

Moisture Sensitivity Assessment of Asphalt: A Multi-Gene Genetic Programming Approach

AH. Motamedi¹, GH. Hamed², F. Moghadas Nejad^{3*} 

1. MSc, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran.
2. Associate Professor, Department of Civil Engineering, University of Guilan, Rasht, Iran.
3. Professor, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran.

Abstract

Moisture damage in asphalt mixtures poses significant challenges to infrastructure durability, necessitating accurate modeling for effective mitigation strategies due to the complex nature of moisture susceptibility. Current tests, such as those utilizing general indicators like the indirect tensile strength ratio, examine moisture susceptibility in asphalt mixtures. However, these tests incur substantial costs and require considerable time. Therefore, this study aims to develop moisture susceptibility prediction models using Multi-Gene Genetic Programming (MGGP). The research utilized four types of aggregates (two limestone and two granite types) and eight different Performance Grade (PG) bitumen types. The modified Lottman test method (AASHTO T283) was employed for moisture susceptibility assessment, with samples subjected to specific conditioning protocols including vacuum saturation (13-67 kPa absolute pressure), freeze-thaw cycles (-18°C for 16 hours), and hot water conditioning (60°C for 24 hours). Indirect tensile strength tests were conducted under controlled loading conditions (2 Hz frequency, 0.1s loading time, 0.4s rest period) at 25°C. The dataset comprised 34 samples and 11 variables to predict two key indicators: Inflection Stripping Point (ISP) and Stripping Slope (SS). The MGGP model demonstrated remarkable performance in predicting both ISP and SS, achieving R^2 values of 0.981 and 0.974 for the test data, respectively. Several crucial parameters were analyzed, including the apparent film thickness (AFT) calculated using aggregate specific surface area, permeability measured through falling head test method (ASTM PS 129-01), and surface free energy components. The surface energy analysis incorporated both cohesive free energy (CFE) and adhesive free energy (AFE), with special attention to the acid-base theory components: Lifshitz-van der Waals (LW), Lewis acid (Γ^+), and Lewis base (Γ^-) components. For ISP prediction, the MGGP model identified key variables including the ratio of base to acid surface free energy (SFE), asphalt-water adhesion ($\Gamma_{\text{Asphalt-Water}}$), cohesive free energy (CFE), adhesive free energy (AFE), permeability of asphalt mixture (PAM), asphalt film thickness (AFT), and degree of saturation (DS). The model for SS prediction emphasized the importance of $\Gamma_{\text{Asphalt-Water}}$, aggregate-water adhesion ($\Gamma_{\text{Aggregate-Water}}$), wettability, specific surface area (SSA), PAM, and DS. The study employed various performance metrics to evaluate the MGGP models. For ISP predictions, the model achieved RMSE, MSE, and MAE values of 5.228, 27.337, and 3.843, respectively. For SS predictions, these values were 0.294, 0.086, and 0.231, respectively, indicating high accuracy and low error rates. These results surpass those of previous studies employing traditional Genetic Programming (GP) methods, highlighting the potential of MGGP as a powerful tool in modeling asphalt moisture susceptibility. The practical implications of this research are significant for improving asphalt mixture durability, reducing maintenance costs, and enhancing road safety. Future research could focus on validating the models across a broader range of asphalt mixtures and environmental conditions.

Review History

Received: Oct 25, 2024

Revised: Feb 12, 2024

Accepted: Mar 11, 2025

Keywords

Asphalt Mixture
Moisture Susceptibility
Machine Learning
Multi-Gene Genetic
Programming

* Corresponding Author Email: moghadas@aut.ac.ir - ORCID: 0000-0003-3830-4555

ارزیابی حساسیت رطوبتی آسفالت: رویکرد برنامه‌ریزی ژنتیک چندژنی

امیرحسین معتمدی^۱، غلام‌حسین حامدی^۲، فریدون مقدس‌نژاد^{۳*} 

۱. کارشناسی ارشد، دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران.

۲. دانشیار، دانشکده مهندسی عمران، دانشگاه گیلان، رشت، ایران.

۳. استاد، دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران.

چکیده

تاریخچه داوری

حساسیت رطوبتی در مخلوط‌های آسفالتی چالشی عمده در دوام زیرساخت‌های راهسازی محسوب می‌شود. دریافت: ۱۴۰/۰۸/۰۴. پیچیدگی این پدیده، مدل‌سازی دقیق را برای ارائه راهکارهای مؤثر ضروری می‌سازد. روش‌های آزمایشگاهی موجود، بازنگری: ۱۴۰۳/۰۹/۲۲. از جمله آزمون‌های مبتنی بر شاخص‌های عمومی مانند نسبت مقاومت کششی غیرمستقیم، اگرچه در ارزیابی حساسیت رطوبت کارآمد هستند، اما با محدودیت‌های قابل توجهی از نظر هزینه و زمان مواجه‌اند. در این پژوهش، با استفاده از چهار نوع سنگدانه (دو نوع آهکی و دو نوع گرانیتی) و هشت نوع قیر با درجه عملکردی مختلف، آزمایش‌هایی شامل روش اصلاح‌شده لاتمن و آزمایش کششی غیرمستقیم انجام شد. مجموعه داده‌ای متشکل از ۳۴ نمونه و ۱۱ متغیر برای پیش‌بینی دو شاخص کلیدی عملکرد حساسیت رطوبتی، نقطه عطف عریان‌شدگی (ISP) و شیب عریان‌شدگی (SS)، با استفاده از روش برنامه‌ریزی ژنتیک چندژنی (MGGP) مورد استفاده قرار گرفت. برخی از پارامترهای مهم مورد بررسی شامل ضخامت ظاهری لایه قیر، نفوذپذیری، انرژی جداشدگی، انرژی آزاد پیوستگی و چسبندگی بود. نتایج حاصل از مدل‌سازی نشان می‌دهد که برای پیش‌بینی ISP، مدل MGGP ضریب تعیین (R^2) ۰٫۹۸۱ را ارائه می‌دهد و در مورد SS، این مقدار ۰٫۹۷۴ می‌باشد. مدل مورد استفاده در این تحقیق می‌تواند فرمول‌های ریاضی ارائه دهد که شامل پارامترهای ورودی مؤثر بر ISP و SS هستند.

کلمات کلیدی

مخلوط آسفالتی
حساسیت رطوبتی
یادگیری ماشین
برنامه‌ریزی ژنتیک چندژنی

۱- مقدمه

خستگی را تشدید می‌کند [3]. اگرچه خرابی رطوبتی یک نگرانی جدی در صنعت راهسازی محسوب می‌شود، مسائل مربوط به شیارشدگی و ترک‌خوردگی توجه بیشتری را به خود جلب کرده‌اند. این تغییر رویکرد به دلیل پیچیدگی آسیب‌های ناشی از رطوبت است که عوامل متعدد شیمیایی، فیزیکی و ترمودینامیکی را شامل می‌شود [4]. خرابی رطوبتی در روسازی‌ها مشکلی پرهزینه محسوب می‌شود، زیرا بیشتر در لایه‌های زیرین ساختار روسازی رخ می‌دهد. رفع این نوع آسیب نیازمند فرآیندی زمان‌بر و پیچیده

مسئله دوام مخلوط‌های آسفالتی، به‌ویژه به دلیل تأثیر تخریب ناشی از رطوبت بر روسازی‌های آسفالتی، از اهمیت ویژه‌ای برخوردار است [1]. خرابی رطوبتی زمانی رخ می‌دهد که آب از طریق مسیرهای مختلف مانند نفوذپذیری، موینگی و انتشار بخار به درون لایه روسازی نفوذ کند [2]. نکته قابل توجه این است که این نوع آسیب به‌ندرت به تنهایی اتفاق می‌افتد و معمولاً سایر مشکلات روسازی مانند تغییر شکل دائمی و ترک‌های ناشی از

است که شامل برداشت و جایگزینی چندین لایه آسفالتی می شود. این عملیات به افزایش حجم ترافیک، ایجاد مشکلات ایمنی و تحمیل هزینه های اضافی به کاربران منجر می شود [5]. تشخیص به موقع آسیب های ناشی از رطوبت نه تنها به حفظ دوام روسازی کمک می کند، بلکه هزینه های نگهداری را در طول عمر سازه به طور چشمگیری کاهش می دهد [6]. با این وجود، روش های متداول ارزیابی حساسیت رطوبتی با معایبی از جمله هزینه های بالا، فرآیندهای زمان بر و احتمال بروز خطای انسانی مواجه هستند که می تواند به نتایج غیرقابل اطمینان منجر شود [7]. به دلیل این محدودیت ها، توجه فزاینده ای به روش های پیش بینی کننده ایجاد شده است. اگرچه روش های آماری متداول مانند رگرسیون خطی و آزمون های معناداری به طور گسترده استفاده می شوند، اما عموماً در تشخیص روابط پیچیده و غیرخطی کارایی لازم را ندارند. در پاسخ به این چالش ها، روش های یادگیری ماشین به عنوان جایگزینی کارآمد مطرح شده اند [8، 9]. استفاده از مدل های یادگیری ماشین، رویکردی مبتنی بر داده ارائه می دهد که در مقایسه با روش های تجربی سنتی، قادر به ارائه پیش بینی های دقیق تر و معتبرتر است [10]. در سال های اخیر، پژوهش های قابل توجهی در زمینه کاربرد مدل های پیش بینی یادگیری ماشین برای ارزیابی خرابی رطوبتی مخلوط های آسفالتی انجام شده است. ویراگاوون و همکاران [8] از روش های یادگیری ماشین برای بررسی این نوع خرابی در مخلوط های آسفالت گرم استفاده کردند. در این مطالعه، مقادیر مقاومت کششی غیرمستقیم (ITS) و مدول ارتعاشی (Es)^۱ به عنوان داده های ورودی به کار گرفته شدند. این داده ها از آزمون های آزمایشگاهی به دست آمده بودند که پس از قرار دادن مخلوط ها در معرض آزمونگر تنش ناشی از رطوبت (MiST)^۲ انجام شده بود. داده های حاصل به عنوان متغیرهای ورودی برای چهار الگوریتم بیز ساده (NB)، ماشین های بردار پشتیبان (SVM)، نزدیک ترین همسایه ها (KNN) و درخت تصمیم (DT) استفاده شدند. نتایج نشان داد که مدل های ایجاد شده با روش های SVM و NB، با دستیابی به دقت ۹۵٪، عملکرد قابل توجهی داشتند که نشان دهنده پتانسیل بالای این روش ها در ارزیابی خرابی رطوبتی مخلوط های آسفالتی است. در مطالعه ای دیگر، ب. مالیک و

همکاران [11] از روش های طبقه بندی نزدیک ترین همسایه (KNN) و بیز ساده (NB) برای پیش بینی حساسیت رطوبتی آسفالت گرم استفاده کردند. در این پژوهش، تحلیل مؤلفه های اصلی برای شناسایی متغیرهای کلیدی به کار رفت که شامل نسبت مقاومت کششی غیرمستقیم (ITS)، مدول ارتعاشی (Es)، انرژی شکست (FE) و نسبت پیکسل سیاه بود. نتایج نشان داد که مدل KNN به دقت ۱۰۰٪ دست یافت، در حالی که روش NB دقت ۸۶٪ داشت. سزاوار و همکاران [12] نیز در پژوهشی از الگوریتم روش گروهی پردازش داده ها (GMDH)^۳ برای ایجاد یک مدل شبکه عصبی مصنوعی (ANN)^۴ استفاده کردند. هدف این مدل، پیش بینی حساسیت رطوبتی آسفالت اصلاح شده با نانو سیلیس بود. در فرآیند مدل سازی، چندین پارامتر آزمایشگاهی مورد توجه قرار گرفت، از جمله انواع قیر، شرایط نمونه، فضای خالی هوا، مقدار رطوبت، مقاومت فشاری، مقاومت کششی غیرمستقیم (ITS) و نسبت مقاومت کششی (TSR). نتایج پیش بینی شده توسط مدل شبکه عصبی GMDH با داده های واقعی آزمایشگاهی مقایسه شد که همبستگی قوی را نشان داد و حاکی از عملکرد قابل توجه مدل بود. در داده های آزمایشی، R^2 برابر ۰٫۹۶۷۱۶ و ریشه میانگین مربعات خطا (RMSE) برابر ۰٫۰۲۲۹۴۵، به دست آمد که دقت بالای مدل را تأیید می کند. در حوزه یادگیری ماشین، روش شبکه عصبی مصنوعی به طور گسترده در کاربردهای مختلف مهندسی عمران و راهسازی به کار گرفته شده است [13]. باباگلی و رضایی [14] مدل های ANN و رگرسیون بردار پشتیبان (SVR) را برای پیش بینی نسبت انرژی شکست (FE)، نسبت مدول ارتجاعی و نسبت مقاومت کششی (TSR) ارائه دادند. این مدل ها از متغیرهای ورودی شامل مقدار رطوبت، لاستیک استایرن-بوتادین، خرده لاستیک و عوامل ضد عریان شدگی استفاده می کردند. نتایج نشان داد که ANN عملکرد بهتری نسبت به SVR داشت. برای داده های آزمایشی، میانگین خطاهای مطلق (MAE) برای ANN، ۰٫۰۰۱۶، برای نسبت FE، ۰٫۰۰۰۸، برای نسبت مدول ارتجاعی و ۰٫۰۰۱۴، برای TSR بود. در مطالعه ای دیگر، باباگلی و رضایی [15] از روش های ANN و رگرسیون خطی چندگانه (MLR) برای پیش بینی حساسیت رطوبتی در مخلوط های اصلاح شده با نانو

³ Group Method of Data Handling⁴ Artificial Neural Network¹ Seismic modulus² Moisture-Induced Stress Tester

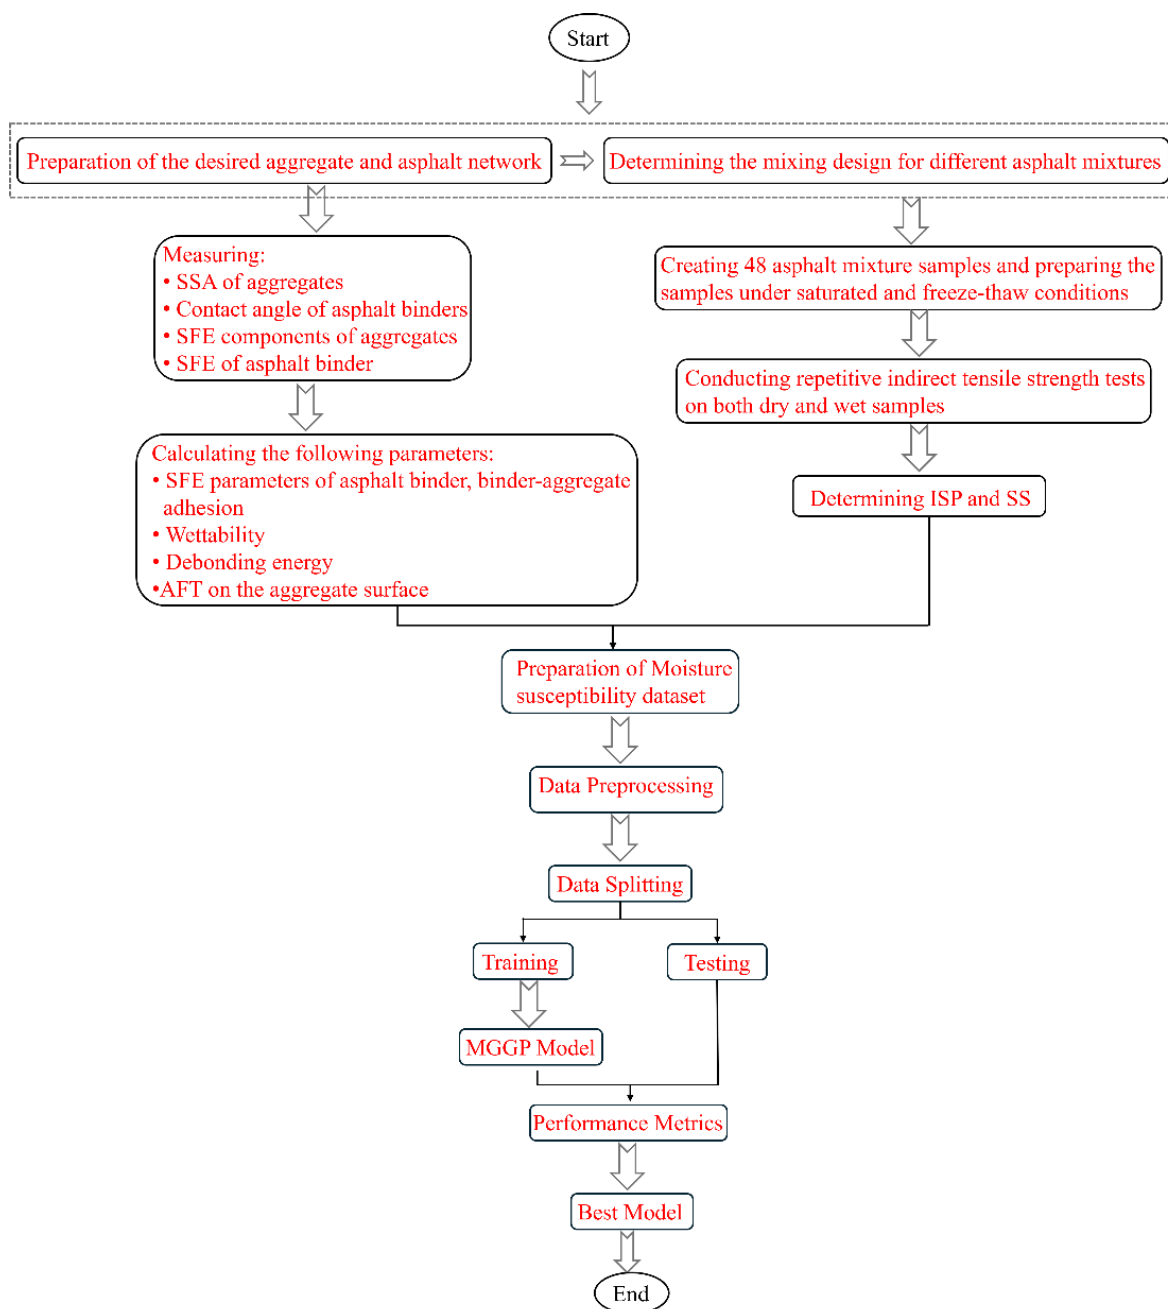
TiO₂ استفاده کردند. این مدل‌ها مقدار افزودنی، نوع سنگدانه و مقدار رطوبت را به عنوان متغیرهای ورودی در نظر گرفتند. مدل ANN عملکرد به مراتب بهتری را نشان داد، با R^2 برابر ۰,۹۹۱ برای TSR و ۰,۹۸۸ برای نسبت FE در داده‌های آزمایشی، که در پیش‌بینی نتایج از MLR پیشی گرفت. ربلو و همکاران [16] با هدف توسعه یک مدل پیش‌بینی کننده برای نسبت مقاومت کششی غیرمستقیم (ITSR) مخلوط‌های آسفالتی، بر متغیرهای مؤثر بر حساسیت آبی تمرکز کردند. آن‌ها با استفاده از سیزده پارامتر، داده‌ها را با استفاده از رگرسیون چندگانه، شبکه عصبی مصنوعی و ماشین بردار پشتیبان (SVM) تحلیل کردند. این مطالعه، SVM را به عنوان مؤثرترین مدل پیش‌بینی کننده برای ITSR شناسایی کرد، با ضریب همبستگی پیرسون (R) برابر ۰,۶۶۷. همچنین مشخص شد که مقدار قیر بیشترین تأثیر را بر حساسیت آبی دارد، پس از آن عواملی مانند ویژگی‌های سنگدانه، خواص قیر و استفاده از افزودنی‌ها قرار دارند. برخلاف روش‌های متداول یادگیری ماشین که از شبکه‌های کم‌عمق و مقدار محدودی داده آموزشی استفاده می‌کنند، کائو و همکاران [17] رویکرد یادگیری عمیق (DL) را برای پیش‌بینی میزان رطوبت در روسازی آسفالتی معرفی کردند. آن‌ها روش جدیدی به نام Mois-ResNets را با استفاده از شبکه‌های عصبی باقیمانده عمیق پیشنهاد دادند. مجموعه داده‌های مورد استفاده در این پژوهش با ترکیبی از آزمایش‌های میدانی و شبیه‌سازی‌های رادار نفوذی به زمین تهیه شد. در مقایسه با روش‌های سنتی یادگیری ماشین، Mois-ResNets به دقت ۹۱٪ دست یافت. این عملکرد به طور قابل توجهی بهتر از روش نزدیک‌ترین همسایه (KNN) با دقت ۷۹٪ و روش‌های ماشین بردار پشتیبان (SVM) و درخت تصمیم (DT) با دقت ۶۵٪ بود. نتایج این پژوهش نشان می‌دهد که برای دستیابی به نتایج بهینه در پیش‌بینی رطوبت روسازی آسفالتی، استفاده از روش‌های پیشرفته یادگیری عمیق می‌تواند مؤثرتر از روش‌های سنتی یادگیری ماشین باشد. با این حال، برقراری یک معادله ریاضی مشخص بین متغیرهای ورودی و خروجی همچنان برای بهبود عملکرد و قابلیت تفسیر مدل‌ها ضروری است. مجیدی فرد و همکاران [18] برای پیش‌بینی FE مخلوط‌های آسفالتی از دو روش یادگیری ماشین یعنی برنامه‌ریزی بیان ژن (GEP) و شبکه عصبی مصنوعی ترکیبی با تبرد شبیه‌سازی شده (ANN/SA) استفاده کردند. در این پژوهش

برای پیش‌بینی FE، با استفاده از متغیرهایی مانند درجه عملکردی قیر، محتوای آسفالت، اندازه سنگدانه، دانه بندی سنگدانه، محتوای آسفالت بازیافتی (RAP)، محتوای شینگل‌های آسفالتی بازیافتی (RAS)، محتوای لاستیک خرد شده و دمای آزمایش معادله ریاضی ارائه شده است. نتایج نشان داد که برای داده‌های آزمایشی روش GEP با مقدار R^2 برابر ۰,۹۶۹ عملکرد بهتری نسبت به ANN/SA با R^2 برابر ۰,۹۳۲ دارد. اما در محدوده این مطالعه، تحقیقات محدودی وجود دارد که یک فرمول ریاضی ارائه می‌دهد. مدل‌های اصلی شامل رگرسیون خطی و غیرخطی، همراه با الگوریتم‌های تکاملی مانند الگوریتم ژنتیک [19، 20] می‌باشند. بر این اساس، گیلانی و همکاران [19] تحقیقی را برای پیش‌بینی آثار اصلاح آهک هیدراته نانو بر تخریب رطوبتی و خستگی در مخلوط‌های آسفالتی انجام دادند. آن‌ها از روش‌های مختلفی از جمله برنامه‌ریزی ژنتیک (GP)، رگرسیون چند متغیره و GMDH استفاده کردند. این مدل‌ها از متغیرهای مستقلی مانند انرژی آزاد چسبندگی و پیوستگی، درصد افزودنی، تعداد چرخه، انرژی جداشدگی و نفوذپذیری مخلوط آسفالتی بهره گرفتند.

در میان سه روش مورد بررسی، رویکرد GMDH با R^2 برابر ۰,۹۹۰ دقت بالاتری را نشان داد و خطاها را به کمترین رساند. با استفاده از نتایج تحقیقات گیلانی و همکاران [19]، بهبهانی و همکاران [20] یک مدل GP را برای بهبود مقاومت در برابر خستگی و آسیب رطوبتی توسعه دادند. این ارزیابی علاوه بر ورودی‌های کار گیلانی و همکاران، پارامتر جدیدی به نام مساحت سطح سنگدانه‌ها را نیز در نظر گرفت. مدل GP دقت پیش‌بینی با R^2 برابر ۰,۹۶۴ را نشان داد.

پژوهش حاضر از آزمایش خستگی کشش غیرمستقیم (ITFT) برای ارزیابی حساسیت مخلوط‌های آسفالتی به مشکلات مرتبط با رطوبت استفاده می‌کند. دو پارامتر مهم وجود دارد که حساسیت رطوبتی را به خوبی بیان می‌کنند. اولی نقطه عطف عریان‌شدگی^۱ (ISP) است که به طور کلی نقطه‌ای است که در آن شیب منحنی آزمایش بارگذاری مکرر ناگهان تغییر می‌کند، و دیگری شیب عریان‌شدگی^۲ (SS) است که می‌توان آن را به عنوان شیب بخش دوم منحنی آزمایش بارگذاری مکرر تعریف کرد [21].

¹ Inflection Stripping Point² Stripping Slope



شکل ۱. فلوچارت روش تحقیق

Fig 1. Flowchart of methodology

۲- مواد و روش‌ها

در طول این مطالعه، آزمایش‌های آزمایشگاهی متعددی برای ایجاد مدل پیش‌بینی‌کننده برای ارزیابی حساسیت رطوبتی در انواع مختلف مخلوط‌های آسفالتی انجام شد. بخش روش تحقیق شامل آزمایش‌ها، جمع‌آوری داده‌ها، پیش‌پردازش داده‌ها و کاربرد برنامه‌ریزی بیان ژن چندژنی است. فلوچارت روش تحقیق مورد استفاده در این مطالعه، در شکل (۱) نشان داده شده است.

این مطالعه، برخلاف تحقیقات پیشین که این پارامترها را نادیده گرفته‌اند، با معرفی مدل‌های پیش‌بینی برای تخمین ISP و SS، آن‌ها را مورد توجه قرار می‌دهد. تمرکز اصلی بر روش محاسبات نرم، به ویژه برنامه‌ریزی ژنتیک چند ژنی (MGGP) است. این روش نه تنها مدلی واضح‌تر و قابل تفسیرتر نسبت به روش‌های سنتی یادگیری ماشین ارائه می‌دهد، بلکه یک چارچوب ریاضی پیش‌بینی‌کننده نیز فراهم می‌کند.

جدول ۱. مواد معدنی تشکیل‌دهنده سنگدانه‌ها

Table 1. The constituent minerals of the aggregates

Aggregate	Mineral Composition (%)						
	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	MgO	Na ₂ O	CaO	Others
Limestone	6.58	4.84	3.87	2.24	3.35	72.47	6.65
	12.44	3.28	4.94	1.26	2.79	65.81	9.48
Granite	69.10	12.60	3.77	1.62	2.04	5.10	5.77
	42.13	7.11	5.70	4.54	4.64	29.90	5.98

جدول ۲. نتایج مشخصات عملکردی قیرها

Table 2. Asphalt binders Performance Characteristics

(Viscosity: ASTM D4402, $G^*/\sin\delta$ and $G^*.\sin\delta$: ASTM D7175, Stiffness and m-value: ASTM D6648)


Bitumen	Viscosity (Pa.s)		$G^*/\sin\delta$ (kPa)		$G^*.\sin\delta$ (kPa)		Stiffness (MPa)		m-value	
	Value	Temperature (°C)	Value	Temperature (°C)	Value	Temperature (°C)	Value	Temperature (°C)	Value	Temperature (°C)
PG 52-16	0.305	135	4.15	52	3050	22	101.2	-6	0.341	-6
PG 52-22	0.305	135	4.12	52	3830	19	80.7	-12	0.325	-12
PG 76-10	0.81	135	1.59	76	2930	37	149.6	0	0.31	0
PG 70-16	0.715	135	1.69	70	3280	31	109.6	-6	0.315	-6
PG 70-10	0.71	135	1.67	70	2850	34	90.4	0	0.348	0
PG 58-22	0.32	135	2.18	58	2650	22	109.5	-12	0.321	-12
PG 64-22	0.33	135	1.76	64	3210	25	140.2	-12	0.302	-12
PG 64-16	0.33	135	1.78	64	2650	28	108.2	-6	0.367	-6

نشان داده شده است.

دی‌اکسید سیلیسیم (SiO₂)، که مسئول اسیدی بودن سنگدانه‌هاست، در سنگدانه‌های گرانیتی غالب بود، در حالی که اکسید کلسیم (CaO)، که نشان‌دهنده قلیایی بودن سنگدانه‌هاست، در سنگدانه‌های آهکی غالب بود. در این جدول، Al₂O₃، Fe₂O₃، MgO و Na₂O به ترتیب نشان‌دهنده اکسید آلومینیوم، اکسید آهن، اکسید منیزیم و اکسید سدیم هستند. سنگدانه‌ها دارای دانه بندی شماره ۴ از MS-2 بودند.

بیشترین اندازه و اندازه اسمی آن‌ها در این دانه بندی به ترتیب ۱۹ و ۱۲٫۵ میلی‌متر است. شکل (۲) نمودار این دانه بندی را نشان می‌دهد. برای حذف تأثیر نوع دانه‌بندی بر نتایج آزمایش ترک‌خوردگی در دمای پایین، از یک دانه‌بندی یکنواخت برای تمام نمونه‌های سنگدانه استفاده شد.

ویژگی‌های سنگدانه‌ها از نظر ویژگی‌های فیزیکی در جدول (۲) ثبت شده است. علاوه بر این، آزمایش حد خمیری که روی سنگدانه‌های ریز طبق استاندارد ASTM D 4318 [22] انجام شد، به طبقه‌بندی غیر خمیری منجر شد.



شکل ۲. منحنی دانه‌بندی سنگدانه‌ها

Fig 2. Gradation of aggregates samples

۱-۲- مصالح مورد استفاده

۱-۱-۲- سنگدانه

در این پژوهش از چهار نوع سنگدانه، متشکل از دو نوع سنگ آهک و دو نوع سنگدانه گرانیتی استفاده شد. این انتخاب‌ها بر اساس کانی‌های تشکیل‌دهنده متفاوت آن‌ها صورت گرفت که امکان در نظر گرفتن طیف وسیعی از سنگدانه‌ها را فراهم می‌کرد. ساختار کانی‌شناسی این چهار نوع سنگدانه با استفاده از روش‌های فلورسانس اشعه ایکس بررسی شد، همانطور که در جدول (۱)

۲-۱-۲- قیر

در این مطالعه، از هشت قیر با درجه عملکردی^۱ مختلف (شرکت آذربام عایق کار، ایران) استفاده شد. نتایج حاصل از آزمایش‌های رئولوژیکی قیرها در جدول (۲) ارائه شده است.

۲-۲- روش تحقیق

۲-۲-۱- طرح اختلاط

در این پژوهش، آزمایش حساسیت رطوبتی بر اساس روش اصلاح‌شده لوتمن (AASHTO T283 [23]) انجام گرفت. این آزمایش به منظور بررسی و ارزیابی ویژگی‌های مخلوط‌های آسفالتی تحت شرایط خشک و تر طراحی شده است [24]. مراحل آزمایشگاهی به شرح زیر است:

۱- برای هر مخلوط، شش نمونه (با قطر ۱۰۰ میلی متر و ارتفاع ۲،۵ ± ۶۳،۵ میلی متر) آماده شد: سه نمونه مرطوب و سه نمونه خشک.

۲- نمونه‌ها با استفاده از چکش مارشال متراکم شدند تا ۰،۵٪ ± ۷ محتوای هوا به دست آید. تعداد ضربات مورد نیاز جهت رسیدن به این محتوای هوا در نمونه‌ها که با آزمون و خطا بدست آمده، مابین ۴۶ تا ۷۱ ضربه است.

۳- قطر، ارتفاع و وزن نمونه‌های متراکم‌شده اندازه‌گیری شد.

۴- چگالی ویژه تعیین شد تا حجم نمونه و فضای خالی هوا محاسبه شود.

۵- نیمی از نمونه‌های هر گروه در شرایط خشک باقی ماندند (نمونه‌های خشک) و نیمی دیگر به شرایط مرطوب منتقل شدند (نمونه‌های مرطوب).

۶- برای نمونه‌های مرطوب:

الف. فرآیند اشباع‌سازی شامل اعمال خلأ (فشار مطلق ۱۳-۶۷ کیلوپاسکال) به مدت ۵ دقیقه و سپس غوطه‌وری به مدت ۱۰-۵ دقیقه بدون خلأ بود.

ب. سپس نمونه‌ها خارج شده و وزن آن‌ها اندازه‌گیری شد. درصد اشباع نمونه‌ها با استفاده از وزن آب جذب‌شده و حجم هوا محاسبه شد.

ج. اگر درصد اشباع کمتر از ۷۰٪ بود، خلأ دوباره تکرار شد؛ و اگر بیشتر از ۸۰٪ بود، یک نمونه جدید تهیه شد.

نمونه جدید نیاز به زمان کمتری تحت شرایط خلأ داشت

و درصد اشباع آن بین ۷۰٪ تا ۸۰٪ قرار گرفت.

۷- نمونه‌های اشباع‌شده به کیسه‌های پلاستیکی منتقل شدند، ۱۰ میلی‌لیتر آب به آن‌ها اضافه شد و کیسه‌ها به مدت ۱۶ ساعت در دمای ۱۸- درجه سانتی‌گراد منجمد شدند.

۸- سپس، نمونه‌ها در یک حمام آب داغ در دمای ۶۰ درجه سانتی‌گراد قرار داده شدند، کیسه‌های پلاستیکی حذف شدند و نمونه‌ها به مدت ۲۴ ساعت در این دما باقی ماندند. پس از آن، نمونه‌ها به دمای اتاق (۲۵ درجه سانتی‌گراد) منتقل شدند و به مدت ۲۴ ساعت در این دما باقی ماندند. این نمونه‌ها به نام نمونه‌های مرطوب شناخته شدند.

۲-۲-۲- مقاومت کششی غیرمستقیم

روش کششی غیرمستقیم برای انجام آزمایش‌های بارگذاری مکرر بر روی نمونه‌های آسفالت خشک و تر شده به‌منظور تعیین مدول آن‌ها تحت شرایط بارگذاری مختلف استفاده شد [21]. این آزمایش خستگی شامل قرار دادن نمونه‌های استوانه‌ای تحت بارگذاری از نوع نیم‌سینوسی با مشخصات زیر بود:

- فرکانس: ۲ هرتز
- زمان بارگذاری: ۰،۱ ثانیه
- زمان استراحت: ۰،۴ ثانیه
- دما: ۲۵ درجه سانتی‌گراد

خروجی این آزمایش مدول سختی مخلوط آسفالت در نمونه‌های خشک و تر است که برای محاسبه روند تغییرات نسبت سختی مخلوط آسفالتی و درصد عریان‌شدگی سطح دانه‌ها در چرخه‌های بارگذاری استفاده می‌شود. در نمودارهای نسبت مدول سختی در شرایط مرطوب به خشک و عریان‌شدگی سطح دانه‌ها در چرخه‌های بارگذاری دو نقطه وجود دارد: ۱. نقطه‌ای که ساختار یکپارچه مخلوط آسفالت از بین رفته و مقاومت در برابر رطوبت کاهش می‌یابد. ۲. شیب بخش دوم نمودار که نشان‌دهنده نرخ عریان‌شدگی است.

این دو مفهوم به عنوان نمونه در شکل (۳) نمایش داده شده است. تلاشی برای بررسی پارامترهای مؤثر در این دو مورد انجام شد که در این تحقیق به آن‌ها عریان‌شدگی اولیه و شیب عریان‌شدگی گفته می‌شود.

¹ Performance Grade

مخلوط‌های آسفالت اهمیت زیادی دارد. این ویژگی به عنوان توانایی مواد متخلخل برای اجازه دادن به عبور آب از طریق منافذ و نفوذ آن در ساختار آن‌ها تعریف می‌شود. وجود رطوبت در سطح تماس بین قیر و سنگدانه عامل اصلی مؤثر در ایجاد آسیب ناشی از رطوبت است. سطح آسفالت به طور مستقیم در تماس با رطوبت ناشی از بارش و روان آب قرار دارد، در حالی که لایه‌های زیرین عمدتاً به دلیل ترک‌ها، منافذ و نفوذ آب در ماستیک در معرض رطوبت هستند. با توجه به چگالی و نفوذپذیری پایین مخلوط‌های آسفالت در این مطالعه، آزمایش بار افتان (falling head test) بر اساس استاندارد ASTM PS 129-01 انجام شد. ضریب نفوذپذیری (K) با استفاده از رابطه (۲) تعیین می‌شود [19, 27].

$$K = \frac{2.3aL}{At} \log \frac{h_1}{h_2} \quad (2)$$


در این رابطه K ضریب نفوذپذیری (cm/sec)، a مساحت مقطع لوله مدرج (cm²)، L ارتفاع نمونه مخلوط آسفالت (cm)، h₁ و h₂ به ترتیب ارتفاع ستون آب در ابتدای و انتهای آزمایش (mm) را نشان می‌دهند، t زمان لازم برای کاهش سطح آب از h₁ به h₂ (sec) و A مساحت مقطع نمونه مخلوط آسفالت (cm²) است.

۲-۲-۵- انرژی آزاد سطحی

انرژی آزاد سطحی (SFE) یک ماده جامد یا مایع، نشان دهنده انرژی مورد نیاز برای ایجاد یک واحد سطح جدید از آن ماده در فضای آزاد است. این انرژی بر اساس پیوندهای بین مواد به دو دسته تقسیم می‌شود: انرژی آزاد چسبندگی زمانی که پیوندها متفاوت هستند، و انرژی آزاد پیوستگی زمانی که پیوندها یکسان هستند [28]. یکی از روش‌های توصیف اجزای SFE، نظریه اسید-باز است [29]. طبق این نظریه، کل SFE یک ماده شامل سه جزء اصلی مرتبط با نیروهای مولکولی سطح است: جزء غیرقطبی یا لیفیتیز-وان در والس (LW)، و همچنین اجزای اسید لوئیس (Γ⁺) و باز لوئیس (Γ⁻). رابطه (۳) کل SFE (Γ) را نشان می‌دهد.

$$\Gamma = \Gamma^{LW} + \Gamma^{\pm} = \Gamma^{LW} + 2\sqrt{\Gamma^{+}\Gamma^{-}} \quad (3)$$

در این رابطه Γ نشان دهنده کل SFE (ergs/cm²) است، Γ^{LW} جزء غیرقطبی (ergs/cm²) را نمایش می‌دهد، Γ⁺ جزء اسیدی (ergs/cm²) است، و Γ⁻ جزء بازی (ergs/cm²) را نشان می‌دهد.



شکل ۳. تعیین SS و ISP

Fig 3. Determination of ISP and SS

۲-۲-۳- ضخامت ظاهری لایه قیر

ضخامت ظاهری لایه قیر روی سطح سنگدانه‌ها تأثیر زیادی بر وقوع، نوع و شدت آسیب‌های رطوبتی دارد. محاسبه AFT قیر در این تحقیق شامل تعیین نسبت بین حجم مؤثر قیر به ازای هر واحد جرم مخلوط آسفالت (m³/kg) و مساحت سطح دانه‌های ۱ کیلوگرم مخلوط آسفالت (m²/kg) بود. این روش محاسبه، همان‌طور که در گزارش NCHRP 567 تشریح شده و در رابطه (۱) توسط کریستنسن و بوناگوئیست [25] بیان شده است، امکان محاسبه AFT را فراهم می‌کند. تعیین مساحت سطح ویژه (SSA) سنگدانه‌ها در این پژوهش، بر اساس مطالعه انجام شده توسط حامدی و مقدس‌نژاد [26] صورت گرفته است.

$$AFT = \frac{1000 \times VBE}{SPG} \quad (1)$$

در این رابطه، AFT نشان دهنده ضخامت ظاهری لایه قیر (μm) می‌باشد. صورت این کسر بیانگر نسبت حجم قیر مصرف شده به ازای واحد حجم مخلوط آسفالتی است، و مخرج آن نشان دهنده سطح سنگدانه‌ها به ازای واحد حجم مخلوط آسفالتی می‌باشد [27]. VBE درصد حجم مؤثر قیر نسبت به حجم کل مخلوط آسفالتی (%) را نشان می‌دهد، و SPG از حاصل ضرب پارامترهای S_s مساحت سطح ویژه (SSA) سنگدانه‌ها (m²/kg)، P_s درصد وزنی سنگدانه‌ها نسبت به کل وزن مخلوط (%) و G_{mb} جرم مخصوص مخلوط (kg/m³) به دست می‌آید.

۲-۲-۴- نفوذپذیری

نفوذپذیری در پیش‌بینی و درک آسیب‌های ناشی از رطوبت در

$$\Delta G_{132}^a = \Gamma_{12} - \Gamma_{13} - \Gamma_{23} \quad (6)$$

$$= - \left[\begin{aligned} & (2\Gamma_3^{LW}) + \left(4\sqrt{\Gamma_3^+ \Gamma_3^-} \right) - \left(2\sqrt{\Gamma_1^{LW} \Gamma_3^{LW}} \right) \\ & - \left(2\sqrt{\Gamma_3^+ \Gamma_1^-} \right) - \left(2\sqrt{\Gamma_1^+ \Gamma_3^-} \right) - \left(2\sqrt{\Gamma_2^{LW} \Gamma_3^{LW}} \right) \\ & - \left(2\sqrt{\Gamma_3^+ \Gamma_2^-} \right) - \left(2\sqrt{\Gamma_2^+ \Gamma_3^-} \right) + \left(2\sqrt{\Gamma_1^{LW} \Gamma_2^{LW}} \right) \\ & + \left(2\sqrt{\Gamma_1^+ \Gamma_2^-} \right) + \left(2\sqrt{\Gamma_2^+ \Gamma_1^-} \right) \end{aligned} \right]$$

در رابطه با مفاهیم کلیدی مرتبط با این اجزا، دو مفهوم مهم وجود دارد: ۱. انرژی جداشدگی: در سیستم قیر و سنگدانه، AFE (انرژی آزاد چسبندگی) در حضور آب به عنوان انرژی جداشدگی شناخته می شود. در این حالت، سیستم انرژی آزاد می کند که فرآیندی خودبه خودی است [21]. ۲. ترشوندگی: پوشش، ترشوندگی و زاویه تماس مفاهیمی هستند که ارتباط نزدیکی با چسبندگی دارند. از دیدگاه ترمودینامیکی، پوشش به تعادل بین نیروهای همبستگی و چسبندگی بستگی دارد. این تعامل، همانطور که در رابطه (۷) مشخص شده، می تواند برای تعیین ضریب پوشش (S) مورد استفاده قرار گیرد.

$$S = W^a - W^c \quad (7)$$

در اینجا S ضریب پوشش (ergs/cm^2)، W^a انرژی آزاد چسبندگی قیر و سنگدانه (ergs/cm^2)، و W^c انرژی آزاد پیوستگی قیر (ergs/cm^2) است. مقدار بزرگتر و مثبت تر ضریب پوشش نشان دهنده غلبه نیروی چسبندگی بر نیروی پیوستگی است. ضریب پوشش منفی نشان دهنده زاویه تماس بزرگ، و ضریب پوشش صفر نشان دهنده تعادل است.

۲-۵-۳-۲-۲-۳- اندازه گیری مؤلفه های انرژی آزاد سطحی سنگدانه

اندازه گیری مستقیم اجزای انرژی سطحی (SFE) یک ماده جامد با چالش های قابل توجهی مواجه است و به همین دلیل، روش های جایگزینی به کار گرفته می شوند. یکی از این روش ها، ارزیابی غیرمستقیم این اجزا از طریق دستگاه جذب یونیورسال (USD) است که توسط بهسین توسعه یافته [33] است. این روش از مواد پروپ با اجزای SFE شناخته شده استفاده می کند تا کار چسبندگی بین این مواد و ماده جامد مورد نظر را تعیین کند. روش USD اجزای SFE را به طور غیرمستقیم از طریق تحلیل ویژگی های جذب گاز سه حلال مشخص می کند و کار چسبندگی بین یک مایع آزمایشی و یک ماده جامد را از طریق نظریه اسید-باز به

۲-۵-۱- انرژی آزاد پیوستگی

از دیدگاه ترمودینامیکی، انرژی آزاد پیوستگی (CFE) نشان دهنده انرژی مورد نیاز برای ایجاد یک ترک با سطح واحد در داخل یک ماده است. در مورد مایعات، کار پیوستگی مقدار انرژی لازم برای جدا کردن یک ستون مایع با سطح مقطع واحد به دو قسمت در خلأ را نشان می دهد [30]. رابطه (۴) کار پیوستگی (ΔG^c) در مواد مختلف را نمایش می دهد.

$$\Delta G^c = W^c = 2\Gamma \quad (4)$$

در این رابطه ΔG^c نشان دهنده انرژی آزاد پیوستگی (ergs/cm^2) است و Γ کل انرژی آزاد سطحی (SFE) (ergs/cm^2) را نشان می دهد.

۲-۵-۲-۲-۲- انرژی آزاد چسبندگی

تعیین انرژی آزاد چسبندگی (AFE) در سیستم قیر و سنگدانه شامل محاسبه انرژی لازم برای ایجاد یک ترک با سطح واحد در ناحیه تماس، به ویژه در شرایط خلأ می باشد.

[31]. این AFE، که با ΔG^a نمایش داده می شود، از دو جزء اصلی تشکیل شده است: اجزای قطبی و غیرقطبی. رابطه (۵) برای محاسبه AFE بین قیر و سنگدانه استفاده می شود.

$$\Delta G^a = -w^a = \Delta G^{aLW} + \Delta G^{aAB} = -2 \left[\left(\sqrt{\Gamma_2^{LW} \Gamma_1^{LW}} \right) + \left(\sqrt{\Gamma_2^+ \Gamma_1^-} \right) + \left(\sqrt{\Gamma_2^- \Gamma_1^+} \right) \right] \quad (5)$$

در این رابطه ΔG^a نشان دهنده انرژی آزاد چسبندگی (ergs/cm^2)، ΔG^{aLW} جزء غیرقطبی (ergs/cm^2)، ΔG^{aAB} جزء قطبی (ergs/cm^2)، Γ_1^{LW} ، Γ_1^+ و Γ_1^- اجزای انرژی آزاد سطحی قیر (ergs/cm^2)، Γ_2^{LW} ، Γ_2^+ و Γ_2^- اجزای SFE سنگدانه ها را نشان می دهند (ergs/cm^2).

محاسبه چسبندگی بین مواد ۱ و ۲ در حضور ماده ۳ (یک مایع قطبی مانند آب) می تواند با استفاده از رابطه (۶)، همانطور که توسط گود و ون اس [32] پیشنهاد شده است، انجام شود.

نکته قابل توجه این است که مقدار منفی برای AFE نشان دهنده تمایل بیشتر به عریان شدگی است [32]. همچنین پارامترهای استفاده شده در این رابطه پیشتر در رابطه (۵) معرفی شده اند. اندیس های ۱، ۲ و ۳ به ترتیب به قیر، سنگدانه و آب اشاره دارند.

حلال مایع با سرعت ثابت و بسیار کم استوار است. استفاده از این روش، عناصر SFE را نشان می‌دهد که شامل اندازه‌گیری زاویه تشکیل شده بین آسفالت و یک مایع است [34].

$$\Gamma_L(1 + \cos \theta) = \quad (10)$$

$$2(\sqrt{\Gamma_S^{LW}\Gamma_L^{LW}} + \sqrt{\Gamma_S^+\Gamma_L^-} + \sqrt{\Gamma_S^-\Gamma_L^+})$$

در این رابطه Γ_L انرژی آزاد سطحی کل مایع (ergs/cm²)، θ زاویه تماس پویا بین قیر آسفالتی و مایع مورد آزمایش (°) که می‌تواند با استفاده از آزمایش WP تعیین شود. همچنین Γ_S^{LW} ، Γ_S^+ و Γ_S^- نشان‌دهنده اجزای انرژی آزاد سطحی قیر آسفالتی (ergs/cm²) و Γ_L^+ ، Γ_L^- و Γ_L^{LW} اجزای انرژی آزاد سطحی مایع هستند (ergs/cm²). نمادهای 'S' و 'L' به ترتیب به اجزای انرژی آزاد سطحی مایع و قیر اشاره دارند.

۲-۳- جمع‌آوری داده‌ها

مجموعه داده‌ها شامل چندین متغیر است که هر یک از آن‌ها جزء مهمی در فرمول مدل پیش‌بینی‌کننده را تشکیل می‌دهد. در مجموع شامل ۱۱ ورودی و دو خروجی می‌باشد. ورودی‌های تحلیل عبارتند از: نسبت جزء انرژی آزاد سطحی باز به اسیدی سنگدانه (نسبت SFE باز به اسیدی)، انرژی آزاد پیوستگی (CFE)، انرژی آزاد چسبندگی (AFE)، انرژی جداشدگی (DE)، قابلیت ترشوندگی، سطح ویژه سنگدانه‌ها (SSA)، نفوذپذیری مخلوط آسفالتی (PAM)، ضخامت ظاهری لایه (AFT) قیر روی سنگدانه، درجه اشباع (DS)، همچنین چسبندگی آسفالت به آب ($\Gamma_{\text{Asphalt-Water}}$) و چسبندگی سنگدانه به آب ($\Gamma_{\text{Aggregate-Water}}$). نقطه عطف جریان‌شدگی و شیب جریان‌شدگی متغیرهای خروجی اصلی هستند.

۲-۴- پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها شامل چندین وظیفه ضروری برای اطمینان از کیفیت و مناسب بودن داده‌ها برای مدل‌سازی پیش‌بینی است، از جمله مدیریت داده‌های گمشده، تشخیص داده‌های پرت، مقیاس‌بندی و نرمال‌سازی داده‌ها، و تقسیم‌بندی داده‌ها. در این پژوهش، هیچ داده گمشده یا داده پرتی در مجموعه داده‌ها شناسایی نشد.

۲-۴-۱- مقیاس‌بندی و نرمال‌سازی داده‌ها

در مدل‌سازی پیش‌بینی، مقیاس‌بندی و نرمال‌سازی داده‌ها نقش مهمی در اطمینان از قرار گرفتن متغیرها در مقیاسی یکسان و دارا

اجزای SFE پیوند می‌دهد. ارزیابی اجزای SFE در جمع‌آوری‌ها با استفاده از روش USD شامل محاسبه اجزای سطحی بر اساس محاسبات سطح ویژه (SSA) و سپس تعیین فشار توزیع بخارهای مایع پروب بر روی سطوح جمع‌آوری است [34]. بنابراین، رابطه (۸) نشان می‌دهد که چگونه کار چسبندگی بین یک ماده جامد (مانند جمع‌آوری) و یک بخار به اجزای SFE مرتبط است.

$$W_{S,L}^a = 2\Gamma_L^{Total} + \pi_e \quad (8)$$

$$= 2(\sqrt{\Gamma_S^{LW}\Gamma_L^{LW}}) + 2(\sqrt{\Gamma_S^+\Gamma_L^-}) + 2(\sqrt{\Gamma_S^-\Gamma_L^+})$$

در این رابطه $W_{S,L}^a$ کار چسبندگی بین سنگدانه‌ها (S) و بخار مایع مورد آزمایش (L) (ergs/cm²)، Γ_L^{Total} انرژی آزاد سطحی کل مایعات مورد آزمایش (ergs/cm²) و π_e فشار توزیع تعادلی بخار-مایع بر روی سطح سنگدانه است (ergs/cm²).

۲-۵-۳-۱- سطح ویژه سنگدانه‌ها

همانطور که پیشتر ذکر شد، یکی از عوامل مهم در محاسبه اجزای سطحی سنگدانه‌ها، سطح ویژه (SSA) است. این عامل نقش مهمی در محاسبه π_e دارد و در این مطالعه به عنوان یک ورودی برای پیش‌بینی حساسیت رطوبت استفاده می‌شود [34]. این پارامتر را می‌توان با استفاده از رابطه برون‌آئر، امت و تیر (BET) محاسبه کرد (رابطه ۹).

$$A = \left(\frac{n_{mono} \times N_A}{M} \right) \alpha \quad (9)$$

در این رابطه A سطح ویژه سنگدانه‌ها (m²/kg)، n_{mono} ظرفیت تک لایه، N_A ثابت آووگادرو، α سطح تصویر شده یک مولکول و M وزن مولکولی بخار ماده مورد آزمایش می‌باشد.

۲-۵-۴- اندازه‌گیری مؤلفه‌های انرژی آزاد سطحی قیر

تعیین انرژی آزاد سطحی (SFE) قیرهای آسفالتی اهمیت زیادی دارد و اطلاعات جامعی درباره رفتار و تعامل آن‌ها ارائه می‌دهد. گود و ون اس [32] روشی بنیادی را بر اساس رابطه یانگ-دوپره [35] ایجاد کردند که امکان محاسبه اجزای SFE قیر را از طریق اندازه‌گیری زاویه تماس فراهم می‌کند، همان‌طور که در رابطه (۱۰) نشان داده شده است. ارزیابی SFE در قیرهای آسفالتی نسبتاً ساده‌تر از سنگدانه‌هاست، بیشتر به دلیل قابلیت اطمینان روش صفحه ویلهلمی (WP). این روش سستی بر تعادل نیروهای جنبشی هنگام غوطه‌ور کردن یا خارج کردن یک صفحه نازک در یا از یک

به مقیاسی یکنواخت تبدیل شدند.

۲-۴-۲- تقسیم داده‌ها

برای ارزیابی مدل پیش‌بینی، مجموعه داده‌ها به زیرمجموعه‌های آموزش و آزمایش تقسیم شد. تقسیم‌بندی داده‌ها روشی مؤثر برای ارزیابی مدل در مواجهه با داده‌های مشاهده نشده قبلی است. در این پژوهش، داده‌ها به دو بخش تقسیم شدند: ۷۰ درصد به عنوان مجموعه آموزش و ۳۰ درصد باقی‌مانده به عنوان مجموعه آزمایش مورد استفاده قرار گرفت.


۲-۵- بررسی هم‌خطی متغیرهای ورودی

برای بررسی هم‌خطی داده‌های ورودی، ابتدا ماتریس همبستگی متغیرهای مستقل محاسبه شد. نتایج این ماتریس در شکل (۴) نمایش داده شده است. مشاهده می‌شود که همبستگی بین برخی از متغیرهای ورودی بیش از ۰٫۸ است، که نشان‌دهنده هم‌خطی قوی بین این متغیرها است. این موضوع مهم است که در تفسیر و تعمیم نتایج مدل در نظر گرفته شود.

بودن محدوده‌های مشابه ایفا می‌کند. این مرحله برای جلوگیری از سوگیری مدل نسبت به متغیرهایی با مقادیر بزرگ‌تر و بهبود همگرایی مدل در طول آموزش، ضروری است. این ملاحظات به‌ویژه زمانی که متغیرها تفاوت‌هایی در واحدها و بزرگی‌ها نشان می‌دهند، اهمیت بیشتری می‌یابند. به عنوان مثال، در مجموعه داده‌های مورد استفاده در این مطالعه، نفوذپذیری مخلوط آسفالتی (PAM) از ۳۷۲ تا ۵۱۷ متغیر است، در حالی که سطح ویژه سنگدانه‌ها (SSA) از ۱٫۷۹ تا ۲٫۲۳ تغییر می‌کند. در نتیجه، از معادله (۱۱) برای مقیاس‌بندی داده‌ها استفاده شد که منجر به قرار گرفتن تمام متغیرها در محدوده‌ای یکسان بین ۰ و ۱ شد [35, 36].

$$N = 0.1 + 0.8 \times \frac{h - h_{min}}{h_{max} - h_{min}} \quad (11)$$

در این معادله، متغیرهای h ، h_{min} و h_{max} به ترتیب نشان‌دهنده مقادیر مقیاس‌بندی شده، مقادیر اولیه، و کمترین و بیشترین مقادیر اولیه هستند. با اعمال این معادله مقیاس‌بندی، تمام متغیرهای ورودی، صرف‌نظر از محدوده‌ها و بزرگی‌های اولیه‌شان،



شکل ۴. نقشه حرارتی همبستگی داده‌های ورودی مدل

Fig 4. Correlation Heatmap of Model Input Variables


است که در آن، راه‌حل‌های پیشنهادی به شکل ساختارهای درختی نمایش داده می‌شوند [38]. GP با بسط اصول الگوریتم‌های ژنتیک، امکان تکامل برنامه‌های کامپیوتری یا مدل‌ها را فراهم می‌کند. این روش با بهره‌گیری از عملگرهای ژنتیکی (مانند جهش و ترکیب)، به ایجاد و بهینه‌سازی درخت‌های برنامه می‌پردازد [39]. در شکل (۵)، نمونه‌ای از یک مدل تولید شده توسط GP نمایش داده شده است، و شکل (۶) چگونگی اجرای فرآیندهای جهش و ترکیب در GP را نشان می‌دهد.

۲-۶-۱- توسعه مدل با استفاده از MGPP

الگوریتم برنامه‌ریزی ژنتیک چند ژنی (MGPP) نسبت به سایر روش‌های یادگیری ماشین از قبیل ANN، SVM و KNN که در مطالعات پیشین استفاده شده‌اند، این مزیت اساسی را دارد که علاوه بر پیش‌بینی دقیق، یک معادله ریاضی صریح بین متغیرهای ورودی و خروجی ارائه می‌دهد. همان‌طور که در بخش پیشینه تحقیق مشاهده می‌شود، بیشتر مطالعات قبلی فقط به ارائه پیش‌بینی‌ها بدون معادله ریاضی بسنده کرده‌اند. این در حالی است که وجود یک فرمول ریاضی مشخص، علاوه بر افزایش قابلیت تفسیرپذیری مدل، امکان استفاده آسان از نتایج را برای مهندسان و پژوهشگران در پروژه‌های عملی فراهم می‌کند. به علاوه، MGPP با بهره‌گیری از ساختار چندژنی خود، قادر است روابط پیچیده و غیرخطی بین متغیرها را با دقت بالاتری مدل‌سازی کند.


برنامه‌ریزی ژنتیک چندژنی نسخه تکامل‌یافته‌ای از برنامه‌ریزی ژنتیک سنتی است. برخلاف GP که راه‌حل‌های پیشنهادی را به صورت یک ساختار درختی منفرد نمایش می‌دهد، MGPP امکان ارائه راه‌حل‌ها را به شکل مجموعه‌ای از زیربرنامه‌ها یا ژن‌های در تعامل با یکدیگر فراهم می‌کند. این قابلیت، MGPP را به ابزاری کارآمد برای حل مسائل پیچیده‌ای تبدیل می‌کند که راه‌حل آن‌ها مستلزم تعامل بین چندین زیرمؤلفه است.

در چارچوب MGPP، پیش‌بینی متغیر وابسته (y) با نماد θ از ترکیب خروجی‌های وزن‌دار چندین درخت یا ژن در یک ساختار چندژنی، به همراه یک جمله ثابت (بایاس) محاسبه می‌شود. هر درخت نمایانگر تابعی است که می‌تواند از هیچ تا چندین متغیر ورودی ($x_1, x_2, x_3, \dots, x_m$) استفاده کند [40]. مدل رگرسیون چندژنی را می‌توان به صورت ریاضی در رابطه (۱۲) نمایش داد.



شکل ۵. مدل برنامه‌ریزی ژنتیک سنتی

Fig 5. Traditional GP model



شکل ۶. عملگرهای GP: جهش و تقاطع

Fig 6. GP Operators: Mutation and Crossover

از طرفی، ویژگی‌های منحصر به فرد و ذاتی مدل MGPP مانند استفاده از توان‌های بالاتر، توابع نمایی، متغیرهای تعاملی و ترکیبات جدید متغیرها به کاهش آثار هم‌خطی کمک می‌کند. با توجه به اینکه حذف متغیرها ممکن است باعث از دست رفتن اطلاعات مهم شود و همچنین اینکه MGPP خود قادر است از بین متغیرها، مؤثرترین و مهم‌ترین را انتخاب کند، پس در این تحقیق متغیری حذف نشده است. در عوض، برای ارزیابی دقت عملکرد مدل، ضرایب تعیین و خطای جذر میانگین مربعات برای داده‌های آموزش و آزمایش مقایسه می‌شود.


۲-۶-۲- مروری بر محاسبات تکاملی

الگوریتم‌های ژنتیک دسته‌ای از الگوریتم‌های تکاملی هستند که از فرآیند تکامل زیستی و انتخاب طبیعی الهام گرفته‌اند. این الگوریتم‌ها برای حل مسائل بهینه‌سازی به کار می‌روند و با استفاده از رویکردی مبتنی بر جمعیت، به یافتن راه‌حل‌های بهینه می‌پردازند [37].


برنامه‌ریزی ژنتیک نوع پیشرفته‌تری از الگوریتم‌های تکاملی

۷- خاتمه: تکرار مراحل ۳ تا ۶ تا رسیدن به تعداد نسل مشخص یا برآورده شدن معیار توقف تعیین شده.

در این پژوهش، توسعه MGPP با استفاده از GPTIPS، یک جعبه ابزار متن باز MATLAB انجام شده است. همانند سایر روش‌های مدل‌سازی، عملکرد و پیچیدگی مدل نهایی MGPP به شدت تحت تأثیر پارامترهای آن قرار دارد و نیازمند فرآیند تنظیم است. این تنظیم معمولاً به روش آزمون و خطا صورت می‌گیرد. مقادیر مختلف پارامترها برای بهینه‌سازی عملکرد مدل بررسی شده‌اند. انتخاب نهایی بهترین مدل‌های MGPP بر اساس قابلیت تعمیم‌پذیری آن‌ها صورت گرفته است. این رویکرد با هدف جلوگیری از بیش‌برازش و اطمینان از عملکرد مطلوب مدل‌ها در مواجهه با داده‌های آزمایشی انجام شده است.



شکل ۷. مدل MGPP
Fig 7. MGPP model



شکل ۸. تصویری از عملیات تقاطع دو نقطه ای

Fig 8. An illustration of a two point crossover operation

$$y = r_0 + r_1 \times (tree)_1 + r_2 \times (tree)_2 + \dots + r_N \times (tree)_N \quad (12)$$

در این رابطه r_0 جمله ثابت (بایاس)، r_1 تا r_m ضرایب اختصاص یافته به ژن‌ها (درخت‌ها)، N تعداد کل درخت‌ها در ساختار فعلی می‌باشد.

ضرایب رگرسیون برای هر ساختار چندژنی با استفاده از روش حداقل مربعات معمولی محاسبه می‌شوند [40]. شکل (۷) نمونه‌ای از یک مدل چندژنی را نشان می‌دهد.

در مدل‌سازی با MGPP، ایجاد توازن بین کنترل پیچیدگی مدل و تضمین دقت آن از اهمیت ویژه‌ای برخوردار است. این توازن به دو پارامتر کلیدی وابسته است: ۱. D_{max} : بیشترین عمق مجاز درخت؛ ۲. G_{max} : بیشترین تعداد مجاز ژن‌ها.

در این روش، جمعیت اولیه با ایجاد نمونه‌هایی شکل می‌گیرد که هر کدام شامل درخت‌های GP با تعداد متغیری از ژن‌ها (بین ۱ تا G_{max}) هستند که به طور تصادفی انتخاب می‌شوند. در هر تکرار MGPP، ژن‌ها با استفاده از عملگر تقاطع درختی، که به عنوان تقاطع سطح بالای دو نقطه‌ای شناخته می‌شود، اضافه یا حذف می‌شود [41]. شکل (۸) نمایی از این فرآیند را ارائه می‌دهد.

الگوریتم MGPP از هفت مرحله اصلی تشکیل شده است:

۱- مقداردهی اولیه: ایجاد جمعیت اولیه از ساختارهای چندژنی، که هر یک شامل چندین ژن برای نمایش راه حل‌های احتمالی است.

۲- ارزیابی: سنجش کارایی هر ساختار در جمعیت بر اساس ژن‌های آن. تابع برازندگی، میزان موفقیت هر برنامه را در حل مسئله یا دستیابی به هدف بهینه‌سازی به صورت کمی بیان می‌کند.

۳- انتخاب: گزینش ساختارها برای تولیدمثل بر پایه میزان برازندگی آن‌ها، با اولویت دهی به ساختارهای با برازندگی بالاتر.

۴- تقاطع: اجرای عملگر تقاطع روی جفت‌های منتخب برای ترکیب ژن‌ها و تولید ساختارهای جدید.

۵- جهش: اعمال تغییرات تصادفی کوچک در ژن‌های برخی ساختارها از طریق عملگر جهش.

۶- جایگزینی: به روزرسانی جمعیت با جایگزین کردن ساختارهای قدیمی با نمونه‌های جدید تولید شده.

۷-۲- معیارهای عملکرد

در این بخش، معیارهای عملکرد شامل ضریب تعیین (R^2)، خطای جذر میانگین مربعات، میانگین مربعات خطا و میانگین خطای مطلق، برای ارزیابی عملکرد مدل‌های پیش‌بینی انتخاب شده‌اند. معادلات مربوط به محاسبه این معیارها را می‌توان در معادلات (۱۳-۱۶) یافت.

$$R^2 = \left(\frac{\sum_{j=1}^k (\alpha_j)(\lambda_j)}{\sqrt{\sum_{j=1}^k (\alpha_j)^2 \sum_{j=1}^k (\lambda_j)}} \right)^2 \quad (13)$$

$$MSE = \frac{\sum_{j=1}^k (\omega_j)^2}{k} \quad (14)$$

$$RMSE = \sqrt{MSE} \quad (15)$$

$$MAE = \frac{1}{k} \sum_{j=1}^k (|\alpha_j|) \quad (16)$$

که در آن α ، ω و λ به ترتیب بیانگر اختلاف بین مقدار هدف واقعی و میانگین داده‌های هدف، مقدار هدف واقعی و مقدار پیش‌بینی شده، و مقدار پیش‌بینی شده و میانگین پیش‌بینی‌های مدل هستند. علاوه بر این، متغیر k نشان‌دهنده تعداد کل نمونه‌های داده است که مورد بررسی قرار گرفته‌اند.

۳- نتایج و بحث

در این پژوهش، مدل (MGGP) با استفاده از یک مجموعه داده

شامل ۳۴ داده و ۱۱ متغیر، با تمرکز بر پیش‌بینی ISP و SS آموزش داده شد.

۳-۱- پیش‌بینی ISP با استفاده از MGGP



مدل MGGP نتایج قابل توجهی در پیش‌بینی ISP نشان داد که در شکل (۹) نمایش داده شده است. شکل (۹ ب) نشان می‌دهد که مدل دارای مقادیر R^2 بالایی معادل ۰٫۹۸۱ برای داده‌های آزمایشی است، همراه با مقادیر پایین RMSE، MSE و MAE. عوامل تأثیرگذار بر ISP همانطور که در رابطه (۱۷) ارائه شده، شناسایی شدند. این متغیرهای کلیدی شامل انرژی آزاد سطحی باز به اسید، $\Gamma_{\text{Asphalt-Water}}$ ، CFE، AFE، PAM، AFT و DS هستند.

۳-۲- پیش‌بینی SS با استفاده از MGGP

شکل (۱۰) مقدار R^2 را نشان می‌دهد که عملکرد MGGP را در پیش‌بینی SS به تصویر می‌کشد. همان‌طور که در شکل (۱۰) نشان داده شده است، مدل با مقادیر R^2 برابر با ۰٫۹۶۲ برای داده‌های آموزشی و ۰٫۹۷۴ برای داده‌های آزمایشی، و همچنین مقادیر پایین RMSE، MSE و MAE، عملکرد خوبی دارد. عوامل مؤثر بر SS همان‌طور که در رابطه (۱۸) نشان داده شده، شامل $\Gamma_{\text{Asphalt-Water}}$ ، ترشوندگی، SSA، PAM و DS هستند.



$$MGGP_{ISP} = (19.607 * \text{Base to Acid SFE}) + (26.360 * CFE) + (19.607 * AFE) - (19.607 * DS) - (19.607 * EXP(DS)) + (13.506 * \Gamma_{\text{Asphalt-Water}}^2 * AFT^2) + (6.735 * \text{Base to Acid SFE} * AFT^3) + (6.735 * AFT^4) + (6.735 * \Gamma_{\text{Asphalt-Water}} * PAM * AFT^2) + 278.738 \quad (17)$$

$$MGGP_{SS} = (1.056 * PAM) - (2.337 * Wettability) - (1.281 * SSA) - (1.056 * \Gamma_{\text{Asphalt-Water}}) + (2.337 * DS) + (1.506 * \Gamma_{\text{Aggregate-Water}}^2) + 5.843 \quad (18)$$



شکل ۹. نمودار پراکندگی پیش‌بینی ISP برای داده‌های (الف) آموزش و (ب) آزمایش

Fig 9. Scatter plot of ISP prediction for (a) training and (b) testing data



شکل ۱۰. نمودار پراکندگی پیش‌بینی SS برای داده‌های (الف) آموزش و (ب) آزمایش

Fig 10. Scatter plot of SS prediction for (a) training and (b) testing data

پیش‌بینی ISP از پارامترهایی مانند انرژی آزاد سطحی، CFE، AFE، PAM، AFT و DS استفاده شده، و برای SS متغیرهایی مانند $\Gamma_{\text{Asphalt-Water}}$ ، $\Gamma_{\text{Aggregate-Water}}$ ، ترشوندگی، SSA، PAM و DS به کار گرفته شده‌اند.

این پژوهش یک مدل ریاضی صریح برای پیش‌بینی ISP و SS ارائه داده است که در مطالعات قبلی به آن پرداخته نشده بود. این مدل نه تنها از دقت بالایی برخوردار است، بلکه قابلیت تفسیر بهتری نیز دارد. همچنین، در نظر گرفتن پارامترهای جدید و موثر در حساسیت رطوبتی، پیشرفت قابل توجهی در پیش‌بینی دقیق‌تر این پدیده به شمار می‌آید.

پژوهش‌های پیشین که توسط گیلانی و همکاران [19] و بهبهانی و همکاران [20] انجام شده، با هدف پیش‌بینی خواص مختلف مرتبط با رطوبت مانند TSR و با استفاده از روش‌های متداول GP صورت گرفته است. جدول (۳) متغیرهای مشترکی را نشان می‌دهد که هم در مدل MGGP توسعه یافته در این پژوهش و هم در مطالعات پیشین مبتنی بر GP استفاده شده‌اند. این متغیرها عبارتند از CFE، AFE، DE و PAM. حضور این متغیرها در هر دو نوع مدل، اهمیت آن‌ها را در مدل‌سازی حساسیت رطوبتی مخلوط‌های آسفالتی نشان می‌دهد. این نتیجه با یافته‌های سایر محققین نیز مطابقت دارد [2، 42-44]. نکته قابل توجه این است که مدل MGGP در پیش‌بینی ISP و SS، ضریب تعیین (R^2) بسیار بالاتری نسبت به مدل‌های GP پیشین که برای پیش‌بینی TSR استفاده شده‌اند، ارائه کرده است.

۳-۳- مقایسه پیش‌بینی‌های رطوبتی MGGP در مقابل مطالعات

پیشین

در این بخش، مقایسه‌ای بین نتایج به دست آمده از مدل MGGP در پیش‌بینی ISP و SS با مطالعات قبلی انجام می‌شود. همچنین، پارامترهای مختلف مرتبط با حساسیت رطوبتی مورد بررسی و تحلیل قرار می‌گیرند.

بررسی پژوهش‌های پیشین نشان می‌دهد که پژوهشگران از روش‌های متنوعی برای حل این مسئله استفاده کرده‌اند. برای مثال، سزاوار همکاران [12] و باباگلی و رضایی [15] با استفاده از شبکه عصبی مصنوعی (ANN) به ترتیب به مقدار R^2 برابر با ۰٫۹۹۱ و ۰٫۹۶۷ دست یافتند. در همین راستا، ویراگوان و همکاران [8] با بهره‌گیری از ماشین بردار پشتیبان (SVM) دقت ۹۵٪ را گزارش کرد، و ب. مالیک و همکاران [11] با استفاده از روش KNN به دقت ۱۰۰٪ رسید.

پژوهش حاضر با معرفی روش برنامه ریزی ژنتیک چند ژنی (MGGP) توانسته است نتایج قابل توجهی در پیش‌بینی پارامترهای ISP و SS به دست آورد. ضرایب R^2 مدل برای پیش‌بینی ISP برابر با ۰٫۹۸۱ و برای SS برابر با ۰٫۹۷۴ بوده است که نشان‌دهنده عملکرد مطلوب این روش است.

نکته قابل توجه در این پژوهش، تفاوت در متغیرهای مورد استفاده است. در حالی که مطالعات پیشین بیشتر بر پارامترهایی مانند مقاومت کششی غیرمستقیم (ITS)، مدول ارتعاشی (Es)، انرژی شکست (FE) و نسبت مقاومت کششی (TSR) تمرکز داشتند، این پژوهش متغیرهای جدیدی را معرفی کرده است. برای

جدول ۳. مقایسه مدل پیش‌بینی برای خواص رطوبتی در مخلوط‌های آسفالتی: مطالعه فعلی در مقابل مطالعات قبلی GP

Table 3. Comparative analysis of predictive models for moisture properties in asphalt mixtures: current study vs. previous GP studies

Model	Output	Variables in Formula	R ²
MGGP	ISP	Base to Acid SFE, $\Gamma_{\text{Asphalt-Water}}$, CFE, AFE, PAM, AFT, DS	0.981
	SS	$\Gamma_{\text{Asphalt-Water}}$, $\Gamma_{\text{Aggregate-Water}}$, Wettability, SSA, PAM, DS	0.974
GP [19]	TSR	CFE, AFE, DE, PAM, Cycle count, Additive percentage	0.981
GP [20]	TSR	SSA, Additive percentage, Cycle count, AFE, PAM, DE	0.964

۴- جمع‌بندی و نتیجه‌گیری

مدل MGGP در پیش‌بینی حساسیت رطوبتی آسفالت عملکرد قابل توجهی را نشان داده است. این مدل به مقادیر R^2 آزمایشی ۰٫۹۸۱ و ۰٫۹۷۴ به ترتیب برای پیش‌بینی‌های ISP و SS دست یافته است. علاوه بر این، معیارهای خطا نیز دقت بالای مدل MGGP را تأیید می‌کنند. برای پیش‌بینی‌های ISP، مقادیر RMSE، MSE و MAE به ترتیب ۵٫۲۲۸، ۲۷٫۳۳۷ و ۳٫۸۴۳ و برای پیش‌بینی‌های SS، این مقادیر به ترتیب ۰٫۲۹۴، ۰٫۰۸۶ و ۰٫۲۳۱ بوده است.

یافته‌ها توانایی مدل MGGP را در دستیابی به پیش‌بینی‌های دقیق با خطاهای کمتر نشان می‌دهند. این مدل از مطالعات پیشین که از مدل‌های مختلف برنامه‌ریزی ژنتیک (GP) برای پیش‌بینی حساسیت رطوبتی استفاده کرده‌اند نیز برتر است. این امر پتانسیل رویکرد MGGP را به عنوان ابزاری قدرتمند در مدل‌سازی پیش‌بینی حساسیت رطوبتی آسفالت برجسته می‌سازد.

در تحلیل پیش‌بینی ISP، مدل MGGP از چندین متغیر مهم از جمله نسبت باز به اسید SFE ، $\Gamma_{\text{Asphalt-Water}}$ ، CFE، AFE، AFT و DS استفاده می‌کند. به طور مشابه، برای پیش‌بینی SS، متغیرهای کلیدی مانند ترشوندگی، SSA، PAM و DS در مدل به کار گرفته شده‌اند.

مدل MGGP برای پیش‌بینی ISP بر اهمیت متغیرهایی از جمله نسبت باز به اسید SFE ، $\Gamma_{\text{Asphalt-Water}}$ ، CFE، AFE، PAM و AFT و

DS تأکید می‌کند. همچنین در در تخمین SS نیز، اهمیت $\Gamma_{\text{Asphalt-Water}}$ ، ترشوندگی، SSA، PAM و DS را برجسته می‌سازد.

پیش‌بینی دقیق حساسیت رطوبتی می‌تواند دوام مخلوط‌های آسفالتی را افزایش دهد، هزینه‌های نگهداری را کاهش دهد و ایمنی جاده را بهبود بخشد. همچنین یافته‌های این پژوهش بر جوامع، اقتصاد و پایداری محیط زیست تأثیر خواهد گذاشت. بنابراین، این مطالعه به ترویج توسعه پایدار و افزایش انعطاف‌پذیری زیرساخت‌ها کمک می‌کند.

قدردانی نویسندگان

نویسندگان از هیئت علمی دانشگاه صنعتی امیرکبیر و دانشگاه گیلان برای انجام این پژوهش، سپاس‌گزاری را به عمل می‌آورند.

تعارض منافع

برای نویسندگان هیچ‌گونه تعارض منافی وجود ندارد.

سهم نویسندگان

سهم نویسندگان با هم برابر است.

منابع مالی

در انجام این پژوهش از کمک‌های مالی هیچ نهاد یا شخصی استفاده نشده است.

References

- Grenfell, J., Ahmad, N., Liu, Y., Apeagyei, A., Large, D. & Airey, G. 2014. Assessing asphalt mixture moisture susceptibility through intrinsic adhesion, bitumen stripping and mechanical damage. *Road Materials and Pavement Design*, 15(1), pp. 131-152.
- Tarefder, R.A. & Ahmad, M. 2015. Evaluating the relationship between permeability and moisture damage of asphalt concrete pavements. *Journal of Materials in Civil Engineering*, 27(5), p. 04014172.
- Caro, S., Masad, E., Bhasin, A. & Little, D.N. 2008. Moisture susceptibility of asphalt mixtures, Part 2: characterisation and modelling. *International Journal of Pavement Engineering*, 9(2), pp. 99-114.
- Caro, S., Masad, E., Bhasin, A. & Little, D.N. 2008. Moisture susceptibility of asphalt mixtures, Part 1: mechanisms. *International Journal of Pavement Engineering*, 9(2), pp. 81-98.
- Diab, A., You, Z., Yang, X. & Mohd Hasan, M.R.

2017. Towards an alternate evaluation of moisture-induced damage of bituminous materials. *Applied Sciences*, 7(10), p. 1049.
6. Veeraragavan, R.K., Kottayi, N.M., Mallick, R.B., Nirala, M.K. & Sarkar, S. 2021. Application of artificial intelligence to predict moisture damage of hot-mix asphalt mixes. In: *Proceedings of the Institution of Civil Engineers-Transport*, 174(3), pp. 197-206.
7. Ling, C. 2013. *Developing evaluation method of moisture susceptibility for cold mix asphalt*.
8. Veeraragavan, R.K., Madankara Kottayi, N. & Mallick, R.B. 2019. Accurate identification of pavement materials that are susceptible to moisture damage with the use of advanced conditioning and test methods and the use of machine learning techniques. *SN Applied Sciences*, 1, pp. 1-7.
9. Zamani, M.G., Saniei, K., Nematollahi, B., Zahmatkesh, Z., Poor, M.M. & Nikoo, M.R. 2023. Developing sustainable strategies by LID optimization in response to annual climate change impacts. *Journal of Cleaner Production*, 416, p. 137931.
10. Ranjbar, S., Moghadas Nejad, F., Zakeri, H. & Gandomi, A.H. 2020. Computational intelligence for modeling of asphalt pavement surface distress. In: *New Materials in Civil Engineering*, pp. 79-116.
11. Mallick, R.B., Madankara Kottayi, N., Veeraragavan, R.K., Dave, E., DeCarlo, C. & Sias, J.E. 2019. Suitable tests and machine learning approach to predict moisture susceptibility of hot-mix asphalt. *Journal of Transportation Engineering, Part B: Pavements*, 145(3), p. 04019030.
12. Sezavar, R., Shafabakhsh, G. & Mirabdolazimi, S. 2019. New model of moisture susceptibility of nano silica-modified asphalt concrete using GMDH algorithm. *Construction and Building Materials*, 211, pp. 528-538.
13. Lagaros, N.D. 2023. Artificial neural networks applied in civil engineering. *MDPI*, 13, p. 1131.
14. Babagoli, R. & Rezaei, M. 2022. Development of prediction models for moisture susceptibility of asphalt mixture containing combined SBR, waste CR and ASA using support vector regression and artificial neural network methods. *Construction and Building Materials*, 322, p. 126430.
15. Babagoli, R. & Rezaei, M. 2022. Using Artificial Neural Network Methods for Modeling Moisture Susceptibility of Asphalt Mixture Modified by Nano TiO₂. *Journal of Materials in Civil Engineering*, 34(6), p. 04022108.
16. Rebelo, F.J., Martins, F.F., Silva, H.M. & Oliveira, J.R. 2022. Use of data mining techniques to explain the primary factors influencing water sensitivity of asphalt mixtures. *Construction and Building Materials*, 342, p. 128039.
17. Cao, Q., Al-Qadi, I.L. & Abufares, L. 2022. Pavement moisture content prediction: A deep residual neural network approach for analyzing ground penetrating radar. *IEEE Transactions on Geoscience and Remote Sensing*, 60, pp. 1-11.
18. Majidifard, H., Jahangiri, B., Buttlar, W.G. & Alavi, A.H. 2019. New machine learning-based prediction models for fracture energy of asphalt mixtures. *Measurement*, 135, pp. 438-451.
19. Gilani, V.N.M., Hosseini, S.M., Behbahani, H. & Hamed, G.H. 2020. Prediction and pareto-based multi-objective optimization of moisture and fatigue damages of asphalt mixtures modified with nano hydrated lime. *Construction and Building Materials*, 261, p. 120509.
20. Behbahani, H., Hamed, G.H. & Gilani, V.N.M. 2020. Predictive model of modified asphalt mixtures with nano hydrated lime to increase resistance to moisture and fatigue damages by the use of deicing agents. *Construction and Building Materials*, 265, p. 120353.
21. Esmaeili, N., Hamed, G.H. & Khodadadi, M. 2019. Determination of the stripping process of asphalt mixtures and the effective mix design and SFE parameters on its different phases. *Construction and Building Materials*, 213, pp. 167-181.
22. ASTM International. 2017. *ASTM D4318-17: Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils*.
23. AASHTO. 2014. *AASHTO T 283: Standard Method of Test for Resistance of Compacted Asphalt Mixtures to Moisture-Induced Damage*.
24. Hamed, G.H. & Moghadas Nejad, F. 2015. Using energy parameters based on the surface free energy concept to evaluate the moisture susceptibility of hot mix asphalt. *Road Materials and Pavement Design*, 16(2), pp. 239-255.
25. Christensen, D.W. & Bonaquist, R.F. 2006. *Volumetric requirements for Superpave mix design*. Transportation Research Board.
26. Hamed, G.H. & Moghadas Nejad, F. 2017. Evaluating the effect of mix design and thermodynamic parameters on moisture sensitivity of hot mix asphalt. *Journal of Materials in Civil Engineering*, 29(2), p. 04016207.
27. Huang, B., Mohammad, L.N., Raghavendra, A. & Abadie, C. 1999. Fundamentals of permeability in asphalt mixtures. *Journal of the Association of Asphalt Paving Technologists*, 68.
28. Hefer, A.W. 2004. *Adhesion in bitumen-aggregate systems and quantification of the effects of water on the adhesive bond*. PhD Dissertation. Texas A&M University.
29. Van Oss, C.J., Chaudhury, M.K. & Good, R.J. 1988. Interfacial Lifshitz-van der Waals and polar interactions in macroscopic systems. *Chemical reviews*, 88(6), pp. 927-941.

30. Yalghouzaghaj, M.N., Sarkar, A., Hamed, G.H. & Hayati, P. 2021. Application of the surface free energy method on the mechanism of low-temperature cracking of asphalt mixtures. *Construction and Building Materials*, 268, p. 121194.
31. Cheng, D., Little, D.N., Lytton, R.L. & Holste, J.C. 2002. Surface energy measurement of asphalt and its application to predicting fatigue and healing in asphalt mixtures. *Transportation Research Record*, 1810(1), pp. 44-53.
32. Good, R.J. & van Oss, C.J. 1992. The modern theory of contact angles and the hydrogen bond components of surface energies. In: *Modern approaches to wettability: theory and applications*, pp. 1-27.
33. Bhasin, A. 2007. *Development of methods to quantify bitumen-aggregate adhesion and loss of adhesion due to water*. PhD Dissertation. Texas A&M University.
34. Hamed, G.H., Asadi, A.H. & Zarrinfam, J. 2024. Investigating the effect of fundamental properties of materials on the mechanisms of thermal cracking of asphalt mixtures. *Construction and Building Materials*, 411, p. 134426.
35. Naseri, H., Jahanbakhsh, H., Moghadas Nejad, F. & Golroo, A. 2020. Developing a novel machine learning method to predict the compressive strength of fly ash concrete in different ages. *AUT Journal of Civil Engineering*, 4(4), pp. 423-436.
36. Ehsani, M., Ostovari, M., Mansouri, S., Naseri, H., Jahanbakhsh, H. & Moghadas Nejad, F. 2024. Machine learning for predicting concrete carbonation depth: A comparative analysis and a novel feature selection. *Construction and Building Materials*, 417, p. 135331.
37. Ranjbar, S., Moghadas Nejad, F. & Zakeri, H. 2024. Image-based severity analysis of Asphalt pavement bleeding using a metaheuristic-boosted fuzzy classifier. *Automation in Construction*, 166, p. 105655.
38. Dargi, M., Khamsehchi, E. & Mahdavi Kalatehno, J. 2023. Optimizing acidizing design and effectiveness assessment with machine learning for predicting post-acidizing permeability. *Scientific Reports*, 13(1), p. 11851.
39. Lissovoi, A. & Oliveto, P.S. 2020. Computational complexity analysis of genetic programming. In: *Theory of Evolutionary Computation: Recent Developments in Discrete Optimization*, pp. 475-518.
40. Searson, D. 2009. *GPTIPS genetic programming & symbolic regression for MATLAB user guide*. Natick, MA: MathWorks.
41. Searson, D.P., Leahy, D.E. & Willis, M.J. 2010. GPTIPS: an open source genetic programming toolbox for multigene symbolic regression. In: *Proceedings of the International multicongress of engineers and computer scientists*, 1, pp. 77-80.
42. Choubane, B., Page, G.C. & Musselman, J.A. 2000. Effects of water saturation level on resistance of compacted hot-mix asphalt samples to moisture-induced damage. *Transportation Research Record*, 1723(1), pp. 97-106.
43. Omar, H.A., Yusoff, N.I.M., Mubarak, M. & Ceylan, H. 2020. Effects of moisture damage on asphalt mixtures. *Journal of Traffic and Transportation Engineering (English Edition)*, 7(5), pp. 600-628.
44. Sengoz, B. & Agar, E. 2007. Effect of asphalt film thickness on the moisture sensitivity characteristics of hot-mix asphalt. *Building and Environment*, 42(10), pp. 3621-3628.

چگونه به این مقاله ارجاع دهیم؟

Motamedi, A.H., Hamed, G.H. and Moghadas Nejad F., 2025. Moisture Sensitivity Assessment of Asphalt: A Multi-Gene Genetic Programming Approach. *Modares Civil Engineering journal*, 25(5), pp. 61-78.

DOI: 10.22034/25.5.3

