

## به کارگیری الگوریتم‌های یادگیری ماشین نظارت‌شده ماشین بردار پشتیبان و جنگل تصادفی به منظور پیش‌بینی مقاومت و روانی مارشال آسفالت

تاریخ دریافت: ۱۴۰۰/۰۸/۲۸

تاریخ پذیرش: ۱۴۰۰/۰۹/۲۹

کد مقاله: ۲۵۵۷۷

حسن حسین زاده<sup>۱\*</sup>، علیرضا حسینی<sup>۲</sup>، سینا آرمان<sup>۳</sup>

### چکیده

هدف اصلی این تحقیق استفاده از الگوریتم‌های ماشین بردار پشتیبان و جنگل تصادفی به منظور پیش‌بینی مقاومت و روانی مارشال مخلوط آسفالتی می‌باشد. با این هدف، ۲۱۶ نمونه به روش طرح اختلاط مارشال با شش درصد قیر متفاوت از ۳٫۵ تا ۶ و حاوی ۲، ۴، ۶ و ۸ درصد از فیلر رایج بین گرم، خاکستر پوسته برنج و خاکستر بادی به‌طور جداگانه ساخته شد و نتایج با یکدیگر مقایسه گردید. نتایج نشان داد که جایگزینی فیلر رایج با RHA و FA خواص مارشال را بهبود می‌بخشد و مقادیر قیر بهینه مخلوط اصلاح‌شده را کاهش می‌دهد. در این پژوهش با استفاده از پارامترهای مارشال اندازه‌گیری شده‌ی ۷۲ نمونه شامل نوع فیلر، درصد فیلر، درصد قیر، وزن مخصوص، درصد فضای خالی، فضای خالی سنگ‌دانه و فضای خالی پر شده با قیر و با به کارگیری مدل‌های SVM و RF، مقاومت و روانی مارشال مدل‌سازی شد. ۷۰ درصد نمونه‌ها برای آموزش مدل و ۳۰ درصد نمونه به‌منظور ارزیابی مدل‌های ساخته‌شده مورد استفاده قرار گرفت. نزدیک بودن نتایج حاصل مدل‌ها و مقادیر واقعی نشان‌دهنده عملکرد مثبت مدل‌ها در پیش‌بینی مقاومت و روانی مارشال آسفالت است. مقدار ضریب تعیین برای مدل‌سازی مقاومت مارشال برای مدل SVM و RF به ترتیب ۰٫۸۷۵ و ۰٫۸۲ و برای مدل‌سازی روانی مارشال به ترتیب ۰٫۸۷۱ و ۰٫۸۱ به دست آمد. می‌توان از این روش‌ها به‌منظور اجتناب از آزمایش‌های وقت‌گیر و مکرر آزمایشگاهی بهره برد.

**واژگان کلیدی:** ماشین بردار پشتیبان، جنگل تصادفی، طرح اختلاط مارشال، خاکستر پوسته برنج، خاکستر بادی.

۱- دانشجوی کارشناسی ارشد مهندسی عمران گریش راه و ترابری، کارشناس تحقیق و توسعه سازمان عمران شهرداری مشهد

(نویسنده مسئول) hosseinzadeh-ha@mashhad.ir

۲- کارشناس مسئول امور تحقیق و توسعه سازمان عمران شهرداری مشهد

۳- رییس اداره برنامه ریزی و توسعه سرمایه انسانی سازمان عمران شهرداری مشهد

رشد زیاد تعداد وسایل نقلیه و بارهای محورها مستلزم افزایش بیشتر شبکه جاده‌ها و در نتیجه مصالح طبیعی مورد استفاده در ساخت آن است (Al-Humeidawi & Mandal, 2018; Al-Khuzai et al., 2019; Al-Khuzai et al., 2020). ارائه روسازی مقرون به صرفه، ایمن و بادوام هدف مسئولان مربوطه جهت تحمل بارهای پیش‌بینی شده است (Airey et al., 2003). مخلوط آسفالتی به دلیل عملکرد خوب در حین سرویس‌دهی، پرکاربردترین ماده در روسازی می‌باشد. مخلوط آسفالتی ترکیبی از سنگ‌دانه، قیر و فیلر است. فیلر جز مهمی به حساب می‌آید زیرا ساختار مخلوط از یک سیستم پراکنده با ترکیب قیر و فیلر تشکیل می‌شود. فعل‌وانفعال فیزیکی و شیمیایی بین قیر و فیلر تأثیر مستقیم و قابل توجهی بر عملکرد HMA دارد. همچنین فیلر می‌تواند فضای خالی مخلوط آسفالت را پر کند که بر پایداری تأثیر می‌گذارد و مقاومت مخلوط را در برابر تغییر شکل پلاستیک در دماهای بالا افزایش می‌دهد (Arabani et al., 2017). استفاده از پرکننده در آسفالت گرم برافزایش عملکرد خستگی، رفتار شیارشدگی و مقاومت در برابر رطوبت تأثیر می‌گذارد (Arabani et al., 2017; Chen et al., 2015; Kim et al., 2018; Tahami et al., 2018). مطالعات مختلفی برای بررسی تأثیر مواد پرکننده معدنی بر رفتار مخلوط‌های قیری و نقش آن‌ها در تقویت پیوند بین قیر و سنگ‌دانه انجام شده است. درحالی‌که رایج‌ترین فیلر در حال حاضر سنگ آهک است اما انواع مختلف فیلر شامل سیمان پرتلند (Guha & Assaf, 2020)، پودر شیشه (Lachance-Tremblay et al., 2016)، گرد و گرد سنگ مرمر (Chandra et al., 2002)، گل قرمز (Choudhary et al., 2018) و ... می‌شود. خاکستر پوسته برنج<sup>۱</sup> و خاکستر بادی<sup>۲</sup> فیلرهایی هستند که به تازگی تحقیقات زیادی در مورد آن‌ها در حال انجام است. یکی از عظیم‌ترین مواد زائد تولید شده از پوسته برنج در ایران، خاکستر پوسته برنج است. این ماده برای تهیه سوخت کارخانجات کارخانه برنج استفاده می‌شود. این امر منجر به نگرانی‌های بسیاری از جمله مشکلات زیست‌محیطی و اقتصادی شده است. طی یک آمار در سال ۲۰۱۳ تقریباً ۵۰۰ میلیون تن پوسته برنج تولید می‌شود که تقریباً ۲۰ درصد آن به RHA تبدیل می‌شود (Sargin et al., 2013). خاکستر بادی محصول فرعی سوخت زغال‌سنگ بوده که شامل سیلیس، آلومین و اکسیدهای آهن است (Montini et al., 2018). تحقیقات زیادی به منظور ارزیابی تأثیر استفاده از این دو نوع فیلر انجام شده است که همگی نشان‌دهنده بهبود عملکرد مخلوط آسفالتی و کاهش درصد قیر بهینه می‌باشد (Al-gurah & Al-Humeidawi, 2021; Arabani & Tahami, 2017; Helal et al., 2020; Lu et al., 2018; Mistry et al., 2019; Mirković et al., 2019; Tahami et al., 2018).

از مهم‌ترین ویژگی‌هایی که در اختلاط آسفالت مورد توجه قرار می‌گیرد مقاومت<sup>۳</sup> و روانی<sup>۴</sup> مارشال آسفالت می‌باشد (Ozgan, 2009). پایین بودن مقدار مقاومت مارشال آسفالت باعث پایین آمدن کارایی آن و ایجاد مشکلاتی از جمله خستگی و ترک‌ها می‌شود به طوری که می‌توان گفت که مقدار مقاومت آسفالت نشان‌دهنده توانایی مخلوط آسفالتی برای مقاومت در برابر شیار شدگی و برآمدگی تحت بارگذاری سنگین ترافیکی است (Choubane et al., 2000) و روانی معیاری است از میزان وارفتن یا به عبارت دیگر تغییر شکل آسفالت تحت تأثیر بار وارده می‌باشد به طوری که هرچه تغییر شکل نسبی بیشتر باشد میزان وارفتن آسفالت پخش شده تحت تأثیر بار بیشتر خواهد بود. بتن آسفالتی از یک استخوان‌بندی مصالح سنگی خوب دانه‌بندی شده با فضای خالی مناسب که قیر سطح دانه‌ها را اندود کرده و آن‌ها را به یکدیگر چسبانده است تشکیل شده و مرغوب‌ترین نوع آسفالت به شمار می‌رود. مقاومت مارشال بتن آسفالتی نیز تابعی از دانه‌بندی، ویژگی‌های مصالح سنگی و همچنین درصد و نوع قیر مصرفی آن می‌باشد (Özgan & Saruhan, 2010). به دلیل متغیرها و پیچیدگی روابط بین آن‌ها و مقاومت مارشال، تاکنون رابطه تحلیلی ریاضی بین این متغیرها و مقاومت مارشال و تأثیر متقابل آن‌ها ارائه نگردیده و صرفاً به کمک آزمایش تعیین می‌گردد. از آنجائیکه ساخت و توسعه راه‌ها از مبانی پیشرفت اقتصادی و فرهنگی کشورها محسوب می‌شود و با توجه به هزینه‌های سنگین آسفالت و نگهداری آن ضرورت استفاده از روش‌های جدید و پیشرفته‌تر در طرح و کنترل کیفی آسفالت روزبه‌روز محسوس‌تر می‌شود (Ozgan, 2009). حجم بالای داده‌ها در مطالعات و ارتباط پیچیده موجود بین معیار باعث شده تا روش‌های تحلیل سنتی دارای عدم قطعیت بالایی باشند. از این رو به‌کارگیری روش‌هایی که توانایی تحلیل و کشف ارتباط پیچیده فضایی را در بین داده‌های اولیه دارا باشند توسعه یافته است. از جمله این روش‌ها می‌توان به خانواده روش‌های مبتنی بر یادگیری ماشین<sup>۵</sup> و تشخیص الگو<sup>۶</sup> اشاره کرد که به‌کارگیری آن‌ها بخصوص در سالیان اخیر محبوبیت بسیاری در بین دانشمندان پیدا کرده است. در دو دهه گذشته الگوریتم‌های هوش مصنوعی در حل مسائل مرتبط با علوم مهندسی به‌صورت وسیعی مورد استفاده قرار گرفته است (Lary et al., 2016). الگوریتم‌های آموزش ماشین به‌عنوان زیرشاخه‌ای از علم هوش مصنوعی، به‌منظور دریافت جوابی با درصد اطمینان قابل قبول توسعه یافته است. هدف از آموزش ماشین در واقع بهینه‌سازی عملکرد سیستم با استفاده از تجربیات گذشته

1 Rice Husk Ash

2 Fly Ash

3 Stability

4 Flow

5 Machine Learning

6 Pattern recognition

است (Kanevski, 2009). یادگیری ماشین یکی از مهم‌ترین بخش‌های هوش مصنوعی است که از علوم کامپیوتر آغاز شده و به سرعت در حال رشد است به طوری که در حوزه‌های دیگر علوم نیز کاربردهای فراوانی یافته است. یکی از تعاریف یادگیری ماشین آن‌طور که از سوی تام میشل ارائه گردیده است بدین شرح است: نوعی برنامه کامپیوتری که با توجه به برخی وظایف گروه T و عملکرد P، تجربه E را شکل می‌دهد، اگر عملکرد آن در گروه وظایف T آن‌طور که توسط P اندازه‌گیری شده با تجربه E بهبود پیدا کند (Mitchell, 1999). به عبارت ساده‌تر، اگر یک برنامه کامپیوتری بتواند عملکرد خود در انجام یک وظیفه را با استفاده از تجربیات قبلی‌اش بهبود ببخشد آنگاه می‌توانید بگویید که آن ماشین یاد گرفته است؛ بنابراین، یادگیری ماشین عبارت از بهینه سازی یک عملکرد با استفاده از تجربیات گذشته است. فرآیند آموزش معمولاً با به‌کارگیری اطلاعات تجربی از هدف مورد بررسی صورت گرفته و پس از ایجاد مدل آموزشی، از آن به‌عنوان مدلی جهت پیش‌بینی و یا طبقه‌بندی رفتار سیستم مورد بررسی استفاده می‌شود (Burkov, 2020; Kanevski, 2009). الگوریتم‌های یادگیری ماشین بر اساس نوع نحوه آموزش به چهار نوع نظارت‌شده<sup>۱</sup>، نظارت‌نشده<sup>۲</sup>، نیمه نظارتی<sup>۳</sup> و یادگیری تقویت شونده<sup>۴</sup> تقسیم می‌شوند. در الگوریتم‌های نظارت‌شده با دو نوع از متغیرها سروکار داریم. نوع اول که متغیرهای مستقل نامیده می‌شوند، یک یا چند متغیر هستند که قرار است بر اساس مقادیر آن‌ها، یک متغیر دیگر را پیش‌بینی کنیم. نوع دوم هم متغیرهای وابسته یا هدف یا خروجی هستند و قرار است مقادیر آن‌ها را به کمک این الگوریتم‌ها پیش‌بینی کنیم. برای این منظور باید تابعی ایجاد شود که ورودی‌ها (متغیرهای مستقل) را گرفته و خروجی مورد نظر (متغیر وابسته یا هدف) را تولید کند. فرآیند یافتن این تابع که در حقیقت کشف رابطه‌ای بین متغیرهای مستقل و متغیرهای وابسته است، فرآیند آموزش<sup>۵</sup> نامیده می‌شود که روی داده‌های موجود (داده‌هایی که هم متغیرهای مستقل و هم متغیرهای وابسته آن‌ها معلوم می‌باشد) اعمال می‌شود و تا رسیدن به دقت لازم، ادامه می‌یابد (Ray, 2019). الگوریتم‌های درخت‌های تصمیم<sup>۶</sup>، جنگل‌های تصادفی<sup>۷</sup>، K نزدیک‌ترین همسایه<sup>۸</sup>، ماشین بردار پشتیبان<sup>۹</sup>، روش‌های مبتنی بر نظریه بیز<sup>۱۰</sup> و رگرسیون لجستیک<sup>۱۱</sup> نمونه‌ای از این یادگیری می‌باشند (Jalil et al., 2019)

## ۲- مطالعات آزمایشگاهی

### ۲-۱- مصالح سنگی

از مصالح کربناته خردشده شن ۱۹-۲۵ میلی‌متر (مطابق با دانه‌بندی رده ۵ جدول ۲ استاندارد ASTM C33)، شن ۱۹-۱۲ میلی‌متر (مطابق با دانه‌بندی رده ۶۷ جدول ۲ استاندارد ASTM C33)، شن ۱۲-۶ میلی‌متر (مطابق با دانه‌بندی رده ۸ جدول ۲ استاندارد ASTM C33) و ماسه ۰-۶ میلی‌متر (مطابق با دانه‌بندی رده ۴ جدول ۱ استاندارد ASTM D1073) در این تحقیق مورد استفاده قرار گرفته است. مشخصات فیزیکی مصالح در جدول ۱ شرح داده شده است. با توجه به نتایج حاصل از دانه‌بندی مصالح سنگی و به منظور دستیابی به حدود دانه‌بندی پیوسته D4 جدول ۱ استاندارد ASTM D3515، درصد وزنی رد شده مخلوط مصالح سنگی به شرح جدول ۲ و شکل ۱ به دست آمد.

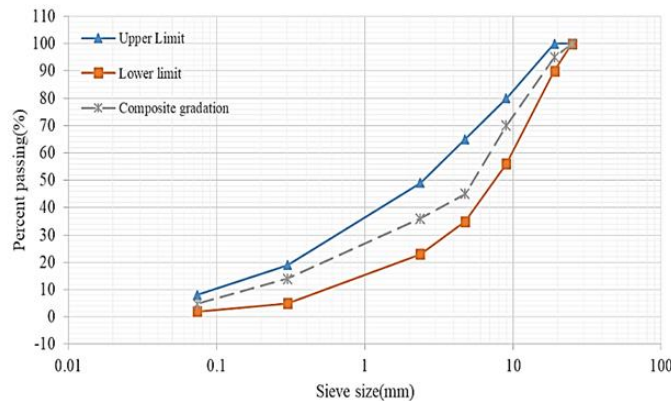
جدول ۱: ارزیابی خواص سنگ‌دانه‌های مورد استفاده

ویژگی	مقدار	
ارزش ماسه‌ای (ASTM D2419)	۸۲	
درصد شکستگی (ASTM D5821)	۹۲	
سایش لس‌انجلس (AASHTO-T96)	۲۴	
شاخص تطویل و تورق (BS-812)	تطویل	۲۴
	تورق	۱۵
وزن مخصوص	درشت‌دانه (AASHTO-T85)	۲,۶۷۹
	ریزدانه (AASHTO-T84)	۲,۶۵۲
جذب آب	درشت‌دانه (AASHTO-T85)	۰,۸
	ریزدانه (AASHTO-T84)	۱,۲

- 1 Supervised
- 2 Unsupervised
- 3 Semi supervised
- 4 Reinforced
- 5 Train
- 6 Decision tree
- 7 Random Forest
- 8 K-Nearest neighbor
- 9 Support vector machine
- 10 Bayes theory
- 11 Logistic regression

جدول ۲: دانه‌بندی به‌دست‌آمده مخلوط آسفالتی مطابق با رده D-4 استاندارد ASTM D3515

سایز الک (mm)	25mm	19mm	9.5mm	4.75mm	2.36mm	0.3mm	0.075mm
حدود بالا و پایین رده D4 (%)	۱۰۰	۱۰۰-۹۰	۸۰-۵۶	۶۵-۳۵	۴۹-۲۳	۱۹-۵	۸-۲
حدود به‌دست‌آمده (%)	۱۰۰	۹۵	۷۰	۴۸	۲۶	۱۴	۲,۴۶,۸



شکل ۱: دانه‌بندی به‌دست‌آمده مطابق با رده D-4 استاندارد ASTM D3515

## ۲-۲- قیر

قیرهای خالص مصرفی در راه‌سازی براساس طبقه‌بندی درجه نفوذ<sup>۱</sup> و عملکردی<sup>۲</sup> تقسیم می‌شوند (Asphalt, 2015). قیر رایج مورد استفاده در مشهد، قیر درجه عملکردی PG64-22 می‌باشد که در این تحقیق این نوع قیر که از شرکت نفت جی تهیه شده استفاده شده است. خصوصیات قیر که در آزمایشگاه کنترل کیفیت شهرداری مشهد مورد بررسی قرار گرفته است در جدول ۳ شرح داده شده است.

جدول ۳: خواص قیر PG64-22 مورد استفاده در این مطالعه

قیر اصلی			
دمای اشتعال	۳۰۰		
ویسکوزیته (ASTM D4402)	دمای آزمایش (°C)	۱۳۵	
	نتیجه آزمایش (پاسکال ثانیه)	۰,۳۵۰	
برش دینامیکی (ASTM D7175)	دمای آزمایش (°C)	۶۴	۷۰
	نتیجه آزمایش $G^*/\sin\delta$ کیلوپاسکال	۱,۰۳۱	۰,۵۴۴
اون لایه نازک متحرک قیر (ASTM D2872)			
افت وزنی، درصد	۰,۰۱		
برش دینامیکی (ASTM D7175)	دمای آزمایش (°C)	۶۴	۷۰
	نتیجه آزمایش $G^*/\sin\delta$ کیلوپاسکال	۲,۳۵۰	۱,۰۴۲
آزمون تسریع پیرشدگی قیر (ASTM D6521)			
دمای پیرشدگی (°C)	۱۰۰		
برش دینامیکی (ASTM D7175)	دمای آزمایش (°C)	۲۵	۲۲
	نتیجه آزمایش $G^*/\sin\delta$ کیلوپاسکال	۲۶۲۰	
سفتی خزش خمشی (ASTM D6618)	دمای آزمایش (°C)	-۱۲	-۱۸
	نتیجه آزمایش سفتی خزش مگا پاسکال	۱۲۳	۲۵۷
	نتیجه آزمایش ضریب m	۰,۳۲۴	۰,۲۶۳

1 Penetration Grad  
2 Performance Grade

### ۳-۲- فیلر

در این مطالعه دو نوع فیلر به‌عنوان جایگزین فیلر رایج استفاده شد: خاکستر پوسته برنج تهیه‌شده از شرکت گیلان کشت و خاکستر بادی تهیه‌شده از شرکت آفاتوس استفاده شده است. هر دو محصول RHA و FA مستقیماً در هنگام احتراق تولید می‌شوند. فیلر رایج (CF) مورد استفاده در مخلوط آسفالتی که از بین گرم به دست می‌آید نیز به‌منظور مقایسه نتایج در این تحقیق استفاده شده است. جدول ۴ خصوصیات فیزیکی و شیمیایی فیلرهای مورد مطالعه را نشان می‌دهد.

جدول ۴: خواص فیزیکی و شیمیایی فیلرهای مورد مطالعه

فیلر	ترکیب شیمیایی								خواص فیزیکی
	SiO <sub>2</sub>	CaO	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	MgO	K <sub>2</sub> O	SO <sub>3</sub>	LOI	
Current filler (CF)	۱۰,۹۸	۳۴,۵۹	۱,۷	۰,۰۵	۱۲	۰,۳	۰,۳۹	۳۹,۰۵	۲,۵۴۹
RHA	۹۶,۰۸	۰,۲۴	۰,۲۱	۰,۱۴	۰,۴۸	۰,۵۱	۰,۱۲	۱,۶۴	۲,۱۱۵
FA	۲۰	۳	۶	۹	۲۸	۶	۵	۳	۲,۲۳۰

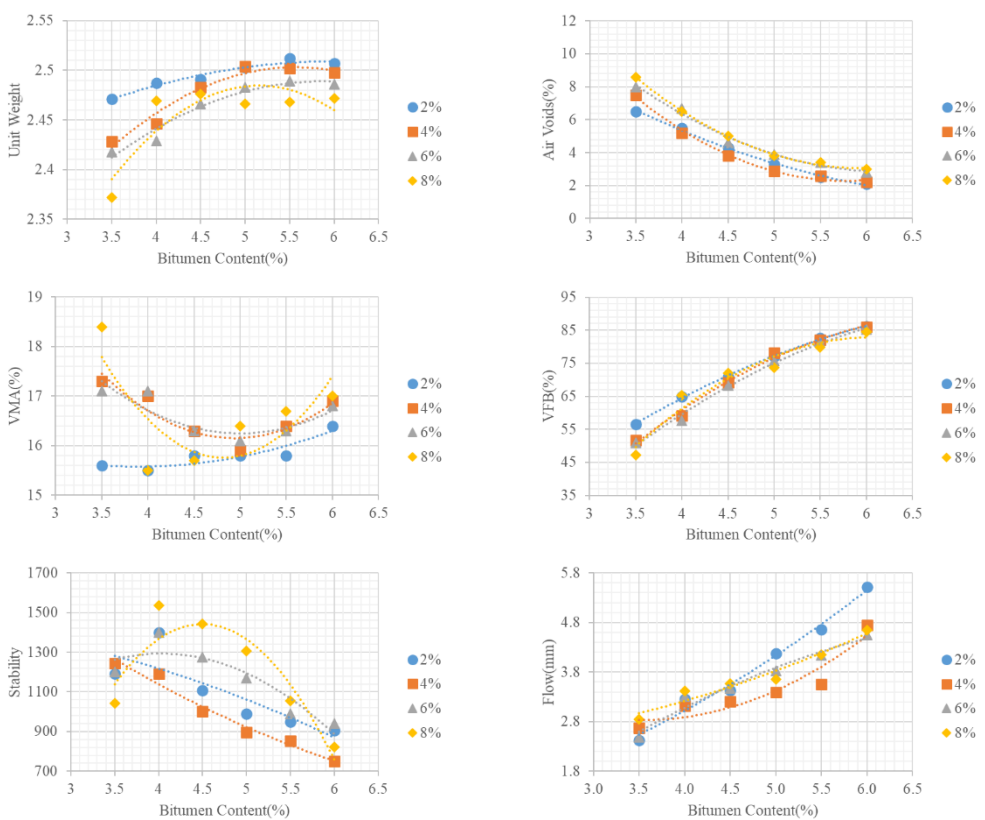
### ۳- طراحی مخلوط آسفالتی

مخلوط آسفالتی در حال حاضر به سه روش مختلف طرح می‌شوند که عبارت‌اند از: آسفالت ممتاز، مارشال و ویم (Asphalt, 2015). در این مطالعه روش مارشال جهت طراحی مخلوط آسفالتی با دانه پیوسته با درصد‌های مختلف فیلر و نوع‌های مختلف فیلر به‌منظور رسیدن به میزان قیر بهینه استفاده شد. دستورالعمل‌های آزمایش مارشال توسط انجمن آزمایش و مصالح آمریکا و انجمن راه و ترابری ایالتی آمریکا استاندارد شده‌اند. برای تهیه نمونه‌ها، سنگ‌دانه‌ها و فیلرها برای صفر شدن رطوبت در دمای ۱۰۰±۵ درجه گرم شدند. طبق دستورالعمل‌های مشخص شده در نشریه MS-2، دماهایی که باید قیر را گرم کرد تا ویسکوزیته کینماتیکی قیر به ۱۵۰-۱۹۰ و ۲۵۰-۳۱۰ که به ترتیب نشان‌دهنده دمای اختلاط و تراکم می‌باشد (Asphalt, 2015)، برسد تعیین شد. براساس این معیار دمای اختلاط و تراکم برای همه مخلوط‌ها به ترتیب ۱۵۵-۱۶۵ و ۱۴۰-۱۴۵ نظر گرفته شد. سنگ‌دانه‌ها با دانه‌بندی مشخص شده، فیلرها با درصد‌های ۲ تا ۸ درصد و قیر با درصد‌های ۳,۵ تا ۶,۵ درصد در دمای اختلاط کاملاً مخلوط شدند و متقابلاً تراکم با چکش اتوماتیک مارشال (۷۵ ضربه در هر طرف) در دمای تراکم انجام شد تا نمونه مارشال با قطر ۱۰۰ میلی‌متر و ارتفاع ۶۳,۵ میلی‌متر تولید شود. سه نمونه برای هر درصد قیر تهیه شد که در مجموع ۲۱۶ نمونه (۶ نوع درصد قیر، ۳ مدل فیلر در ۴ درصد مختلف و سه نمونه برای هر کدام) ساخته شد.

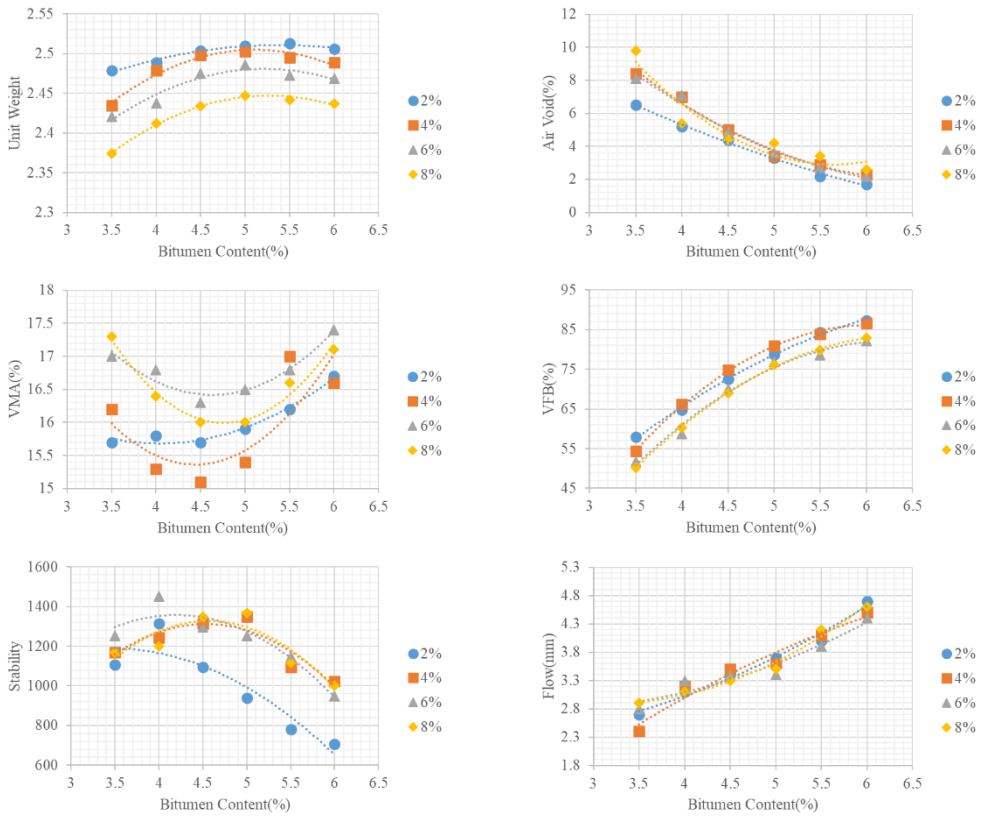
جدول ۵: جزئیات درصد‌های مختلف قیر، نوع فیلر و درصد آن‌ها برای تهیه نمونه‌های آسفالت

نوع فیلر	CF				RHA				FA			
	۲	۴	۶	۸	۲	۴	۶	۸	۲	۴	۶	۸
درصد فیلر	۲	۴	۶	۸	۲	۴	۶	۸	۲	۴	۶	۸
درصد قیر	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵	۳,۵
	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴	۴
	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵	۴,۵
	۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	۵
	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵	۵,۵
	۶	۶	۶	۶	۶	۶	۶	۶	۶	۶	۶	۶

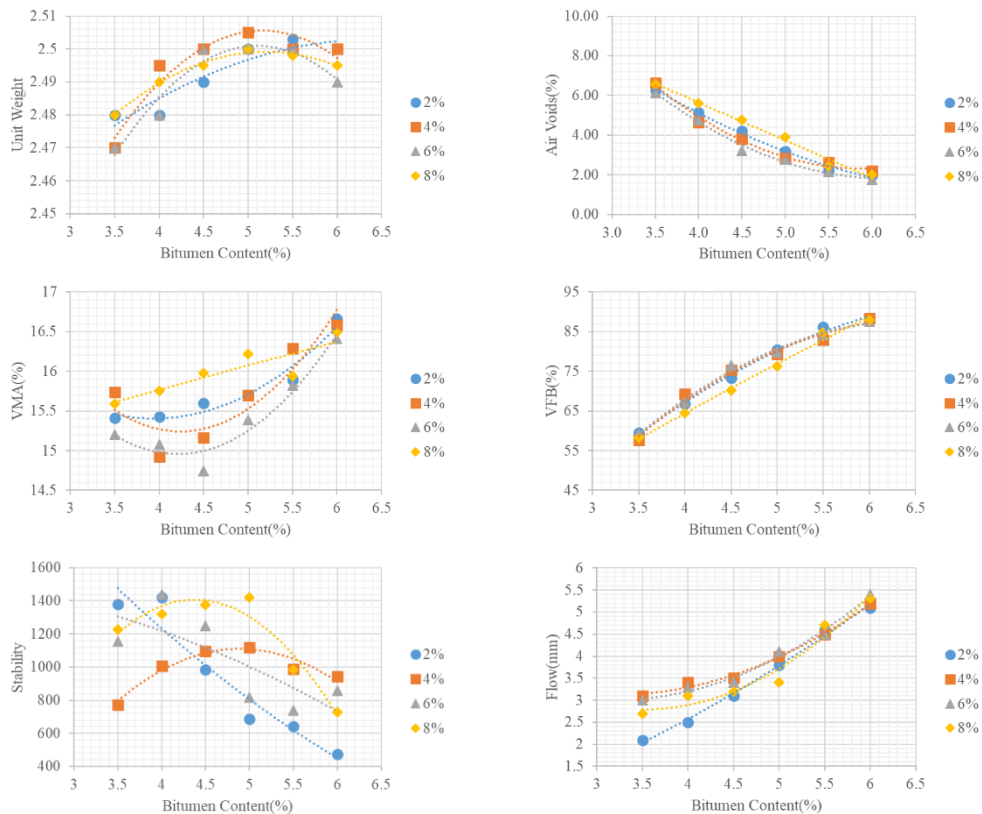
شکل‌های ۲-۴ نتایج آزمایش شامل وزن مخصوص، فضای خالی، فضای خالی مصالح سنگی (VMA)، فضای خالی پر شده با قیر (VFB)، مقاومت، روانی و ضریب مارشال مخلوط‌های آسفالتی مربوط به درصد‌های مختلف قیر و درصد فیلرهای مختلف CF، RHA و FA مورد مطالعه را نشان می‌دهد. به کمک این منحنی‌ها مناسب‌ترین درصد قیر آسفالت مورد آزمایش تعیین می‌گردد. هدف از تعیین مناسب‌ترین درصد قیر، عبارت است از تعیین درصد قیری که آسفالت تهیه‌شده بر مبنای آن دارای بهترین مشخصات باشد یعنی وزن مخصوص و تاب فشاری آن به ماکزیمم نزدیک و فضای خالی آسفالت نیز در حدود ۴ درصد باشد (Asphalt, 2015).



شکل ۲: ویژگی‌های مارشال مخلوط آسفالتی مورد مطالعه حاوی خاکستر پوسته برنج



شکل ۳: ویژگی‌های مارشال مخلوط آسفالتی مورد مطالعه حاوی خاکستر بادی




شکل ۴: ویژگی‌های مارشال مخلوط آسفالتی مورد مطالعه حاوی فیلر رایج بین گرم

مطابق جدول ۶، مقدار قیر بهینه مخلوط با ۲ درصد CF، ۴٫۵۶ می‌باشد. باین حال با افزایش CF (از ۲ به ۴ درصد) مقدار قیر بهینه به ۴٫۵۳ کاهش می‌یابد. اما با ۶ و ۸ درصد فیلر، مقدار بهینه قیر به ترتیب به ۴٫۷ و ۴٫۹۴ رسیده است. نمونه‌های حاوی RHA و FA مصرف کمتر قیر بهینه را در مقایسه CF نشان می‌دهد. مقدار قیر بهینه در ۴ درصد RHA و ۶ درصد FA به ترتیب به ۴٫۲۵ و ۴٫۱۶ می‌رسد که کمتر از مقدار بهینه حاصل از فیلر CF می‌باشد. چون نوع مصالح سنگی، دانه‌بندی و نوع قیر مشابه هستند، بنابراین تغییرات درصد قیر بهینه فقط بسته به نوع فیلر و درصد آن محاسبه می‌شود.

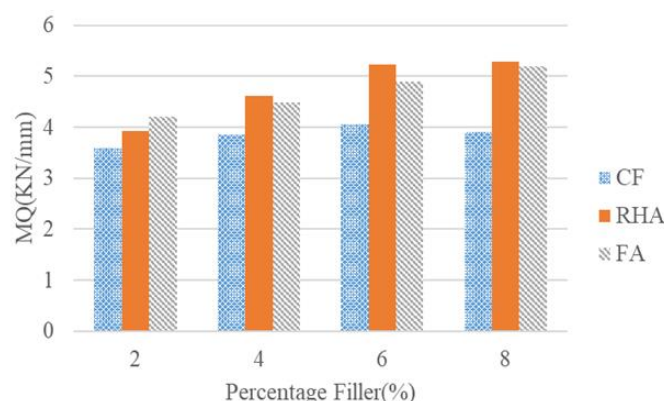
جدول ۶: ویژگی‌های مارشال مرتبط با درصد قیر بهینه در مقادیر مختلف فیلهای CF، RHA و FA

نوع فیلر	مقدار فیلر	قیر بهینه	مقاومت	روانی	VMA	VFB	MQ
CF	۲	۴٫۵۶	۱۱۸۴	۳٫۲۳	۱۶٫۰۸	۷۴٫۵۷	۳٫۵۹
	۴	۴٫۵۳	۱۲۵۰	۳٫۱۸	۱۶٫۱۷	۷۲٫۵۹	۳٫۸۵
	۶	۴٫۷	۱۳۲۵	۳٫۲	۱۶٫۳۲	۷۴٫۷۹	۴٫۰۶
	۸	۴٫۹۴	۱۲۴۵	۳٫۱۲	۱۶٫۵	۷۴٫۸۵	۳٫۹۱
RHA	۲	۴٫۴۹	۱۲۲۸	۳٫۰۶	۱۵٫۳	۷۰٫۴۴	۳٫۹۳
	۴	۴٫۲۵	۱۳۶۴	۲٫۸۹	۱۵٫۶۶	۷۰٫۸۳	۴٫۶۲
	۶	۴٫۷۲	۱۴۴۶	۲٫۷۱	۱۶٫۲۱	۷۳٫۳۴	۵٫۲۳
	۸	۴٫۷۷	۱۳۵۰	۲٫۵	۱۶٫۸۲	۷۳٫۸۷	۵٫۲۹
FA	۲	۴٫۴۲	۱۱۰۲	۲٫۵۷	۱۵٫۶۱	۷۴٫۲۸	۴٫۲۰
	۴	۴٫۳	۱۳۴۳	۲٫۹۴	۱۵٫۱۱	۷۴٫۳۳	۴٫۴۸
	۶	۴٫۱۶	۱۳۷۸	۲٫۷۶	۱۶٫۱۶	۷۳٫۶۲	۴٫۸۹
	۸	۴٫۷۴	۱۴۰۰	۲٫۶۴	۱۶٫۳۷	۷۴٫۳	۵٫۲۰
حدود قابل قبول			حداقل ۸۰۰	۲-۳٫۵	حداقل ۱۳	۶۵-۷۵	



شکل ۵: تغییرات مقادیر قیر بهینه برای نمونه‌های مختلف مورد مطالعه

با استفاده از شکل‌های ۲-۴، نتایج آزمایش مارشال مربوط به درصد قیر بهینه با تمام فیله‌های مورد مطالعه در جدول ۶ و شکل ۵ نشان داده شده است. مقدار متوسط مقاومت برای مخلوط حاوی ۲ درصد CF، ۱۱۸۴ می‌باشد که با افزایش مقدار CF به ۴ و ۶ درصد مقاومت به ترتیب به افزایش ۱۲۵۰ و ۱۳۲۵ می‌یابد. اما در مقدار ۸ درصد مقاومت کاهش پیدا می‌کند. استفاده از RHA مقاومت را در تمامی درصد فیله‌ها نسبت به CF افزایش می‌دهد. به این صورت که مقدار مقاومت در درصدهای ۲، ۴، ۶ و ۸ RHA نسبت به همین درصدها در مخلوط حاوی CF، به ترتیب ۳،۷، ۹،۱، ۹،۱ و ۶،۵ درصد افزایش می‌یابد. در مورد استفاده از ۲ درصد FA، مقدار مقاومت کمی نسبت به مقدار مشابه CF کاهش می‌یابد اما با افزایش FA (از ۴ تا ۸ درصد) مشاهده می‌شود که مقدار مقاومت نیز به ۱۳۴۳، ۱۳۷۸ و ۱۴۰۰ افزایش می‌یابد. این بهبود در مقاومت مارشال برای مخلوط‌های حاوی RHA را می‌توان به ذرات نامنظم RHA نسبت داد که ممکن است مقاومت برشی و سختی قیر را افزایش دهد. علاوه بر این، برای مخلوط‌های FA، یکی از دلایل افزایش مقاومت مارشال این است که شکل منظم ذرات FA (معمولاً کروی) ممکن است به عنوان غلطک‌هایی عمل کنند که اصطکاک کمتری هنگام تراکم ایجاد می‌کند، در نتیجه تراکم بیشتر حاصل می‌شود (Mistry et al., 2019). همچنین، فضای خالی موجود در سنگ‌دانه (VMA) و فضای خالی پر شده با قیر (VFB) از محدوده تعیین شده عبور نمی‌کند. تغییر مقادیر ضریب مارشال (MQ) می‌تواند ماهیت نتایج آزمایش مارشال به دست آمده را بدون زحمت توضیح دهد. ضریب مارشال (MQ) به صورت مقاومت مارشال (KN) به روانی (mm) تعریف می‌شود و به نوعی اشاره به سفتی مخلوط‌ها دارد. پذیرفته شده است که MQ سنجشی است از مقاومت مواد در برابر تنش‌های برشی، تغییر شکل دائمی و در نتیجه خراب شدن است. نتیجه MQ برای همه فیله‌ها در جدول ۵ و شکل ۶ نشان داده شده است. در مخلوط‌های حاوی RHA و FA، مقادیر MQ به تدریج افزایش می‌یابد و از حداکثر مجاز MQ 5 kN/mm تجاوز می‌کند. روند افزایشی مقادیر MQ را می‌توان به این دلیل نسبت داد که با قیر بهینه کمتر و درصد بیشتر فیله، فیله جزء سبک قیر را جذب می‌کند، ویسکوزیته و سفتی قیر را افزایش می‌دهد. این موضوع چسبندگی بین قیر و سنگ‌دانه‌ها را افزایش می‌دهد و توانایی کلی مخلوط آسفالتی را در تحمل بارها بهبود می‌بخشد (Hamedi & Tahami, 2018).




شکل ۶: مقادیر MQ در درصد فیله‌های مختلف



## ۴- کاربرد روش‌های یادگیری ماشین

### ۴-۱- ماشین بردار پشتیبان

استفاده از بردارهای پشتیبان در مسائل دسته‌بندی و رگرسیون، رویکرد جدیدی است که در چند سال اخیر مورد توجه بسیاری قرار گرفته است. ماشین بردار پشتیبان در ابتدا توسط واپنیک<sup>۱</sup> در سال ۱۹۹۰ طراحی شد و نظریه آماری یادگیری را به صورت مستحکم بنا نهاد. در تعریف ساده، SVM الگوریتمی است که به وسیله یک ابرصفحه<sup>۲</sup> جداکننده که روی داده‌های آموزشی تعریف می‌شود، دو کلاس خاص از هم جدا و مشخص می‌شوند (Yang et al., 2008).



شکل ۷: (الف) مجموعه نقاط متعلق به دودسته، (ب) خطوط دسته‌بندی نمونه‌ها

از جمله قابلیت‌های ماشین بردار پشتیبان، توانایی غلبه بر مشکل توزیع غیرخطی داده‌های آموزشی است. در این حالت با استفاده از توابع کرنل<sup>۳</sup>، داده‌ها به فضایی به بعد بزرگ‌تر انتقال می‌یابند که در آن تفکیک پذیری بهتر انجام می‌شود و ابر صفحه جداکننده در آن فضا تعیین می‌شود.


در روش ماشین بردار پشتیبان از چهار تابع کرنل خطی، چندجمله‌ای، تابع پایه شعاعی و تابع سیگموئید بیشتر استفاده می‌شود. روابط این توابع در جدول ۷ آورده شده است.

جدول ۷: توابع کرنل متداول در ماشین بردار پشتیبان (Shawe-Taylor & Cristianini, 2000)

فرمول	نوع تابع
$x_i \times x_j$	خطی
$[\gamma x_i x_j + \text{coefficient}]^d$	چندجمله‌ای
$\exp(-\gamma \ x_i - x_j\ ^2)$	پایه شعاعی
$\tanh(\gamma x_i x_j + \text{coefficient})$	سیگموئید

الگوریتم‌های مبتنی بر ماشین‌های بردار پشتیبان الگوریتم‌هایی هستند که سعی می‌کنند یک حاشیه<sup>۴</sup> را بیشینه کنند. این الگوریتم‌ها برای پیدا کردن خط جداکننده دسته‌ها، از دو خط موازی شروع کرده و این خطوط را در جهت خلاف یکدیگر حرکت می‌دهند تا هر کدام از خطوط به یک نمونه از یک دسته خاص در سمت خود برسند. پس از انجام این مرحله، میان دو خط موازی یک نوار یا حاشیه شکل می‌گیرد. هرچه پهنای این نوار بیشتر باشد، به این معناست که الگوریتم توانسته حاشیه را بیشینه کند و هدف نیز بیشینه نمودن این حاشیه است. در واقع هدف ما این است که بیشترین مقدار ممکن برای این حاشیه انتخاب شود. هرچه حاشیه بیشتر باشد خطای کلاس‌بندی کمتر خواهد بود. در مرکز حاشیه شکل، خط جداکننده دسته‌ها یا همان خط مرکزی (در حالت دوبعدی خط، سه‌بعدی صفحه و در حالت بیشتر از سه‌بعدی ابر صفحه) قرار می‌گیرد. حال از بین خطوطی که رسم می‌شوند، الگوریتم خطی را که حاشیه کناری آن بیشتر باشد، به عنوان خط جداکننده دسته‌ها انتخاب می‌کند. حاشیه مربوط به دو خط B1 و B2 در شکل ۸ نمایش داده شده است. الگوریتم خط B1 را به عنوان خط جداکننده انتخاب می‌کند چرا که حاشیه کناری این خط، نسبت به حاشیه کناری خط B2 بیشتر است.

1 Vapnik  
2 Hyperplane  
3 Kernel functions  
4 Margin



شکل ۸: حاشیه خطوط دسته‌بندی نمونه

فرض کنید داده‌ها آموزشی شامل  $N$  جفت داده به شکل زیر باشد که متغیرهای مستقل  $x_i$  بتوانند در دو کلاس  $y_i = 1$  و  $y_i = -1$  طبقه‌بندی شوند.

$$D = \left\{ (x_i, y_i) \mid x_i \in \mathbb{R}^n, y_i \in \{-1, 1\} \right\}_{i=1}^N \quad (1)$$

در این صورت معادله ابر صفحه جداکننده دو کلاس به صورت زیر است:

$$D = \{x \in \mathbb{R}^n \mid f(x) = w \cdot x + b = 0\}, w \in \mathbb{R}^n, b \in \mathbb{R} \quad (2)$$

که بردار ضرایب ابر صفحه و  $b$  بردار نشان دهنده فاصله ابر صفحه از مبدأ مختصات است. انتخاب جواب‌های منحصر به فرد برای این دو پارامتر منجر به داشتن حداکثر فاصله دو ابر صفحه موازی و بالا رفتن قابلیت تعمیم‌پذیری ابر صفحه جداکننده خواهد شد؛ بنابراین مسئله بهینه‌سازی به صورت زیر مطرح می‌شود:

$$\min_{w, b} \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N \xi_i \quad (3)$$

مشروط به قیود زیر:

$$y_i (\varphi(x_i) \cdot w + b) \geq (1 - \xi_i) \forall i, \xi_i \geq 0 \quad (4)$$

که  $\varphi(x_i)$  تابع کرنل،  $c$  ثابت ظرفیت،  $\xi_i$  پارامتر کمی برای تفکیک داده‌های دارای همپوشانی است. مقادیر بزرگ‌تر  $c$  نشان‌دهنده توجه بیشتر به نقاط در نزدیکی مرز تصمیم‌گیری و مقادیر کوچک‌تر شامل نقاط دورتر از مرز تصمیم‌گیری نیز در حل مسئله بهینه‌سازی خواهد بود.


برای حل رابطه ۳ از تابع لاگرانژین دوگانه ولف با حفظ شرایط Karush-Kuhn-Tucker استفاده می‌شود. با به دست آمدن بردارهای  $w$  و  $b$  توسط بهینه‌سازی کردن تابع لاگرانژین دوگانه ولف، تابع تصمیم‌گیری برای کلاسه‌بندی یک متغیر جدید به صورت زیر خواهد بود (Shawe-Taylor & Cristianini, 2000):

$$G(x) = \text{sign}[f(x)] = \text{sign}[\varphi(x) \cdot w + b] \quad (5)$$

برای به دست آوردن نتایج مناسب کلاسه‌بندی در روش ماشین بردار پشتیبان این نکات را بایستی مورد توجه قرارداد: به دست آوردن مقدار بهینه برای پارامتر  $c$  و تغییر پارامترهای مختلف تابع کرنل یا تعویض آن‌ها با استفاده از روش‌های Cross Validation (Shabankareh & Hezarkhani, 2017).

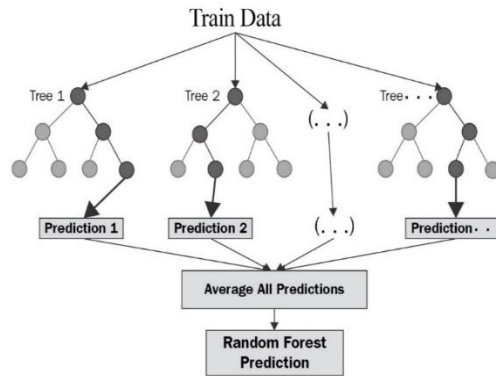
#### ۲-۴- جنگل تصادفی

روش جنگل تصادفی از جمله روش‌های تلفیقی می‌باشد. در روش‌های تلفیقی مدلی که برای دسته‌بندی یا رگرسیون انتخاب می‌شود که ترکیبی از چندین مدل است. هر مدل رأی خود را صادر می‌کند و نتیجه نهایی در مورد مقدار بر اساس این رأی‌ها صادر می‌شود. اغلب صحت یک روش تلفیقی بهتر از مؤلفه‌های تشکیل‌دهنده آن یعنی مدل‌ها است (Mohri et al., 2018).



شکل ۹: ایده کلی الگوریتم‌های تلفیقی

تصور کنید مدل‌های استفاده‌شده در روش تلفیقی همگی از نوع درخت تصمیم هستند، بدین ترتیب این مجموعه تشکیل یک جنگل را خواهد داد. هر یک از درختان تصمیم با استفاده از یک انتخاب تصادفی صفات خاصی موجود در هر گره<sup>۱</sup> جهت تعیین انشعاب ساخته می‌شوند. به عبارت دیگر هر درخت بر اساس مقادیر یک بردار تصادفی ساخته می‌شود. این مقادیر دارای توزیع یکسانی برای تمام درختان موجود در جنگل هستند و به صورت مستقلی نمونه‌گیری می‌شوند. برای دسته‌بندی نیز هر درخت رأی خود را صادر و نتیجه نهایی بارأی اکثریت تعیین می‌شود (Liaw & Wiener, 2002). پارامترهای مهم در الگوریتم جنگل تصادفی، تعداد متغیر انتخاب‌شده در هر گره درخت و تعداد درخت می‌باشند که لازم است برای آن‌ها مقادیر مناسبی تعیین شوند (Harris & Grunsky, 2015).



شکل ۱۰: ایده الگوریتم جنگل تصادفی

در این روش در هر بار نمونه‌گیری با جایگزینی اطلاعات، برخی اطلاعات هرگز نمونه‌گیری نمی‌شوند و برخی دیگر شاید چند بار نمونه‌گیری شوند. به عبارت دیگر برخی داده‌های ورودی برای برخی درخت‌ها در اصطلاح نمونه خارج از کیسه (OOB)<sup>۲</sup> خواهند بود یعنی در ایجاد برخی درخت‌ها مشارکت نخواهند داشت. این داده‌ها عمل یک اعتبارسنج داخلی برای هر درخت را دارند که این اعتبارسنجی از طریق برآورد خطای خارج از کیسه انجام می‌شود. اگر خود داده‌های خارج از کیسه از طریق درختان پیش‌بینی شوند، برای این پیش‌بینی‌ها خطا وجود خواهد داشت و میانگین این خطاها، خطای خارج از کیسه نامیده می‌شود که نشان‌دهنده میزان تأثیر نمونه‌های انتخاب‌نشده بر میزان خطای نتیجه نهایی جنگل تصادفی است (James et al., 2013).

#### ۴-۳- ارزیابی مدل

ارزیابی عملکرد مدل‌های SVM و RF بر اساس ضریب تعیین<sup>۳</sup>، میانگین مربعات خطای تخمین<sup>۴</sup>، میانگین خطای نسبی<sup>۵</sup> و قدر مطلق خطای نسبی<sup>۶</sup> که همگی معرف میزان دقت (خطای) تخمین می‌باشند استفاده شده است. مدلی که بیشترین مقدار R2 و کمترین مقدار RMSE، SDE و MAPE را دارا باشد از عملکرد مناسب‌تری برخوردار است (Nagelkerke, 1991). کمیت R2 که ضریب تعیین نیز نامیده می‌شود، نسبت تغییرات (متغیرهای) تعریف‌شده، به کل تغییرات (متغیرها) می‌باشد. این اندازه‌گیری به ما این امکان را می‌دهد که تعیین کنیم چقدر می‌توان به پیش‌بینی یک مدل یا نمودار مطمئن بود. روش‌های دیگر اگرچه مفید هستند، اما یک اشکال مشترک دارند: از آنجاکه مقادیر آن‌ها می‌تواند بین صفر تا + بی‌نهایت متغیر باشد، یک مقدار واحد آن‌ها در مورد عملکرد به‌تنهایی چیز زیادی نمی‌گوید و فقط در هنگام مقایسه قابل تفسیر هستند (Chicco et al., 2021).

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \quad (6)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (7)$$

1 Node

2 Out Of Bag

3 Coefficient of Determination

4 Root mean square error

5 Standard deviation error

6 Mean absolute percentage error

$$SDE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left( \frac{|y_i - \hat{y}_i|}{y_i} - \frac{MAPE}{100} \right)^2} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (9)$$

#### ۴-۴- داده‌های ورودی

در این مطالعه، از مقادیر طراحی مارشال مخلوط معمولی و اصلاح‌شده برای تولید مدل‌های یادگیری ماشین استفاده شد. در مجموع ۷۲ نمونه برای مدل‌سازی استفاده شد که ۷۰ درصد آن به‌صورت تصادفی برای آموزش و ۳۰ درصد برای آزمایش و اعتبار سنجی نتایج مدل استفاده شدند. محققان نشان داده‌اند که این ترکیب بهترین عملکرد به همراه داشته باشد (Ghorbanzadeh et al., 2018; Tiwari et al., 2018). متغیرهای ورودی در نظر گرفته‌شده برای مدل‌سازی عبارتند از نوع فیلر (FT)، درصد فیلر (PF)، قیر (BC)، وزن مخصوص نمونه‌های متراکم، درصد فضای خالی (Vv)، فضای خالی موجود در سنگ‌دانه (VMA) و فضای خالی پرشده با قیر (VFB).

در زمینه الگوریتم‌های یادگیری ماشین هر نمونه، یک بردار ویژگی ۱ در نظر گرفته می‌شود که محتوای آن (صفات خاصه) توسط نتایج آزمایشات تعریف شده‌اند؛ بنابراین تعداد ابعاد بردار ویژگی برابر با تعداد آزمایشات می‌باشد (Porwal et al., 2004). نتایج تمام آزمایش‌ها برای ایجاد ۷۲ بردار ویژگی ۷ بعدی با یکدیگر ترکیب شدند. داده‌ها بر اساس نتیجه مقاومت و روانی مارشال به‌دست‌آمده برچسب‌گذاری شدند. با توجه به اینکه رنج داده‌ها و واحد اندازه‌گیری آن‌ها در نتایج متفاوت می‌باشند، در الگوریتم‌های یادگیری ماشین عملکرد تابع با محدودیت سخت‌افزاری و نرم‌افزاری همراه است و نمی‌تواند عملکرد مثبتی داشته باشد. برای مثال، در این پژوهش داده‌های وزن مخصوص قیر مقادیری بسیار کوچک‌تر از فضای خالی پرشده با قیر دارند؛ بنابراین نیاز است تا مقادیر پردازش‌شده نرمالایز ۲ شوند (Ioffe & Szegedy, 2015). ساده‌ترین روش برای بی‌مقیاس کردن این است که مقادیر را به مقیاس [0,1] تغییر دهیم. فرمول این روش به‌صورت زیر می‌باشد:

$$\hat{x} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (10)$$

که در آن  $x$  داده اصلی و  $\hat{x}$  مقدار نرمالایز شده می‌باشد (Patro & Sahu, 2015).

#### ۴-۵- نتایج حاصل از مدل‌سازی با استفاده از روش SVM و RF

از داده‌های آموزشی برای ساخت مدل‌های SVM استفاده شده است. همان‌طور که در قبل اشاره شد در این روش می‌بایست از توابع کرنل استفاده کرد. مدل‌سازی بر روی داده‌های آموزشی توسط هر چهار تابع کرنل معرفی‌شده انجام شده است که بهترین نتایج با تابع کرنل پایه شعاعی به دست آمده است. همچنین به‌منظور بهینه کردن پارامترهای  $C$  و  $\gamma$  متعلق به تابع کرنل از روش 10-fold cross validation استفاده شده است که مقدار  $C$  برابر ۸ و مقدار  $\gamma$  برابر ۰.۹ برای مدل‌سازی مقاومت مارشال و مقدار  $C$  برابر ۱۰ و مقدار  $\gamma$  برابر ۰.۸ برای مدل‌سازی روانی مارشال در نظر گرفته شده است. مقادیر غیرازاین دو باعث کاهش دقت و صحت الگوریتم می‌شود. پس از آموزش، مدل توسط داده‌های آزمایشی مورد ارزیابی قرار گرفت و نتایج مربوط SDE، RMSE و MAPE مطابق جدول ۳ به دست آمد. کلیه فرایندهای مدل‌سازی با استفاده از بسته E1071 نرم‌افزار (Meyer et al., 2019) انجام شده است.

در روش RF به‌منظور تعیین تعداد متغیر انتخاب‌شده در هر گره درخت (mtry) و همچنین تعداد درخت (ntree) از روش 10-fold cross validation استفاده شده است. مطابق این روش تعداد ۱۰۰۰ درخت و ۵ متغیر در هر گره مطلوب‌ترین شرایط به برای مدل فراهم کرده است. لذا این مقادیر به‌منظور مدل‌سازی استفاده شد.

پس از ساخت مدل با استفاده از بسته random forest در نرم‌افزار R (Leo Breiman and Adele Cutler, 2018)، مدل توسط داده‌های آزمایشی مورد ارزیابی قرار گرفت که نتایج در جدول ۳ ارائه شده است. یکی از مزایای الگوریتم جنگل تصادفی این است می‌تواند اهمیت متغیرها را در یک مسئله مشخص کند. در این تحقیق اهمیت پارامترهای ورودی بر اساس شاخص اهمیت جینی و اهمیت جایگشتی به دست آمده است (Han et al., 2016) که درصد قیر و درصد فیلر دارای اهمیت بالاتری نسبت به سایر پارامترها می‌باشند.

1 Feature vector

2 Normalize


جدول ۸: نتایج ارزیابی مدل‌های SVM و RF برای مقاومت مارشال

MAPE	RMSE	SDE	R <sup>2</sup>	نوع داده	مدل
۲,۹۸۱	۳۸,۵۲۷	۰,۰۱۸۰	۰,۹۱۳۵	آموزش	SVM
۳,۰۱۷۳	۴۰,۰۴۱۲	۰,۰۲۰۸	۰,۸۷۵	آزمایش	
۳,۰۲۳	۳۹,۹۸۵	۰,۰۲۰۹	۰,۸۷۴۵	آموزش	RF
۳,۱۶۴۱	۴۱,۸۷۰	۰,۰۲۱۱	۰,۸۲۶۹	آزمایش	


جدول ۹: نتایج ارزیابی مدل‌های SVM و RF برای روانی مارشال

MAPE	RMSE	SDE	R <sup>2</sup>	نوع داده	مدل
۲,۹۸	۳۸,۴	۰,۰۱۴۱	۰,۹۲۹	آموزش	SVM
۳,۰۳	۴۰	۰,۰۲۱۴	۰,۸۴۱	آزمایش	
۳	۳۹,۷	۰,۰۲	۰,۸۸۹	آموزش	RF
۳,۱۱	۴۱,۳	۰,۰۲۰۳	۰,۸۱۱	آزمایش	

در شکل ۱۱ و ۱۲ نمودار مقادیر واقعی اندازه‌گیری شده و مقادیر پیش‌بینی شده مقاومت و روانی آسفالت توسط مدل SVM و RF برای داده‌های آموزشی و آزمایشی ترسیم شده است. همان‌طور که در شکل نیز به خوبی دیده می‌شود، نتایج به خط نیم‌ساز نزدیک هستند و می‌توان گفت مقادیر را با دقت خوبی پیش‌بینی کرده است. از لحاظ تئوری اگر R<sup>2</sup> برابر ۱۰۰ درصد شود تمامی مقادیر مشاهده‌شده با مقادیر برازش شده یکسان خواهند بود و همه نقاط داده‌ها بر روی خط برازش شده قرار خواهند گرفت (Devore, 2011).




(ب)




(الف)

شکل ۱۱: مقایسه مقدار مقاومت مارشال پیش‌بینی شده و واقعی (الف) مدل SVM (ب) مدل RF



(ب)



(الف)

شکل ۱۲: مقایسه مقدار روانی مارشال پیش‌بینی شده و واقعی (الف) مدل SVM (ب) مدل RF

## ۵- نتیجه‌گیری

در این مطالعه، تأثیر استفاده از سه نوع فیلر (فیلر حاصل از بین گرم، خاکستر پوسته برنج و خاکستر بادی) در درصد‌های مختلف بر خواص مارشال مخلوط آسفالتی با حداکثر سایز دانه ۲۵ میلی‌متر مورد بررسی قرار گرفت. مقایسه درصد‌های قیرهای نمونه‌های حاوی RHA و FA با نمونه‌های حاوی CF در درصد‌های مشابه اختلاط نشان می‌دهد مقدار قیر بهینه کاهش پیدا

کرده است. همچنین مقاومت مارشال به دست آمده از نمونه‌های حاوی این سه نوع فیلر نشان می‌دهد با توجه به کاهش قیر بهینه در مخلوط‌های حاوی RHA و FA، مقاومت آن‌ها نسبت به نمونه‌های حاوی CF افزایش پیدا کرده است. در مخلوط‌های حاوی CF، مقدار ۴ درصد از این فیلر کمترین مقدار قیر بهینه نتیجه داده است که برابر با ۴,۵۳ می‌باشد. کمترین مقدار قیر بهینه برای مخلوط‌های حاوی RHA برابر با ۴,۲۵ می‌باشد و برای مخلوط حاوی ۴ درصد از این فیلر بدست آمده است و برای مخلوط حاوی FA کمترین مقدار قیر بهینه در ۶ درصد از این فیلر به دست آمده است و برابر با ۴,۱۶ می‌باشد. با توجه به نتایج بدست آمده مقدار ۶ درصد فیلر FA کمترین مقدار قیر بهینه را نتیجه داده است. در مقایسه مقاومت‌های به دست آمده در درصد قیرهای ذکر شده، مخلوط حاوی ۶ درصد FA بیشترین مقاومت را داراست که با مقدار MQ برابر با ۴,۸۹ این مقدار نیز قابل قبول است. براین اساس می‌توان نتیجه گرفت که با استفاده از فیلهای RHA و FA می‌توان در مصرف قیر صرفه‌جویی کرد به طوری که عملکرد روسازی نسبت به قبل بهتر باشد. در ادامه به منظور ارائه مدلی برای پیش‌بینی مقاومت و روانی مارشال مخلوط‌های آسفالتی، از الگوریتم‌های یادگیری ماشین نظارت‌شده‌ی SVM و RF استفاده شد. مدل‌ها با استفاده از پارامترهای طرح مارشال آموزش داده شدند و سپس با استفاده از داده‌های آزمایشی مورد ارزیابی قرار گرفتند. مقدار  $R^2$  برای دو مدل SVM و RF در مدل‌سازی مقاومت مارشال به ترتیب برابر با ۰,۹۱۳۵ و ۰,۸۷۴۵ برای داده آموزشی و ۰,۸۷۵ و ۰,۸۲۶۹ برای داده آزمایشی به دست آمد. این مقدار برای این مدل در مدل‌سازی روانی مارشال نیز به ترتیب ۰,۹۲۹ و ۰,۸۸۹ برای داده‌های آموزشی و ۰,۸۴۱ و ۰,۸۱۱ برای داده آزمایشی بود. نتایج حاصله نشان‌دهنده کارآمدی مدل‌های استفاده شده در برابر روش‌های آزمایشگاهی برای پیش‌بینی مقاومت و روانی مارشال آسفالت می‌باشد که روش SVM عملکرد بهتری را نسبت به RF داراست. به منظور بهینه کردن الگوریتم‌های یادگیری ماشین به دست آمده و طراحی یک مدل پویای پیش‌بینی پیشنهاد می‌شود پس از انجام آزمایشات هر نمونه جدید، از نتایج حاصله در آموزش مجدد الگوریتم استفاده شود.

## منابع

1. Airey, G. D., Rahman, M. M., & Collop, A. C. (2003). Absorption of bitumen into crumb rubber using the basket drainage method. *International Journal of Pavement Engineering*, 4(2), 105-119 .
2. Al-gurah, E. R., & Al-Humeidawi, B. H. (2021). Investigation the effect of different types of mineral fillers on mechanical properties of Hot Mix Asphalt. *Journal of Physics: Conference Series* ,
3. Al-Humeidawi, B. H., & Mandal, P. (2018). Experimental investigation on the combined effect of dowel misalignment and cyclic wheel loading on dowel bar performance in JPCP. *Engineering Structures*, 174, 256-266 .
4. Al-Khuzai, M. G., Al-Humeidawi, B. H., & Ra'id, F. (2019). Assessment of Dowel Bars Performance in Concrete Pavement Containing Crumb Rubber of Tires. *Al-Qadisiyah Journal for Engineering Sciences*, 12(4), 214-219 .
5. Al-Khuzai, M. G., Al-Humeidawi, B. H., & Ra'id, F. (2020). Assessment of the mechanical properties of concrete pavement containing crumb rubber of tires. *IOP Conference Series: Materials Science and Engineering* ,
6. Arabani, M., & Tahami, S. A. (2017). Assessment of mechanical properties of rice husk ash modified asphalt mixture. *Construction and Building Materials*, 149, 350-358 .
7. Arabani, M., Tahami, S. A., & Taghipoor, M. (2017). Laboratory investigation of hot mix asphalt containing waste materials. *Road Materials and Pavement Design*, 18(3), 713-729 .
8. Asphalt, I. (2015). *Asphalt Mix Design Methods MS-2* (Seventh ed., Vol. 188). Asphalt Institute .
9. Burkov, A. (2020). *Machine learning engineering*. True Positive Incorporated .
10. Chandra, S., Kumar, P., & Feyissa, B. A. (2002). Use of marble dust in road construction. *Road Materials and Pavement Design*, 3(3), 317-330 .
11. Chen, M., Zheng, J., Li, F., Wu, S., Lin, J., & Wan, L. (2015). Thermal performances of asphalt mixtures using recycled tyre rubber as mineral filler. *Road Materials and Pavement Design*, 16(2), 379-391 .
12. Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623 .
13. Choubane, B., Page, G. C., & Musselman, J. A. (2000). Suitability of asphalt pavement analyzer for predicting pavement rutting. *Transportation Research Record*, 1723(1), 107-115 .

14. Choudhary, J., Kumar, B., & Gupta, A. (2018). Application of waste materials as fillers in bituminous mixes. *Waste Management*, 78, 417-425 .
15. Devore, J. L. (2011). *Probability and Statistics for Engineering and the Sciences*. Cengage learning .
16. Ghorbanzadeh, O ., Rostamzadeh, H., Blaschke, T., Gholaminia, K., & Aryal, J. (2018). A new GIS-based data mining technique using an adaptive neuro-fuzzy inference system (ANFIS) and k-fold cross-validation approach for land subsidence susceptibility mapping. *Natural Hazards*, 94(2), 497-517 .
17. Guha, A. H., & Assaf, G. J. (2020). Effect of Portland cement as a filler in hot-mix asphalt in hot regions. *Journal of Building Engineering*, 28, 101036 .
18. Hamed, G. H., & Tahami, S. (2018). The effect of using anti-stripping additives on moisture damage of hot mix asphalt. *International Journal of Adhesion and Adhesives*, 81, 90-97 .
19. Han, H., Guo, X., & Yu, H. (2016). Variable selection using mean decrease accuracy and mean decrease gini based on random forest. 2016 7th IEEE International Conference on Software Engineering and Service Science (ICSS) ,
20. Harris, J., & Grunsky, E. C. (2015). Predictive lithological mapping of Canada's North using Random Forest classification applied to geophysical and geochemical data. *Computers & Geosciences*, 80, 9-25 .
21. Helal, M. M. E., Mahdy, H. A.-e., & Ibrahim, M. F. (2020). Effect of Rice Husk Ash on the Performance of Hot Asphalt Mixes. *MEJ. Mansoura Engineering Journal*, 45(2), 8-19 .
22. Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. International conference on machine learning ,
23. Jalil, N. A., Hwang, H. J., & Dawi, N. M. (2019). Machines learning trends, perspectives and prospects in education sector. Proceedings of the 23<sup>rd</sup> International Conference on Education and Multimedia Technology ,
24. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning* (Vol. 112). Springer .
25. Kanevski, M. (2009). *Machine learning for spatial environmental data: theory, applications, and software*. EPFL press .
26. Kim, Y.-R., Little, D. N., & Song, I. (2003). Effect of mineral fillers on fatigue resistance and fundamental material characteristics: mechanistic evaluation. *Transportation Research Record*, 18 A-1 , (1)33
27. Lachance-Tremblay, É., Vaillancourt, M., & Perraton, D. (2016). Evaluation of the impact of recycled glass on asphalt mixture performances. *Road Materials and Pavement Design*, 17(3), 600-618 .
28. Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3-10 .
29. Leo Breiman and Adele Cutler, R. p. b. A. L. a. M. W. (2018). Package 'randomForest'. *The R Journal* .
30. Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22 .
31. Lu, Z., Sha, A., Wang, W., & Gao, J. (2020). Studying the Properties of SBS/Rice Husk Ash-Modified Asphalt Binder and Mixture. *Advances in Materials Science and Engineering*, 2020 .
32. Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., Chang, C.-C., Lin, C.-C., & Meyer, M. D. (2019). Package 'e1071'. *The R Journal* .
33. Mirković, K., Tošić, N., & Mladenović, G. (2019). Effect of different types of fly ash on properties of asphalt mixtures. *Advances in civil engineering*, 2019 .
34. Mistry, R., Karmakar, S., & Kumar Roy, T. (2019). Experimental evaluation of rice husk ash and fly ash as alternative fillers in hot-mix asphalt. *Road Materials and Pavement Design*, 20(4), 979-990 .
35. Mitchell, T. M. (1999). Machine learning and data mining. *Communications of the ACM*, 42(11), 30-36 .

36. Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). Foundations of Machine Learning. Adaptive Computation and Machine Learning series. In: MIT Press.
37. Montini, M., Li, X., Rodrigues, A., Romano, R., Pileggi, R. G., & Scrivener, K. (2018). Activate fly ash reaction using bauxite residue in blended cement. 2nd International Bauxite Residue Valorization and Best Practices Conference ,
38. Nagelkerke, N. J. (1991). A note on a general definition of the coefficient of determination. *Biometrika*, 78(3), 691-692 .
39. Ozgan, E. (2009). Fuzzy logic and statistical-based modelling of the Marshall Stability of asphalt concrete under varying temperatures and exposure times. *Advances in engineering software*, 40(7), 527-534 .
40. Özgan, E., & Saruhan, H. (2010). Modeling of asphalt concrete via simulated annealing. *Advances in engineering software*, 41(4), 680-683 .
41. Patro, S., & Sahu, K. K. (2015). Normalization: A preprocessing stage. *arXiv preprint arXiv:1503.06462* .
42. Porwal, A., Carranza, E., & Hale, M. (2004). A hybrid neuro-fuzzy model for mineral potential mapping. *Mathematical geology*, 36(7), 803-826 .
43. Ray, S. (2019). A quick review of machine learning algorithms. 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon) ,
44. Sargin, Ş., Saltan, M., Morova, N., Serin, S., & Terzi, S. (2013). Evaluation of rice husk ash as filler in hot mix asphalt concrete. *Construction and Building Materials*, 48, 390-397 .
45. Shabankareh, M., & Hezarkhani, A. (2017). Application of support vector machines for copper potential mapping in Kerman region, Iran. *Journal of African Earth Sciences*, 128, 116-126 .
46. Shawe-Taylor, J., & Cristianini, N. (2000). *An introduction to support vector machines and other kernel-based learning methods* (Vol. 204). Volume .
47. Tahami, S. A., Arabani, M., & Mirhosseini, A. F. (2018). Usage of two biomass ashes as filler in hot mix asphalt. *Construction and Building Materials*, 170, 547-556 .
48. Tiwari, S., Babbar, R., & Kaur, G. (2018). Performance evaluation of two ANFIS models for predicting water quality Index of River Satluj (India). *Advances in civil engineering*, 2018 .
49. Yang, Q., Li, X., & Shi, X. (2008). Cellular automata for simulating land use changes based on support vector machines. *Computers & geosciences*, 34(6), 592-602 .