

## پهنه‌بندی مسیر تونل انتقال آب امیرکبیر از نقطه نظر نفوذپذیری با استفاده از روش ماشین بردار

### پشتیبان (SVM)

مریم اسماعیلی<sup>۱</sup>، علی عالی انوری<sup>۲\*</sup>، ملیحه عباس زاده<sup>۲</sup>

پذیرش مقاله: ۱۴۰۱/۰۳/۲۲

دریافت مقاله: ۱۴۰۰/۰۵/۳۰

### چکیده

یکی از مهم ترین عوامل موثر در جریان آب در توده سنگ‌ها و محیط‌های درزه‌دار نفوذپذیری توده سنگ است. با توجه به اهمیت آگاهی از مقدار آب ورودی به درون تونل‌ها، بررسی وضعیت نفوذپذیری توده سنگ‌های مسیر تونل بسیار حائز اهمیت است. از آن جا که آزمایش‌های متداول تعیین نفوذپذیری نظیر آزمایش لوژان بسیار زمان‌بر و هزینه بر هستند ضروری است تا در کوتاهترین زمان ممکن و با صرف کمترین هزینه یک دید کلی نسبت به میزان تراوایی سنگ‌های محل احداث تونل به دست آید. استفاده از روش‌های هوشمند به منظور تخمین یا طبقه‌بندی داده‌ها به ویژه در مسائل مهندسی در دهه‌های اخیر متداول بوده است. الگوریتم‌های زیادی به این منظور طراحی و بهینه‌سازی شده‌اند. از میان این روش‌ها می‌توان به الگوریتم ماشین بردار پشتیبان اشاره کرد. در این تحقیق به منظور پهنه‌بندی مسیر تونل انتقال آب امیرکبیر از نقطه نظر نفوذپذیری از روش ماشین بردار پشتیبان استفاده شده است. به منظور بهینه‌سازی پارامترهای این الگوریتم، روش جستجوی تصادفی انتخاب شده است. نتایج حاصل نشان می‌دهد که دقت مدل‌سازی صورت گرفته با استفاده از این روش بر اساس داده‌های آزمایش ۹۴/۵۹٪ است. همچنین نتایج به دست آمده نشان می‌دهند که بیش از ۸۵ درصد از مسیر تونل در رده با تراوایی کم قرار گرفته است که خطرچندانی از نظر نفوذ آب برای تونل نخواهد داشت.

**کلید واژه‌ها:** تونل امیرکبیر، نفوذپذیری، پهنه‌بندی، ماشین بردار پشتیبان

۱. دانشجوی دکتری مهندسی معدن، دانشگاه کاشان

۲. عضو هیات علمی دانشکده مهندسی، دانشگاه کاشان، ali\_aalianvari@kashanu.ac.ir

\* مسئول مکاتبات

## ۱. مقدمه

ایران در زمره کشورهای قرار گرفته است که همواره با مشکل تامین آب مواجه بوده است. توسعه تونل‌های انتقال آب یکی از راهکارهای تامین آب در ایران است. تونل‌سازی در ایران در زمره صنایع پرکاربرد با گسترش روز افزون قرار می‌گیرد. از آنجا که مقادیر بالای دبی آب زیرزمینی مشکلات عمده‌ای را هم در زمان اجرا و هم در زمان بهره‌برداری ایجاد خواهد کرد، لازم است قبل از عملیات اجرایی تونل، برآوردی از میزان نفوذ آب به درون تونل به دست آید تا قبل از شروع عملیات راهکار مناسب برای مشکلات ناشی از نفوذ آب ارائه شود (Aalianvari, 2017). از مهم‌ترین مشکلات در حین عملیات حفر تونل نشت آب به درون تونل است. بیشترین مشکلات ناشی از نشت آب به درون تونل عبارت است از: کاهش پایداری سنگ‌های اطراف تونل، اعمال فشار اضافه به نگهدارنده‌های موقت و دائم و ایجاد هزینه‌های مالی برای پروژه (Farhadian et al., 2012). هر چند که روش‌های عددی می‌توانند نشت آب در تونل را تخمین بزنند ولی استفاده از این روش‌ها مستلزم در اختیار داشتن اطلاعات کافی و مناسب از وضعیت نفوذپذیری مسیر تونل است. از طرفی روش‌های آزمایشگاهی نیز هزینه‌بر و زمان‌بر می‌باشد. بنابراین نیاز به روش‌هایی است که با سرعت و دقت مناسب بتواند تخمین اولیه‌ای از میزان نفوذ آب به داخل تونل ارائه دهد. حل مساله نشت آب به درون تونل اغلب به صورت تحلیلی مرسوم بوده است. روش‌های تحلیلی با تکیه بر معادلات حاکم بر جریان آب به سمت تونل‌ها با در نظر گرفتن پارامترهایی نظیر نفوذپذیری توده سنگ، ارتفاع سطح ایستابی، شعاع تونل و غیره به تخمین میزان نفوذ آب به تونل‌ها می‌پردازند (Aalianvari2019).

در سال ۲۰۰۵ تیفور و همکاران، با استفاده از شبکه عصبی و مصنوعی و روش المان محدود به مدل‌سازی جریان آب در سد خاکی جزبورسکو (Jeziorsko) در هلند پرداختند. سطح آب در بالا دست و پایین دست سد به عنوان ورودی و سطح آب در پیژومتر به عنوان خروجی در نظر گرفته شده است. نتایج این

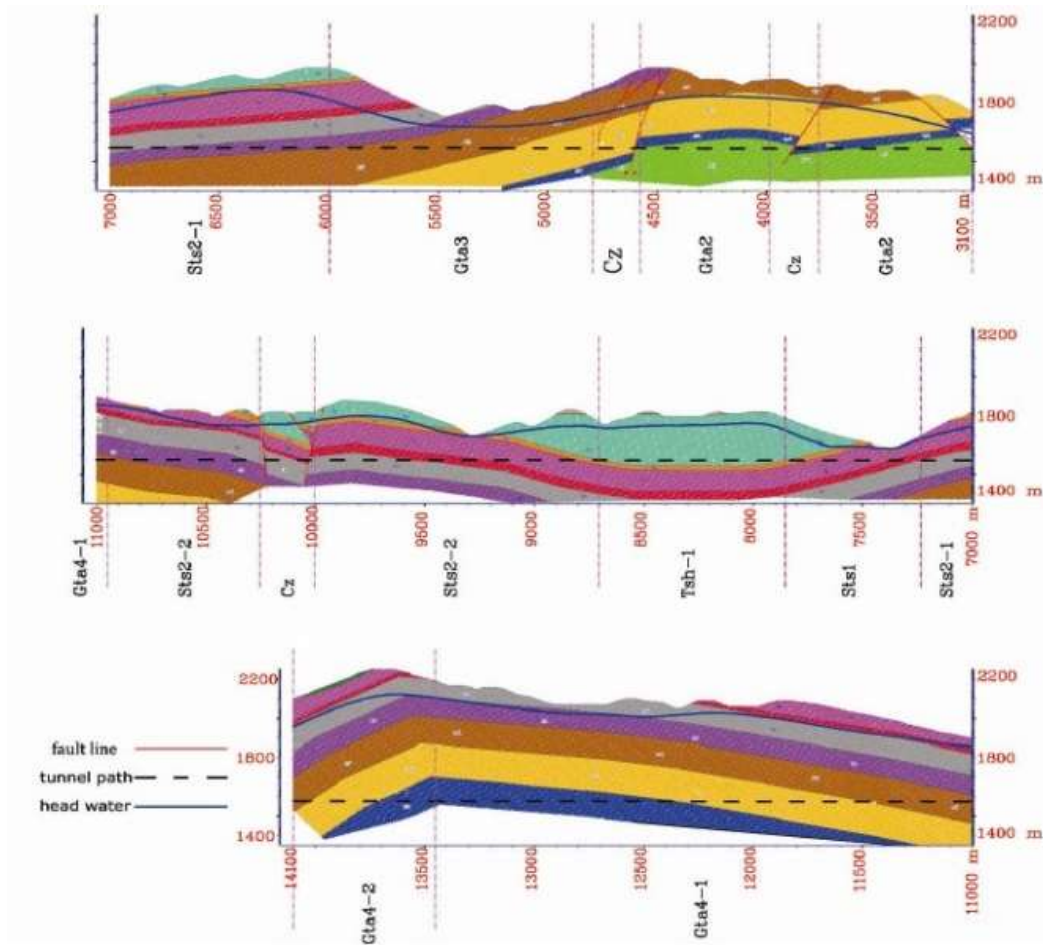
مطالعه نشان می‌دهد که مدل شبکه عصبی مصنوعی عملکرد خوبی دارد و در برخی موارد از روش المان محدود بهتر عمل می‌کند (Tayfur et al., 2005). یان و همکاران در سال ۲۰۰۶ برای تخمین میزان نفوذ آب به معادن زغال از روش ماشین بردار پشتیبان (برای مدل‌سازی یک هد آب) و روش ماشین بردار پشتیبان سلسله مراتبی (برای مدل‌سازی چندین هد آب) استفاده نمودند (Yan et al., 2006). خان و همکاران (Khan et al., 2009) برای مطالعه توزیع مکانی نشت در طول کانال آبی در استرالیا از روش‌های هوشمند (شبکه عصبی مصنوعی) و ژئوفیزیک (الکترومغناطیس) استفاده نمودند. داده‌های ورودی استفاده شده برای آموزش مدل عبارتند از: میزان تراوایی، شوری و عمق کانال نسبت به سطح آب‌های زیرزمینی منطقه مورد مطالعه. این بررسی نشان می‌دهد سالانه بیش از ۴۲ میلیون مترمکعب آب در طول ۵۰ کیلومتری کانال آب مورد بررسی از دست می‌رود. این عدد در تصمیم‌گیری‌های مرتبط با سرمایه گذاری حائز اهمیت است (Khan et al., 2009). در سال ۲۰۱۳ سانتیلان و همکاران برای آنالیز نشت آب از سد لایبلز در بارسلونا اسپانیا از روش شبکه عصبی مصنوعی استفاده کردند (Santillán et al., 2013). در سال ۲۰۱۵ بهرامی و همکاران برای شبیه‌سازی مساله نشت آب به پیت معادن روباز از یک مدل ترکیبی شامل روش شبکه عصبی و الگوریتم ژنتیک استفاده کردند. همبستگی بین داده‌های به دست آمده از برداشت‌های میدانی و داده‌های به دست آمده بسیار خوب و بالاتر از زمانی است که هر یک از این روش‌های شبکه عصبی و الگوریتم ژنتیک به صورت جداگانه استفاده شده‌اند (Bahrami et al., 2015). در سال ۲۰۱۵ فرهادیان و همکاران برای تخمین تراوایی مخازن نفتی از ترکیب داده‌های سایزمیک و روش ماشین بردار پشتیبان استفاده کردند. پاسخ‌های به دست آمده به ویژه برای زمانی که محدودیت زمان و هزینه وجود دارد اقناع کننده بود (Farhadian et al., 2015). همان‌گونه که عنوان شد الگوریتم‌های یادگیری ماشین به طور گسترده برای حل انواع مسائل طبقه‌بندی داده‌ها استفاده می‌شوند. در این مقاله تلاش شده است تا وضعیت نفوذپذیری مسیر تونل انتقال

صورت گرفته است. داده‌های برداشت شده عبارتند از: روباره، ضریب لوژن، هد آب، نفوذ، ضریب سختی درزه، و تراوایی. در مطالعات زمین‌شناسی ۱۴ واحد زمین‌شناسی در مسیر تونل مشخص شده‌است. که شامل مجموعه‌های رسوبی-آتشفشانی سازند کرج می‌باشد. و از لحاظ سنگ‌شناسی شامل لایه‌های توف، ماسه سنگ، کنگلومرا ریزدانه، سیلت استون، گدازه‌های لاوا و آگلومرامی باشد (Farhadian et al., 2015). نیم‌رخ زمین-شناسی تونل امیرکبیر در شکل ۱ نشان داده شده است

آب امیرکبیر با استفاده از روش‌های هوشمند مورد بررسی قرار گرفته و مسیر تونل با توجه به وضعیت نفوذپذیری پهنه‌بندی شود.

## ۲. موقعیت جغرافیایی و زمین‌شناسی

تونل انتقال آب امیرکبیر با طولی در حدود ۳۰ کیلومتر به منظور انتقال آب از سد امیرکبیر کرج به تهران در رشته کوه‌های البرز در ایران احداث شده‌است. به منظور بررسی وضعیت نفوذپذیری مسیر تونل در ۱۱۰ نقطه در مسیر نمونه‌برداری



شکل ۱. نیم‌رخ زمین‌شناسی مهندسی تونل انتقال آب امیرکبیر - کیلومتر ۳/۱ تا ۱۴/۱ (Farhadian et al., 2015).

جدول ۱. ۹ واحد اصلی زمین شناسی مهندسی در کیلومتر ۳/۱ تا ۱۴/۱ تونل انتقال آب امیرکبیر (Farhadian et al., 2015)

Symbol	Description
Gta4-2	tuff, some parts of sandstone and microconglomerate
Sts1	Siliceous green tuff and sandstone
Sts2-1	Green vitric and lithic tuff and siltstone
Sts2-2	Tuff, Limestone with sandstone layer and microconglomerate
Tsh-1	Light cream lithic and vitric tuff
Cr	Sandstone, green vitric tuff and siliceous tuff

جدول ۲. خلاصه اطلاعات آماری داده‌های مورد بررسی

Max	Min	standard deviation	Average	Parameter
660.0	65.0	137.7	320.6	Overburden(m)
23.45	0	5.2	4.4	Lugeon
535.0	55.0	126.5	251.8	Head of water above tunnel(m)
11.0	1.0	3.2	8.5	JRC
10.0	0.01	1.8	0.5	Aperture(mm)
2.35e-06	5e-08	5.2e-07	4.56e-07	Permeability(m/s)

جدول ۳. خلاصه ای از داده‌های مورد استفاده در مدلسازی این تحقیق


Chainage(m)	Unit	Head of water(m)	Permeability(1e-7)
3100-3300	Gta2	115	8
3300-3860	Gta2	195	8
3860-3920	Crz- Gta2	240	15
3920-4500	Gta2	259	6
4500-4610	Gta2	230	6
4610-4770	Crz	185	20
4770-6020	Gta3	138	3
6020-7250	Sts2-1	235	1
7250-7770	Sts1	76	2
7770-7850	Sts1	150	23
7850-8710	Tsh-1	178	3
8710-10020	Sts2-2	173	1
10020-10240	Crz	185	20
10240-10870	Sts2-2	204	1
10780-13400	Gta4-1	403	1
13400-14100	Gta4-2	495	1

## ۳. مواد و روش‌ها

به ۹ بخش تقسیم کرد. این ۹ بخش با علائم اختصاری که شرح آن در جدول ۱ آورده شده است مشخص شده‌اند: مساله مورد بررسی پهنه‌بندی تراوایی در طول تونل انتقال آب امیرکبیر در ۳ کلاس تراوایی متوسط، تراوایی کم و تراوایی

برداشت‌ها در فاصله ی ۳/۱ تا ۱۴/۱ کیلومتری تونل انجام شده‌است. این فاصله را می‌توان از دیدگاه زمین‌شناسی مهندسی

صورت فاصله موجود بین ابرصفحه و نزدیکترین نمونه آموزشی تعریف می‌شود (Shahrabi and Zolghadr Shojaei, 2009). ابر صفحه منجر به حداکثر شدن تفکیک بین کلاس‌ها خواهد شد (شکل ۲) (Salahshoor et al., 2010, Taboada et al., 2006).



شکل ۲. نمایش ابرصفحه‌های مختلفی که امکان جدا کردن داده‌ها را می‌دهند. شکل سمت راست ابرصفحه بهینه را که حداکثر حاشیه و در نتیجه حداکثر شدن تفکیک بین کلاس‌ها را به دنبال دارد نشان می‌دهد (Luts et al., 2010).

به بیان ریاضی در ماشین بردار پشتیبان خطی فرض می‌کنیم  $l$  مشاهده داریم که هر مشاهده مشتمل بر زوج های  $(x_i, y_i)$  است که در آن  $x_i \in R^n$  و  $y_i \in \{-1, 1\}$  بردارهای ورودی و یک مقدار دو وضعیتی برای خروجی مدل و به صورت  $y_i \in \{-1, 1\}$  است. بر این اساس می‌توان مجموعه‌ای از این ابرصفحات را بصورت زیر نشان داد (Zuo and M.Carranza, 2011).

$$\begin{aligned} wx_i + b &\geq +1 & \text{for } y_i = +1 \\ wx_i + b &\leq -1 & \text{for } y_i = -1 \end{aligned} \quad (1)$$

که به صورت معادل می‌توان نوشت:

$$y_i(wx_i + b) \geq 1, \quad i = 1, 2, \dots, l \quad (2)$$

که در آن  $w$  بردار وزن و  $b$  مقدار بایاس می‌باشد. همچنین ابر صفحه را می‌توان به صورت تابع تصمیم زیر نوشت:

$$f(x) = \text{sgn}(wx + b) \quad (3)$$

که در آن  $\text{sgn}$  تابع علامت بوده و به صورت زیر تعریف می‌شود:

$$\text{sgn}(x) = \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{if } x = 0 \\ -1, & \text{if } x < 0 \end{cases} \quad (4)$$

دو مؤلفه یا پارامتر در تابع تصمیم ابر صفحه عبارتند از  $w$  و  $b$  که می‌توان آنها را از حل تابع بهینه‌سازی زیر به دست آورد:

خیلی کم می‌باشد. به منظور انجام طبقه‌بندی مذکور در محدوده مورد بررسی الگوریتم ماشین بردار پشتیبان طبقه‌بندی کننده استفاده شده است. انتخاب پارامترهای بهینه برای الگوریتم SVM در این تحقیق توسط تکنیک جستجوی تصادفی (Random Search) انجام شده است. کلید محاسبات در نرم افزار داده کاوی Weka نسخه ۳.۸ انجام گرفته است.

### ۳-۱. داده‌ها

داده‌های مورد بررسی عبارتند از: روباره، ضریب لوژن، ارتفاع آب بالای تونل، بازشدگی، ضریب زبری درزه (JRC)، و تراوایی. طبقه‌بندی تراوایی هدف این مدل‌سازی می‌باشد. خلاصه اطلاعات آماری داده‌های مورد استفاده در جدول ۲ آمده است:

### ۳-۲. ماشین‌های بردار پشتیبان

در اواخر سال ۱۹۹۰ میلادی وینیک روش ماشین بردار پشتیبان را برای حل مسائل طبقه‌بندی دوتایی ارائه کرد (Cortes et al., 1990). در طبقه‌بندی به روش ماشین بردار پشتیبان ابتدا مدل که مجموعه‌ای از قوانین است بر اساس مجموعه‌ای از داده‌های آموزشی ساخته می‌شود. مجموعه داده‌های استفاده شده برای یادگیری مدل، داده‌های آموزشی و داده‌هایی که برای اندازه‌گیری کیفیت و کارایی مدل بکار می‌روند داده‌های آزمایش نام دارند (Thabtah and Cowling, 2007).

مفهوم کلیدی ماشین‌های بردار پشتیبان، استفاده از ابرصفحه (Hyperplane) در تعریف مرزهای جدا کننده بین نقاط آموزشی در کلاس‌های مختلف است (Luts et al., 2010). نزدیکترین نقاط آموزشی به صفحه جدا کننده بهینه، بردارهای پشتیبان گفته می‌شود. سایر نقاط آموزشی برای تعیین مرز بین کلاس‌ها مناسب نخواهند بود و تنها از بردارهای پشتیبان (نقاط مرزی) می‌توان برای مشخص کردن مرز بین کلاس‌ها استفاده کرد (Shin et al., 2005).

در روش ماشین بردار پشتیبان به دنبال مدلی هستیم که بیشترین حاشیه (Maximal Margin) ابرصفحه را در فضای ویژگی (Feature Space) ایجاد کنند. حاشیه از دیدگاه هندسی به

$$b^* = 1 - w^* x_s \quad \text{for} \quad y_s = +1 \quad (11)$$

معادله ابر صفحه را نیز می توان به صورت زیر نوشت (Zuo and M.Carranza, 2011):

$$f(x) = \text{sgn} \left( \sum_{i=1}^l y_i \alpha_i (x x_i) + b \right) \quad (12)$$

برای حل مسائلی که به صورت خطی جدایی پذیر نیستند می توان با اعمال پیش پردازش داده ها، مسئله را به فضایی برد که در آنجا با یک ابر صفحه ساده قابل حل باشد. برای این منظور یک نگاشت  $\varphi(x)$  تعریف می کنیم که بردار ورودی  $d$  بعدی  $x$  را به بردار  $d'$  بعدی  $z$  تبدیل می کند:

$$\varphi: R^d \rightarrow R^{d'} \quad (13)$$

$\varphi(x)$  باید به گونه ای انتخاب شود که بردارهای فضای ویژگی جدید تفکیک پذیر باشند. در فضای جدید برای داشتن مسئله بهینه سازی، به راحتی بجای  $x$  مقدار  $\varphi(x)$  را قرار می دهیم:

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\varphi(x_i) \cdot \varphi(x_j)) \quad (14)$$

با شرط

$$\alpha_i \geq 0, \quad i = 1, \dots, l, \quad \text{و} \quad \sum_{i=1}^l \alpha_i y_i = 0$$

در این حالت شکل تابع ابر صفحه جدا کننده به صورت زیر خواهد شد:

$$f(x) = \text{sgn} \left( \sum_{i=1}^l y_i \alpha_i (\varphi(x) \cdot \varphi(x_i)) + b \right) \quad (15)$$

همیشه ترکیبی از دو  $\varphi(x)$ ، به صورت ضرب نقطه ای در کنار هم ظاهر می شود. پس اگر بتوان تابعی مانند تابع زیر را برای ضرب نقطه ای در فضای ویژگی جدید با ابعاد بالاتر پیدا کرد، دیگر هیچ نیازی نخواهد بود که خود را مستقیماً با نگاشت  $\varphi(x)$  درگیر کنیم:

$$K(x_a, x_b) = \varphi(x_a) \cdot \varphi(x_b) \quad (16)$$

به این توابع، توابع کرنل گفته می شود. در این حالت فرم تابع ابر صفحه جدا کننده بصورت زیر خواهد بود (Zuo and M.Carranza, 2011):

$$f(x) = \text{sgn} \left( \sum_{i=1}^l y_i \alpha_i K(x_i, x) + b \right) \quad (17)$$

متداول ترین انواع تابع کرنل در جدول ۴ آورده شده است. انتخاب توابع کرنل بستگی به ماهیت مسئله و نوع داده ها دارد.

$$\text{Minimize } \tau(w) = \frac{1}{2} \| w \|^2 \quad (5)$$

که در این شرایط قید زیر را خواهیم داشت:

$$y_i((w x_i) + b) \geq 1, \quad i = 1, \dots, l$$

معادله (۵) را که مسئله اولیه (Primal Problem) خوانده می شود می توان با استفاده از ضرایب لاگرانژ حل کرد. در این صورت تابع هدف اصلی به صورت زیر نوشته می شود:

$$L(w, b, \alpha) = \frac{1}{2} \| w \|^2 - \sum_{i=1}^l \alpha_i (y_i((x_i w) + b) - 1) \quad (6)$$

که در آن  $\alpha_i$  ضریب افزایشنده لاگرانژ است. با مشتق گیری از  $L(w, b, \alpha)$  نسبت به  $w$  و  $b$  و برابر با صفر قرار دادن نتایج، دو شرط بهینگی زیر به دست خواهد آمد:

$$\frac{\partial}{\partial b} L(w, b, \alpha) = 0 \quad (7)$$

$$\frac{\partial}{\partial w} L(w, b, \alpha) = 0$$

تابع لاگرانژ باید نسبت به متغیرهای  $w$  و  $b$  مینیمم و نسبت به  $\alpha_i$  ماکزیمم شود. در ادامه خواهیم داشت:

$$\begin{cases} w = \sum_{i=1}^l \alpha_i y_i x_i \\ \sum_{i=1}^l \alpha_i y_i = 0 \end{cases} \quad (8)$$

ضریب افزایشنده  $\alpha_i$  با استفاده از تابع بهینه سازی زیر که به عنوان مسئله دوگان (Dual Problem) شناخته می شود و با توجه به معادله (۶) و (۸) تعیین می گردد:

$$\max_{\alpha} w(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (9)$$

با شرط

$$\alpha_i \geq 0, \quad i = 1, \dots, l, \quad \text{و} \quad \sum_{i=1}^l \alpha_i y_i = 0$$

پس از تعیین ضریب لاگرانژ بهینه  $\alpha_i^*$  می توان بردار وزن بهینه یعنی  $w^*$  را به کمک معادله (۸) محاسبه نمود:

$$w^* = \sum_{i=1}^l \alpha_i^* y_i x_i \quad (10)$$

سپس با کمک بردار پشتیبانی مثبت  $x_s$  می توان مقدار بهینه اسکالر  $b$  را به صورت زیر تعیین کرد:

#### ۴.۱. پیاده سازی الگوریتم طبقه‌بندی SVM

کتابخانه LiBSVM یک کتابخانه کارا و سریع برای مدل ماشین بردار پشتیبان (SVM) می‌باشد که از سال ۲۰۰۰ توسعه یافته و استفاده گسترده‌ای در اکثر پژوهش‌ها دارد. ماشین بردار پشتیبان یک دسته‌بندی کننده باینری می‌باشد اما LiBSVM حالت چند کلاسه را نیز پشتیبانی میکند. روند معمول استفاده از LiBSVM در دو گام خلاصه میشود: (۱) آموزش با استفاده از داده های آموزشی برای به دست آوردن مدل (۲) استفاده از مدل برای پیش بینی داده های آزمایشی.

برای آموزش مدل پیشنهادی SVM از داده‌های روبراه، ضریب لوژن، هد آب، نفوذ و ضریب سختی درزه برای مدلسازی تراوایی استفاده شده است. جهت مدلسازی از داده‌های ۱۱۰ نقطه برداشت شده در امتداد تونل استفاده شده است که از این تعداد ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد آن برای آزمایش در نظر گرفته شده است. به منظور مدلسازی به روش ماشین بردار پشتیبان لازم است تا در ابتدا پارامترهای مدل شامل پارامتر پنالتی  $C$  و پارامتر  $\gamma$  (پارامتر مرتبط با تابع کرنل پایه شعاعی) تعیین شود. روش‌های بسیاری برای بهینه‌سازی پارامترهای مدل ماشین بردار پشتیبان ارائه شده است. از جمله این روش‌ها می‌توان به روش جستجوی شبکه ای (Grid Search) و روش جستجوی تصادفی اشاره کرد. برای تعیین مقادیر بهینه پارامترهای مدل در این مطالعه از روش جستجوی تصادفی استفاده شده است. روش جستجوی شبکه‌ای اساساً یک روش جستجوی فراگیر است که بر پایه زیرمجموعه‌هایی از فضای ابر پارامترها تعریف می‌شود. ابر پارامترها با استفاده از مقدار کمینه (کران پایین)، مقدار بیشینه (کران بالا) و تعداد گام‌ها مشخص می‌شوند. یک جایگزین ساده برای جستجوی شبکه-ای، جستجوی تصادفی است. همانطور که از نام آن پیداست، نمونه‌های جستجوی تصادفی به طور تصادفی تنظیم می‌شوند تا زمانی که زیر مجموعه های در نظر گرفته شده برای جستجو تمام شود. این روش نسبت به روش جستجوی شبکه‌ای برای محاسبات به زمان کمتری نیاز دارد. در تعیین پارامترهای بهینه مدل همواره از روش اعتبارسنجی متقابل (Cross Validation)

پارامترهای  $\gamma$ ،  $r$  و  $d$  در جدول، پارامترهای کرنل نامیده می‌شوند.

جدول ۴. متداول‌ترین توابع کرنل بکار گرفته شده در مسائل تفکیک‌ناپذیر خطی (Zuo and M.Carranza, 2011).

Kernel Function	Type
$K(x_i, x_j) = \gamma x_i x_j$	Linear
$K(x_i, x_j) = (\gamma x_i x_j + r)^d, \gamma > 0$	Polynomial
$K(x_i, x_j) = \exp\{-\gamma \ x_i - x_j\ ^2\}, \gamma > 0$	Radial Basis
$K(x_i, x_j) = \tanh(\gamma x_i x_j + r), \gamma > 0$	Sigmoid

تابع کرنل انتخاب شده در این پژوهش تابع Radial Basis Function (RBF) است. به طور کلی انتخاب تابع RBF به عنوان هسته یک انتخاب اولیه منطقی است. این تابع غیر خطی نمونه‌ها را به فضایی با ابعاد بالاتر نگاشت می‌کند، بنابراین، برخلاف کرنل خطی می‌تواند مواردی که رابطه بین ورودی‌های مدل خطی نیست را مدیریت کند. با در نظر گرفتن تابع RBF به عنوان تابع کرنل، بنابراین لازم است مقادیر بهینه پارامتر پنالتی  $C$  و پارامتر  $\gamma$  (پارامتر مرتبط با تابع کرنل) تعیین شود.

#### ۴. بحث و نتایج

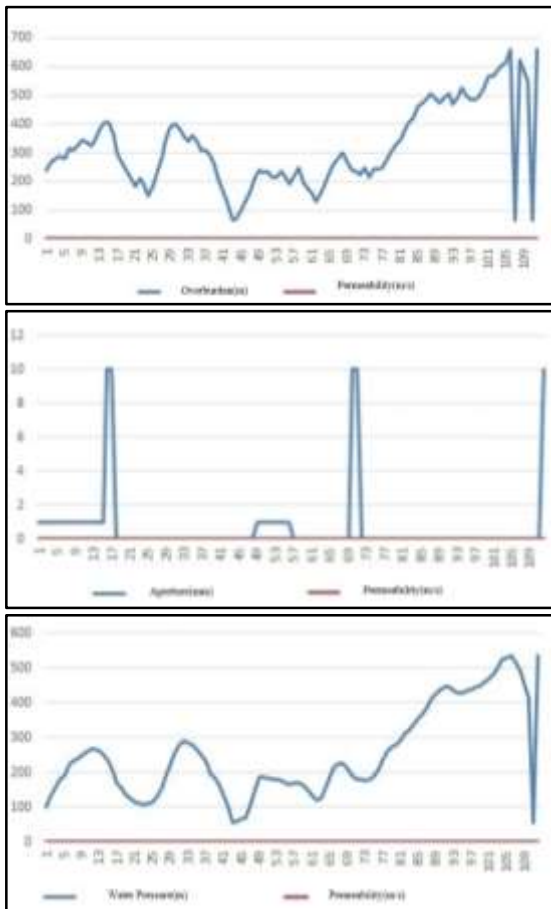
به منظور طبقه‌بندی کلاس تراوایی، ابتدا تراوایی طبق جدول (۵) در سه کلاس تراوایی متوسط، تراوایی کم و تراوایی بسیار کم مشخص شده است.

جدول ۵. طبقه‌بندی تراوایی منطقه مورد بررسی

Class	Permeability(Range)
Medium Permeability(MP)	>۱۰-۶
Low Permeability(LP)	۱۰-۷ ≤ ۱۰-۶
Very Low Permeability(VLP)	<۱۰-۷

به منظور به کارگیری روش SVM برای طبقه‌بندی تراوایی در سه کلاس تراوایی متوسط، تراوایی کم و تراوایی بسیار کم لازم است که مدل با استفاده از داده‌های ورودی و خروجی مناسب در محیط نرم افزار Weka آموزش داده شود. برای بهترین طبقه‌بندی لازم است تا پارامترهای مدل بهینه گردد. در پایان با مقایسه نتایج به دست آمده از مدلسازی و درصد طبقه‌بندی صحیح می‌توان کارایی مدل را مورد سنجش قرار داد.

که گفته شد پیش از طبقه‌بندی داده‌ها با توجه به جدول شماره ۵ در سه کلاس تراوایی متوسط، تراوایی کم و تراوایی بسیار کم طبقه‌بندی شده‌اند. با بررسی نمودار فراوانی کلاس تراوایی در ارتباط با هر یک از ۳ پارامتر روباره، بازشدگی و ارتفاع آب بالای تونل، قبل و بعد از طبقه‌بندی، می‌توان عملکرد الگوریتم ماشین بردار پشتیبان در پهنه‌بندی تونل انتقال آب امیرکبیر را مورد بررسی قرار داد. نمودار فراوانی کلاس تراوایی در ارتباط با هر یک از این پارامترها در شکل ۳ آمده است:



شکل ۳. (۱) نمایش رابطه روباره و تراوایی، (۲) رابطه بازشدگی و تراوایی (۳) رابطه ارتفاع آب بالای تونل و تراوایی در تونل انتقال آب امیرکبیر

استفاده می‌شود چراکه یکی از روش‌های عملی برای مقابله با بیش‌برازشی (Over Fitting) یا کم‌برازشی (Under Fitting)، روش اعتبارسنجی متقابل است که در آن بخشی از داده‌های آموزشی که به آن مجموعه اعتبارسنجی گفته می‌شود، برای بررسی عملکرد آموزش مدل مورد استفاده قرار می‌گیرد. در جدول ۶ نتایج حاصل از مدل‌سازی به روش ماشین بردار پشتیبان طبقه‌بندی کننده آورده شده است.

#### ۴.۲. صحت سنجی نتایج حاصل از طبقه‌بندی به روش

##### ماشین بردار پشتیبان بر اساس داده‌های برداشت شده

در بخش قبلی عملکرد الگوریتم ماشین بردار پشتیبانی که پارامترهای آن به روش جستجوی تصادفی بهینه شده بودند و جداسازی داده‌ها به روش اعتبارسنجی متقابل انجام شده بود، آورده شد. لازم است بررسی شود که نتایج حاصل، داده‌های مربوط به تونل امیرکبیر را چگونه از لحاظ کلاس تراوایی طبقه‌بندی می‌کند و آیا این سطح از دقت برای بررسی‌های کارشناسی کافی است یا خیر؟ بنابراین از مدل ساخته شده در قسمت قبل برای پهنه‌بندی تونل انتقال آب امیرکبیر استفاده شده است.

#### جدول ۶. دقت مدل‌سازی به روش SVM برای طبقه‌بندی


##### تراوایی

Accuracy of test data	Accuracy of training data	
٪۹۰/۹۰	٪۹۴/۵۹	Accuracy
۲۲	۸۸	Number of Date
۰/۲۳	۰/۳۵	Calculation time (s)

به منظور بررسی نتایج قبل و بعد از طبقه‌بندی می‌توان از سه پارامتر ارتفاع آب بالای تونل، روباره و بازشدگی که در ارتباط با تراوایی هستند استفاده نمود. رابطه هر یک از این پارامترها با تراوایی در شکل ۲ آورده شده است.

در شکل ۳ مشاهده می‌شود که تراوایی طیف وسیعی از اعداد را به خود اختصاص می‌دهد و در ارتباط با هر سه پارامتر یاد شده تغییرات زیادی دارد و دارای روند نمی‌باشد. همان‌گونه





شکل ۵. نمایش (۱) رابطه روباره و کلاس تراوایی بعد از پهنه‌بندی، (۲) رابطه بازشدگی و کلاس تراوایی بعد از پهنه‌بندی (۳) رابطه ارتفاع آب بالای تونل و کلاس تراوایی بعد از پهنه‌بندی در تونل انتقال آب امیرکبیر

شکل ۴ - (۱) نمایش رابطه روباره و کلاس تراوایی، (۲) رابطه بازشدگی و کلاس تراوایی (۳) رابطه ارتفاع آب بالای تونل و کلاس تراوایی در تونل انتقال آب امیرکبیر

با مقایسه شکل ۴ و شکل ۵ مشاهده می‌شود که تغییرات کلاس فراوانی تراوایی قبل و بعد از فراوانی اندک و قابل چشم پوشی و عمدتاً در ارتباط با داده‌های دارای تراوایی کم و متوسط می‌باشد. الگوی کلی فراوانی داد ها نیز تغییر زیادی نداشته است و قابل چشم پوشی می‌باشد

نمودار فراوانی کلاس تراوایی بعد از طبقه‌بندی داده‌ها در ارتباط با هر یک از این سه پارامتر روباره، بازشدگی و ارتفاع آب بالای تونل بعد از طبقه‌بندی در شکل ۵ آورده شده است:

۵. نتیجه گیری یکی از نقاط قوت به کارگیری الگوریتم SVM به همراه روش جستجوی تصادفی برای طبقه بندی، زمان پردازش بسیار کم در کنار نتایجی با دقت قابل قبول می باشد. در این جا به منظور پهنه بندی مسیر تونل انتقال آب امیرکبیر از نقطه نظر نفوذپذیری از روش ماشین بردار پشتیبان استفاده شده است. به منظور بهینه سازی پارامترهای این الگوریتم، روش جستجوی تصادفی انتخاب شده است. برای جداسازی داده ها نیز از روش اعتبارسنجی متقابل استفاده شده است. نتایج حاصل نشان می دهد که الگوریتم طبقه بندی را با دقتی معادل ۸۶/۳۶٪ انجام داده است. زمان اندک محاسبات، دقت بالای طبقه بندی به همراه کاهش چشمگیر هزینه آزمایشهای مربوطه، این روش را به گزینه یخوبی در بررسی های اولیه تبدیل می کند. بررسی نمودارهای کلاس فراوانی تراوایی در ارتباط با روباره، بازشدگی و ارتفاع آب بالای تونل و همچنین ماتریس در-هم ریختگی نشان می دهد که الگوی کلی فراوانی کلاس تراوایی پس از طبقه بندی حفظ شده است و خطای طبقه بندی ( معادل ۳/۶۴٪) اندک و قابل چشم پوشی می باشد.

در مواقعی که دقت و صحت تشخیص یک دسته در مقایسه با دقت و صحت تشخیص کلی، اهمیت بیشتری دارد، از مفهوم ماتریس درهم ریختگی ( Confusion Matrix) استفاده می شود. بر اساس این ماتریس، الگوریتم به کار گرفته شده ۹۵ نقطه را در طبقه تراوایی بسیار کم، ۱۲ نقطه را در طبقه تراوایی کم و ۳ نقطه را در طبقه تراوایی متوسط جای داده است. دقت طبقه بندی ۸۶/۳۶٪ می باشد. بررسی نمودارهای نمایش رابطه روباره و کلاس تراوایی، رابطه بازشدگی و کلاس تراوایی و رابطه ارتفاع آب بالای تونل و کلاس تراوایی قبل و بعد از طبقه بندی تفاوت چشمگیری ندارد. به گونه ای که الگوی کلی رابطه کلاس تراوایی با سه پارامتر ارتفاع آب بالای تونل، روباره و بازشدگی حفظ شده است. و به لحاظ کیفی خطای طبقه بندی در تفسیر نتایج تاثیر کمی دارد. از لحاظ کمی نیز در داده های اولیه ۹۱ نقطه دارای تراوایی بسیار کم می باشند که مدل ماشین بردار پشتیبان پیشنهادی تعداد این نقاط را ۹۵ نقطه تخمین زده است. همچنین در داده های اولیه ۱۴ نقطه به کلاس تراوایی کم و ۵ نقطه به کلاس تراوایی متوسط تعلق دارد که مدل ماشین بردار پشتیبان پیشنهادی، تعداد نقاط دارای تراوایی کم را ۱۲ نقطه و تعداد نقاط دارای تراوایی متوسط را ۳ نقطه تخمین زده است.

## منابع

- Aalianvari, A., 2017. Combination of engineering geological data and numerical modeling results to classify the tunnel route based on the groundwater seepage. *Geomechanics and Engineering*, 13(4), p.671
- Aalianvari, A., 2019. Review on Hydraulic Behavior of faults and models. *Scientific Quarterly Journal of Iranian Association of Engineering Geology*, 12(3), pp.57-64
- Aalianvari, Ali, Saeed Soltani-Mohammadi, and Zeynab Rahemi.,2018. "Estimation of geomechanical parameters of tunnel route using geostatistical methods." *Geomechanics and Engineering* 14.5 : 453-458.
- Anifowose, F., Abdulraheem, A., and Al-Shuhail, A.; 2019; "A Parametric Study of Machine Learning Techniques in Petroleum Reservoir Permeability Prediction by Integrating Seismic Attributes and Wireline Data," *J. Pet. Sci. Eng.*, 176, pp. 762–774.
- Bahrami, S., Ardejani, F. D., and Baafi, E.; 2016; "Application of Artificial Neural Network Coupled with Genetic Algorithm and Simulated Annealing to Solve Groundwater Inflow Problem to an Advancing Open Pit Mine," *J. Hydrol.*, 536, pp. 471–484.
- Bergstra, J., and Bengio, Y.; 2012; "Random Search for Hyper-Parameter Optimization," *J. Mach. Learn. Res.*, 13(1), pp. 281–305.
- Cortes, C., and Vapnik, V.; 1995; "Support-Vector Networks," *Mach. Learn.*, 20(3), pp. 273–297.

- Farhadian, H., Aalianvari, A., and Katibeh, H.; 2012; "Optimization of Analytical Equations of Groundwater Seepage into Tunnels: A Case Study of Amirkabir Tunnel," *J. Geol. Soc. India*, 80(1), pp. 96–100.
- Farhadian, H., and Katibeh, H.; 2015; "Groundwater Seepage Estimation into Amirkabir Tunnel Using Analytical Methods and DEM and SGR Method," *World Acad. Sci. Eng. Technol. Int. J. Civil, Struct. Constr. Archit. Eng.*, 9(3).
- Khan, S., Rana, T., Dassanayake, D., Abbas, A., Blackwell, J., Akbar, S., and Gabriel, H. F.; 2009; "Spatially Distributed Assessment of Channel Seepage Using Geophysics and Artificial Intelligence," *Irrig. Drain. J. Int. Comm. Irrig. Drain.* 58(3), pp. 307–320.
- KHOSHRO, M. S. 2010. Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy inference system) classifiers. *Energy* 35 5472-5482
- LUTS, J., OJEDA, F., PLAS, R. V. D., MOOR, B. D., HUFFEL, S. V. & SUYKENS, J. A. K. 2010. A tutorial on support vector machine-based methods for classification problems in chemometrics. *Analytica Chimica Acta* 665 129–145.
- Petropoulos, G. P., Kalaitzidis, C., and Vadrevu, K. P.; 2012; "Support Vector Machines and Object-Based Classification for Obtaining Land-Use/Cover Cartography from Hyperion Hyperspectral Imagery," *Comput. Geosci.* 41, pp. 99–107.
- Santillán, D., Fraile-Ardanuy, J., and Toledo, M. Á.; 2013; "Dam Seepage Analysis Based on Artificial Neural Networks: The Hysteresis Phenomenon," *The 2013 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8.
- SHAHRAFI, J. & ZOLGHADR SHOJAEI, A. 2009. *Advanced Data Mining: Concepts & Algorithms*, Tehran, Iranian Academic Center for Education Culture and Research, AmirKabir Branch. (in Persian)
- SHIN, K.-S., LEE, T. S. & KIM, H.-J. 2005. An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications* 28, 127–135
- Tayfur, G., Swiatek, D., Wita, A., and Singh, V. P.; 2005; "Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziorsko Earthfill Dam in Poland," *J. Hydraul. Eng.*, 131(6), pp. 431–440.
- THABTAH, F. A. & COWLING, P. I. 2007. A greedy classification algorithm based on association rule. *Applied Soft Computing* 7 1102–1111
- XU, C., and XU, X.; 2012; "Spatial Prediction Models for Seismic Landslides Based on Support Vector Machine and Varied Kernel Functions: A Case Study of the 14 April 2010 Yushu Earthquake in China," *Chinese J. Geophys.*, 55(6), pp. 666–679.
- Yan, Z.-G., Zhang, H.-R., and Du, P.-J.; 2006; "Application of SVM in Analyzing the Headstream of Gushing Water in Coal Mine," *J. China Univ. Min. Technol.*, 16(4), pp. 433–438
- ZUO, R. & M.CARRANZA, E. J. 2011. Support vector machine: A tool for mapping mineral prospectivity. *Computers & Geosciences*, 37, 1967–1975