون هوازده در سطح متغیر می‌باشد و می‌تواند تا چند ده متر برسد، زون‌های

تحت تأثیر هوازدگی هیدروترمال در عمق‌های زیاد (تا ۳۴۰ متر از سطح) دیده می‌شوند. شکل ۳-۵ توزیع واحدهای زمین‌شناسی را در امتداد تونل نشان می‌دهد (FARAB.,2012; Pourhashemi et al.,2021).



شکل ۳-۵: توزیع واحدهای زمین‌شناسی در امتداد محور تونل (Pourhashemi et al.,2021)

با توجه به گمانه‌های اکتشافی (در قسمت تونل و نزدیک آن) کیفیت توده سنگ در امتداد قسمت عمده تونل خوب و عالی است ($RQD=84-100\%$) و در زون‌های هوازده ضعیف تا متوسط ($RQD=40-65\%$) تغییرات تعیین کیفیت توده سنگ در امتداد تونل انتقال آب اوما اوپا در جدول ۵-۱ نشان داده شده است. با توجه به برآوردهای میدانی و با توجه به نتایج آزمون آزمایشگاهی، تونل در سنگ‌های قوی تا بسیار قوی با دامنه معمول UCS بین ۷۵ تا ۲۵۰ مگا پاسکال حفر شده است (جدول ۵-۱). همچنین تعدادی نمونه از گمانه‌ها گرفته شده و با استفاده از روش سرشار، به سوئیس (آزمایشگاه مکانیک سنگ EPFL) برای برآورد ساینده‌گی ارسال شده است که در جدول ۵-۱ نتایج نشان داده شده است. همانطور که نشان داده شده، مقادیر پارامتر CAI (شاخص ساینده‌گی Cerchar) برای چهار نوع اصلی از سنگ‌های منطقه متفاوت است. در جدول ۵-۲ درصد کانی‌های تشکیل‌دهنده هر واحد زمین‌شناسی به تفکیک نشان داده شده است (FARAB.,2016; Pourhashemi et al.,2021; Hassanpour.,2014). با بررسی داده‌های ثبت شده برای اندازه‌گیری میزان سایش دیسک کاتر نتایج آن برای هر زون در جدول ۵-۱ آورده شده است.

جدول ۵-۱: مشخصات واحدهای زمین‌شناسی موجود در طول تونل (FARAB.,2016)

زون	واحد زمین شناسی unit	مترژ سنگ‌شناسی section	مقاومت فشاری تک محوره UCS(Mpa)	شاخص سرشار CAI	کیفیت توده سنگ RQD	رده بندی توده سنگ RMR	نرخ سایش W_f (cutter/m)	عمر دیسک کاتر H_f (m ³ /cutter)
۱	pmgk	۱۷۱	۲۵۰	۵	۶۰	۵۸	۰/۰۵	۲۹۰
۲	pmc	۱۲۲	۷۵	۳/۵	۹۰	۴۷	۰/۰۳۴	۴۳۰
۳	Pmq	۱۵۴	۲۰۰	۴/۵	۶۰	۵۵	۰/۰۷۳	۲۰۰
۴	Pmgk	۱۰۶۷	۲۵۰	۵	۷۵	۶۰	۰/۰۵	۲۹۰
۵	Pmgqf	۱۰۴۴	۲۰۰	۵	۷۵	۵۸	۰/۰۴۸	۳۰۵
۶	Pmgga	۹۷۸	۲۲۰	۴/۵	۸۰	۶۰	۰/۰۵۲	۲۸۰
۷	Pmgqf	۶۱۱	۱۵۰	۴	۱۰۰	۶۴	۰/۰۴۳	۳۴۰
۸	Pmgk	۶۰۷	۱۵۰	۳	۸۵	۶۴	۰/۰۴۳	۳۴۰
۹	pmgqf	۳۱۸	۹۰	۲/۵	۱۰۰	۶۴	۰/۰۴	۳۶۰
۱۰	Pmq	۲۲۶	۲۰۰	۴	۹۰	۶۴	۰/۰۷۱	۲۰۵
۱۱	Pmgqf	۸۵	۵۰	۲/۵	۲۵	۳۰	۰/۰۳۹	۳۷۰
۱۲	Pmgqf	۲۳۴	۷۵	۳	۵۰	۵۰	۰/۰۳۸	۳۸۵
۱۳	Pmgk	۵۸۳	۲۵۰	۵	۹۰	۶۵	۰/۰۵۵	۲۶۵
۱۴	Pmgk	۱۵۳۸	۲۵۰	۵	۹۰	۶۵	۰/۰۵۵	۲۶۵
۱۵	Pmc	۲۱۴	۷۵	۲/۵	۹۰	۶۵	۰/۰۳۲	۴۵۰
۱۶	Pmgqf	۶۸۸	۲۰۰	۵	۱۰۰	۶۵	۰/۰۵۲	۲۸۰
۱۷	Pmq	۲۵۹	۲۰۰	۵	۲۵	۴۰	۰/۰۷۴	۱۹۵
۱۸	Pmgqf-ga	۱۶۰۳	۱۰۰	۴/۵	۵۰	۴۵	۰/۰۴۶	۳۱۵
۱۹	Pmq	۱۴۸	۱۰۰	۳	۸۵	۶۵	۰/۰۵۹	۲۴۶,۶
۲۰	Pmgqf	۵۱۵	۱۵۰	۳/۵	۱۰۰	۶۵	۰/۰۴۵	۳۲۵
۲۱	Pmgk	۶۰۲	۲۵۰	۵/۵	۸۰	۶۰	۰/۰۵۵	۲۶۵
۲۲	Pmc	۳۴۵	۷۵	۲/۵	۲۵	۳۰	۰/۰۳	۴۸۰
۲۳	Alt	۹۵۶	۱۵۰	۳/۵	۵۰	۵۵	۰/۰۴۷	۳۱۰
۲۴	Pmc	۲۲۱	۵۰	۳	۲۵	۴۰	۰/۰۲۸	۵۱۰
۲۵	Alt	۳۶۱	۷۵	۲/۵	۲۵	۳۰	۰/۰۴۲	۳۴۵
۲۶	pmgqf	۵۳۹	۲۰۰	۵	۵۰	۵۵	۰/۰۴۶	۳۱۵
۲۷	pmgga	۶۱۷	۲۰۰	۴	۲۵	۳۰	۰/۰۴۶	۳۱۵
۲۸	Alt	۴۵۴	۱۵۰	۴	۸۰	۵۵	۰/۰۴۲	۳۴۶

جدول ۵-۲: خلاصه نتایج درصد کانی های تشکیل دهنده هر واحد زمین شناسی (FARAB.,2016)

واحد زمین شناسی	کوارتز	کلسیت	فلدسپار	گارنت	بیوتیت	ارتوپیروکسن
Pmgk	۱۵	-	۱۵	۲۰>	۲۰-۳۰	۲۰-۳۰
Pmc	۲۰-۳۰	۵۰-۶۰	-	۱۰	-	-
Pmq	۷۰-۹۵	-	۵-۳۰	-	-	-
Pmgqf	۴۰-۵۰	-	۲۰-۵۰	۱۰-۴۰	۱۰>	-

منطقه مورد مطالعه تونل انتقال آب اوما اويا واقع در کشور سریلانکا به طول تقریبی ۱۵/۳ کیلومتر و قطر ۴/۳ متر است که با دو دستگاه حفاری DSTBM مربوط به شرکت هر نکشت آلمان، عملیات حفاری آن اجرا شده است. مشخصات مربوط به تونل و ماشین TBM در جدول ۵-۳ آورده شده است.

جدول ۵-۳: مشخصات مربوط به تونل و ماشین حفار

طول تونل (KM)	۱۵/۳
قطر حفاری (m)	۴/۳
تعداد دیسک	۲۷
قطر دیسک	۱۷ اینچ
ماکزیم نیروی پیشران (KN)	۲۱۲۷
سرعت چرخش (rpm)	۱۱ تا ۱۱
گشتاور (KN.m)	۱۷۲۵
وزن (ton)	۲۴۷

۵-۲-۲- اطلاعات آماری داده های ثبت شده ماشین حفار

در پروژه Uma-Oya در سریلانکا، تمام داده های موجود در حین حفاری TBM جمع آوری شده و در یک پایگاه داده جامع ثبت شده است. این داده ها شامل نیروی پیشران، میزان نرخ نفوذ، سرعت چرخش کله حفار، گشتاور است. مقادیر متوسط آن برای هر زون زمین شناسی در جدول ۵-۴ آورده شده است.

جدول ۴-۵: اطلاعات آماری داده‌های ثبت شده در منطقه مورد مطالعه

زون	واحد زمین شناسی unit	سرعت چرخش کله حفار RPM(rev/min)	نیروی پیشران Th(KN)	نرخ نفوذ ROP(mm/rev)	گشتاور Q(KN.m)
۱	pmgk	۲/۱۰	۲۴۲	۷/۷	۶۵۰
۲	pmc	۲/۱۰	۲۲۰	۵/۹	۶۸۰
۳	Pmq	۹/۱۰	۱۶۰	۵/۲	۴۲۰
۴	Pmgk	۷/۹	۲۳۰	۵/۷	۶۸۴
۵	Pmgqf	۱۰	۲۴۵	۶/۶	۶۵۰
۶	Pmgga	۵/۶	۲۴۵	۱/۵	۶۲۰
۷	Pmgqf	۶/۹	۲۳۰	۹/۳	۶۱۰
۸	Pmgk	۲/۱۰	۲۳۵	۶/۴	۵۱۰
۹	pmgqf	۹	۲۳۰	۹/۳	۵۱۰
۱۰	Pmq	۶	۱۴۰	۱/۳	۴۱۰
۱۱	Pmgqf	۸/۹	۲۰۵	۵/۷	۷۳۰
۱۲	Pmgqf	۱۰	۲۲۸	۷/۸	۷۲۰
۱۳	Pmgk	۴/۸	۲۱۰	۱/۴	۵۱۰
۱۴	Pmgk	۷/۱۰	۲۰۵	۱/۴	۵۱۰
۱۵	Pmc	۳/۴	۲۵۰	۵/۳	۳۲۰
۱۶	Pmgqf	۵/۱۰	۱۸۰	۹/۳	۵۸۰
۱۷	Pmq	۱۱	۲۶۰	۵/۱	۹۸۰
۱۸	Pmgqf-ga	۲/۶	۲۴۵	۵/۶	۶۵۰
۱۹	Pmq	۶/۱۰	۲۰۰	۵/۸	۸۴۰
۲۰	Pmgqf	۶/۹	۲۵۰	۹/۳	۶۰۰
۲۱	Pmgk	۲/۱۰	۲۳۰	۱/۵	۶۲۰
۲۲	Pmc	۳/۴	۲۰۰	۵/۶	۶۸۰
۲۳	Alt	۱/۹	۱۸۰	۴/۶	۷۱۰
۲۴	Pmc	۱/۱۰	۲۰۵	۱۰	۶۰۰
۲۵	Alt	۷	۲۴۰	۷	۵۸۰
۲۶	pmgqf	۸/۹	۲۱۰	۸/۶	۷۸۰
۲۷	pmgga	۵/۹	۲۲۰	۱/۶	۶۹۰
۲۸	Alt	۵/۴	۲۳۵	۹/۵	۶۱۵

۵-۴- پیش‌بینی عمر دیسک کاتر با شبکه‌ی عصبی مصنوعی

به‌منظور پیش‌بینی عمر دیسک کاتر با استفاده از شبکه‌ی عصبی، ابتدا پارامترهای مؤثر بر عمر دیسک-کاتر به‌منظور ایجاد ساختار شبکه انتخاب شده است و سپس به شبیه‌سازی برای دستیابی به شبکه‌ی بهینه پرداخته شده است.

۵-۴-۱- ایجاد ساختار مناسب شبکه‌ی عصبی مصنوعی

عوامل مؤثر بر عمر دیسک‌کاترهای TBM را می‌توان در سه دسته‌ی کلی تقسیم‌بندی نمود که عبارت‌اند از:

(۱) پارامترهای مربوط به سنگ بکر

(۲) پارامترهای مربوط به توده سنگ

(۳) پارامترهای مربوط به ماشین حفار

برای انتخاب پارامترهای ورودی شبکه تلاش شده است، تا اثر این سه دسته عوامل در پیش‌بینی در نظر گرفته شود. درمجموع برای پیش‌بینی نرخ سایش، ۹ پارامتر به عنوان پارامترهای مؤثر و ورودی بر نرخ سایش انتخاب شده است:

(۱) جنس سنگ

(۲) مقاومت فشاری تک‌محوری (مگاپاسکال)

(۳) اندیس سایش سرشار (CAI)

(۴) RQD برای توصیف تعداد درزه‌ها در سنگ

(۵) RMR بیانگر شرایط توده سنگ

(۶) نیروی محوری پیشران یا تراست (کیلونیوتن)

(۷) گشتاور (کیلونیوتن متر)

۸) سرعت چرخش کله حفار (دور بر دقیقه)

۹) نرخ نفوذ (میلی متر بر دور)

پارامتر خروجی شبکه‌ی عصبی نیز، نرخ سایش (m/cutter) است. این پارامترها به سادگی در مراحل انجام پروژه و یا با انجام آزمایش و تکنیک‌های ویژه، قابل جمع‌آوری است.

با توجه به تأثیرگذاری متفاوت هر یک از پارامترهای مختلف زمین و ماشین حفار بر روی سایش دیسک‌کاتر، محققان به طور جداگانه به بررسی تأثیر این پارامترها پرداخته‌اند از این رو جهت تعیین و انتخاب پارامترهای ورودی مناسب به شبکه‌های عصبی از سوابق تحقیقات گذشته کمک گرفته شده است. برای مثال در برخی از تحقیقات قبلی تأثیرگذاری شاخص سرشار بر نرخ سایش دیسک‌کاتر بررسی و به اثبات رسیده است. در نتیجه این پارامتر به عنوان ورودی شبکه‌ی عصبی انتخاب شده است. همچنین به این سبب که با پارامترهای ماشین متفاوت در شرایط یکسان توده سنگ، مقدار نرخ سایش می‌تواند متفاوت باشد، بنابراین پارامترهای ماشین نیز به عنوان ورودی شبکه در نظر گرفته شده است (افتخاری و همکاران، ۱۳۹۱).

ممکن است در نگاه اول به نظر آید که میان برخی از پارامترهای ورودی شبکه عصبی یک همبستگی درونی وجود دارد (RQD, RMR) و ممکن است موجب خطا در نتایج شود. با این حال، هر پارامتر موضوع مشخصی را نشان می‌دهد و اطلاعات تهیه شده می‌تواند به فهم بیشتر مسئله کمک نماید. به عنوان مثال، در یک مقدار RMR انتظار رفتار یکسانی در موارد مختلف وجود دارد در صورتی که تفاوت در مقدار RQD ممکن است منجر به تفاوت در شرایط پایداری شود (افتخاری و همکاران، ۱۳۹۱).

برای ایجاد ساختار مناسب شبکه‌ی عصبی، به مجموعه‌ای از داده‌ها به صورت زوج‌های ورودی و خروجی نیاز است، این اطلاعات با انجام آزمایش‌های برجا و برداشت‌های میدانی از مسیر حفر تونل به دست آمده و در یک بانک اطلاعاتی ذخیره شده است و همانطور که در بخش مبانی شبکه‌های عصبی بیان شده است، یک شبکه باید با مجموعه‌هایی از زوج‌ها به عنوان زوج آموزش مورد آموزش قرار گرفته و با زوج‌های مجموعه‌ی

ارزیابی و آزمون مورد آزمایش قرار گیرد. بنابراین، قبل از عملیات آموزش، مجموعه‌ی بانک اطلاعاتی به طور تصادفی به سه دسته‌ی مجموعه‌ی آموزش، ارزیابی و آزمون افراز خواهد شد (افتخاری و همکاران، ۱۳۹۱).

یکی از مهم‌ترین مراحل در مدل‌سازی با استفاده از شبکه عصبی تعیین ساختار شبکه عصبی است که نیازمند تعیین تعداد مناسب لایه‌ها و همچنین تعداد مناسب نورون‌ها در هر لایه است. قاعده مشخصی برای تعیین شبکه‌ی مناسب وجود ندارد. در حالت کلی پیشنهاد شده است که با ثابت نگه‌داشتن تعداد لایه، تعداد نورون در هر لایه تعیین شود. تعداد نورون‌های لایه ورودی و خروجی به ترتیب با توجه به کمیت‌های ورودی و خروجی محدود می‌شود (افتخاری و همکاران، ۱۳۹۱).

مطالعات گذشته نشان می‌دهد که بسیاری از شبکه‌ها با یک یا دو لایه میانی قابل حل است. به‌منظور دستیابی به نتایج مناسب، در این مطالعه شبکه‌های زیادی با یک و دو لایه‌ی میانی ساخته شده است. مقایسه‌ی نتایج حاصل از آن‌ها نشان داده است که شبکه‌ای با ساختار یک لایه‌ی میانی در این تحقیق مناسب‌تر است، بنابراین در ادامه، به شبیه‌سازی با شبکه عصبی پرداخته و نتایج مربوط به شبکه با یک لایه‌ی میانی ارائه شده است. خلاصه برخی از نتایج حاصله برای شبکه‌ی عصبی با تعداد لایه متفاوت در جدول ۵-۵ نشان داده شده است.

جدول ۵-۵: خلاصه برخی از نتایج به‌دست‌آمده برای ایجاد ساختار مناسب شبکه

خطای متوسط	ضریب همبستگی	ساختار شبکه	خطای متوسط	ضریب همبستگی	ساختار شبکه
۰/۱۵۹	۰/۸۸	۹*۹*۷*۱	۰/۱۲۲	۰/۹۳	۹*۹*۱
۰/۲۸	۰/۸۱	۹*۸*۹*۱	۰/۲۴	۰/۸۳	۹*۸*۱
۰/۱۸	۰/۸۴	۹*۷*۸*۱	۰/۲۴	۰/۷۸	۹*۷*۱
۰/۲۱	۰/۶۴	۹*۶*۹*۱	۰/۱۹	۰/۸۴	۹*۶*۱
۰/۴	۰/۵۲	۹*۱۰*۸*۱	۰/۱۵	۰/۸۱	۹*۵*۱

یکی دیگر از پارامترهای مهم در ساخت شبکه‌ای مناسب برای پیش‌بینی، تعداد نورون‌ها در لایه‌ی میانی است. کم بودن نورون‌های لایه‌ی میانی شبکه سبب عدم شناسایی نگاشت غیرخطی بین ورودی و خروجی می‌شود. زیاد شدن نورون‌های لایه‌ی میانی نیز سبب افزایش پارامترهای تنظیم شونده‌ی شبکه شده و در نتیجه شبکه برای یادگیری نیاز به کمیت‌های ورودی زیادی در مجموعه‌ی آموزشی دارد تا بتواند اوزان خود را تنظیم کند. همچنین سبب افزایش احتمال بیش‌برازشی در شبکه می‌شود (افتخاری و همکاران، ۱۳۹۱). تعیین این مقادیر با استفاده از آزمون و خطا مشخص خواهد شد. به منظور ایجاد شبکه‌ی بهینه، مقیاس داده‌های ورودی و خروجی شبکه به -1 و $+1$ تغییر داده شده است. برای تاثیرگذاری جنس سنگ به هر نوع سنگ کد خاصی نسبت داده شده است که در جدول ۵-۶ نشان داده شده است. برای پیش‌بینی نرخ سایش، شبکه‌ای با تغذیه‌ی پیشرو با یک لایه‌ی ورودی، یک لایه‌ی میانی و یک لایه‌ی خروجی ساخته شده است. تابع انتقال در لایه‌ی میانی تابع تانژانت سیگموئید (Tansig) و تابع انتقال در لایه‌ی خروجی تابع خطی (Purelin) در نظر گرفته شده است. با توجه به سرعت همگرایی الگوریتم لونیگ-مارکوارت در شبکه‌های پیشرو از این الگوریتم برای آموزش شبکه‌ی مورد نظر استفاده شده است. تعداد نورون در لایه‌های میانی با روش سعی و خطا به گونه‌ای انتخاب می‌شود که بهترین جواب ممکن بدست آید.

جدول ۵-۶: کدگذاری هر نوع سنگ

۱	Pmgk
۲	Pmc
۳	Pmq
۴	Pmgqf
۵	Pmga

۵-۴-۱-۱- شبیه‌سازی با شبکه‌های عصبی مصنوعی

با توجه به مطالب مذکور، برای تعیین تعداد نورون‌ها در لایه‌های میانی، شبکه‌های متعددی با تعداد نورون‌های متفاوت در لایه‌ی میانی مورد آموزش و ارزیابی قرار گرفته و بهترین شبکه انتخاب شده است. در

این پژوهش بهترین نتایج با تعداد نورون ۶، ۸، ۹، ۱۰ و ۱۱ عدد در لایه‌ی میانی به‌دست‌آمده است. مقادیر تخمین زده شده برای میزان سایش توسط شبکه در مقابل مقادیر واقعی سایش برای داده‌های آزمون در یک دستگاه مختصات رسم شده و بهترین خط منطبق بر داده‌ها برازش شده است. مقادیر واقعی در محور افقی و مقادیر تخمین زده شده در محور قائم دستگاه مختصات قرار دارند. در صورتی که خروجی شبکه با مقادیر واقعی میزان سایش برابر باشد، تمامی نقاط بر روی خط $y=x$ قرار می‌گیرند. میزان انحراف نقاط نسبت به این خط، بیانگر میزان تفاوت میان خروجی شبکه و مقادیر واقعی است (افتخاری و همکاران، ۱۳۹۱).

برای ارزیابی شبکه‌ها سه باند (جدول ۵-۷) تعریف شده است. ملاک ارزیابی فراوانی نقاط در هر یک از این سه باند است. فراوانی داده‌ها در هر باند نشان می‌دهد که شبکه با چه دقت و احتمالی قادر به پیش‌بینی نرخ سایش است. فراوانی داده‌ها در هر یک از باندهای ذکر شده برای مجموعه‌ی آزمون شبکه‌های ساخته شده با تعداد نورون های ۶، ۸، ۹، ۱۰ و ۱۱ عدد در لایه‌ی میانی در جدول ۵-۸ آورده شده است.


جدول ۵-۷: تعریف باندهای خطا

باند	۱	۲	۳
معادله‌ی خط خطا (c/m)	$y=x \pm 0.25$ ۰،۲۵	$y=x \pm 0.5$ ۰،۵	$y=x \pm 0.75$ ۰،۷۵


مطابق جدول ۵-۸ و با توجه به این که مدل آزمون ۱۷ عضو دارد تعداد نورون مناسب در لایه‌ی میانی ۹ عدد است. با توجه به جدول ۵-۸ احتمال این که خروجی مجموعه‌ی آزمون شبکه‌ی $1 \times 9 \times 9$ با مقدار واقعی میزان سایش کمتر از ۰/۲۵، ۰/۵ و ۰/۷۵ کاتر بر متر تفاوت داشته باشد به ترتیب برابر با ۸۸، ۹۴ و ۱۰۰ درصد است.

جدول ۵-۸: ارزیابی کارایی شبکه با تغییر تعداد نورون‌های لایه میانی

تعداد نورون	۶	۸	۹	۱۰	۱۱
باند ۱	۱۴	۱۳	۱۵	۱۳	۱۴
باند ۲	۱۵	۱۶	۱۶	۱۶	۱۶
باند ۳	۱۷	۱۷	۱۷	۱۷	۱۷
خطای متوسط	۰/۱۹	۰/۲۴	۰/۱۲۲	۰/۲۱	۰/۱۷
میانگین مربعات خطا	۰/۰۵	۰/۰۷	۰/۰۳۰۵	۰/۰۶۵	۰/۰۴
ضریب همبستگی	۰/۸۴	۰/۸۳	۰/۹۳	۰/۸۹	۰/۸۹




ب




الف

شکل ۵-۴: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده میزان سایش: الف) برای مجموعه داده‌های آموزش ب) برای مجموعه داده‌های ارزیابی



ب



الف


شکل ۵-۵: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده میزان سایش: الف) برای مجموعه داده‌های آزمون ب) فراوانی در هر باند

مطابق شکل ۵-۴ الف، شکل ۵-۴ ب و شکل ۵-۵ الف ضریب تعیین بین مقادیر تخمین زده شده

و مقادیر واقعی برای مجموعه‌ی آموزش، ارزیابی و آزمون این شبکه به ترتیب، ۹۳، ۸۷ و ۸۶ درصد به‌دست‌آمده

است. فراوانی داده‌ها در هر یک از سه باند برای مجموعه‌ی آزمون شبکه در شکل ۵-۵-ب نشان داده شده است. خطای متوسط بین این مقادیر ۰/۱۲۲ برآورد شده است.

با استفاده از شبکه‌ی به‌دست آمده به پیش‌بینی نرخ سایش در طول ۹ کیلومتر از مسیر ۶ تا ۱۵ کیلومتری از مسیر تونل انتقال آب اوما اويا پرداخته شده است. بدین منظور بانک اطلاعاتی شامل ۱۵ زوج ورودی و خروجی از داده‌ها ایجاد شده است (مجموعه داده تونل خروجی). همانند روند قبل مقادیر تخمین زده شده میزان سایش توسط شبکه در مقابل مقادیر واقعی میزان سایش برای این مجموعه داده در یک دستگاه مختصات رسم و بهترین خط منطبق بر داده‌ها برازش شده است. ضریب تعیین بین مقادیر پیش‌بینی شده و مقادیر واقعی برای این مجموعه داده توسط شبکه ایجاد شده ۷۶ درصد (شکل ۵-۶) به‌دست آمده است.




شکل ۵-۶: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده میزان سایش برای مجموعه‌ی داده‌های آزمون جدید

۵-۴-۱-۲- آنالیز حساسیت

یکی از اقدامات اساسی پس از مدل‌سازی، تعیین میزان حساسیت هدف مدل‌سازی شده نسبت به پارامترهای ورودی است. به‌منظور تعیین مقدار تأثیر پارامترهای ورودی بر روی هدف، روش‌های متنوعی وجود دارد که در این مطالعه با استفاده از روش وزن‌های اتصال^{۴۰} به بررسی تأثیر پارامترهای ورودی بر روی هدف پرداخته شده است. آنالیز حساسیت به روش وزن‌های اتصالی برای اولین بار توسط گارسون به کار برده شده

^{۴۰} Weight Method

است و توسط گوج تکرار شده است (Garson.,1991; Goh.,1995). برای آنالیز حساسیت به کمک روش وزن-های اتصالی به‌مانند شکل ۵-۷ یک شبکه عصبی با سه ورودی و یک لایه میانی با چهار نورون در این لایه در نظر گرفته شده است (Goh.,1995).



شکل ۵-۷: ساختار شبکه عصبی سه لایه با چهار نورون در لایه میانی

همانطور که در شکل ۵-۷ مشخص است W_{ji} وزن‌های اتصالی بین نورون‌های لایه ورودی و لایه میانی است و W_{kj} وزن‌های اتصالی بین نورون‌های لایه میانی و نورون لایه خروجی است که در جدول ۵-۹ نشان داده شده است.

جدول ۵-۹: وزن‌های اتصالی بین نورون‌های لایه‌های مختلف شبکه عصبی

وزن‌ها				نورون‌های لایه میانی
خروجی	ورودی سوم	ورودی دوم	ورودی اول	
W_{k1}	W_{13}	W_{12}	W_{11}	لایه میانی اول
W_{k2}	W_{23}	W_{22}	W_{21}	لایه میانی دوم
W_{k3}	W_{33}	W_{32}	W_{31}	لایه میانی سوم
W_{k4}	W_{34}	W_{42}	W_{41}	لایه میانی چهارم

روش کار بدین صورت است که در مرحله اول بایستی وزن‌های اتصالی بین نورون‌های لایه ورودی و میانی (W_{ji}) را در وزن‌های اتصالی بین نورون‌های لایه میانی و خروجی (W_{kj}) ضرب شود. در جدول ۵-۱۰ نحوه محاسبه آن نشان داده شده است.

جدول ۵-۱۰: نحوه محاسبه حاصل ضرب وزن‌های W_{ji} در W_{kj}

$P_{ji}=W_{ji} \times W_{kj}$			نورون‌های لایه میانی
ورودی سوم	ورودی دوم	ورودی اول	
$P_{13}=W_{13} \times W_{k1}$	$P_{12}=W_{12} \times W_{k1}$	$P_{11}=W_{11} \times W_{k1}$	لایه میانی اول
$P_{23}=W_{23} \times W_{k2}$	$P_{22}=W_{22} \times W_{k2}$	$P_{21}=W_{21} \times W_{k2}$	لایه میانی دوم
$P_{33}=W_{33} \times W_{k3}$	$P_{32}=W_{32} \times W_{k3}$	$P_{31}=W_{31} \times W_{k3}$	لایه میانی سوم
$P_{43}=W_{43} \times W_{k4}$	$P_{42}=W_{42} \times W_{k4}$	$P_{41}=W_{41} \times W_{k4}$	لایه میانی چهارم

در مرحله دوم هر کدام از متغیرهای p بدست آمده بر مجموع متغیرهای p هر ورودی به مانند رابطه‌ی ۵-۱ تقسیم می‌شود و شاخص Q_{ij} محاسبه می‌شود. در جدول ۵-۱۱ نحوه محاسبه شاخص Q_{ij} نشان داده شده است.

$$Q_{ij} = \frac{P_{ij}}{\sum_{j=1}^3 P_{ij}} \quad (۵-۱)$$

جدول ۵-۱۱: نحوه محاسبه شاخص Q

$P_{ji}=W_{ji} \times W_{kj}$			نورون‌های لایه میانی
ورودی سوم	ورودی دوم	ورودی اول	
$Q_{13}=P_{13}/(P_{11}+P_{12}+P_{13})$	$Q_{12}=P_{12}/(P_{11}+P_{12}+P_{13})$	$Q_{11}=P_{11}/(P_{11}+P_{12}+P_{13})$	لایه میانی اول
$Q_{23}=P_{23}/(P_{21}+P_{22}+P_{23})$	$Q_{22}=P_{22}/(P_{21}+P_{22}+P_{23})$	$Q_{21}=P_{21}/(P_{21}+P_{22}+P_{23})$	لایه میانی دوم
$Q_{33}=P_{33}/(P_{31}+P_{32}+P_{33})$	$Q_{32}=P_{32}/(P_{31}+P_{32}+P_{33})$	$Q_{31}=P_{31}/(P_{31}+P_{32}+P_{33})$	لایه میانی سوم
$Q_{43}=P_{43}/(P_{41}+P_{42}+P_{43})$	$Q_{42}=P_{42}/(P_{41}+P_{42}+P_{43})$	$Q_{41}=P_{41}/(P_{41}+P_{42}+P_{43})$	لایه میانی چهارم

در نهایت با جمع کردن شاخص Q برای هر ورودی میزان تاثیرگذاری پارامتر ورودی بر هدف مشخص خواهد شد (رابطه‌ی ۵-۲). میزان درصد تاثیرگذاری هر پارامتر ورودی مطابق رابطه‌ی ۵-۳ محاسبه می‌شود.


$$S_j = \sum_{i=1}^4 Q_{ij} \quad (2-5)$$

$$\frac{S_j \times 100}{\sum S_j} \quad (3-5)$$

با توجه به مطالب بیان شده نتایج به دست آمده برای آنالیز حساسیت مدل شبکه عصبی ایجاد شده به روش وزن‌های اتصالی در جدول ۱۲-۵ و شکل ۸-۵ نشان داده شده است.

جدول ۱۲-۵: آنالیز حساسیت داده‌های ورودی بر تابع هدف

Rock	UCS	CAI	RMR	RQD	RPM	Th	ROP	Q	پارامترهای ورودی
۱۳/۶۴۵	۱۲/۶۰۸	۱۰/۱۱۷	۶/۰۰۷	۱۲/۷۵	۱۴/۹۰۳	۷/۵۳۰۲	۱۲/۹۱۹	۹/۵۲۰۹	درصد تاثیرگذاری



شکل ۸-۵: نتایج آنالیز حساسیت داده‌های ورودی بر تابع هدف

جدول ۱۲-۵ و شکل ۸-۵ نشان‌دهنده آن است که سرعت چرخش کله حفار و جنس سنگ بیشترین


تأثیر را در بین پارامترهای ورودی بر میزان سایش دیسک کاتر دارد و پارامتر شاخص رده‌بندی توده سنگ تأثیر کمتری نسبت به پارامترهای دیگر دارد.

۵-۵- مقایسه‌ی بین مدل شبکه عصبی با سایر مدل‌های سایش


برای انجام این کار نتایج حاصله از نرخ سایش برای مدل‌های CSM، NTNU، Gehering و مدل شبکه عصبی در جدول ۵-۱۳ آمده است و نتایج حاصل با نرخ سایش واقعی مورد بررسی قرار گرفته و در شکل ۵-۹ نشان داده شده است، همچنین میانگین اختلاف مقادیر پیش‌بینی شده نرخ سایش با مقادیر واقعی نرخ سایش، برای مدل‌های مختلف در شکل ۵-۱۰ ترسیم شده است. با توجه به نتایج می‌توان دریافت که مدل شبکه عصبی به دلیل اختلاف کمتر بین مقادیر پیش‌بینی با نرخ سایش واقعی عملکرد بهتری را نسبت به سایر مدل‌ها دارد.

جدول ۵-۱۳: نتایج حاصل برای نرخ سایش با استفاده از مدل‌های مختلف

مقدار واقعی	H_f (ANN)	H_f (CSM)	H_f (NTNU)	H_f (Gehering)
۲۶۵	۲۲۵/۴۲۳۶۹	۷۴/۹۹۲۲۵۲۲	۱۸۳/۶۷۰۳۶۶۸	۶۰/۹۰۲۵۱۱۴۹
۴۵۰	۴۴۸/۵۱۷۱۳	۱۲۸/۰۳۵۵۵۲	۹۲/۵۵۰۷۰۱۴۱	۱۹۸/۱۱۰۴۰۳۱
۲۸۰	۲۵۴/۶۲۰۸	۷۱/۳۳۴۰۹۳۵	۱۲۱/۳۲۶۹۶۹۹	۵۷/۹۳۱۶۵۷۲۷
۱۹۵	۱۸۶/۰۳۸۸۱	۲۷/۴۳۶۱۸۹۸	۳۳/۵۹۸۲۳۷۸۲	۲۲/۲۸۱۴۰۶۶۴
۳۱۵	۴۰۲/۸۸۳۲۸	۱۳۲/۱۰۰۱۷۳	۱۹۱/۰۶۶۰۹۴۴	۱۱۸/۳۲۵۰۳۹۸
۲۴۶	۲۱۸/۹۴۸۷۸	۲۵۹/۱۱۹۵۷	۱۴۲/۴۱۷۷۲۷۳	۳۳۸/۴۰۶۲۳۶۶
۳۲۵	۳۹۰/۵۷۸۶۲	۱۰۱/۹۰۵۸۴۸	۱۰۰/۳۰۹۶۹۹۵	۱۱۵/۳۱۲۵۹۲۳
۲۶۵	۲۳۴/۶۲۹۶۶	۸۴/۸۰۲۷۶۸۵	۲۴۶/۴۵۷۶۲۴۹	۶۳/۰۲۸۰۱۶۴۱
۴۸۰	۴۸۰/۵۸۸۱۴	۲۳۷/۷۸۰۳۱۲	۱۷۳/۲۳۳۲۵۸۹	۳۶۷/۹۱۹۳۲۰۱
۳۱۰	۲۷۲/۰۴۹۸۹	۱۶۷/۲۳۰۱۰۹	۱۶۴/۶۱۰۷۸۹	۱۸۹/۲۳۰۹۲۰۷
۵۱۰	۴۷۴/۴۱۱۵۳	۳۰۴/۸۴۶۵۵۳	۲۹۷/۸۶۷۱۴۲	۳۹۸/۱۲۴۹۸۴۲
۳۴۵	۴۶۲/۶۵۶۸۲	۲۵۶/۰۷۱۱۰۵	۱۸۶/۵۵۸۸۹۴۲	۳۹۶/۲۲۰۸۰۶۲
۳۱۵	۲۶۳/۱۶۹۷۹	۱۲۴/۳۷۷۳۹۴	۲۱۱/۵۴۴۴۶۰۴	۱۰۱/۰۹۰۴۳۴
۳۱۵	۳۴۶/۸۵۵۹۶	۱۳۹/۴۶۷۲۹۸	۱۴۴/۶۴۱۹۳۲۶	۱۳۹/۳۸۵۴۷۰۶
۳۴۶	۳۷۵/۲۰۵۶۱	۱۳۴/۸۹۴۶	۱۵۸/۹۷۶۷۸۸۸	۱۳۴/۸۱۵۴۵۵۲



شکل ۵-۹: مقایسه مدل‌های بررسی نرخ سایش



شکل ۵-۱۰: میانگین اختلاف مقادیر پیش‌بینی شده نرخ سایش با مقادیر واقعی نرخ سایش

با توجه به نتایج به دست آمده برای مدل‌های مختلف نرخ سایش ابزار مدل شبکه عصبی به علت میانگین خطای کمتر و ضریب تعیین بالاتر مدل مناسب‌تری برای پیش‌بینی نرخ سایش است.

۵-۶- توسعه مدل شبکه عصبی برای استفاده در شرایط لیتولوژی متفاوت

برای انجام این منظور از داده‌های تونل انتقال آب کرج، زاگرس - ارومیه و تونل ورودی تونل انتقال آب اوما اوپا برای آموزش شبکه استفاده شده است. شبکه‌ی جدید با ساختار جدید به وجود آمده است که دارای ورودی‌های زیر است:

(۱) مقاومت فشاری تک‌محوری (مگاپاسکال)

(۲) اندیس سایش سرشار (CAI)

(۳) RQD برای توصیف تعداد درزه‌ها در سنگ

(۴) RMR بیانگر شرایط توده سنگ


(۵) نیروی محوری پیشران یا تراست (کیلونیوتن)

(۶) گشتاور (کیلونیوتن متر)


(۷) سرعت چرخش کله حفار (دور بر دقیقه)

(۸) نرخ نفوذ (میلی‌متر بر دور)

با روش آزمون و خطا بهترین نتیجه برای شبکه‌ی عصبی با دو لایه میانی، هفت نورون برای لایه میانی دوم و ۹ نورون برای لایه میانی اول به دست آمده است ($1*7*9*8$). ضریب تعیین بین مقادیر تخمین زده شده و مقادیر واقعی برای مجموعه‌ی آموزش، ارزیابی و آزمون این شبکه به ترتیب، ۹۰، ۸۶ و ۸۱ درصد به دست آمده و به ترتیب در شکل ۵-۱۱-الف، شکل ۵-۱۱-ب و شکل ۵-۱۲ آورده شده است.




ب



الف


شکل ۵-۱۱: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده نرخ سایش: الف) برای مجموعه داده‌های آموزش ب) برای مجموعه داده‌های ارزیابی



شکل ۵-۱۲: نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده میزان سایش برای مجموعه‌ی داده‌های آزمون

۵-۶-۱- آنالیز حساسیت

یکی از اقدامات اساسی پس از مدل‌سازی، تعیین میزان حساسیت هدف مدل‌سازی شده نسبت به پارامترهای ورودی است. در این بخش با استفاده از روش مشتقات جزئی به بیان این امر پرداخته شده است. برای یک شبکه پرسپترون چهار لایه فرضی که در شکل ۵-۱۳ نشان داده شده است می‌توان روابط آنالیز حساسیت را به دست آورد.



شکل ۵-۱۳: یک شبکه پرسپترون چند لایه فرضی

در این شبکه، برای یک نورون در لایه ورودی که پردازشی روی آن صورت نمی‌گیرد خروجی این نورون به صورت رابطه‌ی ۴-۵ است.

$$N_i = X_i \quad (۴-۵)$$

که در این رابطه i زیرنویس نورون در لایه ورودی، X متغیر ورودی به شبکه و N سیگنال خروجی از نورون است. نورونی که در لایه میانی اول باشد سیگنال ورودی را به فرم رابطه‌ی ۵-۶ پردازش می‌کند.

$$S_h = N_p \times W_{hp} + \sum_{i \neq p}^n N_i \times W_{hi} \quad (۵-۵)$$

$$N_h = Q_h(S_h) \quad (۶-۵)$$

که در این روابط S سیگنال ورودی به نورون، زیرنویس p یک ورودی مستقل را نشان می‌دهد که حساسیت آن به دست می‌آید، W_{hi} وزن اتصال بین نورون i و نورون h در لایه میانی اول، زیرنویس h برای یک نورون در لایه میانی اول و Q نشان دهنده تابع انتقال است. نورونی که در لایه میانی دوم باشد سیگنال ورودی را به فرم رابطه‌ی ۷-۵ پردازش می‌کند.

$$S_d = N_h \times W_{dh} + \sum_{j \neq h}^m N_j \times W_{dj} \quad (۷-۵)$$

$$N_d = Q_d(S_d) \quad (۸-۵)$$

که در این روابط S سیگنال ورودی به نورون، W_{dh} وزن اتصال بین نورون h و نورون d در لایه میانی دوم، زیرنویس d برای یک نورون در لایه میانی دوم، زیرنویس نورون در لایه میانی اول است. سیگنال خروجی از نورون d در لایه میانی دوم نیز به صورت رابطه‌ی ۹-۵ و ۱۰-۵ به نورون لایه خروجی تغذیه می‌شود.

$$S_o = N_d \times W_{od} + \sum_{k \neq d}^m N_k \times W_{ok} \quad (۹-۵)$$

$$N_o = Q_o(S_o) \quad (۱۰-۵)$$

که در این روابط k نشان‌دهنده یک نورون در لایه میانی دوم و زیرنویس o مبین نورون در لایه خروجی است. در نتیجه تعیین مشتق مرتبه اول خروجی نسبت به متغیر ورودی X_p به صورت روابط زیر بیان می‌شود.

$$\frac{\partial S_h}{\partial N_p} = W_{hp} \quad (۱۱-۵)$$

$$\frac{\partial S_d}{\partial N_h} = W_{dh} \quad (۱۲-۵)$$

$$\frac{\partial S_o}{\partial N_d} = W_{od} \quad (۱۳-۵)$$

$$\frac{\partial N_o}{\partial N_p} = \frac{\partial N_o}{\partial S_o} \times \frac{\partial S_o}{\partial N_d} \times \frac{\partial N_d}{\partial N_h} \times \frac{\partial N_h}{\partial N_p} = \left(\frac{dN_o}{dS_o} \times \frac{\partial S_o}{\partial N_d} \right) \times \left(\frac{dN_d}{dS_d} \times \frac{\partial S_d}{\partial N_h} \right) \times \left(\frac{dN_h}{dS_h} \times \frac{\partial S_h}{\partial N_p} \right) \quad (۱۴-۵)$$

از طرفی از روابط ۶-۵، ۸-۵ و ۱۰-۵ روابط ۱۵-۵، ۱۶-۵ و ۱۷-۵ حاصل شده است. در نتیجه رابطه‌ی ۵-۱۴ به فرم رابطه‌ی ۱۸-۵ بازنویسی می‌شود.

$$\frac{dN_o}{dS_o} = Q'_o(S_o) \quad (۱۵-۵)$$

$$\frac{dN_d}{dS_d} = Q'_d(S_d) \quad (۱۶-۵)$$

$$\frac{dN_h}{dS_h} = Q'_h(S_h) \quad (۱۷-۵)$$

$$\frac{\partial N_o}{\partial N_p} = (Q'_o(S_o) \times W_{od}) \times (Q'_d(S_d)W_{dh}) \times (Q'_h(S_h) \times W_{hp}) \quad (18-5)$$

رابطه‌ی نهایی حساسیت خروجی با توجه به اینکه در لایه‌های میانی بیش از یک نورون وجود دارد به صورت رابطه‌ی ۱۹-۵ نوشته می‌شود.

$$\frac{\partial N_o}{\partial N_p} = \sum_{d=1}^m \sum_{h=1}^n (Q'_o(S_o) \times W_{od}) \times (Q'_d(S_d) \times W_{dh}) \times (Q'_h(S_h) \times W_{hp}) \quad (19-5)$$

که در این رابطه تعداد نورون در لایه میانی اول با n و تعداد نورون در لایه میانی دوم با m نشان داده می‌شود. در این مطالعه تابع تانژانت سیگموئید برای لایه‌های میانی و تابع خطی برای لایه خروجی به عنوان توابع انتقال در نظر گرفته شده است که مشتق این توابع به ترتیب در رابطه‌ی ۲۰-۵ و ۲۱-۵ نشان داده شده است.

$$Q'_h(S_h) = (1 - Q_h^2(S_h)) = 1 - N_h^2 \quad (20-5)$$

$$Q'_o(S_o) = 1 \quad (21-5)$$

با جایگذاری روابط ۲۰-۵ و ۲۱-۵ در رابطه‌ی ۱۹-۵ رابطه‌ی نهایی حساسیت برای شبکه عصبی به صورت رابطه‌ی ۲۲-۵ به دست می‌آید.

$$\frac{\partial N_o}{\partial N_p} = \sum_{d=1}^m \sum_{h=1}^n (1 - N_d^2) \times (1 - N_h^2) \times W_{dh} \times W_{hp} \times W_{od} \quad (22-5)$$


در نهایت اهمیت نسبی هر متغیر ورودی نسبت به خروجی شبکه در روش PAD با شاخص مجموع مربع مشتقات به صورت رابطه‌ی ۲۳-۵ محاسبه می‌شود.

$$SSD_p = \sum_{R=1}^{NO} \left(\frac{\partial N_o}{\partial N_p} \right)^2 \quad (23-5)$$

که در این رابطه R شمارنده داده‌های مشاهداتی روی دامنه متغیر ورودی P با NO رکورد ثبت شده است. $\left(\frac{\partial N_o}{\partial N_p}\right)$ محاسبه شده برای هر متغیر در صورت مثبت بودن نشان دهنده رابطه مستقیم و یک مقدار منفی نشان دهنده رابطه معکوس متغیر مورد نظر با خروجی است. شاخص SSD نشان دهنده اهمیت نسبی متغیرهای ورودی شبکه است و جهت تاثیر را مشخص نمی‌کند. هر اندازه مقدار این شاخص بیشتر باشد نشان دهنده اهمیت بیشتر متغیر ورودی در خروجی هدف است. در این تحقیق محاسبات لازم برای آنالیز حساسیت مدل شبکه عصبی ایجاد شده به روش PaD انجام شده و نتایج در جدول ۵-۱۴ و شکل ۵-۱۴ نشان داده شده است (Nourani & Fard.,2012;Gevrey et al.,2003).

جدول ۵-۱۴: آنالیز حساسیت داده‌های ورودی بر تابع هدف

UCS	CAI	RMR	RQD	RPM	Th	ROP	Q	پارامترهای ورودی
۵/۷۸۷۵	۷/۳۳۳	۱۹/۱۲۷	۱۶/۳۰۸	۱۱/۰۲۸	۸/۱۲۴۶	۱۷/۲۳۳	۱۵/۰۶	درصد تاثیرگذاری



شکل ۵-۱۴: نتایج آنالیز حساسیت داده‌های ورودی بر تابع هدف

نتایج به دست آمده نشان دهنده آن است که پارامتر رده‌بندی توده سنگ (RMR) و پارامتر مقاومت فشاری تک‌محوره (UCS) به ترتیب دارای بیشترین و کمترین تأثیر در خروجی مدل شبکه عصبی است.

۵-۶-۲- اعتبارسنجی مدل ایجاد شده


برای اعتبارسنجی مدل ایجاد شده از داده‌های تونل انتقال آب کرمان و داده‌های تونل خروجی تونل انتقال آب اوما اوپا که در ساخت شبکه عصبی نقشی نداشته است استفاده شده است. خروجی مدل شبکه عصبی را برای این داده‌ها به دست آورده و با سایر مدل‌ها مقایسه شده است که در ادامه به توضیح آن پرداخته شده است.

۵-۶-۲-۱- مقایسه‌ی بین مدل شبکه عصبی با سایر مدل‌های سایش در تونل انتقال آب اوما اوپا


با استفاده از مدل شبکه‌ی عصبی به دست آمده به پیش‌بینی نرخ سایش در طول تونل خروجی تونل انتقال آب اوما اوپا پرداخته شده است. بدین منظور بانک اطلاعاتی شامل ۱۵ زوج ورودی و خروجی از داده‌ها ایجاد شده است. نتایج حاصله از نرخ سایش برای مدل‌های CSM، NTNU، Gehering و مدل شبکه عصبی در جدول ۵-۱۵ آمده است و نتایج حاصل با نرخ سایش واقعی مورد بررسی قرار گرفته و در شکل ۵-۱۵ نشان داده شده است. همچنین میانگین اختلاف مقادیر پیش‌بینی شده نرخ سایش با مقادیر واقعی نرخ سایش برای مدل‌های مختلف در شکل ۵-۱۶ ترسیم شده است با توجه به نتایج می‌توان دریافت که مدل شبکه عصبی به دلیل اختلاف کمتر بین مقادیر پیش‌بینی با نرخ سایش واقعی عملکرد بهتری را نسبت به سایر مدل‌ها دارد. ضریب تعیین ۶۷ درصد و متوسط خطا در حدود ۵۶ مترمکعب به ازای هر دیسک کاتر در مدل شبکه عصبی است که نسبت به سایر مدل‌ها وضعیت بهتری را دارا است.

جدول ۵-۱۵: نتایج حاصل برای نرخ سایش با استفاده از مدل‌های مختلف

مقدار واقعی	$H_f(ANN)$	$H_f(CSM)$	$H_f(NTNU)$	$H_f(gehering)$
۲۶۵	۳۷۲/۹۶۲۸۶	۷۴/۹۹۲۲۵۲۲	۱۸۳/۶۷۰۳۶۶۸	۶۰/۹۰۲۵۱۱۴۹
۴۵۰	۵۶۰/۱۶۴۹۹	۱۲۸/۰۳۵۵۵۲	۹۲/۵۵۰۷۰۱۴۱	۱۹۸/۱۱۰۴۰۳۱
۲۸۰	۲۲۵/۷۳۵۸۱	۷۱/۳۳۴۰۹۳۵	۱۲۱/۳۲۶۹۶۹۹	۵۷/۹۳۱۶۵۷۲۷
۱۹۵	۱۷۳/۱۲۹۹۲	۲۷/۴۳۶۱۸۹۸	۳۳/۵۹۸۲۳۷۸۲	۲۲/۲۸۱۴۰۶۶۴
۳۱۵	۳۰۳/۴۳۴۴۶	۱۳۲/۱۰۰۱۷۳	۱۹۱/۰۶۶۰۹۴۴	۱۱۸/۳۲۵۰۳۹۸
۲۴۶	۲۰۲/۰۲۸۲۴	۲۵۹/۱۱۹۵۷	۱۴۲/۴۱۷۷۲۷۳	۳۳۸/۴۰۶۲۳۶۶
۳۲۵	۳۶۶/۷۸۹۹۵	۱۰۱/۹۰۵۸۴۸	۱۰۰/۳۰۹۶۹۹۵	۱۱۵/۳۱۲۵۹۲۳
۲۶۵	۲۸۱/۵۴۳۹۸	۸۴/۸۰۲۷۶۸۵	۲۴۶/۴۵۷۶۲۴۹	۶۳/۰۲۸۰۱۶۴۱
۴۸۰	۵۰۲/۲۶۱۶	۲۳۷/۷۸۰۳۱۲	۱۷۳/۲۳۳۲۵۸۹	۳۶۷/۹۱۹۳۲۰۱
۳۱۰	۳۹۴/۴۲۲۵۷	۱۶۷/۲۳۰۱۰۹	۱۶۴/۶۱۰۷۸۹	۱۸۹/۲۳۰۹۲۰۷
۵۱۰	۴۶۸/۸۶۹۹	۳۰۴/۸۴۶۵۵۳	۲۹۷/۸۶۷۱۴۲	۳۹۸/۱۲۴۹۸۴۲
۳۴۵	۴۹۰/۸۵۷۵۷	۲۵۶/۰۷۱۱۰۵	۱۸۶/۵۵۸۸۹۴۲	۳۹۶/۲۲۰۸۰۶۲
۳۱۵	۲۳۰/۱۶۶۹۱	۱۲۴/۳۷۷۳۹۴	۲۱۱/۵۴۴۴۶۰۴	۱۰۱/۰۰۹۰۴۳۴
۳۱۵	۲۷۵/۳۷۷۴	۱۳۹/۴۶۷۲۹۸	۱۴۴/۶۴۱۹۳۲۶	۱۳۹/۳۸۵۴۷۰۶
۳۴۶	۳۶۹/۳۸۷۷۷	۱۳۴/۸۹۴۶	۱۵۸/۹۷۶۷۸۸۸	۱۳۴/۸۱۵۴۵۵۲



شکل ۵-۱۵: مقایسه مدل‌های بررسی نرخ سایش



شکل ۵-۱۶: میانگین اختلاف مقادیر پیش‌بینی شده نرخ سایش با مقادیر واقعی نرخ سایش

۵-۲-۲-۶-۵- مقایسه‌ی بین مدل شبکه عصبی با سایر مدل‌های سایش در تونل انتقال آب کرمان

تونل انتقال آب کرمان به طول ۳۶ کیلومتر در محیط سنگ سخت به‌وسیله ماشین حفاری تمام مقطع حفاری شده است. ۱۴ کیلومتر از طول مسیر تونل از طرف جنوبی حفاری شده است. قطر تونل ۴/۶۶۵ متر است. در طول حفاری تونل داده‌های مربوط به پارامترهای عملیاتی ماشین ثبت شده است و یک پایگاه داده شامل داده‌های ماشین و پارامترهای ژئوتکنیکی مسیر تونل برای انجام تحلیل‌ها فراهم شده است (جدول ۵-۱۶). میزان سایش دیسک‌کاتر برای هر زون زمین‌شناسی نیز محاسبه شده و در جدول ۵-۱۶ نشان داده شده است (Karami et al., 2021).


جدول ۵-۱۶: مشخصات واحدهای زمین‌شناسی موجود در طول تونل و پارامترهای عملیاتی ماشین حفار

UCS	CAI	RMR	RQD	RPM	Th	ROP	Q	H _f (m ³ /c)
۱۶۰	۴	۴۳	۳۰	۶/۲	۱۸۵	۸/۶	۶۷۵	۱۳۶۷
۱۳۰	۳/۵	۳۷	۲۵	۶/۸	۲۲۰	۸/۶	۷۰۸	۱۱۳۹
۱۸۰	۴/۵	۳۵	۲۳	۷	۱۲۵	۸/۷	۷۶۳	۱۷۴۳
۹۰	۱/۸	۵۰	۴۳	۷	۲۵۹	۹/۳	۷۱۹	۱۹۱۹
۱۸۰	۳/۷	۶۴	۶۰	۷	۱۲۵	۹/۶	۷۵۷	۸۵۴


نتایج حاصله از نرخ سایش برای مدل‌های CSM، NTNU، Gehering و مدل شبکه عصبی در جدول ۱۷-۵ آمده است و نتایج حاصل با نرخ سایش واقعی مورد بررسی قرار گرفته و در شکل ۵-۱۷ نشان داده شده است، همچنین میانگین اختلاف مقادیر پیش‌بینی شده نرخ سایش با مقادیر واقعی نرخ سایش، برای مدل‌های مختلف در شکل ۵-۱۸ ترسیم شده است. با توجه به نتایج می‌توان دریافت که مدل شبکه عصبی نسبت به دو مدل CSM و NTNU به دلیل ضریب همبستگی و میزان خطای متوسط کمتر، عملکرد بهتری را دارا است، اما خطای متوسط به دست آمده توسط مدل شبکه عصبی نسبت به مدل گیرینگ کمی بالاتر بوده است. یکی از علت‌های این امر می‌تواند به داده‌های مربوط به تربیت شبکه عصبی بازگردد. عمده داده‌های بخش تربیت شبکه عصبی طبق طبقه‌بندی ساینده‌گی ارائه شده توسط آقای حسن‌پور در کلاس‌های ساینده‌گی متوسط تا زیاد قرار گرفته‌اند ($H_f=500-1000$)، سهم بیش از ۸۰ درصدی داده‌ها مربوط به ساینده‌گی‌های زیاد ($500-$ $H_f=100$) است و سهم بسیار کمی از داده‌ها با ساینده‌گی کم در تربیت شبکه عصبی نقش داشته است در حالی که اکثر داده‌های تونل انتقال آب کرمان در کلاس ساینده‌گی کم قرار گرفته‌اند ($H_f=1000-2000$). اما با توجه به ضریب تعیین بالای مدل شبکه عصبی، توانایی این مدل در پیش‌بینی نرخ سایش با استفاده از رابطه‌ی همبستگی به دست آمده را می‌توان مناسب ارزیابی کرد. ضریب تعیین ۷۴ درصد و متوسط خطا در حدود ۱۰۵۲ مترمکعب به ازای هر دیسک‌کاتر در مدل شبکه عصبی است.

جدول ۵-۱۷: نتایج حاصل برای نرخ سایش با استفاده از مدل‌های مختلف

مقدار واقعی	Hf(ANN)	Hf(CSM)	Hf(NTNU)	Hf(gehering)
۱۳۶۷	۳۶۷/۲۹۷۴۸۴۵	۲۲۶	۲۳۰	۲۲۰
۱۱۳۹	۲۶۹/۹۲۲۲۶۰۶	۲۴۸	۲۴۵	۲۷۵
۱۷۴۳	۳۳۷/۰۳۲۹۳۵۱	۲۰۷	۲۰۵	۲۱۰
۱۹۱۹	۵۵۸/۴۳۹۷۴۴۸	۴۰۰	۴۰۰	۱۱۲۵
۸۵۴	۲۲۶/۱۹۴۴۱۳۹	۲۶۳	۲۶۳	۲۶۳




شکل ۵-۱۷: مقایسه مدل‌های بررسی نرخ سایش در تونل انتقال آب کرمان



شکل ۵-۱۸: میانگین اختلاف مقادیر پیش‌بینی شده نرخ سایش با مقادیر واقعی نرخ سایش در تونل انتقال آب کرمان

۷-۴- ساختار شبکه عصبی ۱*۷*۹*۸

برای پیش‌بینی نرخ سایش، شبکه‌ای با تغذیه‌ی پیشرو با یک لایه‌ی ورودی، دو لایه‌ی میانی و یک لایه‌ی خروجی ساخته شده است. تابع انتقال در لایه‌ی میانی تابع تانژانت سیگموئید (Tansig) و تابع انتقال در لایه‌ی خروجی تابع خطی (Purelin) در نظر گرفته شده است. با توجه به سرعت همگرایی الگوریتم لوببرگ - مارکوارت در شبکه‌های پیشرو از این الگوریتم برای آموزش شبکه‌ی موردنظر استفاده شده است. در شکل ۱۹-۵ شکل کلی از ساختار این مجموعه شبکه عصبی نشان داده شده است.



شکل ۱۹-۵: نمای کلی از ساختار شبکه عصبی

ماتریس ضرایب شبکه عصبی در شکل ۵-۲۰ نشان داده شده است.

وزن های اتصالی بین نورون های لایه ورودی و میانی اول (IW)							
-۰/۷۷۰۲۴۵	۰/۷۱۱۸۵۳۹	۰/۹۴۴۱۶۷۱	۰/۱۷۰۴۱۰۹	۱/۲۴۴۰۵۹۴	-۰/۲۴۲۹۸۴	۰/۱۵۹۴۰۵۱	۱/۵۹۹۹۹۷۷
۱/۳۴۴۸۴۱۶	۱/۰۱۴۷۷۳۵	-۰/۴۲۹۱۵۸	-۰/۹۴۹۳۷۴	-۰/۹۶۵۱۷	۰/۰۰۸۱۵۴۳	۰/۵۱۴۷۷۳	۰/۸۲۰۹۹۲۷
۰/۵۵۱۳۰۷۲	-۰/۷۸۲۵۱۱	-۱/۱۷۴۸۰۵	-۰/۵۴۶۸۸۹	-۱/۱۵۱۸۲۵	۱/۷۶۸۲۶۷۲	-۱/۹۵۳۰۵۳	-۰/۷۴۹۰۱۵
۲/۸۹۳۱۱۴۶	۱/۳۵۱۰۱۰۳	۰/۱۱۲۸۳۹۶	-۰/۷۶۰۰۳۲	۰/۱۹۶۹۳۸۸	۰/۵۶۹۸۰۳۴	-۰/۰۸۸۲۸۶	۰/۵۶۹۱۰۵
۰/۳۸۷۸۰۸۷	۰/۴۱۳۰۵۵۶	۱/۰۱۳۷۵۳۶	۱/۵۹۴۸۱۱۹	۰/۹۰۸۳۸۹۵	۰/۳۳۵۱۹۲۶	۱/۱۹۱۸۹۸۹	۱/۲۵۹۶۱۰۳
۱/۲۷۹۲۲۴	-۰/۵۰۲۵۸۲	۱/۳۰۲۳۱۶۲	-۰/۲۲۶۹۳۲	-۰/۱۱۶۹۳۸	-۱/۰۹۲۱۹۳	-۰/۲۸۳۴۷۵	۱/۱۴۱۶۴
-۰/۲۶۰۰۲۶	۰/۷۶۱۳۲۴۷	۱/۲۸۶۳۱۹۶	-۱/۹۰۵۴۳۲	-۰/۲۹۷۰۷۳	۰/۲۰۲۳۶۴	۰/۰۹۱۱۱۶۱	۰/۳۳۰۰۴۵۸
-۰/۲۴۷۰۸	۱/۲۹۵۵۹۴۷	۱/۰۹۹۵۳۲۳	-۱/۳۴۰۷۲۵	۰/۲۶۶۳۶۲۱	۰/۵۸۲۹۶۲۷	-۱/۲۰۴۸۶۷	-۱/۶۰۸۷۰۲
۰/۹۳۱۳۷۴۳	-۰/۷۹۳۴۷۲	۰/۳۹۲۴۴۷۲	۰/۳۲۶۱۵۲۸	-۰/۷۹۷۹۴۳	۱/۰۶۳۴۱۵۸	۰/۲۶۷۸۱۵۹	-۰/۴۲۱۲۹۲

وزن‌های اتصالی بین نورون‌های لایه میانی اول و دوم (LW_1)								
-۰/۱۵۲۹۱۳	-۰/۴۶۸۳۳۴	-۰/۹۹۳۶۸	۰/۱۹۰۱۸۸	۰/۲۵۹۲۵۷۷	۰/۹۴۱۴۴۲۶	-۰/۹۳۲۹۴۷	۱/۰۲۷۱۶۵۷	-۰/۳۶۷۲۹۱
-۰/۱۹۷۳۱۸	۰/۱۱۲۲۸۶۱	۰/۹۵۹۱۶۲۷	۱/۰۷۶۶۸۶۸	-۰/۳۷۰۵۹۷	-۱/۰۴۱۱۷۶	۰/۳۳۸۹۸۸۵	۱/۰۴۱۷۷۱۳	۰/۴۷۶۵۲۱۷
۱/۰۹۹۱۹۴۴	-۰/۱۵۲۷۵۷	۰/۴۹۲۴۴۳۳	۰/۸۱۴۸۶۷۴	-۱/۱۲۰۸۰۱	۰/۱۳۶۲۶۰۲	۱/۱۳۸۳۹۴۵	۰/۷۶۸۲۳۹۹	۰/۶۵۵۳۲۲۷
۱/۴۲۹۷۱۳۷	۰/۳۵۰۸۸۳۷	-۰/۷۳۹۷۷۴	۰/۱۰۳۳۰۶۷	۰/۷۳۸۰۰۳۲	۰/۵۹۶۹۳۵۳	۰/۰۲۷۲۸۱۷	-۰/۲۲۴۷۳۳	-۰/۹۶۷۶۹۴
-۰/۸۲۶۷۶۹	۱/۲۰۸۰۶۴۸	-۰/۸۵۹۵۰۶	-۰/۱۵۷۰۳۴	-۰/۵۴۴۲۷۷	-۰/۱۱۱۹۹۹	۰/۲۱۲۷۹۱۸	۰/۸۲۸۵۳۱۳	۰/۲۷۸۷۷۲
-۰/۱۸۶۶۷	-۰/۵۶۸۶۸۶	۰/۲۵۷۲۹۲۶	۰/۹۴۸۲۴۴۸	۰/۹۵۷۱۳۳۶	-۱/۱۳۹۰۲۲	۰/۶۱۸۲۹۴۶	-۰/۲۵۳۹۳۳	-۰/۵۱۹۲۳
-۰/۸۲۶۰۶۳	-۰/۱۸۲۶۳۳	۱/۱۱۳۰۶۹۷	-۱/۰۷۹۸۵۳	-۰/۲۶۱۸۳۵	-۰/۴۷۷۴۳۵	-۰/۸۷۸۲۴۶	-۰/۸۱۵۳۴	۰/۷۱۶۰۳۶

وزن‌های اتصالی بین نورون‌های لایه میانی دوم و لایه خروجی (LW_2)						
۰/۱۶۱۸۰۸	۰/۰۹۱۴۳۲۳	۰/۶۲۵۶۸۴۳	۰/۱۸۰۶۸۶۳	-۰/۸۷۵۴۴۳	-۰/۲۱۵۹۵	-۰/۲۲۸۵۴۲

شکل ۵-۲۰: ماتریس ضرایب شبکه عصبی

رابطه‌ی ریاضی نحوه رسیدن به نرخ سایش در رابطه‌ی ۵-۲۴، ۵-۲۵ و ۵-۲۶ نشان داده شده است. که در این رابطه منظور از X و روی‌های شبکه است که در شکل ۵-۲۱ نحوه به کارگیری آن نشان داده شده است.

$$YN_1 = \text{TANH}(IW \times X + b1) \longrightarrow \text{خروجی نورون‌های لایه میانی اول} \quad (۲۴-۵)$$

$$YN_2 = \text{TANH}(LW_1 \times YN_1 + b2) \longrightarrow \text{خروجی نورون‌های لایه میانی دوم} \quad (۲۵-۵)$$

$$Y_{\text{output}} = \text{PURLIN}(LW_2 \times YN_2 + b3) \longrightarrow \text{خروجی نهایی} \quad (۲۶-۵)$$

X
UCS
CAI
RMR
RQD
RPM
Th
ROP
Q

شکل ۵-۲۱: نحوه به کارگیری ورودی‌های شبکه برای استفاده در رابطه‌ی ۵-۲۴

با توجه به ماتریس ضرایب و ورودی‌های شبکه که در شکل ۵-۲۰ و ۵-۲۱ نحوه به‌کارگیری آن نشان داده شده است و استفاده از رابطه‌ی ۵-۲۶ می‌توان به تشکیل این مدل شبکه عصبی در متلب و یا تشکیل این روابط در نرم‌افزارهای محاسباتی نظیر اکسل اقدام به پیش‌بینی نرخ سایش در پروژه‌های مشابه کرد.

۵-۸- جمع‌بندی

در این فصل ابتدا به بررسی زمین‌شناسی مهندسی مسیر تونل با استفاده از اطلاعات زمین‌شناسی و نتایج آزمایش‌های آزمایشگاهی و صحرایی پرداخته شده است. اطلاعات به‌دست‌آمده در جدول ۵-۱ ثبت شده است و سپس به بررسی اطلاعات مربوط به ماشین حفار پرداخته و در جدول ۵-۴ نشان داده شده است. در ادامه به بررسی پیش‌بینی نرخ سایش دیسک‌کاتر با استفاده از روش شبکه عصبی پرداخته شده است و همچنین پیش‌بینی نرخ سایش با استفاده از روش شبکه عصبی با مدل‌های دیگر مورد مقایسه قرار گرفته است.

به‌منظور تحلیل با روش شبکه‌های عصبی مصنوعی، شبکه‌های زیادی با ساختارهای متفاوت با در نظر گرفتن یک و دو لایه‌ی میانی و همچنین تعداد نورون‌های متفاوت در لایه‌ها ساخته شده است. در نهایت شبکه‌ای با یک لایه‌ی میانی، ۹ پارامتر ورودی متشکل از پارامترهای مربوط به سنگ بکر، توده سنگ و پارامترهای اجرایی ماشین و ۹ نورون در لایه‌ی میانی و پارامتر نرخ سایش در لایه‌ی خروجی به عنوان شبکه‌ی مناسب برای پیش‌بینی نرخ سایش انتخاب شده است. به‌منظور اطمینان از مدل ایجاد شده، بار دیگر این شبکه با استفاده از مجموعه‌ی آزمون جدیدی که در بانک اطلاعاتی مربوط به ساخت شبکه وجود نداشته، مورد بررسی قرار گرفته است. ضریب تعیین ۷۶ درصد و خطای متوسط ۳۹ مترمکعب بر کاتر و مقایسه‌ی آن با سایر مدل‌های سایش نشان‌دهنده‌ی صحت انتخاب شبکه‌ی ایجاد شده است. پس از ایجاد شبکه‌ی مناسب برای پیش‌بینی، می‌توان به تحلیل حساسیت بر روی پارامترهای ورودی پرداخت. در این مطالعه با استفاده از روش وزن‌های اتصال به تحلیل حساسیت بر روی پارامترهای ورودی پرداخته شده است. نتایج تحلیل‌ها نشان داده که سرعت چرخش کله حفار و جنس سنگ بیشترین تأثیر را در نرخ سایش داشته است.

برای ایجاد مدل شبکه عصبی برای شرایط لیتولوژی متفاوت از داده‌های تونل انتقال آب کرج، زاگرس - ارومیه و تونل ورودی تونل انتقال آب اوما اوپا استفاده شده است. با استفاده از روش آزمون و خطا مدل شبکه عصبی با ساختار $1*7*9*8$ به وجود آمده است. با مقایسه بین مدل شبکه با سایر مدل‌ها در تونل‌های انتقال آب کرمان و تونل خروجی اوما اوپا مشخص شده است که مدل شبکه عصبی با توجه به ضرایب تعیین و میزان خطای متوسط مدل مناسب‌تری نسبت به سایر مدل‌ها در تونل انتقال آب اوما اوپا و نسبت به دو مدل CSM و NTNU در تونل انتقال آب کرمان بوده است. مدل شبکه عصبی در مقایسه با مدل گیرینگ در تونل انتقال آب کرمان از ضریب تعیین مناسب‌تر اما خطای متوسط ایجاد شده در این مدل کمی بالاتر از مدل گیرینگ بوده است.

فصل ششم

نتیجه‌گیری و پیشنهادات

۶-۱- نتیجه گیری

در این تحقیق با توجه به اهمیت موضوع سایش دیسک کاتر ابتدا مفهوم تئوری سایش و عوامل مؤثر بر آن معرفی شده است سپس به بیان مدل‌های تخمین نرخ سایش و مقایسه‌ی این مدل‌ها توسط کرمی و فرخ پرداخته شده است و در نهایت به بررسی تأثیر هر یک از پارامترهای ورودی نرخ سایش در مدل‌های گیرینگ، برولند ۱۹۹۸ و رستمی ۱۹۹۷ پرداخته شده است.

در فصل دوم مشخص شد که هرکدام از مدل‌های تخمین عمر دیسک کاتر در شرایط زمین‌شناسی مشابه دارای نتایج متفاوتی است و همین‌طور پارامترهای ورودی این مدل‌ها تأثیر متفاوتی بر روی هرکدام از مدل‌ها ایجاد کرده است بنابراین بایستی دقت لازم را برای انتخاب مدل تخمین نرخ سایش برای پروژه‌های حفاری تونل داشت.

برای تأثیر پارامترهای بیشتر در نرخ سایش و ایجاد مدلی که بتوان برای شرایطی که امکان برقراری ارتباط بین پارامترهای تأثیرگذار بر نرخ سایش مشخص نیست، استفاده از شبکه عصبی پیشنهاد شده است. استفاده از شبکه‌های عصبی به جهت پویا بودن و عدم نیاز به روابط ریاضی محض ایده مناسبی است که در این تحقیق به این موضوع پرداخته شد.

با استفاده از داده‌های تونل ورودی انتقال آب اوما اوپا متشکل از اطلاعات سنگ بکر، توده سنگ و اطلاعات مربوط به ماشین حفار اقدام به مدل‌سازی با استفاده از شبکه عصبی برای پیش‌بینی میزان سایش دیسک کاتر شده است. برای ارزیابی و اعتبارسنجی مدل ایجاد شده از داده‌های تونل خروجی انتقال آب اوما اوپا (داده‌های مربوط به ۶ - ۱۵ کیلومتری تونل) که در بخش تربیت شبکه عصبی وجود نداشته اند استفاده شده است. با توجه به ضریب تعیین 0.76 و خطای متوسط 39 مترمکعب بر کاتر و مقایسه‌ی آن با مدل‌های گیرینگ، NTNU و CSM نشان دهنده کارایی مناسب و لازم مدل شبکه عصبی ایجاد شده برای پیش‌بینی نرخ سایش در این تونل بوده است.

برای ایجاد مدل شبکه عصبی در شرایط لیتولوژی متفاوت از داده‌های تونل انتقال آب کرج، زاگرس – ارومیه و داده‌های تونل ورودی اوما اوپا استفاده شده است. با بررسی داده‌ها مشخص شده است که سهم عمده داده‌ها در طبقه بندی انجام شده توسط آقای حسن‌پور برای ساینده‌گی سنگ‌ها در کلاس ساینده‌گی متوسط تا زیاد قرار گرفته‌اند. با استفاده از این داده‌ها به مدل‌سازی با استفاده از شبکه عصبی برای پیش‌بینی نرخ سایش پرداخته شده است. برای ارزیابی مدل ایجاد شده از داده‌های تونل خروجی انتقال آب اوما اوپا و تونل کرمان استفاده شده است. خروجی مدل شبکه عصبی را برای این داده‌ها بدست آورده و با سایر مدل‌ها مقایسه شده است که در جدول ۶-۱ نشان داده شده است.

جدول ۶-۱: خلاصه نتایج مقایسه‌ی بین شبکه عصبی و سایر مدل‌های سایش

مدل	ضرایب آماری	اوما اوپا	کرمان
NTNU	MAE(m ³ /c)	۱۶۷	۱۱۳۵
	R ²	۰/۱۶	۰/۱۸
CSM	MAE	۱۸۲	۱۱۳۵
	R ²	۰/۳۸	۰/۱۸
Gehering	MAE	۱۶۹	۹۸۵
	R ²	۰/۴۲	۰/۳۸
ANN	MAE	۵۸	۱۰۵۰
	R ²	۰/۶۷	۰/۷۴

با در نظر گرفتن این موضوع که داده‌های تونل خروجی اوما اوپا در کلاس ساینده‌گی زیاد قرار گرفته است انتظار عملکرد مناسب از مدل شبکه عصبی آموزش دیده با داده‌های مربوط به کلاس ساینده‌گی متوسط تا زیاد وجود دارد. ضریب تعیین ۰/۶۷ و خطای متوسط ۵۸ متر مکعب بر کاتر است که توسط مدل شبکه عصبی ایجاد شده است. ضریب تعیین بالاتر از سایر مدل‌ها و میزان خطا نسبت به سایر مدل‌ها تقریباً ۳ برابر کمتر بوده است. در مجموع می‌توان عملکرد مدل شبکه عصبی در این تونل را مناسب ارزیابی کرد.

داده‌های تونل انتقال آب کرمان در کلاس سایندهی کم قرار گرفته است. ضریب تعیین به دست آمده توسط مدل شبکه عصبی برای این تونل را می‌توان مناسب ارزیابی کرد. اما خطای ایجاد شده کمی بالاتر از مدل گیرینگ بوده است که می‌توان علت آن را به عدم وجود داده‌های کافی از کلاس سایندهی کم در آموزش شبکه عصبی دانست. بنابراین عملکرد مدل شبکه عصبی را نمی‌توان نسبت به مدل گیرینگ برتر دانست اما از دو مدل CSM و NTNU مناسب‌تر بوده است.

۶-۲- پیشنهادات

با توجه به مطالب ارائه شده در این پژوهش، پیشنهاداتی برای توسعه الگوی ارائه شده و کمک به محققان بعدی در ادامه بیان شده است.

جمع آوری داده‌های پروژه‌های مختلف تونل سازی بر اساس طبقه‌بندی سایندهی ارائه شده توسط آقای حسن‌پور و ارائه مدل‌های شبکه عصبی برای پیش‌بینی نرخ سایش در هر یک از کلاس‌های سایندهی و بررسی و ارزیابی مدل‌های ایجاد شده.

استفاده از داده‌های گسترده‌تر شامل چندین پروژه تونل سازی برای تأثیرگذاری پارامترهای بیشتر نظیر نوع سنگ و تعداد دیسک‌کاتر و غیره.

بررسی شبکه‌های عصبی متفاوت با شبکه بررسی شده، به‌منظور بررسی عملکرد شبکه‌ی استفاده شده.

استفاده از روش‌های بروزتر نظیر شبکه‌های یادگیری عمیق در تخمین نرخ سایش.

مبنای تئوری شبکه‌ها عصبی نیاز به ارائه تئوری توسعه‌یافته در راستای بهینه‌سازی پارامترهای شبکه‌ها به‌خصوص در تعیین ساختار شبکه عصبی است.

منابع

منابع فارسی

- آمون، صادق، شهریار، کوروش، شریف‌زاده، مصطفی،، طریق ازی، صادق. (۱۳۹۴). ارزیابی سایش ابزار برشی در تونل سازی مکانیزه در زمین‌های نرم- مطالعه موردی: تونل قطعه شمالی- جنوبی خط ۷ متروی تهران، نشریه تونل و فضاهاى زیرزمینی.
- ابوالحسینی، ح. (تابستان ۹۳). ارزیابی ارتباط پارامترهای ژئوتکنیکی سنگ های مسیر تونل نوسود با پارامترهای مرتبط با ماشین حفاری با استفاده از روش شبکه عصبی، پایان نامه کارشناسی ارشد.
- ارباب سیر، م. ح. (تابستان ۹۲). ارائه مدلی جدید برای پیش بینی نرخ نفوذ TBM در سنگ سخت، پایان نامه کارشناسی ارشد.
- افتخاری، س. م.، باغبانان، ع.، باقرپور، ر. (۱۳۹۱). بررسی تاثیر پارامترهای اجرایی ماشین TBM بر نرخ نفوذ آن با استفاده از روش شبکه های عصبی مصنوعی-مطالعه موردی تونل بلند زاگرس. نشریه مهندسی تونل و فضاهاى زیر زمینی، ۱(۱)، ۲۹-۴۶.
- برزگری، ق.، ارومیه، ع. (۱۳۹۴). راندمان حفاری مکانیزه تونل به روش سپر تعادلی در زمین های نرم و ساینده . نشریه علمی پژوهشی مهندسی معدن. ۶۷-۶۹.
- حسن پور، ج.، رستمی، ج. (۱۳۸۹). عملکرد ماشین های تونل بری در سنگ سخت. نشر خرم - نشر فن.
- خداپرستی، کامران. (۱۳۹۰). اصول سختی سنجی و کاربردهای آن، نشریه مشانیر، شماره ۵۶.
- خدایاری، ج.، برزگری، ق. (۱۳۹۸). بررسی پدیده سایش دیسکهای برشی ماشین حفاری تونل در سنگهای سخت. نشریه علمی-پژوهشی مهندسی معدن، ۱۴(۴۵)، ۴۶-۶۲.

غلامی، م و اجل لوئیان، رسول. (۱۳۹۸). بررسی تأثیر برهم‌کنش ماشین TBM و زمین بر روی تغییرات نیروی پیشران و نرخ نفوذ ماشین-مطالعه‌ی موردی: تونل انتقال آب کرج-تهران (قطعه‌ی ۲). مهندسی عمران امیرکبیر، ۵۱(۲)، ۳۱۵-۳۲۶.

فتح آبادی، ب.، محمدی، م.، سعیدی، غ. (۱۳۹۱). پیش بینی ماکزیمم نشست در اطراف تونل خط هفت متروی تهران از طریق شبکه عصبی، دومین کنفرانس ملی مدیریت بحران، تهران.

منهاج، م. ب. (۱۳۹۱). مبانی شبکه‌های عصبی. تهران، ایران: انتشارات دانشگاه صنعتی امیرکبیر.

نجاتی، ح.، احمدی، م. (۱۳۸۹). تخمین ضریب بهره‌وری ماشین حفر تونل (TBM) با استفاده از شبکه عصبی مصنوعی. فصلنامه زمین شناسی محیط زیست، ۴(۱۲)، ۶۳-۷۲.

همزبان، م. ت.، معماریان، ح.، رستمی، ج. (۱۳۹۲). مقایسه روش‌های مختلف تعیین ساینده‌ی سنگ‌ها. نشریه مهندسی معدن، ۸(۱۹)، ۸۷-۱۰۶.

یاوری، ش. م.، و مهدوری، س. (۱۳۸۵). پیش بینی نرخ نفوذ ماشین‌های تونلبری با استفاده از شبکه‌ی عصبی. نشریه‌ی دانشکده‌ی فنی، دانشگاه تهران، ۴(۱)، ۱۱۵-۱۲۱.

یاوری، ش. م.، مهدوری، س. (۱۳۸۶). پیش بینی ضریب بهره‌وری ماشین‌های حفر تونل بدون سپر. نشریه علمی پژوهشی مهندسی معدن، دانشگاه اصفهان، ۲(۳)، ۱-۱۰.

منابع انگلیسی

- Bruland, A. (1998a). Hard rock tunnel boring advance rate and cutter wear. Trondheim: Norwegian Institute of Technology.
- Bruland, A. (1998b). Hard rock tunnel boring: Drillability test methods. Project report 13A-98, NTNU Trondheim, 21.
- Cho JW, Jeon S, Yu SH, Chang SH (2010) Optimum spacing of TBM disc cutters: a numerical simulation using the three-dimensional dynamic fracturing method. Tunn Undergr Sp Tech 25(3):230-244

- Ciamei, A., Grandori, R., 2011. Tsuen Wan drainage project – Hong Kong challenges of TBM excavation in difficult ground conditions and narrow working spaces, 37th ITAAITES World Tunnel Congress, Finland.
- Dahl, F., Bruland, A., Jakobsen, P.D., Nilsen, B. and Grov, E. (2012) Classifications of properties influencing the drillability of rocks, based on the NTNU/SINTEF test method. *Tunn. Undergr. Space. Technol.* 28, 150–158.
- Demuth, H. and Beal, M. (2012) Neural Network Toolbox User's Guide, MATLAB USER MANUAL.
- FARAB, Energy & Water Projects ,INTERIM REPORT No. 3 (UOPUOMDP/2016/IR3) on Additional Geological, Geotechnical, Hydrogeological and Geophysical Investigations along Headrace Tunnel UMA OYA MULTIPURPOSE DEVELOPMENT PROJECT
Compiled by Department of Geology, University of Peradeniya
- Farrokh, E., & Kim, D. Y. (2018). A discussion on hard rock TBM cutter wear and cutterhead intervention interval length evaluation. *Tunnelling and Underground Space Technology*, 81, 336-357.
- Farrokh E, Rostami J, Askilrud OG (2013) A discussion on TBM cutterchange time and cutter life. SME Annual Meeting.
- Frenzel C (2011) Disc Cutter Wear Phenomenology and their Implications on Disc Cutter Consumption for TBM, 45th US rock mechanics symp. San Francisco, USA.
- Frenzel, C., Käsling, H., & Thuro, K. (2008). Factors influencing disc cutter wear. *Geomechanik und Tunnelbau*, 1, 55-60.
- Garson, G.D. (1991). "Interpreting neural network connection weights." *J. of Artif. Intell. Expert*, 6, 47-51.
- Gehring K (1995) Prognosis of advance rates and wear for underground mechanized excavations (in German). *Felsbau* 13(6):439–448
- Gevrey, M., Dimopoulos, I., & Lek, S. (2003). Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological modelling*, 160(3), 249-264.
- Grima, M. A., Bruines, P. A., & Verhoef, P. W. (2000). Modelling Tunnel Boring Machine Performance by Neuro-Fuzzy Methods. *Tunnelling and Underground Space Technology*, 15 (3), 259-269.

- Goh, A. T. (1995). Back-propagation neural networks for modeling complex systems. *Artificial intelligence in engineering*, 9(3), 143-151.
- Hassanpour J, Rostami J, Zhao J, Azali ST (2015) TBM performance and disc cutter wear prediction based on ten years experience of TBM tunnelling in Iran. *Geomech Tunnell* 8(3):239–247
- Hassanpour, J., Azali, S. T., & Rostami, J. (2014). TBM Performance and Tool Wear Prediction Along Two Lots of Dyaaba Headrace Tunnel (Uma-Oya Project, Sri Lanka). *North American Tunneling: 2014 Proceedings*.
- Hassanpour J, Rostami J, Tarigh Azali S, Zhao J (2014) Introduction of an empirical TBM cutter wear prediction model for pyroclastic and mafic igneous rocks; a case history of Karaj water conveyance tunnel, Iran. *Tunn Undergr Space Technol* 43:222–231.
- Hashemnejad, A., Ghafoori, M. and TrighAzali, S. (2016) Utilizing water, mineralogy and sedimentary properties to predict LCPC abrasivity coefficient. *Bull. Eng. Geol. Environ.* 75(2), 841–851.
- Herrenknecht, M. and Frenzel, C. (2005) Long Tunnels in Hard Rock—A Preliminary Review. *Bauingenieur* 80, 343–349
- Karami, M., Zare, S., & Rostami, J. (2021). Introducing an empirical model for prediction of disc cutter life for TBM application in jointed rocks: case study, Kerman water conveyance tunnel. *Bulletin of Engineering Geology and the Environment*, 80(5), 3853-3870.
- Karami, M., Zare, S., & Rostami, J. (2021). Study of common wear prediction models for hard rock TBM disc cutters and comparison with field observation in Kerman water conveyance tunnel. *Bulletin of Engineering Geology and the Environment*, 80(2), 1467-1476.
- Liu QS, Liu JL, Pan YC, Zhang XP, Peng XX, Gong QM, Du LJ (2017) A wear rule and cutter life prediction model of a 20-in. TBM cutter for granite: a case study of a water conveyance tunnel in China. *Rock Mech Rock Eng* 50(5):1303–1320
- Maidl B, Schmid L, Ritz W, Herrenknecht M (2008) *Hardrock tunnel boring machines*. John Wiley & Sons.
- Moradzadeh, M., Cheshomi, A., Ghafoori, M. and TrighAzali, S. (2016) Correlation of equivalent quartz content, Slake durability index and Is50 with Cerchar abrasiveness index for different types of rock. *Int. J. Rock. Mech. Min. Sci.* 86, 42–47.

- Nilsen, B., Dahl, F., Holzhäuser, J., & Raleigh, P. (2007, June). New test methodology for estimating the abrasiveness of soils for TBM tunneling. In Proceedings of the rapid excavation and tunneling conference (RETC) (pp. 104-106).
- Nourani, V., & Fard, M. S. (2012). Sensitivity analysis of the artificial neural network outputs in simulation of the evaporation process at different climatologic regimes. *Advances in Engineering Software*, 47(1), 127-146.
- Plinninger, R.J. and Restner, U. (2008) Abrasiveness Testing, Quo Vadis? A commented overview of abrasiveness testing methods. *Geomechanik und Tunnelbau* 1(2008), 61–70
- Pourhashemi, S. M., Ahangari, K., Hassanpour, J., & Eftekhari, S. M. (2021). Analysis of Grinding and Chipping Processes beneath Disc Cutters of Hard Rock Tunnel Boring Machines (Case study: Uma-Oya water Conveyance Tunnel, SriLanka). *Journal of Mining and Environment*, 12(1), 281-297.
- Rostami J (1997) Development of a force estimation model for rock fragmentation with disc cutters through theoretical modeling and physical measurement of crushed zone pressure. Dissertation, Colorado School of Mines
- Sun, Z., Zhao, H., Hong, K., Chen, K., Zhou, J., Li, F., ... & He, R. (2019). A practical TBM cutter wear prediction model for disc cutter life and rock wear ability. *Tunnelling and Underground Space Technology*, 85, 92-99.
- Thuro, K., & Käsling, H. (2009). Classification of the abrasiveness of soil and rock. *Geomechanics and Tunnelling*, 2(2), 179-188.
- Thuro, K. (1997). Drillability prediction: geological influences in hard rock drill and blast tunnelling. *Geologische Rundschau*, 86(2), 426-438.
- Wittke, W., Erichsen, C., & Gattermann, J. (2007). Stability analysis and design for mechanized tunnelling. *Geotechnical Engineering in Research and Practice*, 581.
- Yagiz, S., Gokceoglu, C., Sezer, E., & Iplikci, S. (2009). Application of two non-linear prediction tools to the estimation of tunnel boring machine performance. *Engineering Applications of Artificial Intelligence*, 22(4-5), 808-814.
- Yang, Y., Hong, K., Sun, Z., Chen, K., Li, F., Zhou, J., & Zhang, B. (2018). The derivation and validation of TBM disc cutter wear prediction model. *Geotechnical and Geological Engineering*, 36(6), 3391-3398.

- Zhang, X., Xia, Y., Zhang, Y., Tan, Q., Zhu, Z., & Lin, L. (2017). Experimental study on wear behaviors of TBM disc cutter ring under drying, water and seawater conditions. *Wear*, 392, 109-117.
- Zhao, J., Gong, Q. M., & Eisensten, Z. (2007). Tunnelling through a frequently changing and mixed ground: a case history in Singapore. *Tunnelling and Underground Space Technology*, 22(4), 388-400.

Abstract

Due to the costs of drilling tool wear in tunnel construction projects, the growing need to provide a comprehensive and practical model for estimating and predicting wear rates has been felt more than ever. Many researchers, following the importance of abrasion and its effect on drilling efficiency and time, have tried to estimate and predict the wear rate using experimental and semi-theoretical models. Due to the fact that these models have been developed in specific geological conditions and also the impact of all parameters affecting the wear rate in these models has not been considered, they can not be generalized to all geological conditions. The shortcomings of these methods on the one hand and the growth of science in the fields of artificial intelligence and neural network on the other hand, have led researchers to use and study the application of this method compared to previous methods. Neural networks are a good idea for modeling when the relationship between the input and output parameters of a quantity is not clear. In this study, the effect of rock and machine parameters on disk cutter life prediction models (CSM, NTNTU and Gehring) has been investigated. The results show a different effect of each of these parameters on the models of disc cutter wear, which shows the importance of choosing a suitable model according to the geological conditions of the region. In the following, using the neural network method, a model for estimating and predicting the life of the disc cutter and comparing it with other common models for predicting the life of the disc cutter is presented. After determining the parameters affecting the wear rate and creating a suitable structure of the neural network, the wear rate in the Uma Oya and Kerman water transfer tunnels has been predicted. Considering the high coefficient of determination of 0.6 and the average error obtained for the neural network model and its comparison with CSM, NTNTU and Gehring methods, it shows the proper efficiency of the neural network in predicting the rate of disc cutter wear in tunnels with high abrasivity class. But in tunnels with low abrasivity class, more investigation is needed.

Keywords: Wear rate, neural network, Disk Cutter, modeling



Shahrood University of Technology

Faculty of mining, Petroleum and Geophysics Engineering

M.Sc. Thesis in Rock Mechanic

**Prediction Of Hard Rock TBM Cutter Life Using Neural
Network Method – Case Study UMA OYA Water
Conveyance Tunnel**

By: Hamid Reza Moradi

Supervisors:

Dr. Shokrollah Zare

September 2021