

## کاربرد مدل سری‌های زمانی در پیش‌بینی نرخ نفوذ ماشین حفر تونل تمام مقطع

مسعود مذهبی؛ سید مصلح افتخاری\*

گروه مهندسی معدن، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران

پذیرش:

دریافت: \*\*

### چکیده

در حفاری مکانیزه، نرخ نفوذ تعیین‌کننده هزینه‌ها و زمان حفاری پروژه است. از این رو پیش‌بینی نرخ نفوذ بسیار مهم و تعیین‌کننده می‌باشد. نرخ نفوذ نسبت فاصله حفاری شده به زمان انجام آن در طول حفاری پیوسته است. از آنجاکه پارامتر نرخ نفوذ به ازای سیکل‌های مختلف حفاری ثبت می‌شود و از طرف دیگر، یک سری زمانی، دنباله‌ای مرتب‌شده از مشاهدات است و با توجه به مقادیر گذشته و حال، می‌توان مقادیر آینده سری را پیش‌بینی کرد، در این مطالعه به بررسی کاربرد مدل سری‌های زمانی در پیش‌بینی نرخ نفوذ *TBM* پرداخته شده است. مقادیر نرخ نفوذ بیش از ۲۳۰۰ سیکل حفاری در تونل بلند زاگرس مورد تحلیل قرار گرفته است. نتایج پیش‌بینی نرخ نفوذ با مدل سری‌های زمانی ضریب تطبیق ۸۷ درصد را نشان می‌دهد و بیانگر قابلیت و کاربرد مناسب رویکرد سری‌های زمانی در پیش‌بینی نرخ نفوذ *TBM* است.

### واژگان کلیدی

نرخ نفوذ، پیش‌بینی، سری‌های زمانی، ماشین حفر تونل

### ۱- مقدمه

افزایش احداث تونل‌های متفاوت با کاربری‌های مختلف و افزایش روزافزون استفاده از حمل‌ونقل زمینی و زیرزمینی و تونل‌های انتقال آب و همچنین لزوم ساخت مسیرهای جدید و تونل‌های بلند و طولانی منجر به پیدایش و گسترش ماشین حفر تونل *TBM* از اوایل قرن نوزدهم شد. یکی از عوامل تعیین‌کننده روش حفر تونل (سنتی یا مکانیزه)، مدت‌زمان حفر آن است. در روش سنتی این زمان تابع سیکل آتشیاری می‌باشد و در روش حفاری مکانیزه، مدت‌زمان حفر را نرخ پیشروی<sup>۱</sup> تعیین می‌کند. نرخ نفوذ<sup>۲</sup> *TBM* یکی از تأثیرگذارترین عوامل مؤثر بر سرعت حفر تونل است. در تعریف نرخ نفوذ باید عنوان کرد که نسبت فاصله حفاری شده به زمان انجام آن در طول حفاری

پیوسته است یا به عبارتی برابر نرخ پیشروی آبی ماشین می‌باشد و معمولاً برحسب میلی‌متر بر دور تاج حفار یا متر بر ساعت بیان می‌شود [۱]. اهمیت پارامتر نرخ نفوذ در پروژه‌های تونل‌سازی سبب شده است تا محققین بسیاری به پیش‌بینی این پارامتر با روش‌های گوناگون از جمله روش‌های تئوری، تجربی و مدل‌سازی عددی و همچنین شبیه‌سازی با روش‌های هوشمند بپردازند. در روش تئوری، محققانی با توجه به ارتباط تئوری میان پارامترهای ماشین و نفوذ دیسک و همچنین در برخی موارد پارامترهایی از سنگ به پیش‌بینی نرخ نفوذ پرداخته‌اند [۴،۲،۳]. در حالی که روش تجربی بر مبنای ارتباط واقعی و ذاتی بین پارامترهای زمین و ماشین برقرار است و به واسطه برآزش بین خصوصیات سنگ و پارامترهای ماشین با نرخ نفوذ به دست آمده‌اند [۸،۷،۶،۵]. با این حال، مدل‌های تجربی ارائه شده با اطمینان قابل‌تعمیم به تمام شرایط نمی‌باشند و می‌توان در شرایط یکسان با تحقیق انجام شده مورد استفاده قرار

<sup>۱</sup> Advance Rate  
<sup>۲</sup> Penetration Rate

ازدحام ذرات<sup>۲</sup> پرداخته‌اند. ایشان به این نتیجه رسیده‌اند که الگوریتم بهینه‌سازی ازدحام ذرات برای پیش‌بینی عملکرد از روش شبکه‌های عصبی مصنوعی و شبکه‌های عصبی مصنوعی فازی بهتر عمل می‌کند [۲۳]. قاسمی و همکاران در سال ۲۰۱۴ به پیش‌بینی نرخ نفوذ با تکنیک فازی پرداخته‌اند. اطلاعات موردنیازشان از بخش دوم تونل سوم پروژه انتقال آب کوئینز نیویورک برداشت شده است. پارامترهای ورودی آن‌ها مقاومت فشاری تک‌محوره، مقاومت کششی برزیلی، زاویه  $\alpha$ ، شکنندگی سنگ، فاصله بین صفحات ضعف است [۲۴]. لی و بینگ در سال ۲۰۱۵ در شرایط سنگ سخت با داده‌های دو پروژه انتقال آب تهران - کرج و تونل انتقال آب شهر نیویورک (بخش دوم تونل کوئینز) به پیش‌بینی نرخ نفوذ پرداخته‌اند. ایشان از پارامترهای مقاومت فشاری تک‌محوره، مقاومت کششی برزیلی، فاصله بین صفحات ضعف، زاویه بین محور تونل و صفحات ضعف (زاویه  $\alpha$ ) به‌عنوان ورودی استفاده کرده‌اند. آن‌ها از روش‌های ماشین بردار پشتیبان<sup>۳</sup> و روش حداقل مربعات جزئی<sup>۴</sup> استفاده کرده‌اند و به این نتیجه رسیده‌اند که این دو روش از قابلیت خوبی برای پیش‌بینی برخوردار می‌باشند و صحت قابل قبولی را ارائه می‌دهند. این نتیجه نیز حاصل شده است که این دو روش دارای برتری نسبی نسبت به سایر روش‌های آماری برای پیش‌بینی می‌باشند [۲۵]. فتاحی و مرادی در سال ۲۰۱۶ با در نظر گرفتن عوامل و فاکتورهای مقاومت فشاری تک‌محوره، فاصله بین صفحات ضعف توده‌سنگ، زاویه  $\alpha$ ، مقاومت کششی برزیلی و درجه شکستگی سنگ<sup>۵</sup> توسط مدل‌های رگرسیونی چندمتغیره به پیش‌بینی نرخ نفوذ پرداخته‌اند. ایشان مدل رگرسیونی چندمتغیره را برای پیش‌بینی نسبت به روش‌های خطی، توانی، چندجمله‌ای و لگاریتمی بهتر یافته‌اند [۲۶]. مینه و همکاران در سال ۲۰۱۷ با در نظر گرفتن فاکتورهای مقاومت فشاری تک‌محوره، مقاومت کششی برزیلی، فاصله بین صفحات شکستگی‌ها، ضریب شکنندگی سنگ و زاویه  $\alpha$  با روش‌های رگرسیونی و مدل‌های مختلف رگرسیون، همچنین با در نظر گرفتن و مقایسه مدل فازی به پیش‌بینی نرخ نفوذ ماشین *TBM* پرداخته‌اند. این مطالعه با چهار مدل خطی، لگاریتمی، توانی و توانی دومتغیره

گیرند. علاوه بر این، از میان روش‌های بررسی نرخ نفوذ، روش عددی را به‌دلیل دارا بودن روش حل صحیح و با دقت بالا می‌توان به‌عنوان روشی بسیار مفید در شبیه‌سازی مدل‌هایی با شرایط نزدیک به واقعیت دانست؛ بنابراین، تاکنون مطالعات متعددی با ابزارهای مختلف روش عددی و با رویکردها و اهداف متفاوتی جهت مدل‌سازی فرآیند شکست سنگ در اثر بار دیسک‌های *TBM* و یا نرخ نفوذ صورت پذیرفته است [۹-۱۸]. همچنین، با توجه به قابلیت‌های روش‌های هوشمند در پیش‌بینی مسائل پیچیده‌ای که شناسایی روابط و ارتباط پارامترها در آن‌ها به‌سادگی امکان‌پذیر نیست، مطالعات متعددی در سال‌های اخیر با این روش‌ها به‌منظور پیش‌بینی نرخ نفوذ انجام شده است. یاگیز و همکارانش در سال ۲۰۰۹ چهار پارامتر مقاومت فشاری تک‌محوری، اندیس تردی، فاصله صفحات ضعف و زاویه بین این صفحات و محور تونل را به‌عنوان ورودی شبکه‌های عصبی مصنوعی<sup>۱</sup> در نظر گرفته‌اند و شبکه‌ای با چهار ورودی و یک خروجی ایجاد کرده‌اند. آن‌ها همچنین با استفاده از داده‌های مورد استفاده در شبکه عصبی به پیش‌بینی نرخ نفوذ به کمک رگرسیون‌گیری چند متغیره غیرخطی پرداخته‌اند. از مقایسه مقادیر پیش‌بینی شده با استفاده از شبکه عصبی و رگرسیون چند متغیره غیرخطی با مقادیر واقعی نرخ نفوذ، این نتیجه حاصل شده است که نتایج شبکه عصبی نسبت به رگرسیون غیرخطی به واقعیت نزدیک‌تر است [۱۹]. غلام‌نژاد و طیرانی (۲۰۱۰) با استفاده از روش شبکه عصبی به پیش‌بینی نرخ نفوذ با استفاده از پارامترهای مقاومت فشاری تک‌محوری، فاصله بین صفحات ضعف در توده‌سنگ و *RQD* پرداخته‌اند [۲۰]. افتخاری و همکاران در سال ۲۰۱۰ با استفاده از روش شبکه‌های عصبی مصنوعی و با ورودی‌های مقاومت فشاری تک‌محوره، نوع سنگ، درصد کوارتز، مقاومت کششی سنگ، *RMR*، *RQD*، نیروی محوری پیشران، گشتاور و سرعت چرخش کله حفار به پیش‌بینی نرخ نفوذ پرداخته‌اند [۲۱]. ترابی و همکارانش نیز در سال ۲۰۱۱ به کمک شبکه عصبی به بررسی اثر پارامترهای ژئوتکنیکی بر نرخ نفوذ پرداخته و عنوان کرده‌اند که شبکه عصبی نسبت به روش آماری نتایج قابل‌اطمینان‌تری می‌دهد [۲۲]. کاراهان و یاگیز در سال ۲۰۱۱ به پیش‌بینی عملکرد *TBM* با روش بهینه‌سازی

Particle Swarm Optimization <sup>۲</sup>Support Vector Machine <sup>۳</sup>Partial Least Squares <sup>۴</sup>Rock Fracture Class <sup>۵</sup>Artificial Neural Networks <sup>۱</sup>

انجام پذیرفته که مدل‌های توانی از قابلیت عملکرد بالاتری نسبت به مدل‌های خطی و لگاریتمی برخوردار هستند. همچنین مدل فازی در تطبیق از هر چهار مدل فوق عملکرد بهتری در پیش‌بینی نرخ نفوذ داشته است [۲۷]. ارمغانی و همکاران (۲۰۱۷) با در نظر گرفتن چندین عامل ورودی به پیش‌بینی نرخ نفوذ ماشین *TBM* پرداخته‌اند. ایشان داده‌های موردنیاز را از تونل انتقال آب پاهانگ در منطقه سلانگور کشور مالزی جمع‌آوری کرده‌اند. پارامترهای ورودی استفاده‌شده شامل مقاومت فشاری تک‌محوره، مقاومت کششی برزیلی، درجه کیفی سنگ (*RQD*)، درجه تعیین کیفیت سنگ (*RMD*)، فرسایش بر اثر آب‌وهوا، نیروی محوری ماشین حفار و سرعت چرخش تاج حفار است. ایشان روش‌های هوشمند و ترکیب آن‌ها را برای پیش‌بینی انتخاب کرده‌اند. ترکیب روش‌های شبکه‌های عصبی مصنوعی و بهینه‌سازی ازدحام ذرات و همچنین شبکه‌های عصبی مصنوعی و الگوریتم رقابت استعماری (*ICA*) را با روش شبکه‌های عصبی مصنوعی مقایسه کرده و عنوان نموده‌اند که روش‌های ترکیبی بالا عملکرد بهتری از *ANN* دارند و روش *PSO-ANN* پیش‌بینی بهتری نسبت به *ICA-ANN* ارائه می‌دهد [۲۸].

مرور مطالعات گذشته نشان می‌دهد که عوامل متعددی در ارتباط با سنگ و ماشین بر نرخ نفوذ مؤثرند اما اثر تمامی این عوامل مؤثر را نمی‌توان شناسایی و در نظر گرفت، درعین‌حالی که بعضی از عوامل مؤثر نیز در برخی پروژه‌ها در دسترس نمی‌باشند. علاوه بر این، در نظر گرفتن یک مقدار ثابت برای پارامترهای مربوط به سنگ در طول یک مقطع زمین‌شناسی چندان نزدیک به واقعیت نیست، زیرا توده‌سنگ به‌طور ذاتی محیطی ناهمگن است و مقادیر پارامترهای آن نمی‌تواند ثابت باقی بماند؛ اما باید در نظر داشت که مقدار به‌دست‌آمده برای نرخ نفوذ در هر سیکل حفاری ناشی از تأثیر تمامی پارامترهای مؤثر بر آن است و به‌عبارت‌دیگر اثر تمامی پارامترهای مؤثر را به‌خودی‌خود شامل می‌شود و به عبارتی تفاوت مقدار نرخ نفوذ در سیکل‌های مختلف حفاری، ناشی از تفاوت و تغییر در پارامترهای مؤثر آن است.

یک سری زمانی<sup>۱</sup> دنباله‌ای مرتب‌شده از مشاهدات است که برحسب زمان یا متغیر دیگری مرتب‌شده است و هدف از تحلیل آن، به دست آوردن مدلی است که مکانیسم تصادفی

<sup>۱</sup> Time series

## ۲- منطقه مورد مطالعه

منطقه مورد مطالعه برای این تحقیق بخشی از قطعه دوم تونل بلند زاگرس واقع در غرب کشور ایران می‌باشد. قطعه دوم این تونل به طول ۲۶ کیلومتر و به قطر ۶/۷۳ متر به‌وسیله ماشین حفاری تونل (*TBM*) با سپر دبل اجرا شده است. مشخصات مربوط به این تونل و ماشین *TBM* در جدول ۱ آمده است [۳۰].

جدول ۱: مشخصات مربوط به تونل و ماشین *TBM* [۳۰]

۲۶	طول تونل (KM)
۶/۷۳	قطر حفاری (m)
ماشین دو سپر	نوع <i>TBM</i>
۴۲	تعداد دیسک
۹۰	فاصله دیسک‌ها (mm)
۴۳۲	قطر دیسک (mm)
۰-۹/۰۵	سرعت چرخش (1/min)

با توجه به مطالعات زمین‌شناسی و زمین‌شناسی مهندسی صورت گرفته در مراحل مختلف و با در نظر گرفتن تکرار واحدها در قسمت‌های مختلف مجموعاً در محدوده مورد مطالعه ۲۱ واحد زمین‌شناسی مهندسی قابل تفکیک است [۳۰]. شکل ۱ برش زمین‌شناسی مسیر تونل را نشان می‌دهد. به‌منظور استفاده از رویکرد سری‌های زمانی به سابقه‌ی حفاری و مقادیر نرخ نفوذ در سیکل‌های مختلف نیاز است، از این‌رو در این تحقیق مقادیر نرخ نفوذ بیش از ۲۳۰۰ سیکل حفاری ماشین حفر تونل مورد استفاده قرار گرفته است.



### ۳-۳- انواع مدل‌های سری‌های زمانی

مدل‌های مختلفی برای ساخت سری‌های زمانی وجود دارند که بر اساس ماهیت در روند پیشروی آن سری زمانی شکل می‌گیرد. از آن جمله می‌توان به مدل‌های خودتوضیح<sup>۲</sup>، میانگین متحرک<sup>۳</sup>، خود توضیح میانگین متحرک<sup>۴</sup> و خود توضیح جمعی میانگین متحرک<sup>۵</sup> اشاره کرد که در ادامه توضیح داده خواهند شد [۲۹].

#### ۳-۳-۱- مدل خود توضیح یا اتورگرسیو

فرایند خود توضیح که با نماد  $AR(P)$  نشان داده می‌شود، ساده‌ترین و پایه‌ای‌ترین مدل تشکیل سری‌های زمانی است. در این فرایند مقدار مؤلفه سری زمانی یا مقدار جاری متغیر موردنظر برحسب مؤلفه‌ها یا مقادیر قبل از خود و یک جزء تصادفی شکل می‌گیرد. به میزان برگشت آن متغیر به مقادیر گذشته درجه خود توضیح مدل مشخص می‌شود. رابطه کلی فرایند این مدل به شکل زیر است:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon_t \quad (6)$$

به‌عنوان مثال  $AR(1)$  که اتورگرسیو مرتبه اول است به شکل زیر حاصل می‌شود:

$$Y_t = \Phi_1 Y_{t-1} + \varepsilon_t \quad (7)$$

$\varepsilon_t$  جزء تصادفی است و  $\Phi_1$  ضریب ثابتی بین  $[-1, +1]$  بوده و  $\{\varepsilon_t\}$  از فرایند اخلال خالص تبعیت می‌کند [۳۳].


#### ۳-۳-۲- مدل میانگین متحرک

فرایند میانگین متحرک نیز از ساده‌ترین و پایه‌ای‌ترین مدل‌های تشکیل سری‌های زمانی است. در این مدل  $Y_t$  به صورت تابعی از مقادیر با وقفه یک متغیر اخلال خالص  $\{\varepsilon_t\}$  بیان می‌شود. این مدل با نماد  $MA(q)$  نشان داده می‌شود. رابطه کلی این مدل به شکل زیر است:


$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (8)$$

$$ACF_s = \frac{\text{cov}[Y_t, Y_{t-s}]}{\sqrt{\text{var}[Y_t] \text{var}[Y_{t-s}]}} \quad (1)$$

علاوه بر تابع خودهمبستگی، کمیت دیگری تحت عنوان خودهمبستگی جزئی<sup>۱</sup> (۱) نیز وجود دارد که رابطه آن مشابه رابطه بالاست با این تفاوت که در محاسبه کوواریانس  $Y_{t-s}, Y_t$  تنها همبستگی مستقیم میان این دو مقدار مدنظر قرار می‌گیرد و همبستگی‌های غیرمستقیم میان آن‌ها حذف می‌شود [۳۳]. نحوه تشخیص ایستایی سری‌های زمانی از روی نمودارهای خودهمبستگی با توجه به شکل‌های زیر مشخص می‌شود.



شکل ۲: نمودار خودهمبستگی سری زمانی ایستا به صورت شماتیک [۳۳]



شکل ۳: نمودار خودهمبستگی سری زمانی نایستا به صورت شماتیک [۳۳]

آن‌چنان‌که مشاهده می‌شود کاهش شدید نمودارهای خودهمبستگی نشان از ایستایی سری زمانی (شکل ۲) و کاهش تدریجی نمودارها نشان از عدم ایستایی دارد (شکل ۳) [۳۳].

<sup>۱</sup> AR: Auto Regressive

<sup>۲</sup> MA: Moving Average

<sup>۳</sup> ARMA: Auto Regressive Moving Average

<sup>۴</sup> ARIMA: Auto Regressive Integrated Moving Average

<sup>۱</sup> Partial Auto correlation Function (PCF)

افت شدید میزان تابع خودهمبستگی جزئی در تأخیر دوم از علائم ایستایی سری زمانی می‌باشند؛ بنابراین داده‌های نرخ نفوذ ایستا می‌باشند و قابلیت مدل‌سازی با رویکرد سری‌های زمانی را دارا است.

به‌منظور مدل‌سازی سری زمانی باید فاکتورهای  $p$  و  $q$  که به ترتیب درجه خود توضیح و میانگین متحرک هستند تعیین شوند تا بتوان به مدل بهینه دست‌یافت. مدل سری زمانی  $ARMA$  به لحاظ ایستابودن سری داده‌های نرخ نفوذ و عملکرد خوب آن برای سری‌های ایستا انتخاب شده است. به‌منظور تعیین مدل بهینه جهت پیش‌بینی با سری‌های زمانی، مدل‌های متعددی با مقادیر متفاوت درجه خود توضیح و میانگین متحرک ساخته شده و علاوه بر ضریب تطبیق مدل‌ها از معیار خطای استاندارد رگرسیون و معیار آکائیک جهت سنجش نتایج این مدل‌ها استفاده شده است. معیار خطای استاندارد رگرسیون، انحراف و خطا از خط رگرسیون را ارائه می‌دهد و اندازه درستی پیش‌بینی را بررسی می‌کند. معیار آکائیک، معیاری برای سنجش نیکویی برازش است و نشان می‌دهد که استفاده از یک مدل آماری به چه میزان باعث از دست رفتن اطلاعات می‌شود. این معیار با توجه به رابطه زیر به دست می‌آید:

$$AIC = 2K - 2\ln(L) \quad (11)$$

که در آن،  $K$ ، تعداد پارامترهای مدل آماری و  $L$  مقدار حداکثر تابع درست‌نمایی<sup>۲</sup> برای مدل برآورد شده است. به‌عبارت‌دیگر، این معیار تعادلی میان دقت مدل و پیچیدگی آن برقرار می‌کند. این معیار توسط هیرو توگو آکائیک برای انتخاب بهترین مدل پیشنهاد شده است. هرچه این معیار برای مدلی کمتر باشد نشانگر بهتر بودن آن مدل در مقایسه با سایر مدل‌ها است [۳۴].

برای یافتن مدل بهینه جدولی با ردیف  $p$  و ستون  $q$ ،  $8 \times 10$  تشکیل شده و مقادیر ضریب تطبیق مدل‌ها که شاخص بسیار مناسبی برای ارزیابی رگرسیون است، برای مدل‌های مختلف  $Arma(p,q)$  محاسبه و در جدول ۲ ثبت شده است. همچنین در جدول ۳، نتایج معیار خطای استاندارد رگرسیون و در جدول ۴ نتایج معیار آکائیک مدل‌ها ارائه شده است.

همان‌طور که مشاهده می‌شود با بسط جزء تصادفی حاصل از اندازه‌های هر مؤلفه سری زمانی این مدل سری زمانی شکل می‌گیرد. ساده‌ترین شکل این مدل  $MA(1)$  است که فقط برحسب یک جزء تصادفی قبل از خود شکل گرفته است. رابطه آن به‌صورت زیر است:

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (9)$$

ایده اصلی فرایند میانگین متحرک این است که هر تغییر تصادفی بزرگ در هر لحظه از زمان، با نقاط هم‌جواری میانگین گرفته شود، تأثیر متعادل‌تری از خود به‌جا خواهد گذاشت [۳۳].

### ۳-۳-۳- مدل خود توضیح میانگین متحرک

یکی از پرکاربردترین مدل‌ها در مدل‌سازی سری‌های زمانی است که با نماد  $ARMA(p,q)$  نشان داده می‌شود. این مدل تلفیقی از دو مدل خود توضیح و میانگین متحرک است. رابطه آن به‌صورت زیر است:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (10)$$


بررسی وضعیت ایستایی فرایندهای  $ARMA$  بسیار پیچیده‌تر از فرایندهای پیشین است [۳۳].

### ۳-۳-۴- مدل خود توضیح جمعی میانگین متحرک

در این مدل هم‌انباشستگی (*Integration*) هم افزوده می‌شود. در این روش با تفاضل‌گیری از مدل  $ARMA$  آن را ایستا نموده و قابلیت پیش‌بینی به آن داده می‌شود [۳۳].

### ۴- پیش‌بینی نرخ نفوذ با رویکرد سری‌های زمانی

به‌منظور مدل‌سازی‌ها از نرم‌افزار ایویوز<sup>۱</sup> نسخه ۹ استفاده شده است. پیش‌بینی نرخ نفوذ به‌وسیله بیش از ۲۳۰۰ داده واقعی نرخ نفوذ انجام شده است. ابتدا ایستایی سری زمانی با نرم‌افزار ایویوز مورد بررسی قرار می‌گیرد همان‌طور که در شکل ۴ نشان داده شده است نمودارهای خودهمبستگی و خودهمبستگی جزئی از تأخیر ۱ تا ۳۶ رسم شده‌اند. روند نزولی میزان توابع خودهمبستگی ( $ACF$ ) در طول پیشروی وقفه‌ها و



شکل ۴: نمودار خودهمبستگی و خودهمبستگی جزئی داده‌های نرخ نفوذ

جدول ۲: ضریب تطبیق مدل‌های سری زمانی تشکیل شده

□ - □	درجه میانگین متحرک (q)										
	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	
درجه اتورگرسیون (p)	۰		۰/۶۹۰۱	۰/۷۸۰۶	۰/۸۰۵	۰/۸۳۳۶	۰/۸۴۱۷	۰/۸۴۲۲	۰/۸۴۵۲	۰/۷۸۰۶	۰/۸۴۱۷
	۱	۰/۸۵۱۴	۰/۸۵۹۸	۰/۸۶۰۴	۰/۸۶۱۴	۰/۸۶۱۸	۰/۸۶۳۶	۰/۸۶۳۶	۰/۸۶۶	۰/۸۶۰۴	۰/۸۶۳۳
	۲	۰/۸۵۸۶	۰/۸۶۱۵	۰/۸۶۱۹	۰/۸۶۲۱	۰/۸۶۲۴	۰/۸۶۳۶	۰/۸۶۴۳	۰/۸۶۶	۰/۸۶۱۹	۰/۸۶۹۲
	۳	۰/۸۵۹۵	۰/۸۶۲	۰/۸۶۲	۰/۸۶۲	۰/۸۶۹	۰/۸۶۶۱	۰/۸۶۶۴	۰/۸۶۶۳	۰/۸۶۳۱	۰/۸۵۲۴
	۴	۰/۸۶	۰/۸۶۲	۰/۸۶۲۱	۰/۸۶۴۹	۰/۸۶۹۴	۰/۸۶۶۳	۰/۸۶۶۴	۰/۸۶۶۴	۰/۸۶۱۴	۰/۸۵۶۳
	۵	۰/۸۶۰۱	۰/۸۶۲۲	۰/۸۶۲۱	۰/۸۶۵	۰/۸۶۵۵	۰/۸۷۴۸	۰/۸۶۶۴	۰/۸۷۶۱	۰/۸۵۹۸	۰/۸۶۳۲
	۶	۰/۸۶۲۳	۰/۸۶۳۸	۰/۸۶۵۹	۰/۸۶۶۶	۰/۸۶۶۸	۰/۸۷۵۳	۰/۸۷۶۱	۰/۸۶۸۵	۰/۸۶۹۴	۰/۸۷۱۱
	۷	۰/۸۶۵۶	۰/۸۶۵۷	۰/۸۶۶۷	۰/۸۶۶۶	۰/۸۶۶۸	۰/۸۶۶۸	۰/۸۷۲۷	۰/۸۷۳۸	۰/۸۶۴۱	۰/۸۶۵۲

جدول ۳: بررسی تطبیق مدل‌ها با معیار خطای استاندارد رگرسیون

□ - □	درجه میانگین متحرک (q)										
	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	
درجه آنورگرسیون (p)	۰		۱/۰۱۵۲	۰/۸۷۸۹	۰/۸۳۶۳	۰/۷۸۰۶	۰/۷۶۵۱	۰/۷۶۵۹	۰/۷۶۱۴	۰/۸۱۶۳	۰/۷۸۲۹۹
	۱	۰/۷۳۵۵۳	۰/۷۲	۰/۷۱۸۲	۰/۷۱۷۹	۰/۷۱۸۸	۰/۷۱۶۲	۰/۷۱۸۰۷	۰/۷۱۳۹	۰/۷۲۵۴	۰/۷۲۹۸۶
	۲	۰/۷۲۰۸۵	۰/۷۱۵۷	۰/۷۱۶۵	۰/۷۱۸	۰/۷۱۹۲	۰/۷۱۸۱۱	۰/۷۱۸۲	۰/۷۱۵۸	۰/۷۱۶۵	۰/۷۱۶۴۷
	۳	۰/۷۲۰۴۱	۰/۷۱۶۳	۰/۷۱۸۱	۰/۷۲۳۶	۰/۷۰۴۷	۰/۷۱۳۸۶	۰/۷۱۵۱۴	۰/۷۱۷	۰/۷۲۶۴	۰/۷۱۲۷۱
	۴	۰/۷۲۱۱۸	۰/۷۱۸۱	۰/۷۱۹۹	۰/۷۱۴۹	۰/۷۰۵۸	۰/۷۱۵۱۹	۰/۷۱۷۰۲	۰/۷۱۸۸	۰/۷۱۹۹	۰/۷۲۸۶۶
	۵	۰/۷۲۲۷۶	۰/۷۱۹۶	۰/۷۲۱۷	۰/۷۱۶۶	۰/۷۱۷۵	۰/۶۹۶۱	۰/۷۱۸۹	۰/۶۹۵۷	۰/۷۲۴۱	۰/۷۱۶۳۳
	۶	۰/۷۱۹۳۹	۰/۷۱۷۵	۰/۷۱۴۴	۰/۷۱۴۵	۰/۷۱۶۱	۰/۶۹۶۰۹	۰/۶۹۵۸	۰/۷۱۷۳	۰/۷۱۹۲	۰/۷۲۵۴۸
	۷	۰/۷۱۳۲۶	۰/۷۱۴۸	۰/۷۱۴۳	۰/۷۱۶۴	۰/۷۱۷۸	۰/۷۱۹۷۴	۰/۷۰۶۷	۰/۷۰۵۵	۰/۷۱۳۷	۰/۷۲۳۶۹

جدول ۴: بررسی تطبیق مدل‌ها با معیار آکائیک


p-q	درجه میانگین متحرک (q)										
	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	
درجه آنورگرسیون (p)	۰		۳/۴۱۵	۳/۱۸۳	۳/۰۶۸	۲/۹۸۶	۲/۹۸۱	۲/۹۶۲	۲/۹۶۱	۲/۹۴۱	۲/۹۵۶
	۱	۲/۹۴۶	۲/۹۴۶	۲/۹۴۷	۲/۹۵۳	۲/۹۵۵	۲/۹۴۳	۲/۹۴۷	۲/۹۶۳	۲/۹۵۴	۲/۹۶۸
	۲	۲/۹۴۳	۲/۹۴۶	۲/۹۵۳	۲/۹۵۳	۲/۹۵۶	۲/۹۵۴	۲/۹۶۵	۲/۹۶۸	۲/۹۶۸	۲/۹۶۷
	۳	۲/۹۴۶	۲/۹۵۶	۲/۹۵۸	۲/۹۶۱	۲/۹۶۴	۲/۹۶۲	۲/۹۶۷	۲/۹۵۹	۲/۹۵۸	۲/۹۷۴
	۴	۲/۹۵۲	۲/۹۵۶	۲/۹۶۲	۲/۹۶۵	۲/۹۷۲	۲/۹۶۸	۲/۹۴۳	۲/۹۴۱	۲/۹۴	۲/۹۳۸
	۵	۲/۹۴۳	۲/۹۳۷	۲/۹۴۵	۲/۹۳۷	۲/۹۳۱	۲/۹۳۵	۲/۹۳۴	۲/۹۲۸	۲/۹۳۴	۲/۹۴۲
	۶	۲/۹۳۷	۲/۹۴۱	۲/۹۴۳	۲/۹۴	۲/۹۴۲	۲/۹۳۸	۲/۹۳۱	۲/۹۳۲	۲/۹۳۷	۲/۹۴۵
	۷	۲/۹۳۱	۲/۹۳۶	۲/۹۴۱	۲/۹۴۷	۲/۹۳۹	۲/۹۳۵	۲/۹۴۳	۲/۹۴۸	۲/۹۵۲	۲/۹۵۶

با توجه به روند نزولی تدریجی خودهمبستگی داده‌های نرخ نفوذ انتظار می‌رفت که با افزایش مقدار درجه خود توضیح از یک مقداری به بعد میزان تغییرات و یا به عبارتی بهبود نتایج کاهش یابد که این نتیجه در مقادیر ثبت شده در جداول ۲ تا ۴ نیز مشاهده می‌شود؛ بنابراین، مدل (۷ و ۵) Arma با ضریب تطبیق ۰/۸۷۶۱ و مقدار خطای استاندارد رگرسیون، ۰/۶۹۵۷ و میزان معیار آکائیک این مدل با توجه به جدول ۴، ۲/۹۲۸

دارای بیشترین تطبیق بوده و به‌عنوان مناسب‌ترین مدل انتخاب می‌شود.

به‌منظور نمایش تطبیق مقادیر واقعی و پیش‌بینی شده نرخ نفوذ، این مقادیر به‌صورت مقایسه‌ای در شکل ۵ نشان داده شده است. همان‌طور که از شکل قابل مشاهده است، مدل سری زمانی با دقت قابل قبولی تغییرات نرخ نفوذ در سیکل‌های مختلف حفاری را پیش‌بینی می‌کند.





شکل ۵: منحنی تطبیق مقادیر واقعی با مقادیر پیش‌بینی‌شده برای بهترین مدل سری زمانی (۷ و ۵) Arma

خودهمبستگی مقادیر نرخ نفوذ نشان می‌دهد که سری زمانی تشکیل‌شده ایستا است و بنابراین می‌توان با بهره‌گیری از مدل‌های سری‌های زمانی به پیش‌بینی پرداخت. از این‌رو مدل‌های مختلفی با روش آرما به‌وسیله داده‌های نرخ نفوذ بررسی شده و مدل (۷ و ۵) Arma با توجه به معیارهای مختلف و با ضریب تطبیق ۸۷٪ به‌عنوان مدل مناسب انتخاب شده است. مقایسه مقادیر پیش‌بینی‌شده با مقادیر واقعی نرخ نفوذ نشان می‌دهد که مدل سری زمانی با دقت قابل قبولی تغییرات نرخ نفوذ در سیکل‌های مختلف حفاری را پیش‌بینی می‌کند؛ بنابراین می‌توان از مدل سری‌های زمانی در جهت پیش‌بینی نرخ نفوذ TBM استفاده نمود. مزیت استفاده از این روش نسبت به روش‌های دیگر پیش‌بینی نرخ نفوذ که در آن‌ها اثر عوامل متعددی در ارتباط با سنگ و ماشین را در نظر می‌گیرند این است که از یک‌طرف، با روش‌های پیشین اثر تمامی عوامل مؤثر را نمی‌توان به‌راحتی شناسایی و در نظر گرفت و همچنین در برخی مواقع مقادیر بعضی از عوامل مؤثر انتخاب‌شده در روش‌های گذشته در دسترس نیست. از طرف دیگر، مقدار نرخ

نتایج به‌دست‌آمده از بررسی سری‌های زمانی در جهت پیش‌بینی نرخ نفوذ TBM نشان می‌دهد که داده‌های نرخ نفوذ در سیکل‌های مختلف حفاری قابلیت مدل‌سازی با سری‌های زمانی را دارا می‌باشد و نتایج نشان می‌دهد که رویکرد سری‌های زمانی نتایج قابل قبولی از پیش‌بینی نرخ نفوذ ارائه می‌دهد. مزیت استفاده از این روش نسبت به روش‌های دیگر پیش‌بینی نرخ نفوذ، استفاده از سابقه خود پارامتر نرخ نفوذ در پیش‌بینی می‌باشد که علاوه بر در دسترس بودن مقادیر آن، به‌طور ذاتی اثر تمامی پارامترهای مؤثر بر نرخ نفوذ را نیز در برمی‌گیرد.

## ۵- نتیجه‌گیری

پارامتر نرخ نفوذ از مهم‌ترین عوامل تعیین‌کننده در عملیات تونل‌سازی می‌باشد. پیش‌بینی نرخ نفوذ در تعیین هزینه‌های پروژه و کنترل عوامل متعدد در حین عملیات حفاری بسیار حائز اهمیت است. با توجه به تناوب و تکرار مرتب سیکل‌های حفاری ماشین TBM قابلیت استفاده از مدل سری زمانی جهت پیش‌بینی نرخ نفوذ مورد توجه قرار گرفته است. نتایج تحلیل

نظر می‌رسد که استفاده از سابقه خود پارامتر نرخ نفوذ در پیش‌بینی سبب می‌شود تا علاوه بر در دسترس بودن مقادیر آن، به‌طور ذاتی اثر تمامی پارامترهای مؤثر بر نرخ نفوذ را نیز در نظر گرفت.

نفوذ در هر سیکل حفاری را می‌توان در نتیجه اثر تمامی پارامترهای مؤثر بر نرخ نفوذ در نظر گرفت و به عبارتی تفاوت مقدار نرخ نفوذ در سیکل‌های مختلف حفاری، احتمالاً ناشی از تفاوت و تغییر در پارامترهای مؤثر آن است؛ بنابراین این‌طور به

## ۶- مراجع

Underground Space Technology, 21(1), 46-55.

[12] Gong, Q., & Zhao, J. (2007). Influence of rock brittleness on TBM penetration rate in Singapore granite. *Tunnelling and underground space technology*, 22(3), 317-324.

[13] Haeri, H., & Marji, M. F. (2016). Simulating the crack propagation and cracks coalescence underneath TBM disc cutters. *Arabian Journal of Geosciences*, 9(2), 124.

[14] Haeri, H., Marji, M. F., & Shahriar, K. (2015). Simulating the effect of disc erosion in TBM disc cutters by a semi-infinite DDM. *Arabian Journal of Geosciences*, 8(6), 3915-3927.

[15] Marji, M., Hosseini Nasab, H., & Hossein Morshedi, A. (2009). Numerical modeling of crack propagation in rocks under TBM disc cutters. *Journal of Mechanics of Materials and Structures*, 4(3), 605-627.

[16] Marji, M. F. (1997). Modeling of cracks in rock fragmentation with a higher order displacement discontinuity method. PhD Thesis, Mining Engineering Department, Middle East Technical University ....

[17] Marji, M. F. (2015). Simulation of crack coalescence mechanism underneath single and double disc cutters by higher order displacement discontinuity method. *Journal of Central South University*, 22(3), 1045-1054.

[۱۸] طیرانی، ن. س. و مرچی، م. ف. (۱۳۹۲). مدل سازی انتشار ترک انشعایی زیرنافذهای کند در سنگ با استفاده از روش المان مرزی نامحدود. *نشریه علمی-پژوهشی مهندسی معدن*, ۸(۲۱), ۷۶-۸۲.

[19] Yagiz S., Gokceoglu C., Sezer E. & Iplikci S. (۲۰۰۹). Application of two non-linear prediction tools to the estimation of tunnel boring machine performance. *Engineering Applications of Artificial Intelligence*, 22, 808-814.

[20] Gholamnejad J. & Tayarani N. (2010). Application of artificial neural networks to the prediction of tunnel boring machine penetration rate. *Mining Science and Technology (China)*, 20, 727-733.

[21] Eftekhari M., Baghbanan A. & Bayati M. (2010). Predicting penetration rate of a tunnel boring machine

[1] Alber M. (2000). Advance rates of hard rock TBMs and their effects on project economics. *Tunnelling and underground space technology*, 15, 55-64.

[2] Nilsen, B., & Ozdemir, L. (1993). Hard rock tunnel boring prediction and field performance. Paper presented at the Proceedings of the rapid excavation and tunneling conference.

[3] Roxborough, F. F., & Phillips, H. R. (1975). Rock excavation by disc cutter. Paper presented at the International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts.

[4] Boyd, R. (1986). Hard rock continuous mining machine: Mobile Miner MM-120. Paper presented at the Rock excavation engineering seminar.

[5] Kahraman, S. (2002). Correlation of TBM and drilling machine performances with rock brittleness. *Engineering Geology*, 65(4), 269-283.

[6] Park, C., Park, C., Synn, J., Sunwoo, C., & Chung, S. (2001). TBM Penetration Rate with Rock Mass Properties in Hard Rock. Paper presented at the Proceedings of the AITES-ITA 2001 World Tunnel Congress, Milan.

[7] Yagiz, S. (2006). TBM performance prediction based on rock properties. *Proceedings of Multiphysics Coupling and Long Term Behavior in Rock Mechanics*, EUROCK, 6, 663-670.

[8] Yagiz, S., Rostami, J., Kim, T., Ozdemir, L., & Merguerian, C. (2009). Factors influencing performance of hard rock tunnel boring machines. Paper presented at the ISRM Regional Symposium-EUROCK 2009.

[9] Eftekhari, M., Baghbanan, A., & Bagherpour, R. (2014). The effect of fracture patterns on penetration rate of TBM in fractured rock mass using probabilistic numerical approach. *Arabian Journal of Geosciences*, 7(12), 5321-5331.

[10] Gong, Q.-M., Zhao, J., & Jiao, Y.-Y. (2005). Numerical modeling of the effects of joint orientation on rock fragmentation by TBM cutters. *Tunnelling and underground space technology*, 20(2), 183-191.

[11] Gong, Q., Jiao, Y., & Zhao, J. (2006). Numerical modelling of the effects of joint spacing on rock fragmentation by TBM cutters. *Tunnelling and*

7, 60-68.

[28] Armaghani D.J., Mohamad E.T., Narayanasamy M.S., Narita N. & Yagiz S. (2017). Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition. *Tunnelling and Underground Space Technology*, 63, 29-43.

[۲۹] کرایر، ج. و. (۱۳۸۹). تجزیه و تحلیل سری های زمانی. ترجمه حسینعلی نیرومند. انتشارات دانشگاه فردوسی، چاپ چهارم.

[۳۰] مهندسین مشاور ساحل. (۱۳۸۶). مطالعات زمین‌شناسی مهندسی مسیر تونل، گزارش ۲۰۲۶.

[۳۱] سوری، علی. (۱۳۹۱). اقتصادسنجی همراه با کاربرد Eviews. نشر فرهنگ شناسی و نشر نورعلم، چاپ سوم.

[۳۲] والتر اندرس. (۱۳۹۱). اقتصادسنجی سری های زمانی با رویکرد کاربردی (جلد اول). ترجمه مهدی صادقی. انتشارات دانشگاه امام صادق (ع)، چاپ سوم.

[۳۳] نریمانی، ا. و نریمانی، ر. (۱۳۹۴). تحلیل سری های زمانی با استفاده از Eviews و Matlab. انتشارات ناقوس، چاپ اول.

Akaike H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19, 716-723.

using artificial neural network. In: ISRM International Symposium-6th Asian Rock Mechanics Symposium. International Society for Rock Mechanics.

[22] Torabi S., Shirazi H., Hajali H. & Monjezi M. (2013). Study of the influence of geotechnical parameters on the TBM performance in Tehran-Shomal highway project using ANN and SPSS. *Arabian Journal of Geosciences*, 6, 1215-1227.

[23] Yagiz S. & Karahan H. (2011). Prediction of hard rock TBM penetration rate using particle swarm optimization. *International Journal of Rock Mechanics and Mining Sciences*, 48, 427-433.

[24] Ghasemi E., Yagiz S. & Ataei M. (2014). Predicting penetration rate of hard rock tunnel boring machine using fuzzy logic. *Bulletin of Engineering Geology and the Environment*, 73, 23-35.

[25] Gao L. & Li X.-b. (2015). Utilizing partial least square and support vector machine for TBM penetration rate prediction in hard rock conditions. *Journal of Central South University*, 22, 290-295.

[26] Fattahi H. & Moradi A. (2017). Risk Assessment and Estimation of TBM Penetration Rate Using RES-Based Model. *Geotechnical and Geological Engineering*, 35, 365-376.

[27] Minh V.T., Katushin D., Antonov M. & Veinthal R. (2017). Regression Models and Fuzzy Logic Prediction of TBM Penetration Rate. *Open Engineering*,