

الله الرحمن الرحيم



دانشکده مهندسی عمران

پایان نامه کارشناسی ارشد مهندسی عمران (گرایش راه و ترابری)

پیش بینی شاخص خود ترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی چندلایه

نگارنده: مهسا روحی فریمان

استاد راهنما

دکتر سید علی حسینی

استاد مشاور

مهندس عباس محمدی

شهریور ۱۴۰۰

شماره: ۵۲۴ / ع=

تاریخ: ۱۴۰۰ / ۲ / ۲۸

ویرایش:

باسمه تعالی

فرمهای ارزشیابی پایان نامه کارشناسی ارشد
مربوط به ورودی های ۹۴ به بعد



مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم مهسا روحی فریمان با شماره دانشجویی ۹۸۱۳۵۲۴ رشته مهندسی عمران گرایش راه و ترابری تحت عنوان پیش بینی شاخص خودترمیمی مخلوط های آسفالتی با استفاده از شبکه عصبی مصنوعی چندلایه که در تاریخ ۱۴۰۰/۰۶/۰۲ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار شد به شرح ذیل اعلام می گردد:

<input type="checkbox"/> الف) درجه عالی: نمره ۱۹-۲۰	<input type="checkbox"/> ب) درجه خیلی خوب: نمره ۱۸/۹۹ - ۱۸
<input type="checkbox"/> ج) درجه خوب: نمره ۱۷/۹۹ - ۱۶	<input type="checkbox"/> د) درجه متوسط: نمره ۱۵/۹۹ - ۱۴
<input type="checkbox"/> ه) کمتر از ۱۴ غیر قابل قبول و نیاز به دفاع مجدد دارد	
نوع تحقیق: <input checked="" type="checkbox"/> نظری <input type="checkbox"/> عملی	

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	دکتر سید علی حسینی	استادیار	
۲- استاد راهنمای دوم			
۳- استاد مشاور	مهندس عباس محمدی	مربی	
۴- استاد داور اول	دکتر حسین قاسم زاده طهرانی	استادیار	
۵- استاد داور دوم	دکتر ایمان آقایان	دانشیار	
۶- نماینده تحصیلات تکمیلی	دکتر مهدی گلی	استادیار	

نام و نام خانوادگی رئیس دانشکده:

تاریخ و امضاء و مهر دانشکده:



تقدیم به:

پدر و مادر عزیز و مهربانم که در سختی ها و دشواری های زندگی، همواره یاری دلسوز و خداکار و پشتیبانی محکم و مطمئن برایم

بوده اند.

مشکر و قدردانی

استاد گرامی جناب آقای دکتر سید علی حسینی دلسوزی، تلاش و کوشش حضرتعالی در تعلیم و تربیت و انتقال معلومات و

تجربیات ارزشمند دکنار برقراری رابطه صمیمی و دوستانه با دانشجویان و ایجاد فضائی دلنشین برای کسب علم و دانش و درک

شرایط دانشجویان حقیقتاً قابل ستایش است. اینجانب بر خود و نطفه میدانم در کسوت ساگر دی از زحمات و خدمات

ارزشمند شما استاد عزیز تقدیر و تشکر نمایم. از خداوند متعال برایتان سلامتی، موفقیت و بهمراه یاد دادن را مسئلت دارم.

و همچنین از استاد مشاور کراتقدر جناب آقای مهندس عباس محمدی کمال تشکر را دارم.


بسی شایسته است از اساتید فرهیخته و فرزندانم جناب آقای دکتر حسین قاسم زاده طهرانی و جناب آقای دکتر ایمان

آقایان که همده دارد دآوری این کار بودند تقدیر و تشکر نمایم.

تعمیر نامه

اینجانب مهسا روحی فریمان دانشجوی دوره کارشناسی ارشد رشته مهندسی عمران-راه و ترابری دانشکده مهندسی عمران دانشگاه صنعتی شاهرود نویسنده پایان نامه پیش بینی شاخص خود ترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی چندلایه تحت راهنمایی دکتر سید علی حسینی متعهد می‌شوم.

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



تاریخ ۱۴۰۰/۶/۲۹

امضای دانشجو

مالکیت نتایج و حق نشر

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

چکیده

جاده‌ها از سرمایه‌های مهم هر کشور محسوب می‌شوند و سالانه بخش زیادی از بودجه کشور صرف عملیات ترمیم و نگهداری می‌شود. بخش زیادی از هزینه‌های عملیات ترمیم و نگهداری راه‌ها برای رفع ترک خوردگی‌ها صرف می‌شود. پتانسیل خود ترمیمی آسفالت، یکی از عواملی است که می‌تواند در افزایش عمر مفید روسازی آسفالتی تأثیرگذار باشد. زمانی که روسازی تحت دمای بیشتر باشد، ترمیم افزایش می‌یابد، بنابراین خود ترمیمی مخلوط آسفالتی به دما وابسته است. به منظور افزایش ظرفیت خود ترمیمی از طریق افزایش دما، از فرآیند گرمایش مایکروویو و گرمایش القایی استفاده می‌شود. همچنین برای افزایش بازدهی گرمایش و بهبود خود ترمیمی، انواع مختلف ضایعات فلزی (الیاف فولادی، براده آهن، سرباره فولاد و ...) به مخلوط آسفالتی اضافه می‌شود.

با توجه به زمان‌بر و هزینه‌بر بودن فعالیت‌های آزمایشگاهی، استفاده از شبکه‌های عصبی مصنوعی در پیش‌بینی نتایج آزمایشگاهی در دهه‌های اخیر مورد توجه محققان قرار گرفته است. در مهندسی روسازی از شبکه‌های عصبی مصنوعی برای پیش‌بینی عمر خستگی مخلوط‌های آسفالتی، پیش‌بینی مدول غیرخطی لایه‌های روسازی و ... استفاده کرده‌اند.

هدف این پژوهش این است که با در نظر گرفتن عوامل مؤثر بر شاخص خود ترمیمی (مانند نوع افزودنی، درصد افزودنی، دانه‌بندی مخلوط آسفالتی، نوع قیر، چرخه ترمیم ترک و ...) به عنوان ورودی‌های شبکه عصبی مصنوعی در نرم افزار متلب و شاخص خود ترمیمی به عنوان خروجی، بتوان به شبکه عصبی مناسبی دست یافت و از این شبکه در جهت پیش‌بینی شاخص خود ترمیمی بهره برد. شبکه عصبی چندلایه (MLP^1)، شبکه عصبی چندلایه بهینه‌سازی شده با الگوریتم ازدحام ذرات (PSO^2)، شبکه عصبی شعاعی پایه (RBF^3) و تجزیه و تحلیل آماری با نرم افزار $SPSS^1$ مورد بررسی

¹ Multi Layer perceptron

² Particle Swarm Optimization

³ Radial Basis Function

قرار گرفت و نتایج این روش‌ها با یکدیگر مقایسه شدند. نتایج نشان داد، شبکه عصبی چندلایه

(MLP) نسبت به دیگر روش‌ها عملکرد بهتری در زمینه پیش‌بینی شاخص خود ترمیمی دارد.

کلمات کلیدی: خود ترمیمی، الیاف فولادی، براده آهن، سرباره فولاد، گرمایش میکروویو، گرمایش القایی، شبکه عصبی مصنوعی

فهرست مطالب

و	فهرست جداول
ز	فهرست اشکال
۱	فصل ۱: مقدمه
۲	۱-۱ مقدمه
۳	۱-۲ ضرورت انجام تحقیق
۴	۱-۳ روش انجام تحقیق
۴	۱-۴ فرض های تحقیق
۵	۱-۵ فرضیه های تحقیق
۵	۱-۶ ساختار پایان نامه
۷	فصل ۲: مروری بر تحقیقات گذشته
۸	۲-۱ مقدمه
۸	۲-۲ خرابی در روسازی
۹	۲-۲-۱ انواع خرابی های روسازی
۱۴	۲-۳ مفهوم خود ترمیمی
۱۵	۲-۴ مواد بازیافتی قابل استفاده در مخلوط های آسفالتی
۱۵	۲-۴-۱ خرده آسفالت تراشیده شده (RAP)
۱۶	۲-۴-۲ ضایعات فلزی
۱۹	۲-۵ فناوری های خود ترمیمی مخلوط های آسفالتی
۱۹	۲-۵-۱ فناوری میکروکپسول
۲۰	۲-۵-۲ فناوری گرمایش القایی

۲۱ فناوری گرمایش مایکروویو
۲۲ فاکتورهای مؤثر بر خود ترمیمی
۲۲ ۲-۶-۱ خواص قیر
۲۴ ۲-۶-۲ ترکیبات مخلوط آسفالتی
۲۵ ۲-۶-۳ محیط
۲۶ ۲-۷ مزایای اقتصادی و زیست محیطی مخلوط آسفالتی با قابلیت خود ترمیمی
۲۷ ۲-۸ بررسی آزمون های آزمایشگاهی جهت تعیین شاخص خود ترمیمی
۲۷ ۲-۸-۱ آزمایش خمش نیم دایره ای
۲۹ ۲-۸-۲ آزمایش گرمایش مایکروویو و گرمایش القایی
۳۰ ۲-۹ مروری بر مطالعات خود ترمیمی مخلوط های آسفالتی
۳۵ ۲-۱۰ استفاده از شبکه عصبی مصنوعی در مهندسی روسازی
۳۹	فصل ۳: شبکه عصبی مصنوعی
۴۰ ۳-۱ مقدمه
۴۰ ۳-۲ مدل بیولوژیکی شبکه های عصبی
۴۰ ۳-۳ ساختار نورون طبیعی
۴۱ ۳-۳-۱ سیناپس ها (Synapses)
۴۱ ۳-۳-۲ بدنه سلول (Soma)
۴۱ ۳-۳-۳ دندریت ها (Dendrites)
۴۲ ۳-۳-۴ آکسون (Axon)
۴۲ ۳-۴ شبکه های عصبی مصنوعی
۴۳ ۳-۵ ساختار نورون مصنوعی
۴۴ ۳-۶ توابع انتقال (Transfer Functions)

۴۴	۳-۶-۱ تابع انتقال خطی (Linear Transfer Function)
۴۵	۳-۶-۲ تابع پله ای (Hard-Limit)
۴۶	۳-۶-۳ تابع لگاریتم سیگموئید (logsig)
۴۶	۳-۶-۴ تابع سیگموئید (tansig)
۴۷	۳-۷ انواع شبکه های عصبی مصنوعی
۴۷	۳-۷-۱ شبکه عصبی پرسپترون
۴۹	۳-۷-۲ شبکه عصبی شعاعی پایه (Radial Basis Networks)
۵۰	۳-۷-۳ شبکه عصبی بازگشتی (Recurrent Neural Networks)
۵۲	۳-۷-۴ شبکه عصبی خود رمزگذار (Auto Encoder)
۵۳	۳-۷-۵ شبکه عصبی هاپفیلد (Hopfield Networks)
۵۴	۳-۷-۶ ماشین بولتزمن (Boltzmann Machines)
۵۴	۳-۷-۷ شبکه باور عمیق (Deep Belief Network)
۵۴	۳-۷-۸ شبکه پیچشی عمیق (Deep Convolutional Network)
۵۵	۳-۷-۹ شبکه دکانولوشنی (Deconvolution Network)
۵۵	۳-۷-۱۰ شبکه عصبی کوهنن (Kohonen Network)
۵۶	۳-۷-۱۱ ماشین بردار پشتیبان (Support Vector Machine)
۵۶	۳-۷-۱۲ یادگیرنده رقمی ساز بردار (Learning Vector Quantization)
۵۶	۳-۸ الگوریتم های آموزش شبکه عصبی مصنوعی چندلایه
۵۶	۳-۸-۱ الگوریتم پس انتشار لونبرگ-مارکوارت
۵۷	۳-۸-۲ الگوریتم ازدحام ذرات (PSO)
۵۸	۳-۹ مزایا و معایب شبکه های عصبی
۵۸	۳-۹-۱ مزایا

۵۸.....	۳-۹-۲ معایب.....
۵۹.....	۳-۱۰ سنجش میزان یادگیری و عملکرد شبکه عصبی.....
۵۹.....	۳-۱۰-۱ میانگین مربع خطاها و ریشه میانگین مربعات خطا.....
۶۰.....	۳-۱۰-۲ ضریب همبستگی خطی.....
۶۳	فصل ۴: مدل‌سازی و تحلیل نتایج
۶۴.....	۴-۱ مقدمه.....
۶۴.....	۴-۲ داده‌ها.....
۶۵.....	۴-۳ تجزیه و تحلیل آماری داده‌ها.....
۶۶.....	۴-۳-۱ رگرسیون چندگانه در SPSS.....
۷۵.....	۴-۴ فرآیند مدل‌سازی توسط شبکه عصبی مصنوعی.....
۷۵.....	۴-۴-۱ شبکه عصبی چندلایه (MLP).....
۹۳.....	۴-۴-۲ شبکه عصبی چندلایه (MLP) بهینه‌سازی شده با الگوریتم ازدحام ذرات (PSO).....
۱۰۲.....	۴-۴-۳ شبکه عصبی شعاعی پایه (RBF).....
۱۱۱.....	۴-۴-۴ مقایسه نتایج شبکه عصبی MLP، شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO و شبکه عصبی RBF.....
۱۱۲.....	۴-۴-۵ مقایسه نتایج قدرت تعمیم شبکه عصبی MLP، شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO و شبکه عصبی RBF.....
۱۱۲.....	۴-۴-۶ عوامل مؤثر بر خودترمیمی با توجه به وزن‌های شبکه عصبی MLP، شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO و شبکه عصبی RBF.....
۱۱۵	فصل ۵: نتیجه‌گیری
۱۱۶.....	۵-۱ نتیجه‌گیری.....
۱۱۷.....	۵-۲ پیشنهادات.....

فهرست جداول

- جدول ۱-۲. فرمولاسیون مخلوط های تهیه شده ۳۱
- جدول ۲-۲. اطلاعات مقالات مورد استفاده جهت برداشت داده ها ۳۵
- جدول ۱-۴. ورودی ها و خروجی شبکه عصبی و دامنه تغییرات آن ها ۶۵
- جدول ۲-۴. توضیح متغیرهای رگرسیونی ۷۴
- جدول ۳-۴. ضریب همبستگی و میانگین مربعات خطای لایه ها و نورونهای مختلف ۷۸
- جدول ۴-۴. MSE، RMSE و R بین مقادیر واقعی و پیش بینی شده داده های آموزش، اعتبارسنجی و آزمایش شبکه عصبی MLP ۸۶
- جدول ۴-۵. مقایسه شاخص خود ترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی برای شبکه عصبی MLP ۹۱
- جدول ۴-۶. نتایج شبکه عصبی چندلایه با تعداد متغیرهای مختلف ۹۲
- جدول ۴-۷. پارامترهای الگوریتم بهینه سازی ازدحام ذرات ۹۴
- جدول ۴-۸. MSE، RMSE و R بین مقادیر واقعی و پیش بینی شده داده های آموزش و آزمایش شبکه عصبی MLP بهینه سازی شده با PSO ۹۸
- جدول ۴-۹. مقایسه شاخص خود ترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی برای شبکه عصبی MLP بهینه سازی شده با PSO ۱۰۱
- جدول ۴-۱۰. MSE، RMSE و R بین مقادیر واقعی و پیش بینی شده داده های آموزش و آزمایش شبکه عصبی RBF ۱۰۷
- جدول ۴-۱۱. مقایسه شاخص خود ترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی برای شبکه عصبی RBF ۱۱۰
- جدول ۴-۱۲. نتایج مدلسازی شبکه های عصبی برای داده های آزمایش ۱۱۱
- جدول ۴-۱۳. مقایسه نتایج MSE و RMSE داده های اضافی برای بررسی قدرت تعمیم شبکه های عصبی ۱۱۲
- جدول ۴-۱۳. متوسط وزن های بدست آمده از آموزش شبکه های عصبی ۱۱۳

فهرست اشکال

- شکل ۱-۲. ترک خوردگی خستگی ۱۰
- شکل ۲-۲. ترک خوردگی طولی ۱۰
- شکل ۲-۳. ترک خوردگی طولی ۱۱
- شکل ۲-۴. ترک خوردگی بلوکی ۱۱
- شکل ۲-۵. ترک خوردگی لغزشی ۱۲
- شکل ۲-۶. ترک خوردگی لبه ۱۳
- شکل ۲-۷. شیارشدگی ۱۴
- شکل ۲-۸. روند ترمیم ترک در مصالح قیری در طول دوره‌ی استراحت [۸] ۱۴
- شکل ۲-۹. خرده آسفالت تراشیده شده [۵] ۱۶
- شکل ۲-۱۰. الیاف فولادی [۵] ۱۸
- شکل ۲-۱۱. براده آهن [۱۳] ۱۸
- شکل ۲-۱۲. مکانیسم فناوری خود ترمیمی میکروکپسول [۱] ۲۰
- شکل ۲-۱۳. مکانیسم فناوری خود ترمیمی گرمایش القایی [۲] ۲۰
- شکل ۲-۱۴. مکانیسم فناوری خود ترمیمی گرمایش مایکروویو [۱۶] ۲۱
- شکل ۲-۱۵. اثر ویسکوزیته و مقدار قیر بر میزان ترمیم ۲۳
- شکل ۲-۱۶. تاثیر دانه بندی بر خود ترمیمی ۲۵
- شکل ۲-۱۷. روند تهیه نمونه های نیم دایره ای [۱۳] ۲۸
- شکل ۲-۱۸. تجهیزات آزمایش خمش نیم دایره ای [۲۵] ۲۹
- شکل ۳-۱. سلول عصبی (نورون) [۳۷] ۴۱
- شکل ۳-۲. مدل شبکه عصبی مصنوعی [۳۹] ۴۳
- شکل ۳-۳. شباهت های طراحی نورون طبیعی و مصنوعی [۳۹] ۴۳
- شکل ۳-۴. تابع انتقال خطی [۴۰] ۴۵
- شکل ۳-۵. تابع پله ای [۴۰] ۴۵
- شکل ۳-۶. تابع لگاریتم سیگموئید [۴۰] ۴۶
- شکل ۳-۷. تابع سیگموئید [۴۰] ۴۶
- شکل ۳-۸. شبکه عصبی پرسپترون تک لایه ۴۸
- شکل ۳-۹. شبکه عصبی پرسپترون چندلایه ۴۹
- شکل ۳-۱۰. شبکه عصبی شعاعی پایه [۳۹] ۴۹
- شکل ۳-۱۱. تابع انتقال شبکه عصبی شعاعی [۳۹] ۵۰
- شکل ۳-۱۲. شبکه عصبی جردن [۳۹] ۵۰

شکل ۱۳-۳. حافظه کوتاه/بلند مدت [۳۹].....	۵۲
شکل ۴-۱. رگرسیون چندگانه در SPSS.....	۶۸
شکل ۴-۲. متغیرهای موجود در مدل.....	۶۸
شکل ۴-۳. خلاصه برازش مدل.....	۶۹
شکل ۴-۴. آنالیز واریانس.....	۷۱
شکل ۴-۵. برآورد ضرایب و خصوصیات مربوط به آزمون آن ها.....	۷۳
شکل ۴-۶. توزیع باقی مانده ها.....	۷۵
شکل ۴-۷. پنجره آموزش شبکه عصبی در متلب.....	۷۷
شکل ۴-۸. روند تغییرات ضریب همبستگی برحسب تعداد نورون های لایه های پنهان.....	۷۹
شکل ۴-۹. روند تغییرات میانگین مربعات خطا برحسب تعداد نورون های لایه های پنهان.....	۷۹
شکل ۴-۱۰. ساختار شبکه عصبی MLP.....	۸۰
شکل ۴-۱۱. همبستگی داده های آموزش، صحت سنجی، آزمایش و تمام داده های شبکه عصبی MLP.....	۸۱
شکل ۴-۱۲. مقایسه نتایج آزمایشگاهی با نتایج به دست آمده از شبکه عصبی MLP.....	۸۳
شکل ۴-۱۳. میانگین مربع خطاها و ریشه میانگین مربعات خطا شبکه عصبی MLP.....	۸۵
شکل ۴-۱۴. توزیع خطای پیش بینی شبکه عصبی MLP.....	۸۷
شکل ۴-۱۵. هیستوگرام خطا شبکه عصبی MLP.....	۸۸
شکل ۴-۱۶. روند تغییرات تابع عملکرد خطا شبکه عصبی MLP.....	۸۹
شکل ۴-۱۷. نتایج حاصل از مقایسه شبیه سازی شبکه عصبی MLP با نتایج تجربی.....	۹۲
شکل ۴-۱۸. ساختار شبکه عصبی MLP بهینه سازی شده با PSO.....	۹۴
شکل ۴-۱۹. همبستگی داده های آموزش، آزمایش و تمام داده های شبکه عصبی MLP بهینه سازی شده با PSO.....	۹۵
شکل ۴-۲۰. مقایسه نتایج آزمایشگاهی با نتایج به دست آمده از شبکه عصبی MLP بهینه سازی شده با PSO.....	۹۶
شکل ۴-۲۱. میانگین مربع خطاها و ریشه میانگین مربعات خطا شبکه عصبی MLP بهینه سازی شده با PSO.....	۹۷
شکل ۴-۲۲. توزیع خطای پیش بینی شبکه عصبی MLP بهینه سازی شده با PSO.....	۹۹
شکل ۴-۲۳. نتایج حاصل از مقایسه شبیه سازی شبکه عصبی MLP بهینه سازی شده با PSO با نتایج تجربی.....	۱۰۲
شکل ۴-۲۴. ساختار شبکه عصبی RBF.....	۱۰۲
شکل ۴-۲۵. رگرسیون داده های آموزش، آزمایش و تمام داده های شبکه عصبی RBF.....	۱۰۴
شکل ۴-۲۶. مقایسه نتایج آزمایشگاهی با نتایج به دست آمده از شبکه عصبی RBF.....	۱۰۵

- شکل ۲۷-۴. میانگین مربع خطاها و ریشه میانگین مربعات خطا شبکه عصبی RBF..... ۱۰۶
- شکل ۲۸-۴. توزیع خطای پیش بینی شبکه عصبی RBF..... ۱۰۸
- شکل ۲۹-۴. نتایج حاصل از مقایسه شبیه سازی شبکه عصبی RBF با نتایج تجربی..... ۱۱۱

فصل ۱ : مقدمه

۱-۱ مقدمه

آسفالت به طور گسترده در بسیاری از کشورهای جهان به عنوان روسازی راه‌ها مورد استفاده قرار می‌گیرد. شرایط محیطی همراه با بارهای ترافیکی پویا در خرابی زودرس روسازی‌ها مؤثر می‌باشند و استحکام و دوام آن‌ها را با گذشت زمان کاهش می‌دهد [۱].

ترک خوردگی یکی از شایع‌ترین خرابی‌های روسازی آسفالتی است و در اثر عوامل مختلفی از قبیل خستگی، درجه حرارت پایین و پیرشدگی قیر ایجاد می‌شود. اگرچه ترک‌ها یک مشکل هستند، از آنجا که باعث کاهش ظرفیت ساختاری و افزایش نفوذپذیری می‌شوند، در صورت رسیدن قیر به دمای بین ۳۰ تا ۷۰ درجه سانتی‌گراد، ترک‌ها خود به خود ترمیم می‌شوند. ترمیم ترک به دلیل خصوصیات فیزیکی قیر ایجاد می‌شود که با افزایش دما باعث کاهش ویسکوزیته می‌شود. با رسیدن به ویسکوزیته کم، قیر در ریز ترک‌های باز جریان می‌یابد. با کاهش درجه حرارت قیر و افزایش ویسکوزیته، ترک‌ها ترمیم می‌شوند [۲].

یکی از روش‌های مؤثر برای حل مشکل ترک خوردگی آسفالت در عملیات نگهداری روسازی‌های آسفالتی، استفاده از افزودنی‌هایی برای تسریع در روند خود ترمیمی مخلوط‌ها است. در این مخلوط‌ها، ضایعات فلزی، به طور معمول الیاف فولادی و براده آهن، اضافه می‌شوند، زیرا انرژی حرارتی بیشتری را نسبت به قیر و سنگدانه‌ها جذب می‌کنند و باعث افزایش هدایت الکتریکی مخلوط‌ها می‌شوند. برای گرم کردن مصنوعی و ترمیم این نوع مخلوط‌های آسفالتی، از یک میدان الکترومغناطیسی خارجی، مانند القای الکترومغناطیسی یا میکروویوها برای افزایش دمای ضایعات فلزی استفاده می‌شود. گرمای ضایعات فلزی به قیر و سنگدانه‌ها منتقل می‌شود و باعث کاهش ویسکوزیته قیر و ترمیم ترک‌های باز می‌شود [۲].

ترمیم ترک در مخلوط‌های آسفالتی توسط گرمایش خارجی با شاخص خود ترمیمی (% مقاومت اولیه بازیابی شده) بدست می‌آید، به عنوان مثال، نسبت بین مقاومت خمشی سه نقطه‌ای نمونه (F_i) بعد از چرخه ترمیم i ام و قدرت اولیه نمونه (F_0) قبل از ترمیم، ارزیابی می‌شود.

هدف این پایان نامه این است که با در نظر گرفتن عوامل مؤثر بر شاخص خود ترمیمی (مانند نوع افزودنی، درصد افزودنی، دانه بندی مخلوط آسفالتی، نوع قیر، نوع گرمایش، چرخه ترمیم ترک و ...) به عنوان ورودی های شبکه عصبی مصنوعی در متلب و شاخص خود ترمیمی به عنوان خروجی، بتوان به شبکه عصبی مناسبی دست یافت. شبکه های عصبی با داشتن خصوصیتی مانند یادگیری تطبیقی، تحمل خطا، دسته بندی، تعمیم دهی، حساسیت بالا به رخداد اشتباه و سرعت بالا در مدلسازی در رشته های مختلف از جمله مهندسی عمران کاربرد داشته باشد.

۱-۲ ضرورت انجام تحقیق

شبکه های عصبی مصنوعی در تخصص های گوناگون بکار گرفته می شوند. از موارد کاربرد شبکه های عصبی می توان به طبقه بندی اطلاعات، شناخت ویژگی های حروف و شکل ها، برآورد توابع و ... اشاره کرد.

یکی از مزایای شبکه های عصبی مصنوعی سرعت بالا و قابلیت نامحدود در مدلسازی نسبت به دیگر روش های موجود مانند تحلیل دستی و رگرسیون است. البته باید به این نکته توجه کرد که مدلسازی شبکه های عصبی نیازمند داده های زیادی می باشد که ممکن است زمان زیادی برای جمع آوری آنها صرف شود. این نکته نیز قابل ذکر است که روش های تحلیل دستی و آنالیز رگرسیون در صورت وجود اشتباه در داده های ورودی، دچار اشکال در تمامی محاسبات خواهند شد، اما شبکه های عصبی بدلیل تحمل پذیری خطا و آموزش براساس تجربه، در صورتیکه در داده های ورودی اشتباهات جزئی رخ دهد، کارآیی شبکه دچار مشکل نخواهد شد و قابلیت تحمل خطا را خواهد داشت.

در رشته مهندسی عمران استفاده از شبکه های عصبی، روز به روز در حال گسترش است و در آینده شاهد فراگیر شدن و توسعه این علم خواهیم بود. استفاده از شبکه های عصبی برای جلوگیری از آزمایشات متعدد و زمان بر و هزینه بر بودن آزمایشات، کاربرد قابل ملاحظه ای دارد.

۳-۱ روش انجام تحقیق

در این پژوهش، پس از بررسی تحقیقات گذشته پارامترهایی که بر شاخص خودترمیمی اثر دارند، مشخص شدند و این پارامترها به عنوان متغیر برای ایجاد مدل شبکه عصبی در نظر گرفته شدند. پارامترهایی که به عنوان ورودی مدل در نظر گرفته شدند، عبارتند از: ابعاد نمونه آزمایش، روش تراکم نمونه، دانه بندی مخلوط آسفالتی، درصد افزودنی‌ها (براده آهن، RAP¹، سرباره فولاد و الیاف فولادی)، نوع قیر، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش. ساخت مدل با استفاده از داده‌های آزمایشگاهی در مقالات مطالعه شده در زمینه خود ترمیمی مخلوط‌های آسفالتی انجام شد. در نهایت دقت مدل را با استفاده از داده‌های آزمایشگاهی مقایسه و ضریب همبستگی (R)، میانگین مربعات خطاها (MSE) و ... ارائه خواهد شد.

برای ساخت مدل داده‌های آزمایشگاهی را وارد نرم افزار اکسل کرده و سپس به نرم افزار متلب انتقال داده می‌شود. با استفاده از جعبه ابزار شبکه عصبی و روش برنامه‌نویسی، با تعیین تعداد نورون‌ها، لایه-ها و توابع انتقال، مدل ساخته شده، مورد بررسی قرار خواهد گرفت و نتایج ارائه خواهد شد.

در این مطالعه تحلیل داده‌ها با استفاده از شبکه‌های عصبی چندلایه (MLP)، شبکه عصبی چندلایه با الگوریتم بهینه ساز ازدحام ذرات (PSO)، شبکه عصبی شعاعی پایه (RBF) و تجزیه و تحلیل آماری با نرم افزار SPSS انجام خواهد شد و نتایج این روش‌ها با یکدیگر مقایسه خواهد شد.

۴-۱ فرض های تحقیق

از فرض‌های پژوهش می‌توان به موارد زیر اشاره کرد:

(۱) طول و وزن مخصوص الیاف فولادی و براده آهن مشخصات یکنواختی داشتند، به همین

دلیل از معرفی این داده‌ها به مدل شبکه عصبی صرف نظر شد.

(۲) سرباره فولاد مورد استفاده در مقالات جایگزین بخش درشت دانه بودند و از معرفی دانه-

¹ Reclaimed Asphalt Pavement

بندی آن به مدل صرف نظر شد و فقط درصد استفاده از آن در نتایج آزمایشگاهی مقالات، به مدل شبکه عصبی معرفی شد.

۱-۵ فرضیه های تحقیق

از فرضیه های پژوهش می توان به موارد زیر اشاره کرد:

- ۱) روش شبکه عصبی مصنوعی نسبت به روش رگرسیون عملکرد بهتری دارد.
- ۲) شبکه عصبی در برابر داده های تجربه نشده (داده های آزمایشگاهی که در مدلسازی بکار گرفته نشدند) قدرت تعمیم مناسبی دارد.

۱-۶ ساختار پایان نامه

این پایان نامه شامل ۵ فصل می باشد، فصل اول، مقدمه، ضرورت انجام تحقیق، روش تحقیق و فرض- های تحقیق می باشد.

در فصل دوم، مروری بر کارهای گذشته در زمینه خود ترمیمی مخلوط های آسفالتی انجام شده است. در این فصل با مرور و بررسی کارهای انجام شده در گذشته، پارامترهای مؤثر بر شاخص خود ترمیمی و روش های آزمایش مورد مطالعه قرار گرفته است. به استفاده از شبکه های عصبی در زمینه مهندسی روسازی نیز پرداخته شده است.

در فصل سوم، شرحی از ساختار شبکه های عصبی مصنوعی، کاربرد و انواع آن و فرآیند یادگیری شبکه های عصبی ارائه شده است.

در فصل چهارم، روش مدلسازی با شبکه های عصبی و نرم افزار SPSS بیان شده و نتایج بدست آمده مورد تحلیل قرار خواهد گرفت.

در فصل پنجم، خلاصه کار انجام شده در تحقیق و جمع بندی نتایج ارائه خواهد شد.

فصل ۲ : مروری بر تحقیقات گذشته

۱-۲ مقدمه

امروزه روسازی‌های آسفالتی (انعطاف‌پذیر) پرکاربردترین روسازی مورد استفاده در جهان می‌باشند. به عنوان مثال، از ۴.۳ میلیون کیلومتر راه در ایالات متحده، ۹۴٪ از آن‌ها روسازی آسفالتی دارند [۳]، در حالی که در اتحادیه اروپا بیش از ۹۰٪ از شبکه راه‌ها آسفالتی هستند [۴].

شرایط جوی، بار ترافیکی و عدم اجرای صحیح روسازی می‌تواند منجر به بروز خرابی در روسازی گردد. ترک خوردگی یکی از شایع‌ترین خرابی روسازی آسفالتی است و در اثر چرخه بارگذاری (خستگی)، پیرشدگی قیر (اکسیداسیون) و تغییر دما (حرارتی) ایجاد می‌شود. ترک خوردگی باعث کاهش مقاومت مکانیکی روسازی آسفالتی و دوام آن‌ها بویژه در معرض نفوذ آب می‌شود [۵].

به طور کلی، ترک‌های مشاهده شده در سطح روسازی می‌تواند توسط دو مکانیسم اصلی ایجاد شود، ترک‌های پایین به بالا و ترک‌های بالا به پایین. ترک‌های پایین به بالا توسط کرنش‌های کششی در پایین لایه آسفالتی و ترک‌های بالا به پایین با تنش‌های کششی و برشی سطحی، اثرات محیطی و پیرشدگی آغاز می‌شوند. مخلوط آسفالتی یک ماده ترمیم است و در صورت استفاده از انرژی کافی، می‌توان خصوصیات مکانیکی اصلی را تا حدی یا تقریباً به طور کامل بازیابی کرد. چنین فناوری می‌تواند کاهش قابل توجهی در مصرف منابع طبیعی، از جمله سنگدانه‌ها و قیرهایی را که باید در اقدامات بازسازی یا تعمیر و نگهداری در شبکه جاده استفاده شوند، ممکن سازد. افزایش عمر مفید روسازی موجود، می‌تواند باعث کاهش عملیات تعمیر و نگهداری شود، بنابراین در هزینه‌های مربوطه صرفه جویی خواهد شد و همچنین اختلالات ترافیکی ناشی از چنین اقداماتی به حداقل می‌رسد [۶].

۲-۲ خرابی در روسازی

در یک روسازی عوامل متعددی بر عمر و عملکرد آن تأثیر خواهند داشت. از جمله عوامل مؤثر می‌توان نوع خاک بستر، حجم و نوع ترافیک، مشخصات مصالح روسازی، عوامل جوی و شرایط محیطی را

نام برد. عدم بازرسی و ارزیابی به موقع و عدم مرمت خرابی‌ها، در راه‌ها می‌تواند باعث از بین رفتن سرمایه‌های عظیم مالی و ناراحتی کاربران راه‌ها گردد [۷].

کیفیت و ایمنی سطح رویه‌های آسفالتی به دلیل ترک خوردگی در اثر تکرار بارگذاری و شرایط آب و هوایی، کاهش می‌یابد. بررسی‌هایی که بر روی روسازی‌ها انجام شده، نشان می‌دهد با وجود اینکه خرابی‌های روسازی با عمر آن‌ها متناسب است، ولی رابطه مستقیم ندارند، به نحوی که در ابتدای عمر مفید خود شدت خرابی‌ها کم بوده و با سپری شدن زمان بر شدت آن‌ها اضافه می‌شود [۷].

به طور کلی خرابی‌های روسازی به دو گروه کلی تقسیم می‌شوند که شامل خرابی‌های سازه‌ای و عملکردی است. خرابی‌های سازه‌ای به آن دسته از خرابی‌هایی می‌گویند که در بطن سازه اصلی ظاهر شده و موجب تغییر شکل بیش از اندازه در لایه‌های مختلف روسازی می‌شود. در این نوع خرابی، توان باربری سیستم روسازی از بین رفته و سازه این روسازی‌ها بدون افزایش بیشتر خرابی نمی‌تواند بار بیشتری تحمل کند. اما خرابی‌های عملکردی در حالتی اتفاق می‌افتد که سیستم روسازی به لحاظ سازه‌ای مقاومت کافی دارد، ولی بهره‌وری آن‌ها به علت ناهمواری‌های سطح رویه با اشکال روبرو است [۷].

۲-۲-۱ انواع خرابی‌های روسازی

متداول‌ترین انواع ترک خوردگی عبارتند از:

۲-۲-۱-۱ ترک خوردگی خستگی

ترک خستگی معمولاً ترک خوردگی سوسماری نامیده می‌شود (شکل ۲-۱). علت آن شکست لایه سطحی به دلیل بارگیری مکرر ترافیک (خستگی) است. در واقع عدم کفایت باربری خاک بستر یا زیرسازی راه می‌تواند موجب رخداد این نوع از ترک‌ها شود. ترک خوردگی خستگی معمولاً با مشکلات زهکشی همراه است. مناطق کوچک ممکن است با وصله یا تعمیر ناحیه برطرف شوند. مناطق بزرگتر نیاز به احیا یا بازسازی دارند [۸].



شکل ۱-۲. ترک خوردگی خستگی

۲-۲-۱-۲ ترک خوردگی طولی

ترک‌های طولی ترک‌های بلندی هستند که در راستای تقریبی محور طولی رویه روسازی بوجود می‌آیند (شکل ۲-۲). این ترک‌ها ممکن است در اثر جمع شدگی و انقباض لایه آسفالتی، سیکل دمایی روزانه و بروز ترک خوردگی در درزهای ساخت روسازی ایجاد شوند [۸]. ترمیم اینگونه خرابی‌ها با استفاده از دوغاب قیری (همراه و یا بدون ماسه ریزدانه) امکان‌پذیر است.



شکل ۲-۲. ترک خوردگی طولی

۲-۲-۱-۳ ترک خوردگی عرضی

این ترک‌ها عمدتاً در عرض روسازی اتفاق می‌افتند و بر محور اصلی راه عمود هستند (شکل ۲-۳). این ترک‌ها بطور منظم از هم فاصله دارند. دلایل به وجود آمدن ترک‌های عرضی را می‌توان ناشی از

کاهش شدید دمای روسازی، شکست روسازی و یا خستگی مصالح به دلیل وقوع سیکل‌های حرارتی و افزایش و کاهش‌های متناوب دما دانست [۸].



شکل ۲-۳. ترک خوردگی طولی

۲-۲-۱-۴ ترک خوردگی بلوکی (موزاییکی)

ترک بلوکی مجموعه‌ای از ترک‌های به هم پیوسته است که روسازی را به قطعات نامنظم تقسیم می‌کند (شکل ۲-۴). این امر گاهی نتیجه تلاقی ترک‌های عرضی و طولی است. این نوع از ترک‌ها به دلیل تغییر حجم یا جمع شدگی در رویه آسفالتی، اساس و یا خاک بستر رخ می‌دهند. ترک‌های بلوکی با شدت کم را می‌توان، توسط درزگیری ترمیم نمود. برای ترمیم ترک‌های بلوکی با شدت بالا، روسازی مجدداً نوسازی می‌شود و یا روسازی قدیمی توسط روکش پوشانیده می‌شود [۸].



شکل ۲-۴. ترک خوردگی بلوکی

۵-۱-۲-۲ ترک خوردگی لغزشی (هلالی)

ترک‌های هلالی به صورت چین خوردگی بر روی سطح آسفالت ظاهر می‌شوند. در نواحی که وسایل نقلیه به طور ناگهانی توقف می‌کنند (نزدیک چهارراه‌ها، ایستگاه‌های اخذ عوارض، ایستگاه‌های اتوبوس و ...)، ایجاد می‌شوند (شکل ۵-۲). علت ایجاد این ترک‌ها، ترمز و یا تغییر جهت چرخ‌های وسایل نقلیه، چسبندگی ضعیف لایه‌های آسفالتی و لایه‌های قرار گرفته روی بستر، وجود آب و روغن هنگام اجرا بین دو لایه آسفالتی و عدم اجرای اندود سطحی و اندود نفوذی در بین لایه‌ها است. برای ترمیم خرابی، لازم است که ناحیه ترک خورده با استفاده از مخلوط آسفالتی مناسب جایگزین شود [۸].



شکل ۵-۲. ترک خوردگی لغزشی

۶-۱-۲-۲ ترک خوردگی انعکاسی

یکی از مهم‌ترین روش‌های تعمیر و نگهداری راه‌ها، اجرای روکش است. در این خصوص، پس از آنکه عملیات ساخت روکش به اتمام رسید، وقوع هرگونه جابجایی افقی یا عمودی روسازی زیرین در محل ترک که منشأ آن بارگذاری و یا تغییر درجه حرارت محیط باشد، به تدریج موجب گسترش ترک‌ها از روسازی زیرین به روسازی جدید فوقانی شده و خرابی آن را نیز در پی خواهد داشت. الگوی این ترک‌ها مشابه ترک‌های پیشین بوده و اصطلاحاً ترک‌های انعکاسی نامیده می‌شوند. این نوع از ترک‌ها به صورت طولی، عرضی و یا بلوکی مشاهده می‌شوند [۸].

۲-۲-۱-۷ ترک خوردگی لبه

ترک‌های لبه معمولاً به صورت هلال از لبه روسازی شروع می‌شوند (شکل ۲-۶). این ترک به دلیل ضعف اساس یا خاک بستر به وجود می‌آید، با بارگذاری ترافیکی شدت می‌گیرد و سیکل‌های ذوب و یخبندان که معمولاً در ضعیف نمودن اساس و خاک بستر نقش چشمگیری دارند، بر شدت آن می‌افزایند. برای ترمیم ترک با شدت کم لازم است ترک‌ها پر شوند، با افزایش شدت، وصله و جایگزینی مناطق خرابی ممکن است لازم باشد [۸].



شکل ۲-۶. ترک خوردگی لبه

۲-۲-۱-۸ شیارشدگی


این نوع از خرابی، یک خرابی سازه‌ای است و به آن تغییر شکل دائم نیز می‌گویند (شکل ۲-۷). شیارشدگی به دلیل ضعف باربری مصالح موجود، عدم تراکم کافی مخلوط و سائیدگی روسازی به دلیل استفاده از لاستیک‌های آجدار یخ‌شکن زمستانی ایجاد می‌شود. شیارشدگی جزئی را می‌توان با پوشش سطحی تعمیر کرد. شیارشدگی عمیق‌تر با قرار دادن پوشش و صاف کردن و تراز کردن مسیر برطرف می‌شود. اگر آسفالت سطحی ناپایدار باشد، بازیافت سطح بهترین گزینه است. اگر مشکل در لایه زیر سطح باشد، بازسازی ممکن است لازم باشد [۸].



شکل ۷-۲. شیارشدگی

۲-۳ مفهوم خود ترمیمی

بازگشت خواص مصالح و کاهش ترک خوردگی، به عنوان قابلیت خود ترمیمی مصالح قیری بیان شده است. شکل ۸-۲ روند ترمیم ترک در مصالح قیری را در طول دوره‌ی استراحت به خوبی نشان می‌دهد. با گذشت زمان، خواص مصالح به علت خرابی‌های جزئی (ریزترک‌ها)، کاهش می‌یابد. این ترک‌ها به مرور زمان رشد کرده و باعث شکست در مصالح می‌شوند. امروزه محققان در تلاش‌اند تا با افزودن مواد خود ترمیم به مواد طبیعی، عمر مفید آن‌ها را بهبود بخشند [۹]. افزایش پایداری روسازی آسفالتی با فن‌آوری خود ترمیمی، عملیات نگهداری را کاهش می‌دهد که باعث می‌شود، نیاز به منابع اضافی (سنگدانه، قیر و...) کم شود و انتشار گازهای گلخانه‌ای به جو نیز کاهش یابد [۱۰].



شکل ۸-۲. روند ترمیم ترک در مصالح قیری در طول دوره‌ی استراحت [۸]

ترمیم به خواص سُل-ژل قیر ارتباط دارد. فرآیند سُل-ژل یک روش شیمیایی مرطوب است که در مهندسی و علم مواد به طور گسترده استفاده می‌شود. این روش معمولاً برای تولید مواد با شروع از یک محلول کلئیدی (سُل) که به عنوان پیش ماده برای یک شبکه به هم پیوسته (ژل) از ذرات گسسته یا پلیمرهای شبکه‌ای است، بکار می‌رود. قیر یک سیستم کلئیدی شامل ذرات آسفالتین با وزن مولکولی بالا است که در مالتین‌های روغنی با وزن مولکولی پایین‌تر پراکنده شده یا به صورت محلول در آن وجود دارد. در سیستم سُل-ژل قیر، تبدیل سُل به ژل یا ژل به سُل با توجه به تغییرات درجه حرارت، تنش و ... اتفاق می‌افتد. خواص کلئیدی قیر از نوع ژل مانند در دمای پایین به نوع سُل مانند در دمای بالا تغییر می‌کند. هنگامی که درجه حرارت کاهش می‌یابد، خواص کلئیدی قیر از سُل به ژل تغییر می‌کند. بارگذاری باعث می‌گردد قیر مانند سُل رفتار کند، درست مانند آب و هنگامی که بارگذاری پایان می‌یابد، خواص قیر بلافاصله به حالت ژل مانند تغییر می‌کند. برخی از پژوهشگران ترمیم مخلوط آسفالتی در طول دوره‌های استراحت را به وسیله ی تئوری سُل-ژل بیان کردند. تحت بارهای تکراری قیر به تدریج از یک ژل به ساختار سُل تغییر می‌کند. در نتیجه در دمای بالا، ترمیم با توجه به بازگشت مجدد سُل به ساختار ژلاتینی قیر صورت می‌گیرد. اگر دوره استراحت کافی باشد، ترمیم تقریباً به صورت کامل انجام می‌شود. در درجه حرارت پایین، دوره‌های استراحت توانایی ترمیم ترک‌های به وجود آمده توسط چرخه‌های بارگذاری را ندارند و ترمیم به صورت جزئی می‌باشد [۱۱].

۲-۴ مواد بازیافتی قابل استفاده در مخلوط های آسفالتی

۲-۴-۱ خرده آسفالت تراشیده شده (RAP)

آسفالت بازیافتی از کندن روسازی‌های قدیمی حاصل می‌شود که دارای قیر پیرشده و سنگدانه است (شکل ۹-۲). محدودیت منابع و مصالح سنگی مرغوب و قیر، حل معضلات زیست محیطی ناشی از

تولید تراشه‌های خرده آسفالت و فواید اقتصادی سبب بهره برداری مجدد از مصالح موجود در صنعت روسازی شده است. صرفه جویی اقتصادی و حفظ منابع طبیعی از دلایل عمده استفاده از خرده آسفالت تراشیده شده در روسازی‌های آسفالتی می‌باشند [۵].



شکل ۹-۲. خرده آسفالت تراشیده شده [۵]

۲-۴-۲ ضایعات فلزی

جامعه ما هر روز مقادیر زیادی ضایعات فلزی بویژه در بخش‌هایی مانند ساخت و ساز (۳۴.۷٪)، معدن و استخراج معادن (۲۸.۲٪) و تولید (۱۰.۲٪) تولید می‌کند. براساس گزارش (Eurostat (2017)، در اروپا (EU-28)، تولید سالانه زباله‌ها از ۲/۵ میلیارد تن در سال ۲۰۱۴ فراتر رفته است. از این مقدار، ۹۹.۷ میلیون تن (۳.۸٪) ضایعات فلزی (عمدتاً آهن قراضه و فولاد) هستند که از این مقدار حدود ۳۱٪ در محل‌های دفن زباله جمع می‌شوند (آژانس محیط زیست، ۲۰۱۶) [۱۲].

قانون جدید پیشنهاد شده است تا امکان استفاده مجدد و بازیافت برخی از ضایعات را داشته باشد و تحقیقات زیادی در طی سال‌های گذشته انجام شده است تا روش‌های جدیدی برای انجام آن پیدا شود (آژانس محیط زیست، ۲۰۱۶). صنعت آسفالت نیز از این قاعده مستثنا نیست، زیرا در طی سال-های گذشته طیف گسترده‌ای از ضایعات را در روسازی‌ها، از قبیل ضایعات شیشه‌ای، سرباره فولاد، لاستیک، پلاستیک، پودر ضایعات زغال سنگ و زباله‌های ساختمانی استفاده کرده است. به عنوان

نمونه، اگرچه می‌توان از الیاف لاستیک برای سایر کاربردها استفاده مجدد کرد، اما امروزه فقط ۲۱٪ از مواد موجود در لاستیک‌های قدیمی بازیافت می‌شوند. بقیه معمولاً دفن شده، انباشته یا برای تولید انرژی مورد استفاده قرار می‌گیرند [۱۲].

از الیاف فولادی می‌توان برای آماده‌سازی جاده‌هایی با هدایت الکتریکی استفاده کرد. رسانایی الکتریکی مخلوط آسفالتی با افزودن الیاف بتدریج افزایش می‌یابد. آسفالت رسانا باعث می‌شود برف و یخ با روش‌های حرارتی-الکتریکی در زمستان و تنش‌ها و تغییر شکل‌های جاده‌ها را برطرف کند، زیرا تغییر شکل‌های داخلی آسفالت بر هدایت الکتریکی آن تأثیر می‌گذارد [۱۲].

یک مزیت دیگر روسازی آسفالتی رسانا این است که می‌توان آن را با استفاده از انرژی گرمایی خارجی گرم کرد، که به کاهش ترک خوردگی در جاده‌ها کمک می‌کند. هنگامی که الیاف‌های رسانا در محدوده میدان مغناطیسی متناوب قرار می‌گیرند، دمای آن‌ها افزایش می‌یابد. بنابراین، ویسکوزیته قیر را کاهش داده و ترک‌ها را پر می‌کند [۱۲].

۱-۲-۴-۲ الیاف فولادی (SWF¹)

الیاف فولادی یک تقویت کننده فلزی است که ابعاد و شکل‌های مختلفی دارد. الیاف‌های فولادی موجود بازارهای جهانی، معمولاً براساس چهار روش زیر تولید می‌شوند [۵]:

- (۱) کشیدن و بریدن سیم‌های فولادی (الیاف سیمی)
- (۲) نورد و برش ورق‌های فولادی (الیاف برشی یا نواری) (شکل ۱۰-۲)
- (۳) با استفاده از مواد مذاب (الیاف ریخته‌گری)
- (۴) تراشیدن سطح ورق‌های فولادی با استفاده از دستگاه صفحه تراش

¹ Steel Wool Fiber



شکل ۱۰-۲. الیاف فولادی [۵]

۲-۴-۲-۲ براده آهن

براده‌های آهن (شکل ۱۱-۲) تولید شده توسط صنعت فلزکاری نوع دیگری از پسماندهای جامد است که باعث ایجاد مشکلات زیست محیطی می‌شود. این تراش‌ها به دلیل زمان اکسیداسیون طولانی مدت در محیط باقی می‌مانند. یکی از کاربردهای براده‌های آهن در صنعت آسفالت می‌باشد [۱۳].



شکل ۱۱-۲. براده آهن [۱۳]

۲-۴-۲-۳ سرباره فولاد

سرباره فولاد یکی از ضایعات صنعتی است که بیش از ۱۰٪ از فولاد خام را از بین می‌برد و مقدار زیادی سرباره فولاد در فرآیند ساخت فولاد تولید می‌شود. ترکیب معدنی سرباره فولاد شامل کلسیم سیلیکات (C_2S)، فریت کلسیم (C_2F , C_4AF) و آلومینات کلسیم ($C_{12}A_7$, C_3A) می‌باشد [۱۴].


سرباره فولاد خواص مکانیکی بسیار عالی که دارد، از نظر زبری، شکل، زاویه، سختی و مقاومت در برابر سایش به طور گسترده‌ای در روسازی‌ها مورد استفاده قرار می‌گیرد. از نظر زیست محیطی، استفاده از سرباره‌های فولادی اجازه می‌دهد تا مقدار مواد برای دفع کاهش یابد؛ بنابراین، اختلاط در مخلوط‌های آسفالتی اجازه می‌دهد مواد زائد به یک منبع تبدیل شوند [۶].

۲-۵ فناوری‌های خود ترمیمی مخلوط‌های آسفالتی

تحقیقات علمی قیر را به عنوان یک ماده خود ترمیم معرفی می‌کند. در صورت رسیدن دمای مخلوط آسفالتی به ۳۰ تا ۷۰ درجه سانتیگراد ترک‌ها می‌توانند به خودی خود ترمیم شوند. سه روش اصلی برای تسریع در روند خود ترمیمی مخلوط‌های آسفالتی وجود دارد؛ از جمله فناوری میکروکپسول، گرمایش القایی و گرمایش مایکروویو.

۲-۵-۱ فناوری میکروکپسول

جوان کننده‌های کپسوله شده ذرات کروی یا کپسول‌هایی هستند که حدود ۷۰٪ روغن، مانند روغن آفتابگردان دارند و به عنوان افزودنی به مخلوط آسفالتی اضافه می‌شوند. روغن یک حلال قدرتمند برای قیر است. مکانیسم فناوری خود ترمیمی میکروکپسول (شکل ۱۲-۲) مبتنی بر این است که کپسول‌ها برای سال‌ها در روسازی آسفالتی غیرفعال خواهند ماند تا اینکه یک محرک مکانیکی خارجی در جاده اتفاق بیفتد [۱]. از این رو، هنگامی که یک ترک ریز در روسازی آسفالتی رخ می‌دهد، ترک به کپسول می‌رسد و پوسته کپسول را در زمان مناسب می‌شکند و منجر به آزاد شدن ماده جوان‌ساز در روسازی آسفالتی می‌شود. به دلیل آزاد شدن روغن و انتشار آن در مخلوط، ویسکوزیته قیر به طور موضعی در اطراف کپسول‌ها کاهش می‌یابد و می‌تواند به راحتی در ترک جریان یابد و تخلیه شود [۱۵]. عیب این روش آن است که فقط برای یک بار قابل استفاده است؛ زیرا هنگامی که ماده جوان‌ساز از میکروکپسول آزاد می‌شود دیگر نمی‌توان برای استفاده مجدد آن را پر کرد [۱۱].




شکل ۱۲-۲. مکانیسم فناوری خود ترمیمی میکروکپسول [۱]

۲-۵-۲ فناوری گرمایش القایی

فناوری گرمایش القایی را اولین بار مینسک بکار گرفت که برف روی سطح روسازی را با افزودن گرافیت به عنوان ماده رسانا به مخلوط آسفالتی و استفاده از گرمایش القایی ذوب کرد. در ده‌های اخیر گرمایش القایی را برای بهبود خود ترمیمی مخلوط‌های آسفالتی بکار گرفته‌اند که به دلیل درجه حرارت بالا، قیر در مخلوط آسفالتی جریان می‌یابد و ترک‌ها را پر می‌کند [۱۱].


گرمایش القایی، فرایند گرم کردن مواد رسانا از طریق القا الکترومغناطیسی است. در فرآیند گرمایش، یک جریان الکتریکی در یک سیم پیچ رسانا اعمال می‌شود و یک میدان الکترومغناطیسی متناوب با فرکانس در محدوده کیلوهرتز تا مگاهرتز ایجاد می‌کند. میدان الکترومغناطیسی ایجاد شده در ماده رسانا جریان پیدا می‌کند، دمای آن‌ها را افزایش می‌دهد، حرارت ایجاد شده به سنگدانه‌ها و قیر منتقل شده و باعث کاهش ویسکوزیته قیر می‌شود (شکل ۱۳-۲) [۲].



شکل ۱۳-۲. مکانیسم فناوری خود ترمیمی گرمایش القایی [۲]

۳-۵-۲ فناوری گرمایش میکروویو

با توجه به روش گرمایش میکروویو برای اهداف خود ترمیمی، تحقیقات بر روی این روش امیدوار کننده است. بر اساس اصل مگا هرتز، مولکول‌های مواد قیری پس از قرار گرفتن در معرض میدان‌های الکترومغناطیسی، جهت‌گیری خود را تغییر می‌دهند (شکل ۱۴-۲). این فرآیند باعث ایجاد اصطکاک داخلی می‌شود که دمای کل مخلوط آسفالتی را افزایش می‌دهد. با افزودن مقدار بسیار کمی از ذرات فلزی، می‌توان افزایش دما را به طرز چشمگیری تسریع کرد زیرا این مواد افزودنی از توانایی بالایی در بازتاب میکروویو برخوردار هستند [۱۶].



شکل ۱۴-۲. مکانیسم فناوری خود ترمیمی گرمایش میکروویو [۱۶]

بسیاری از محققان این عقیده را دارند که روش گرمایش میکروویو در مقایسه با گرمایش القایی به دلایل زیر انتخاب بهتری است:

(۱) صرفه اقتصادی: Gallego و همکاران [2013] خاطر نشان کرد که گرمایش میکروویو

انرژی کمتر (۱/۲ کیلو وات در مقایسه با توان ۵۰ کیلو وات مورد نیاز دستگاه گرمایش

القایی) و درصد فولاد کمتری (تقریباً ده برابر کمتر) مصرف می‌کند [۱۷].

(۲) راندمان بالاتر: طبق تحقیقات Norambuena-Contreras و Garcia [2016]، استفاده از

فناوری میکروویو نسبت به گرمایش القایی برای تعمیر آسفالت جاده مؤثرتر است. این

محققان همچنین اظهار داشتند که گرمایش میکروویو دمای قیر را نسبت به گرمایش

القایی بالا می‌برد و در نتیجه نسبت خود ترمیمی افزایش می‌یابد [۱۸].

۳) تجهیزات ساده: تمام آنچه برای گرمایش مایکروویو لازم است فقط اون مایکروویو

است [۱۷].


۲-۶ فاکتورهای مؤثر بر خود ترمیمی

عوامل بسیاری بر میزان ترمیم مخلوط‌های آسفالتی مؤثر هستند. این عوامل به سه دسته شامل خواص قیر، ترکیبات مخلوط آسفالتی و محیط تقسیم می‌شوند.

۲-۶-۱ خواص قیر

۲-۶-۱-۱ نوع قیر

برخی از محققان دریافته‌اند که ویژگی‌های قیر نقش مهمی در قابلیت ترمیم روسازی‌های آسفالتی دارد، قیر نرم دارای قابلیت ترمیم بالاتر در مقایسه با قیر سخت است. قیر با درجه نفوذ بالاتر برای عملکرد ترمیم مطلوب‌تر است. علاوه بر این، ویسکوزیته ممکن است یک عامل حیاتی در تعیین قابلیت ترمیم قیر باشد. بنابراین می‌توان فرض کرد که، گر انرژی کم می‌تواند روند ترمیم در قیر را افزایش دهد. همان طور که در شکل ۲-۱۵ مشخص است، با افزایش مقدار قیر، میزان ترمیم نیز افزایش می‌یابد. میزان ترمیم برای قیرهای با درجه نفوذ بالاتر (قیر نرم‌تر) بیشتر از قیرهای با درجه نفوذ کمتر (قیر سفت‌تر) است، در شکل ۲-۱۵ نیز نشان داده شده است که قیر با درجه نفوذ ۸۰/۱۰۰ ظرفیت ترمیم بالاتری نسبت به قیر با درجه نفوذ ۵۰/۶۰ دارد [۱۹].



شکل ۱۵-۲. اثر ویسکوزیته و مقدار قیر بر میزان ترمیم

۲-۶-۱-۲ ترکیبات قیر

قیر با تحرک مولکولی بالاتر از قابلیت پخش بالاتری برخوردار است. بر این اساس، بر اساس ترکیب شیمیایی قیر، Kim و همکاران (۱۹۹۰) دو پارامتر برای تعیین کمی تحرک مولکولی قیر از جمله نسبت $MMHC^1$ (اتم‌های هیدروژن متیلن و متیلن به اتم‌های کربن متیل و متیلن) و نسبت CH_2/CH_3 (متیلن به متیل) که به ترتیب به میزان انشعاب در زنجیرها و طول زنجیرها مربوط می‌شود، معرفی کردند. علاوه بر این، Kim و همکارانش (۱۹۹۰) گزارش کرده اند که با کاهش نسبت $MMHC$ (میزان انشعاب)، نفوذ و سرعت ترمیم افزایش می‌یابد [۲۰].

۲-۶-۱-۳ پیرشدگی

Bhasin و همکارانش (۲۰۱۱) درصد ترمیم سه نوع قیر (قیرهایی با درجه عملکردی ۲۲-۶۴، ۲۲-۷۰ و ۲۲-۷۶) را در دمای مختلف و شرایط پیرشدگی بررسی کردند. سختی نمونه آزمایش پس از پیرشدگی کوتاه مدت ($RTFO^2$) به ۷۵٪ از حد اولیه رسیده است، در حالی که پس از پیرشدگی بلند

¹ methylene and methylene hydrogen atoms to methyl and methylene carbon atoms

² Rolling Thin-Film Oven

مدت (PAV¹) سختی نمونه آزمایش پس از ۶۰ دقیقه ماندن در دمای ۲۰ درجه سانتیگراد، به ۶۰٪ از حد اولیه رسید. پیرشدگی قیر سرعت ترمیم طبیعی را کاهش می دهد [۲۱].

۲-۶-۲ ترکیبات مخلوط آسفالتی

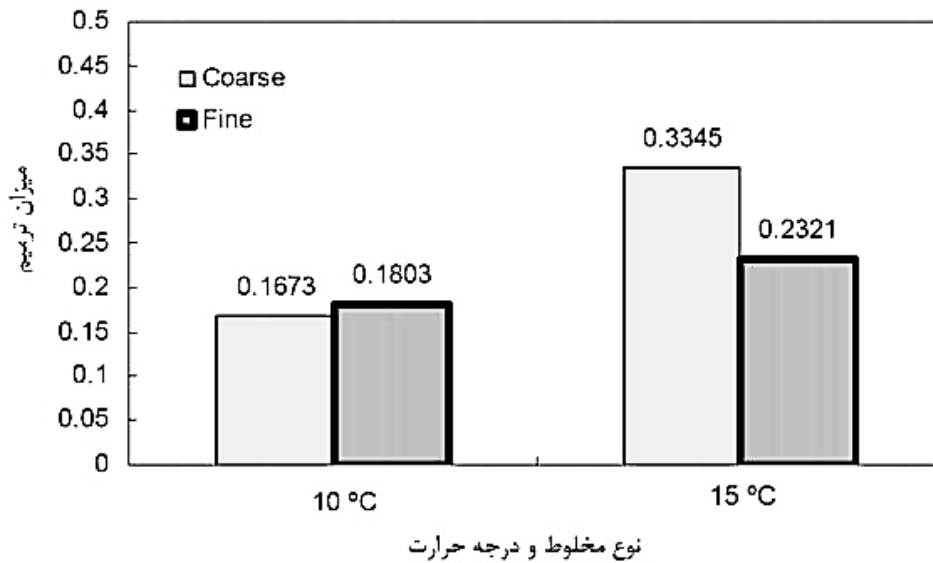
۲-۶-۲-۱ مقدار قیر

قیر موجود در مخلوط آسفالتی خاصیت خود ترمیمی دارد، بنابراین مقدار قیر بر ترمیم مخلوط آسفالتی تأثیر دارد. برخی مطالعات نشان داده اند که مخلوط آسفالتی با درصد قیر بالاتر سرعت ترمیم بیشتری دارد. همان طور که در شکل ۲-۱۵ مشاهده می شود مخلوط آسفالتی با قیر بیشتر، میزان ترمیم بیشتری دارد [۱۹].

۲-۶-۲-۲ دانه بندی مخلوط آسفالتی

فرآیند ترمیم در مخلوط آسفالتی با دانه بندی درشت بسیار سریعتر از مخلوط ریزدانه است (شکل ۲-۱۶). دانه بندی درشت با مساحت سطح پایین می تواند یک قیر ضخیم تر و مناطق انتقال کمتر بین سنگدانه و قیر را فراهم کند. علاوه بر این، نتایج یک مطالعه دیگر نشان داد که در بین مخلوط های مختلف آسفالتی، SMA قابلیت ترمیم بالاتری دارد [۱۹].

¹ Pressure Ageing Vessel



شکل ۱۶-۲. تاثیر دانه بندی بر خود ترمیمی

۲-۶-۲-۳ نوع و درصد ماده افزودنی رسانا

یکی از تکنیک‌های اخیر برای حل مشکل نگهداری روسازی‌های آسفالتی استفاده از افزودنی‌هایی برای تسریع در روند خود ترمیمی مخلوط‌ها است. گزینه‌ای برای تسریع این روند افزودن انواع مختلف الیاف یا ذرات فلزی است که خصوصیات مکانیکی مخلوط را افزایش می‌دهد. خود ترمیمی با افزودن درصد ذرات فلزی تا مقدار مشخصی از ذرات افزایش می‌یابد و در صورت افزایش درصد ذرات از مقدار بهینه بدلیل توزیع ناهمگن آن در مخلوط که باعث پدیده گرمایش بیش از حد قیر می‌شود، کاهش می‌یابد.

۲-۶-۳ محیط

۲-۶-۳-۱ نوع گرمایش

از دو روش می‌توان برای تسریع روند خود ترمیمی مخلوط‌های آسفالتی استفاده کرد، که شامل گرمایش القایی و گرمایش میکروویو می‌باشد. بسیاری از محققان این عقیده را دارند که روش گرمایش میکروویو به سه دلیل صرفه اقتصادی، راندمان بالاتر و کنترل دما انتخاب بهتری است [۱۷]. استفاده از فناوری میکروویو نسبت به گرمایش القایی برای تعمیر آسفالت جاده مؤثرتر است. گرمایش

مایکروویو دمای قیر را نسبت به گرمایش القایی بالا می‌برد و در نتیجه نسبت خود ترمیمی افزایش می‌یابد [۱۸].

۲-۳-۶-۲ زمان گرمایش

قیر یک ماده پلیمری ویسکوالاستیک با رفتار وابسته به دما-زمان است. سطح ترمیم با افزایش زمان ماندن، سرعت ترمیم و سطح دما افزایش می‌یابد. با این حال، گرم شدن بیشتر نمونه منجر به کاهش سرعت ترمیم می‌شود.

شاخص ترمیم هنگامی که دما به میزان مشخصی افزایش یابد به اوج خود می‌رسد. مدت زمان طولانی گرم شدن ممکن است منجر به مشکلات انبساطی و تخلیه قیر شود، بنابراین بازده ترمیم کاهش می‌یابد [۲۲].

۲-۳-۶-۳ چرخه شکست-ترمیم ترک

با افزایش تعداد چرخه‌های خود ترمیمی، نسبت خود ترمیمی کاهش می‌یابد.

۲-۷ مزایای اقتصادی و زیست محیطی مخلوط آسفالتی با

قابلیت خود ترمیمی

برای ارزیابی دقیق هزینه‌هایی که جهت استفاده از مواد خود ترمیم انجام شده است، باید تغییر (افزایش) هزینه مصالح با تغییر (کاهش) هزینه نگهداری مقایسه شود. زمانی که از مواد خود ترمیم استفاده می‌شود، دوره‌های بین نگهداری راه طولانی‌تر خواهد شد و در نتیجه تراکم ترافیک و هزینه‌های مربوط به آن کاهش می‌یابد. با توجه به تحقیقی که در کشور هلند صورت گرفت، مشخص شد، برای روسازی آسفالتی با ۲۵ درصد عمر مفید بیشتر، صرفه جویی سالیانه، شامل صرفه جویی مربوط به تعمیرات اساسی و هزینه‌های ترافیکی، حدود ۶۵ میلیون یورو و این صرفه جویی برای روسازی آسفالتی با ۵۰ درصد عمر مفید بیشتر، بیش از ۱۰۰ میلیون یورو است [۲۳]. نتیجه گرفته شد که اگر

قیمت روسازی آسفالتی خود ترمیم دو برابر قیمت روسازی آسفالتی استاندارد باشد، کشور هلند با سرمایه گذاری بر روی روسازی آسفالتی خود ترمیم با ۵۰ درصد عمر مفید بیشتر، تقریباً سالیانه ۹۰ میلیون یورو صرفه جویی می‌نماید. بنابراین استفاده از فناوری خود ترمیمی در طراحی مخلوط‌های آسفالتی مزایای اقتصادی زیادی دارد.


در تحقیقی اثر خود ترمیمی بر طول عمر، مصرف انرژی و مسائل زیست محیطی روسازی آسفالتی مورد مطالعه قرار گرفت [۲۴]. با استفاده از تحلیل چرخه عمر (LCA^۱) که به واسطه‌ی یک مدل عددی ظرفیت خود ترمیمی بتن آسفالتی را شبیه سازی نمود، مشخص شد که روسازی آسفالتی خود ترمیم عمر مفید روسازی را در مقایسه با روسازی آسفالتی استاندارد، ۱۰ درصد افزایش می‌دهد. با افزایش ۱۰ درصدی عمر مفید روسازی، مصرف انرژی و انتشار کربن دی اکسید، ۳ درصد کاهش می‌یابد. بنابراین فناوری خود ترمیمی روسازی آسفالتی باعث کاهش هزینه، کاهش مصرف انرژی و کاهش انتشار کربن دی اکسید خواهد شد.

۲-۸ بررسی آزمون‌های آزمایشگاهی جهت تعیین شاخص خود ترمیمی

۲-۸-۱ آزمایش خمش نیم دایره ای

^۱ Life Cycle Analysis

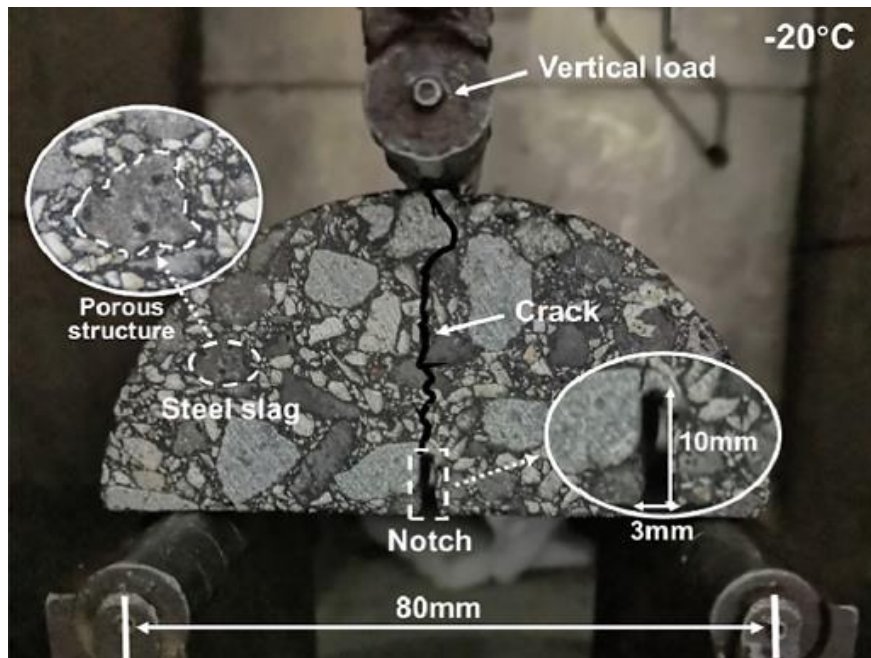
مقاومت خمشی سه نقطه‌ای نمونه‌های مخلوط آسفالتی با استفاده از آزمایش خمش نیم دایره‌ای اندازه‌گیری می‌شود. برای این آزمایش از نمونه‌های نیم دایره‌ای استفاده می‌شود. ساخت این نمونه‌ها به این صورت است که مخلوط مورد نظر در قالب مارشال که از قبل گرم شده است، قرار داده می‌شود، سپس مخلوط با استفاده از چکش مارشال فشرده و به هر طرف نمونه ۷۵ ضربه وارد می‌شود. نمونه‌های استوانه‌ای مارشال با قطر ۱۰۰ میلی‌متر و ارتفاع تقریباً ۶۰ میلی‌متر، حداقل برای یک روز در آزمایشگاه باقی می‌مانند. مرحله بعدی تولید چهار نمونه نیم دایره‌ای با برش دادن یک نمونه مارشال است (شکل ۱۷-۲). علاوه بر این، برای هدایت ترک خوردگی نمونه در طی آزمایش خمش نیم دایره‌ای، شکافی با طول ۱۰ میلی‌متر و ضخامت ۳ میلی‌متر در قسمت میانی نمونه برش داده می‌شود [۲].



شکل ۱۷-۲. روند تهیه نمونه های نیم دایره ای [۱۳]

پس از ساخت، نمونه‌ها ۲۴ ساعت قبل از آزمایش در دمای ۲۰- درجه سانتی‌گراد نگهداری می‌شوند. نمونه‌های نیم دایره‌ای بر روی دو غلتک به فاصله ۸۰ میلی‌متر از هم قرار می‌گیرند. یک غلتک بارگذاری سوم در قسمت میانی بالای نمونه‌ها قرار می‌گیرد (شکل ۱۸-۲). آزمایش در داخل محفظه محیطی در دمای ۲۰- درجه سانتی‌گراد انجام می‌شود. تجهیزات مورد استفاده برای آزمایش، یک دستگاه تست جهانی با ظرفیت ۲۰ کیلو نیوتن می‌باشد و نرخ بارگذاری ۰.۵ میلی‌متر در دقیقه تعیین شده است. پس از اتمام آزمایش خمش، نمونه‌های آسفالتی ترک خورده به مدت ۳ ساعت در دمای

اتاق قرار می‌گیرند تا زمانی که به ۲۰ درجه سانتی‌گراد برسند، برای اینکه اطمینان حاصل شود که رطوبت سطح ناشی از انجماد کاملاً تبخیر شود [۲۵].



شکل ۲-۱۸. تجهیزات آزمایش خمش نیم دایره ای [۲۵]

۲-۸-۲ آزمایش گرمایش میکروویو و گرمایش القایی

دو سطح ترک خورده نمونه‌های آزمایشی در کنار هم گذاشته می‌شوند و در میکروویو با قدرت ۷۰۰ وات و فرکانس ۲.۴۵ گیگاهرتز قرار می‌گیرند [۲۶]. زمان گرمایش از ۱۰ تا ۵۰ ثانیه انتخاب می‌شود. زمان گرمایش ۴۰ ثانیه براساس نتایج تحقیقات قبلی برای ترمیم میکروویو مناسب می‌باشد [۲].

آزمایش گرمایش القایی با استفاده از یک ژنراتور گرمایش القایی ۶ کیلوواتی با حداکثر فرکانس ۳۵۰ کیلوهرتز قابل انجام می‌باشد [۲۷]. زمان گرمایش براساس مطالعات پیشین ۱۲۰ ثانیه انتخاب می‌شود. پس از خنک شدن، نمونه اولین چرخه ترمیم را کامل می‌کند و آماده شروع یک چرخه جدید می‌شود که در آن نمونه دوباره آزمایش خواهد شد و بار اوج، (F_i) ثبت می‌شود [۲۶]. نرخ ترمیم برای هر نمونه آسفالتی، HR، به عنوان رابطه بین حداکثر نیروی نمونه آزمایش که ابتدا آزمایش شده است، (F_0) و حداکثر نیرو اندازه‌گیری شده در نمونه آزمایش پس از چرخه ترمیم i ام، (F_i) تعریف می‌شود:

$$HL = \frac{F_i}{F_0}$$

(۲-۱)

۲-۹ مروری بر مطالعات خود ترمیمی مخلوط های آسفالتی

- Norambuena-Contreras و همکاران (۲۰۱۶) خود ترمیمی مخلوط آسفالتی توسط گرمایش مایکروویو و گرمایش القایی را ارزیابی کردند. برای این هدف، مخلوط های آسفالتی با ۲٪، ۴٪، ۶٪ و ۸٪ حجم کل قیر از الیاف فولادی برای ساخت نمونه ها آماده شد. خواص خود ترمیمی مخلوط های آسفالتی با استفاده از آزمایش خمش سه نقطه ای قبل و بعد از ترمیم با زمان گرمایش ۴۰ ثانیه برای مایکروویو و زمان های ۸۰، ۶۰ و ۱۲۰ ثانیه برای گرمایش القایی طی ده چرخه ترمیم ترک اندازه گیری شد. نتایج نشان داد، برای ترمیم ترک-ها گرمایش مایکروویو مؤثرتر از گرمایش القایی است. علاوه بر این، سطح ترمیم مخلوط های آسفالتی با هر چرخه ترمیم کاهش می یابد، تا اینکه نمونه های آزمایش نتوانند در برابر چرخه های ترمیم ترک بیشتر مقاومت کنند [۲۷].
- Norambuena-Contreras و همکاران (۲۰۱۷) تأثیر زمان گرمایش مایکروویو بر خواص خود ترمیمی مخلوط های آسفالتی تقویت شده با الیاف فولادی را ارزیابی کردند. مقدار الیاف اضافه شده به مخلوط مورد مطالعه ۲٪، ۴٪، ۶٪ و ۸٪ حجم کل قیر بود. خواص خود ترمیمی مخلوط های آسفالتی با استفاده از آزمایش خمش سه نقطه ای قبل و بعد از ترمیم مایکروویو برای چهار زمان مختلف گرمایش (۱۰ ثانیه، ۲۰ ثانیه، ۳۰ ثانیه و ۴۰ ثانیه)، طی ده چرخه ترمیم ترک اندازه گیری شد. در این تحقیق نتیجه گیری شد که ۴۰ ثانیه بهترین زمان گرمایش برای رسیدن به بالاترین سطح ترمیم با کمترین آسیب به نمونه های آسفالتی است و زمان گرمایش بیش از ۳۰ ثانیه می تواند ترکها را ترمیم کند [۲۸].
- Gonzalez و همکاران (۲۰۱۸) تأثیر افزودن براده آهن و RAP بر خواص مخلوط آسفالتی با قابلیت ترمیم ترک با گرمایش مایکروویو را ارزیابی نمودند. سنگدانه ها با ۰، ۱۰، ۲۰ و ۳۰

درصد RAP ترکیب شدند. درصد براده آهن از نظر حجم کل قیر: ۰٪، ۱٪، ۲٪ و ۴٪ بود. محاسبه مقاومت خمشی نمونه‌های نیم دایره‌ای با استفاده از آزمایش خمش سه نقطه‌ای انجام شد. نتایج نشان داد که میانگین شاخص ترمیم برای مخلوط‌های بدون براده آهن برابر با ۰/۴۵۲۶، در حالی که برای مخلوط‌ها با براده آهن برابر با ۰/۵۳۷۴ بود، این نشان می‌دهد که براده آهن ترمیم مخلوط‌های آسفالتی را بهبود می‌بخشد. میانگین شاخص ترمیم برای کلیه مخلوط‌های بدون RAP، ۰.۵۹۶۸ و برای مخلوط‌ها با RAP، ۰.۴۸۷۲ بود، این نشان می‌دهد که افزودن RAP باعث کاهش ترمیم برای مدت زمان گرمایش ثابت مایکروویو ۴۰ ثانیه می‌شود [۲].

- Tam Minh Phan و همکاران (۲۰۱۸) از چهار درصد مختلف الیاف فولادی (SWF) به عنوان یک ماده افزودنی رسانا و از دو نوع مصالح استفاده کردند: سرباره فولاد و مصالح معمولی. بر اساس تجربه و تحقیقات اولیه، چهار درصد مختلف SWF شامل ۲، ۴، ۶ و ۸ درصد وزن مخلوط آسفالتی استفاده شده است. ۱۰ فرمولاسیون مخلوط مختلف تهیه شده است که در جدول ۱-۲ ارائه شده است.

جدول ۱-۲. فرمولاسیون مخلوط‌های تهیه شده

مخلوط	قیر	سنگدانه معمولی درشت	سرباره فولاد	الیاف فولادی
C		100%	0%	0%
F2		100%	0%	2%
F4		100%	0%	4%
F6		100%	0%	6%
F8		100%	0%	8%
SC	5.4%	70%	30%	0%
SF2		70%	30%	2%
SF4		70%	30%	4%
SF6		70%	30%	6%
SF8		70%	30%	8%

مقاومت نمونه‌ها توسط آزمایش خمش سه نقطه‌ای انجام شد. نتایج نشان داد عملکرد ترمیم مخلوط - های SWF با سنگدانه‌های طبیعی پس از ۱۰ چرخه به تدریج کاهش یافته و اکثر نمونه‌ها در آخرین چرخه سطح ترمیم بالاتر از ۴۰٪ نداشتند. از بین آن‌ها، مخلوط F2 به ترتیب بعد از ۵ و ۱۰ چرخه ۷۶٪ و ۴۹٪ عملکرد ترمیم داشت. عملکرد ترمیم مخلوط F6 و F8 کمترین بود؛ ممکن است به دلیل استفاده بیش از حد از درصد SWF باشد که باعث توزیع نامناسب حرارتی و ایجاد پدیده بیش از حد گرم شدن قیر می‌شود.

نتایج ترمیم مخلوط SWF ساخته شده توسط سرباره‌های فولادی نشان داد که اضافه کردن ۳۰٪ سرباره فولاد به عنوان سنگدانه درشت به مخلوط SWF باعث بهتر شدن عملکرد ترمیم در مقایسه با نمونه طبیعی می‌شود. نمونه‌های سرباره عملکرد ترمیم بالاتر از ۹۰٪ تا چرخه چهارم را ایجاد کردند. در حالی که، این مقدار در نمونه معمولی پس از چرخه دوم به زیر ۸۸٪ کاهش یافت. مصالح سرباره با دو درصد SWF، (SF2) بعد از پنج چرخه عملکرد ترمیم ۸۲٪ را داشتند که تقریباً ۶ درصد بیشتر از مخلوط‌ها با مصالح طبیعی است. این بهبود ممکن است به دلیل حساسیت بیشتر ذرات سرباره فولاد در برابر اشعه مایکروویو باشد [۱۶].

- González و همکاران (۲۰۱۸) تأثیر افزودن روسازی آسفالتی بازیافت شده (RAP) و الیاف فولادی را مورد بررسی قرار دادند. درصد RAP در مخلوط ۰٪، ۱۰٪، ۲۰٪ و ۳۰٪ و درصد الیاف از نظر حجم کل قیر: ۰٪، ۱٪، ۲٪ و ۴٪ بود. مخلوط‌های بدون RAP نیز با ۶٪ از الیاف فلزی تهیه شدند تا تأثیر درصد بیشتر فلز در مخلوط‌هایی با مواد دست نخورده را نشان دهند. آزمایش خمش سه نقطه‌ای برای ارزیابی ترمیم ترک مخلوط‌های آسفالتی انجام شد. اثر افزودن RAP به مخلوط آسفالتی باعث کاهش شاخص ترمیم شد. در مقابل، اثر الیاف فولادی افزایش شاخص ترمیم بود [۵].

- Norambuena-Contreras و همکاران (۲۰۱۸) تأثیر افزودن الیاف فولادی و براده آهن را بر خواص خود ترمیمی نمونه‌ها با استفاده از گرمایش مایکروویو در دو زمان مختلف، ۳۰ ثانیه و

۴۰ ثانیه ارزیابی کردند. درصد ضایعات فلزی بر اساس حجم کل قیر ۲٪، ۴٪، ۶٪ و ۸٪ بود. مشخص شد که اضافه کردن الیاف برای ترمیم ترک هنگام استفاده از زمان گرم شدن کوتاه‌تر (۳۰ ثانیه) مؤثرتر است، در حالی که وجود براده آهن در مخلوط‌های آسفالتی هنگام استفاده از زمان گرمایش طولانی‌تر (۴۰ ثانیه) به مقادیر خود ترمیمی بالاتری می‌رسد [۲۵].

- Alvaro González و همکاران (۲۰۱۹) قابلیت‌های ترمیم ترک مخلوط‌های آسفالتی معمولی بدون مواد افزودنی فلزی را در مقابل مخلوط‌های آسفالتی اصلاح شده با الیاف فولادی، براده آهن و کاربید سیلیکون (SiC) برای ترمیم ترک مخلوط‌های آسفالتی توسط گرمایش میکروویو مورد مطالعه و مقایسه قرار دادند. درصد الیاف فولادی و براده آهن ۴٪ حجم کل قیر بود و ۵/۲ درصد حجمی، SiC اضافه شده به مخلوط با سعی و خطا تست گرمایش میکروویو مشخص شد. آزمایش خمش سه نقطه ای بر روی نمونه‌های نیمه دایره‌ای انجام شد تا مقاومت خمشی مخلوط آسفالتی مورد ارزیابی قرار گیرد [۲۶].

- Ziming Liu و همکاران (۲۰۱۹) تأثیر افزودن الیاف فولادی را بر خواص خود ترمیمی نمونه‌ها با استفاده از گرمایش القایی در زمان ۱۲۰ ثانیه ارزیابی کردند. درصد الیاف فولادی بر اساس حجم کل قیر ۲٪، ۳٪ و ۴٪ بود. با افزایش درصد الیاف، میزان گرمایش القایی به طور قابل توجهی افزایش یافت. نمونه‌ها با ۴٪ الیاف بهترین اثر ترمیم را داشتند. با افزایش چرخه‌های ترمیم ترک، نرخ ترمیم نمونه‌ها به تدریج کاهش می‌یابد [۳۰].

- Baowen Lou و همکاران (۲۰۲۰) از Hot braised steel slag (HBSS) استفاده کردند. HBSS (۰٪، ۲۰٪، ۴۰٪، ۶۰٪، ۸۰٪، ۱۰۰٪) به جای سنگدانه آهکی با اندازه ذرات ۴.۷۵ تا ۹.۵ میلی متر استفاده شد. در این مطالعه، آزمایش خمش نیم دایره‌ای (SCB) انجام شد. نمونه‌های معمولی (تشکیل شده از سنگ آهک) عملکرد ترمیم مطلوبی نداشتند، به خصوص در چرخه‌های بعدی؛ این به دلیل کمبود مواد برای جذب و هدایت انرژی گرمایشی در نمونه معمولی است. HBSS60 بالاترین اثر ترمیم را نشان داد و برای سایر درصدها، سطح راندمان

پایین تر بود. متوسط شاخص ترمیم HBSS60 پس از چرخه اول ۷۶.۸٪ بود که تقریباً برابر ۱.۴۷، ۱.۲۶، ۱.۱۳، ۱.۲۵ و ۱.۳۲ برابر HBSS0، HBSS20، HBSS40، HBSS80 و HBSS100 است. مخلوط‌های آسفالتی با درصد بیش از حد HBSS ممکن است قیر را به شدت نرم کند و باعث مشکل گرمای بیش از حد در طی فرآیند گرمایش میکروویو شود. این مشکل در چرخه‌های اولیه رخ داده، نمونه‌ها را خراب کرده و در نتیجه سطح ترمیم کاهش یافته است. از این رو میزان جایگزینی مناسب HBSS به نظر می‌رسد ۶۰٪ از حجم کل سنگدانه‌ها با اندازه ۴.۷۵ تا ۹.۵ میلی‌متر باشد [۲۹].

- Mansour Fakhri و همکاران (۲۰۲۰) تأثیر افزودنی‌های براده آهن، الیاف فولادی تایلر بازیافتی و پرکننده سرباره مس بر خواص مکانیکی و خود ترمیمی مخلوط‌های آسفالتی از طریق گرمایش میکروویو را بررسی کردند. درصد پرکننده در کلیه مخلوط‌ها ۶٪ کل وزن سنگدانه بود. مقدار براده آهن و الیاف فولادی تایلر بازیافت شده ۰.۱٪، ۰.۲٪ و ۰.۴٪ کل حجم قیر بر اساس مطالعات قبلی انتخاب شدند. همچنین از ساسوبییت به مقدار ۱.۵٪ وزن قیر به عنوان اصلاح کننده قیر استفاده شد. شاخص خود ترمیمی مخلوط‌های آسفالتی حاوی براده آهن، الیاف فولادی تایلر بازیافتی و پرکننده سرباره مس با استفاده از آزمایش SCB پس از ۲۰، ۳۰ و ۴۰ ثانیه گرمایش میکروویو انجام شد. نتایج نشان داد که نمونه‌هایی که به مدت ۴۰ ثانیه گرم می‌شوند نسبت به نمونه‌هایی که برای ۲۰ یا ۳۰ ثانیه گرم می‌شوند نسبت خود ترمیمی بالاتری دارند. با افزایش تعداد چرخه‌های خود ترمیمی، شاخص خود ترمیمی کاهش می‌یابد [۱۳].

داده‌های استفاده شده در آموزش و بررسی قدرت تعمیر شبکه عصبی از مقالات برداشت شده است که اطلاعات این مقالات در جدول ۲-۲ ارائه شده است.

جدول ۲-۲. اطلاعات مقالات مورد استفاده جهت برداشت داده ها

نام مقالات	نویسندگان	سال انتشار	ژورنال چاپ
Self-healing of asphalt mixture by microwave and induction heating	J. Norambuena-Contreras, A. Garcia	2016	Materials and Design
Influence of the Microwave Heating Time on the Self-Healing Properties of Asphalt Mixtures	Jose Norambuena-Contreras and Irene Gonzalez-Torre	2017	Applied Sciences
Self-healing properties of recycled asphalt mixtures containing metal waste: An approach through microwave radiation heating	A. Gonzalez et al.	2018	Journal of Environmental Management
Crack healing performance of hot mix asphalt containing steel slag by microwaves heating	Tam Minh Phan et al.	2018	Construction and Building Materials
Effect of RAP and fibers addition on asphalt mixtures with self-healing properties gained by microwave radiation heating	A. Gonzalez et al.	2018	Construction and Building Materials
Effect of metallic waste addition on the electrical, thermophysical and microwave crack-healing properties of asphalt mixtures	J. Norambuena-Contreras et al.	2018	Construction and Building Materials
Microwave crack healing on conventional and modified asphalt mixtures with different additives: an experimental approach	A. Gonzalez et al.	2019	Taylor & Francis
Induction Heating and Fatigue-Damage Induction Healing of Steel Fiber-Reinforced Asphalt Mixture	Ziming Liu et al.	2019	J. Mater. Civ. Eng.
Effect of metallic-waste aggregates on microwave self-healing performances of asphalt mixtures	Baowen Lou et al.	2020	Construction and Building Materials
An Evaluation of the Mechanical and Self-healing Properties of Warm Mix Asphalt Containing Scrap Metal Additives	Mansour Fakhri et al.	2020	Journal of Cleaner Production

۱۰-۲ استفاده از شبکه عصبی مصنوعی در مهندسی روسازی

در زمینه پیش بینی شاخص خود ترمیمی با شبکه عصبی تاکنون مطالعه‌ای انجام نشده است، اما

درمورد کاربرد آن در شاخه مهندسی روسازی مطالعاتی انجام گرفته است که به شرح زیر است:

- Saltan و همکارانش در سال ۲۰۰۲ محاسبات برگشتی پارامترهای لایه‌های روسازی را با استفاده از شبکه‌های عصبی مصنوعی انجام دادند [۳۱].
- X.Mei و همکارانش در سال ۲۰۰۴ عمق ترک‌های خستگی در روسازی‌های آسفالتی را بر اساس اندازه‌گیری سریع ویژگی‌های سطح آن‌ها مثل خصوصیات هندسی سطح ترک‌ها، خصوصیات روسازی و ویژگی‌های ترافیکی توسط یک شبکه عصبی تخمین زدند. وظیفه یادگیری توسط یک پایگاه داده که شامل مشخصات مربوط به ترافیک و روسازی شبکه بزرگراه ایالتی فلوریدا است، انجام شد و نتیجه گرفتند که می‌توان عمق ترک واقعی را با استفاده از مدل شبکه عصبی که شامل هندسه سطح ترک، ترافیک و سایر داده‌های روسازی است، به طور منطقی تخمین زد [۳۲].
- Gopalakrishnan و همکارانش در سال ۲۰۰۶، از یک شبکه عصبی پیشرو چند لایه تحت الگوریتم پس انتشار خطا برای پیش بینی مدول غیر خطی لایه‌های روسازی آسفالتی فرودگاه‌ها تحت بار چرخ هواپیماهای نسل جدید استفاده کردند. نتایج نشان دهنده موفقیت شبکه‌های عصبی مصنوعی در تخمین مدول عکس العمل روسازی‌های انعطاف پذیر بود [۳۳].
- Huang و همکارانش (۲۰۰۷) پیش بینی عمر خستگی مخلوط‌های آسفالتی را با استفاده از شبکه‌های عصبی مصنوعی انجام دادند و نتیجه گرفتند روش شبکه عصبی پیش بینی دقیق تری نسبت به دیگر روش‌های رگرسیونی دارد [۳۴].
- Sollazzo و همکارانش (۲۰۱۷) با استفاده از یک پایگاه داده بزرگ از برنامه عملکرد بلند مدت روسازی، یک شبکه عصبی مصنوعی را برای تخمین عملکرد ساختاری روسازی‌های آسفالتی از داده‌های زبری ایجاد کردند. چندین پارامتر ورودی قابل توجه، مربوط به ترافیک، آب و هوا و جنبه‌های ساختاری، در تجزیه و تحلیل گنجانده شد. نتایج نشان داد که شبکه

عصبی مدل مناسبی برای اثبات این رابطه است. شبکه عصبی همچنین نتایج بهتری در

مقایسه با رگرسیون خطی ارائه می‌دهد [۳۵].

• طاهرخانی و ابراهیمی مقدم (۱۳۹۱) با بکارگیری داده‌های آزمایشگاهی ایالت کانزاس آمریکا،

عمر خستگی مخلوط‌های آسفالتی را با استفاده از شبکه‌های عصبی پیش بینی کردند. عوامل

مؤثر بر عمر خستگی شامل کرنش کششی، سختی، کندروانی قیر، درصد قیر، درصد فضای

خالی و دانه بندی بودند. نتایج نشان داد که شبکه عصبی مدل مناسبی برای پیش بینی عمر

خستگی مخلوط‌های آسفالتی است. شبکه عصبی همچنین نتایج بهتری در مقایسه با

رگرسیون خطی ارائه می‌دهد [۷].

تمام این تحقیقات در راستای هدایت فعالیت‌های مهندسی به سمت بهینه سازی فعالیت‌های نگهداری

و بهسازی بوده و مهندسین را در راستای انتخاب بهترین استراتژی تخصیص منابع و فعالیت‌ها هدایت

می‌کند.

فصل ۳ : شبکه عصبی مصنوعی

۳-۱ مقدمه

فعالیت‌های آزمایشگاهی از آن رو که زمان بر و پرهزینه هستند محققان را واداشته است تا امکان پیش بینی نتایج آزمایش را بررسی کنند. شبکه‌های عصبی مصنوعی در بیشتر رشته‌های مهندسی، کاربرد قابل ملاحظه‌ای برای پیش‌بینی داشته‌اند. در این تحقیق به علت عدم وجود پایگاه داده جامع از داده‌های آزمایشگاهی مقالات معتبر برای مدل‌سازی استفاده می‌شود.


۳-۲ مدل بیولوژیکی شبکه‌های عصبی

در بدن انسان شبکه‌ای پیچیده از سلول‌های عصبی وجود دارد. سلول‌های عصبی، عصب یا نورون نیز نامیده می‌شوند. وظیفه این سلول‌ها این است که پیام ارسالی از سلول مجاور خود را به سلول بعدی انتقال دهند. این انتقال پیام آنقدر توسط سلول‌های عصبی ادامه می‌یابد تا به مغز انسان رسیده و در آنجا توسط مغز انسان مورد پردازش قرار می‌گیرد. مغز انسان نیز با توجه به پیام (سیگنال) دریافتی عکس‌العمل مناسب را نسبت به این پیام نشان می‌دهد. بعد از مدتی مغز انسان نسبت به پیام‌ها و تحریکات پیرامون خود دارای تجربیاتی می‌شود. به عبارت دیگر مغز پس از دریافت مجموعه‌ای از پیام‌های مشابه آن‌ها را در هر دسته طبقه‌بندی می‌کند و با توجه به تجربه قبلی به آن‌ها پاسخ مناسب می‌دهد [۳۶].

مغز انسان مجموعه‌ای از بیش از ۱۰ میلیارد نورون بهم پیوسته است. هر نورون یک سلول است که از واکنش‌های بیوشیمیایی برای دریافت، پردازش و انتقال اطلاعات استفاده می‌کند [۳۷].

۳-۳ ساختار نورون طبیعی

از نقطه نظر پردازش اطلاعات یک سلول عصبی یا نورون شامل چهار قسمت زیر با عملکردهای مجزا ولی مکمل هم است (شکل ۳-۱).



شکل ۱-۳. سلول عصبی (نورون) [۳۷]

۳-۳-۱ سیناپس ها (Synapses)

محل برخورد اکسون با دندریت، سیناپس نام دارد. سیناپس ها عناصر ذخیره کننده هستند و حافظه بلند مدت برای تجربیات جمع شده گذشته ایجاد می کنند و این مخزنی برای پایگاه دانش است. سیناپس از طریق تطبیق پیوسته وزنش با ورودی های جدید، یاد می گیرد. یک تک سلول عصبی بطور متوسط ۱۰۰۰۰ رابطه سیناپسی دارد [۳۸].

۳-۳-۲ بدنه سلول (Soma)

این سلول مسئول پردازش اطلاعاتی است که از دندریت ها دریافت می کند. [۱۷].

۳-۳-۳ دندریت ها (Dendrites)

هر نورون ممکن است یک یا چند دندریت داشته باشد. بیشتر علائم منتقل شده از سایر نورون ها بوسیله راهی از دندریت ها وارد بدنه سلول می شوند. دندریت ها یک رشته پرپشت ساختمانی هستند که از بدنه سلول سرچشمه می گیرند. روی دندریت ها اتصال های سیناپتیک است که معمولا علائم از دیگر اکسون ها به آن می رسند [۳۸].

۳-۳-۴ آکسون (Axon)

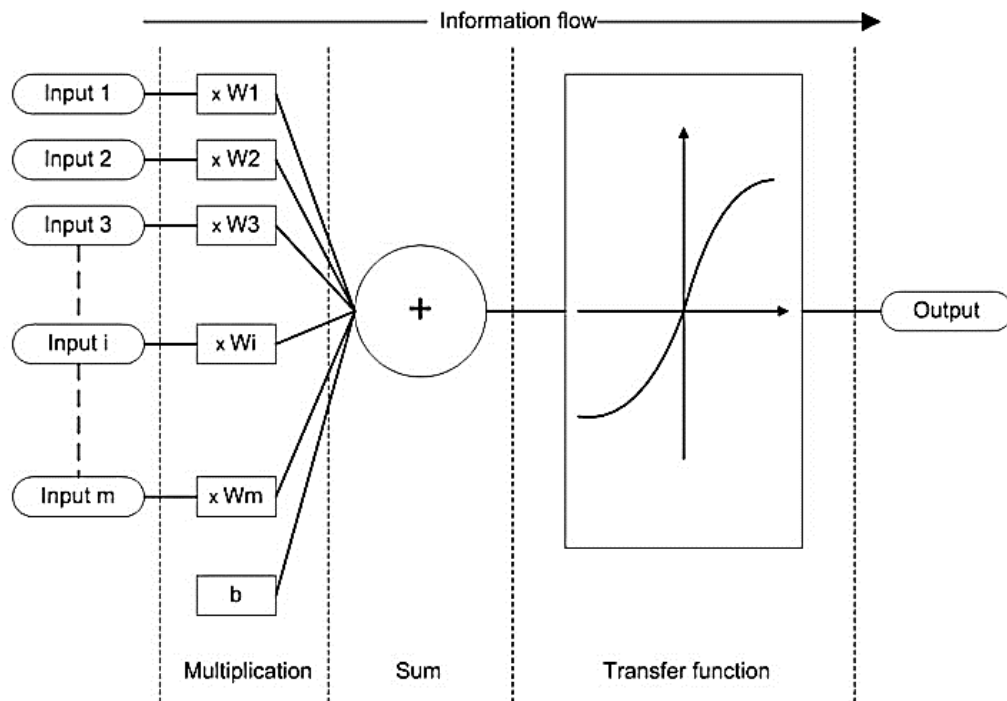
برای هر نورون فقط یک آکسون وجود دارد و این آکسون اطلاعات را به دیگر سلول‌ها انتقال می‌دهد [۳۸].

۳-۴ شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی با الهام از شبکه نورون‌های مغز انسان، سعی در توسعه پردازش اطلاعات دارد. فرآیند یادگیری شبکه عصبی درست مثل مغز انسان است. ما از زمان تولد، با دیدن مثال‌های مختلف از مسائلی که باید حل کنیم (حرکت، خوردن، ارتباط برقرار کردن و ...) به تدریج آموزش می‌بینیم و در نهایت به جایی می‌رسیم که در هر موقعیت متناسب با شرایط واکنش مناسبی را ارائه می‌دهیم. شبکه عصبی مصنوعی هم دقیقاً به همین شکل از ابتدای شکل‌گیری شروع به یادگیری می‌کند تا در نهایت بتواند واکنش درخوری را به یک موقعیت خاص بدهد. قابلیت چشم‌گیر این شبکه‌ها استفاده نامحدود از آن‌ها در ارائه جواب به اطلاعاتی است که پیش‌تر با آن‌ها مواجه نبوده‌اند [۷].

شبکه عصبی مصنوعی (ANN^1) یک مدل ریاضی است که سعی در شبیه‌سازی ساختار و عملکرد شبکه‌های عصبی بیولوژیکی دارد. بلوک اصلی ساخت هر شبکه عصبی مصنوعی، نورون مصنوعی است، یعنی یک مدل ریاضی (تابع) ساده. چنین مدلی سه قانون ساده دارد: ضرب، جمع و تابع فعال-سازی (شکل ۲-۳) [۳۹].


¹ Artificial neural network



شکل ۲-۳. مدل شبکه عصبی مصنوعی [۳۹]

۳-۵ ساختار نورون مصنوعی

نورون مصنوعی یک عنصر اساسی در ساخت هر شبکه عصبی مصنوعی است. طراحی و ویژگی‌های آن از مشاهده یک نورون بیولوژیکی حاصل می‌شود که عنصر اصلی ساختمان شبکه‌های عصبی بیولوژیکی است. شباهت‌های موجود در طراحی و ویژگی‌ها را می‌توان در شکل ۳-۳ مشاهده کرد. شکل الف، یک نورون مصنوعی را با ورودی‌ها، وزن‌ها، تابع انتقال، بایاس و خروجی‌های و شکل ب، یک نورون بیولوژیکی را با سوما، دندریت‌ها و آکسون نشان می‌دهد [۳۹].



شکل ۳-۳. شباهت‌های طراحی نورون طبیعی و مصنوعی [۳۹]

اطلاعات نورون بیولوژیکی از طریق دندریت به بدنه سلول (soma) منتقل شده، بدنه سلول اطلاعات را پردازش کرده و از طریق آکسون به دیگر سلول‌ها منتقل می‌کند. در نورون مصنوعی، اطلاعات از طریق ورودی‌هایی که وزن می‌شوند به بدنه یک نورون مصنوعی وارد می‌شود (هر ورودی به صورت جداگانه در یک وزن ضرب می‌شود). بدنه یک نورون مصنوعی ورودی‌های وزن شده و بایاس را با یکدیگر جمع کرده و وارد تابع انتقال می‌کند. در پایان اطلاعات پردازش شده را از طریق خروجی (ها) منتقل می‌کند. خروجی از طریق مدل زیر محاسبه می‌شود [۳۹]:

$$y(k) = F \left(\sum_{i=0}^m w_i(k) \cdot x_i(k) + b \right) \quad (3-1)$$

که در آن، $x_i(k)$ ورودی، $w_i(k)$ وزن، b بایاس، F تابع فعالساز و $y(k)$ خروجی است. همانطور که در معادله (۳-۱) مشاهده می‌شود، عمده‌ترین متغیر ناشناخته مدل، تابع انتقال آن است. تابع انتقال خصوصیات نورون مصنوعی را مشخص می‌کند و می‌تواند هر عملکرد ریاضی باشد [۳۹].

۳-۶ توابع انتقال (Transfer Functions)


توابع انتقال که بعضاً توابع تحریک (Activation Functions) نیز نامیده می‌شوند به منظور پردازش اطلاعات که حاصل جمع سلول‌های عصبی وزن دار و مقدار بایاس می‌باشد بکار می‌رود. توابع مختلفی برای پردازش اطلاعات ارائه شده‌اند. معروف‌ترین آن‌ها شامل تابع خطی ساده، تابع Hard-Limit، تابع سیگموید (tansig) و تابع لگاریتم سیگموید (logsig) می‌باشد [۳۶].

۳-۶-۱ تابع انتقال خطی (Linear Transfer Function)

یک تابع فعالساز خطی، هیچ تغییری روی ورودی ایجاد نمی‌کند (شکل ۳-۴). این تابع از دو طرف بی‌کران و یک رابطه خطی بین ورودی‌ها و خروجی‌ها برقرار است و خاصیت غیرخطی در نورون مصنوعی ایجاد نمی‌کند. رابطه این تابع به صورت زیر می‌باشد [۴۰]:

a=n

(۳-۲)




شکل ۳-۴. تابع انتقال خطی [۴۰]

۳-۶-۲ تابع پله ای (Hard-Limit)

تابع پله ای خروجی را به صورت دو سطحی نشان می‌دهد، اگر ورودی به یک آستانه مشخص رسیده باشه خروجی ۱ را نشان می‌دهد و در غیر این صورت (اگر منفی باشد) خروجی ۰ می‌شود (شکل ۵-۳).

(۳) رابطه این تابع به صورت زیر می‌باشد [۴۰]:

$$\begin{cases} a = 0 & n < 0 \\ a = 1 & n \geq 0 \end{cases} \quad (۳-۳)$$




شکل ۳-۵. تابع پله ای [۴۰]

۳-۶-۳ تابع لگاریتم سیگموئید (logsig)

این تابع غیرخطی، یکنواخت، پیوسته و مشتق پذیر است (شکل ۳-۶). معمولاً در مختصات لگاریتمی رسم می‌شود. این تابع برای استفاده در مسائل طبقه بندی کاربرد دارد و مقادیر ورودی بسیار کم یا بسیار زیاد را به بازه‌ی صفر تا یک تبدیل می‌کند. رابطه این تابع به صورت زیر می‌باشد [۴۰]:

$$a = \frac{1}{1 + e^{-n}} \quad (۳-۴)$$




$$a = \text{logsig}(n)$$

شکل ۳-۶. تابع لگاریتم سیگموئید [۴۰]

۳-۶-۴ تابع سیگموئید (tansig)

شکل این تابع همانند تابع logsig (به شکل S)، اما نسبت به مبدأ متقارن است (شکل ۳-۷). رابطه این تابع به صورت زیر می‌باشد [۴۰]:

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} = \tanh(n) \quad (۳-۵)$$



$$a = \text{tansig}(n)$$

شکل ۳-۷. تابع سیگموئید [۴۰]

۳-۷ انواع شبکه های عصبی مصنوعی


شبکه های عصبی انواع مختلفی دارند، که هر کدام برای کاربردهای متفاوتی مورد استفاده قرار می-گیرند. در همه شبکه های عصبی، یک ساختار ریاضی وجود دارد که توسط الگوریتم یادگیری (Training Algorithm) آنقدر تنظیم و بهینه می شود، تا پاسخ مناسبی ارائه دهد. در ادامه، مروری بر انواع مختلف شبکه های عصبی آمده است.

۳-۷-۱ شبکه عصبی پرسپترون

پرسپترون (Perceptron)، داده های ورودی را دریافت کرده و با اعمال کردن تابع فعال سازی، داده ها را به لایه خروجی منتقل می کند [۳۹].

۳-۷-۱-۱ شبکه عصبی پرسپترون تک لایه (Single Layer Neural Network) (Perceptron)

شبکه عصبی پرسپترون تک لایه، تعداد مشخصی داده ورودی را به عنوان ورودی دریافت می کند. در هر مرحله یکی از داده های ورودی وارد شبکه عصبی می شود. با داشتن مجموعه ای از وزن ها و مقدار بایاس (Bias)، خروجی که وارد تابع انتقال (Transfer Function) یا تابع فعال سازی (Activation Function) شده تولید می شود (شکل ۳-۸) [۳۹].



شکل ۸-۳. شبکه عصبی پرسپترون تک لایه


۲-۱-۷-۳ شبکه عصبی پرسپترون چندلایه (Multi-Layer Perceptron)

پرسپترون چند لایه یا MLP، ساده‌ترین مدل شبکه عصبی موجود است (شکل ۹-۳) که عملکردی مانند نحوه انتقال اطلاعات در مغز انسان دارد.

در یک شبکه عصبی پرسپترون چند لایه، حداقل سه لایه (Layer) وجود خواهند داشت:

- لایه ورودی (Input Layer)
- لایه پنهان (Hidden Layer)
- لایه خروجی (Output layer)


در این شبکه عصبی، خروجی‌های لایه ورودی، ورودی‌های لایه پنهان هستند و خروجی‌های آخرین لایه پنهان به عنوان ورودی‌های لایه خروجی در نظر گرفته می‌شوند. به لایه‌هایی که بین لایه ورودی و لایه خروجی قرار می‌گیرند، لایه‌های پنهان (Hidden Layers) گفته می‌شود. شبکه‌های چند لایه، دارای مجموعه‌ای از وزن‌ها و بایاس هستند که برای آموزش شبکه عصبی تنظیم می‌شوند [۳۹].



شکل ۹-۳. شبکه عصبی پرسپترون چندلایه

۲-۷-۳ شبکه عصبی شعاعی پایه (Radial Basis Networks)

شبکه‌های عصبی شعاعی پایه (RBF) دارای سه لایه (لایه‌ی ورودی، لایه‌ی پنهان با تابع فعال‌ساز گوسی و لایه‌ی خروجی) می‌باشند. این شبکه‌ها از تابع شعاعی پایه (Radial Basis Function)، به عنوان تابع فعال‌سازی استفاده می‌کنند. شکل ۱۰-۳، یک شبکه عصبی RBF را نشان می‌دهد [۳۹].




شکل ۱۰-۳. شبکه عصبی شعاعی پایه [۳۹]

شبکه‌های عصبی RBF و شبکه‌های MLP از نظر ساختاری تفاوت زیادی با یکدیگر ندارند و تنها نوع پردازشی که نورون‌ها روی ورودی‌هایشان انجام می‌دهند، متفاوت است. تابع انتقال شبکه عصبی RBF

طبق رابطه زیر است و در شکل ۱۱-۳ نشان داده شده است [۳۹]:

$$\text{radbas}(n) = e^{-n^2}$$




شکل ۳-۱۱. تابع انتقال شبکه عصبی شعاعی [۳۹]

شبکه‌های RBF سریع‌تر از شبکه‌های MLP آموزش داده می‌شوند و نیز محدوده‌های تصمیم‌گیری بهتری را ایجاد می‌کنند. با وجود اینکه، این شبکه‌ها نیازمند نورون‌های بیش‌تری نسبت به شبکه‌های MLP هستند، ولی می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های MLP، آن‌ها را آموزش داد. کاربرد شبکه‌های RBF در تقریب توابع، پیش‌بینی سری‌های زمانی و دسته‌بندی است.

۳-۷-۳ شبکه عصبی بازگشتی (Recurrent Neural Networks)

شبکه‌های عصبی بازگشتی (RNN) سلول‌های پنهانی دارند که به خودشان نیز متصل هستند. اولین نوع شبکه‌های عصبی RNN، شبکه‌ی Jordan Network نام دارد که در این نوع شبکه هر یک از لایه‌های پنهان خروجی خود را بیش از یک یا چندبار تکرار می‌کند (شکل ۳-۱۲) [۳۹].



شکل ۳-۱۲. شبکه عصبی جردن [۳۹]


این نوع از شبکه‌های عصبی اساساً هنگامی استفاده می‌شوند که تصمیم‌گیری‌ها از تکرارهای قبلی یا نمونه‌ها، می‌تواند نمونه‌های کنونی را تحت تاثیر قرار دهد. به عنوان مثالی متداول از این نوع، می‌توان به متن (Text) اشاره کرد. در متن، یک کلمه را می‌توان تنها در زمینه کلمه یا جمله پیشین تحلیل کرد.

هدف این شبکه‌ها پردازش داده‌های دنباله‌ای است. شبکه‌های عصبی بازگشتی دارای حافظه داخلی هستند که می‌توانند ورودی قبلیشان را به یاد داشته باشند و از این حافظه برای پردازش دنباله‌ای از ورودی‌ها استفاده کند. در این شبکه‌ها خروجی گره‌های پردازشی ذخیره می‌شود و نتیجه دوباره به مدل بازگردانده می‌شود. این نوع شبکه‌ها اطلاعات را تنها در یک جهت (از لایه ورودی به خروجی) عبور نمی‌دهند. هر گره در شبکه‌های RNN مانند یک سلول حافظه عمل می‌کند و محاسبه و اجرای عملیات را ادامه می‌دهد. اگر شبکه پیش‌بینی نادرستی انجام دهد، سیستم خود یادگیری (self-learn) انجام می‌دهد و به اصلاح پیش‌بینی خود در طول پس انتشار (backpropagation) ادامه می‌دهد. شبکه عصبی بازگشتی برای داده‌های سری زمانی (به عنوان مثال پیش‌بینی قیمت یک سهام در یک ماه خاص)، داده‌های متنی و داده‌های صوتی به کار می‌رود. دو نوع متداول تر شبکه‌های بازگشتی حافظه کوتاه مدت طولانی (long short term) یا LSTM و واحدهای بازگشتی دروازه‌ای (Gated Recurrent Units) یا GRU هستند [۳۹].

۱-۳-۷-۳ حافظه کوتاه/بلند مدت (Long/Short Term Memory)

حافظه کوتاه/بلند مدت (LSTM) نوع جدیدی از سلول حافظه (Memory Cell) را معرفی می‌کند. این سلول می‌تواند داده‌ها را هنگامی که دارای شکاف زمانی (یا تاخیر زمانی) هستند، پردازش کند. LSTM می‌تواند قاب‌های ویدئو را با به خاطر سپردن چیزی که در قاب‌های بسیار پیشین اتفاق افتاده است پردازش کند. شبکه‌های LSTM به طور گسترده‌ای برای بازشناسی گفتار (Speech Recognition) و بازشناسی نوشتار (Writing Recognition) مورد استفاده قرار می‌گیرند. سلول‌های

حافظه اساساً ترکیبی از یک جفت عنصر که به آن‌ها گیت گفته می‌شود هستند. این عناصر، بازگشتی هستند و چگونگی به یاد آوردن و فراموش کردن اطلاعات را کنترل می‌کنند. ساختار این نوع از شبکه‌ها، در شکل ۱۳-۳ مشخص است. این نکته که هیچ تابع فعال‌سازی بین بلوک‌ها وجود ندارد نیز شایان توجه است [۳۹].



شکل ۱۳-۳. حافظه کوتاه/بلند مدت [۳۹]

۲-۳-۷-۳ شبکه عصبی واحد بازگشتی گیتی (Gated Recurrent Unit)

واحد بازگشتی گیتی (GRU) نوعی از LSTM با گیت‌ها و دوره زمانی متفاوت است. این نوع از شبکه‌های عصبی بازگشتی در حال حاضر بیشتر در موتور متن به گفتار (Speech Synthesis) و ترکیب صدا (Music Synthesis) به کار می‌رود [۴۱].

۴-۷-۳ شبکه عصبی خود رمزگذار (Auto Encoder)

شبکه خود رمزگذار دارای لایه ورودی، لایه(ها)ی پنهان و لایه خروجی است. در ساده‌ترین حالت یک خود رمزگذار شامل یک encoder (رمزگذار) و decoder (رمزگشا) به همراه تنها یک لایه پنهان می‌باشد. ورودی به encoder داده شده و خروجی از decoder استخراج می‌شود. در این نوع شبکه به جای آموزش شبکه و پیش‌بینی مقدار تابع هدف در ازای ورودی X ، خود رمزگذار آموزش می‌بیند که ورودی خود را بازسازی کند؛ بنابراین بردار خروجی همان ابعاد بردار ورودی X را خواهد داشت؛ یعنی

تعداد نورون‌های موجود در لایه ورودی و خروجی با یکدیگر برابر است. همانطور که گفته شد در این شبکه خروجی بازسازی ورودی بوده و برای آموزش شبکه از الگوریتم پس انتشار خطا استفاده شده است. خود رمزگذارها با حداقل کردن خطای بازسازی شبکه را آموزش می‌دهند. معمولاً تعداد نورون‌های موجود در لایه پنهان کمتر از لایه encoder/decoder می‌باشد. لایه پنهان یا کد در حقیقت representation یا نمایش داده در فضای بعد کاهش یافته آن می‌باشد و عملاً متناظر با ویژگی‌های استخراج شده است. پس از آموزش شبکه بخش decoder حذف شده و خروجی میانی‌ترین لایه پنهان به عنوان ویژگی‌های استخراج شده در نظر گرفته می‌شود. به منظور کاهش بیشتر ابعاد می‌بایست از تعداد لایه‌های پنهان بیشتری در شبکه استفاده کرد که در اصطلاح خود رمزگذار عمیق نامیده می‌شود [۳۹].

شبکه‌های عصبی خود رمزگذار (AE) برای دسته‌بندی، خوشه‌بندی (Clustering) و فشرده‌سازی ویژگی‌ها (Feature Compression) استفاده می‌شوند. با توجه به ساختار این شبکه‌ها (که در آن تعداد لایه‌های پنهان کوچک‌تر از تعداد سلول‌های ورودی است و تعداد سلول‌های خروجی برابر با سلول‌های ورودی است) و اینکه AE به نوعی آموزش داده می‌شود که خروجی تا حد امکان به ورودی نزدیک باشد، شبکه عصبی خود رمزگذار مجبور می‌شود داده‌ها را تعمیم دهد و به دنبال الگوهای متداول بگردد [۳۹].

۳-۷-۵ شبکه عصبی هاپفیلد (Hopfield Networks)

شبکه‌های هاپفیلد (HN) روی مجموعه محدودی از نمونه‌ها آموزش دیده‌اند و بنابراین، به یک نمونه شناخته شده با نمونه مشابهی پاسخ می‌دهند. پیش از آموزش، هر سلول به عنوان یک سلول ورودی، در طول آموزش به عنوان یک سلول پنهان و در هنگام استفاده، به عنوان یک سلول خروجی کار می‌کند. این شبکه‌ها برای بازگردانی ورودی‌ها مورد استفاده قرار می‌گیرند. در صورتی که به این شبکه‌ها نیمی از یک تصویر یا توالی یاد گرفته شده ارائه شود، نمونه کامل را باز می‌گردانند [۳۹].

شبکه عصبی هاپفیلد، یکی از قدیمی‌ترین انواع شبکه‌های عصبی است که با ساختار بازگشتی خود، فیدبک‌های داخلی ایجاد می‌کند. هاپفیلد عملکردی شبیه به یک سیستم حرکتی با دو یا چند نقطه تعادل دارد. الگوریتم این شبکه به این صورت است که با شروع از هر وضعیت به یکی از نقاط تعادل خود همگرا می‌شود. از شبکه عصبی هاپفیلد می‌توان به عنوان یک راه حل برای مسائل طبقه‌بندی شده استفاده کرد.[۳۹].

۳-۷-۶ ماشین بولتزمن (Boltzmann Machines)

ماشین‌های بولتزمن (BM) از این جهت که برخی از سلول‌ها به عنوان ورودی علامت‌گذاری می‌شوند و پنهان باقی می‌مانند، شباهت زیادی به شبکه‌های هاپفیلد دارند. سلول‌های ورودی به محض اینکه سلول‌های پنهان حالت خود را بروزرسانی می‌کنند، به سلول‌های خروجی مبدل می‌شوند (در طول آموزش، ماشین بولتزمن/ شبکه هاپفیلد، سلول‌ها را یکی یکی بروزرسانی می‌کند و این کار به صورت موازی انجام نمی‌شود)[۴۲].

۳-۷-۷ شبکه باور عمیق (Deep Belief Network)

شبکه باور عمیق (DBN) از ماشین‌های بولتزمن استفاده می‌کنند که به صورت زنجیر وار پشت هم قرار می‌گیرند و با یک الگوی خاص به تولید داده‌ها می‌پردازند. بیشترین کاربردها شامل: تشخیص نوع موسیقی، بازشناسی گفتار، نظارت ویدئویی هوشمند و بازشناسی تصویر[۴۳].

۳-۷-۸ شبکه پیچشی عمیق (Deep Convolutional Network)

شبکه پیچشی عمیق (DCN) سلول‌های پیچشی (لایه‌های پولینگ) و کرنل‌هایی دارند که هر یک، کار متفاوتی انجام می‌دهند. ورودی‌ها توسط کرنل‌های پیچشی پردازش می‌شوند و لایه‌های پولینگ

(گردآوری) این کار را با کاهش ویژگی‌های غیرلازم، با استفاده از توابع غیرخطی، ساده‌تر می‌کنند [۳۹].

شبکه‌های عصبی پیچشی عمیق معمولاً برای بازشناسی تصویر (Image Recognition) مورد استفاده قرار می‌گیرند؛ این شبکه‌ها، روی یک زیرمجموعه از تصاویر (چیزی در حدود 20×20) عمل می‌کنند. پنجره ورودی، روی کل تصویر به صورت کرکره‌ای، پیکسل به پیکسل، عبور می‌کند. داده‌ها به لایه‌های پیچشی پاس داده می‌شوند و این امر موجب می‌شود که یک کیف شکل بگیرد (فشرده‌سازی ویژگی‌های ورودی). در حوزه بازشناسی تصویر، اولین لایه گرادیان، دومین لایه خطوط و سومین لایه شکل را شناسایی می‌کند [۳۹].

۳-۷-۹ شبکه دکانولوشنی (Deconvolution Network)

شبکه دکانولوشنی (DN)، معکوس DCN است. شبکه دکانولوشنی تصویر را دریافت و برداری مانند $\{dog:0,lizard:0,horse:0,cat:1\}$ می‌سازد. شبکه پیچشی عمیق می‌تواند این بردار را دریافت کند و بر اساس آن، تصویر را بکشد [۳۹].

۳-۷-۱۰ شبکه عصبی کوهنن (Kohonen Network)

شبکه عصبی کوهنن (KN)، ویژگی فاصله تا سلول را معرفی می‌کند. در واقع کارکرد اصلی این نوع شبکه، یافتن شباهت‌ها در بین تعداد زیادی از داده‌ها است که به عنوان ورودی به شبکه معرفی شده‌اند. همانند کاری که مغز انسان انجام می‌دهد و تعداد زیادی از ورودی‌های حسی و حرکتی را در گروه‌های مشابه طبقه‌بندی کرده است. این نوع از شبکه‌ها معمولاً همیشه به عنوان شبکه‌های عصبی واقعی به حساب نمی‌آیند. یادگیری این شبکه به صورت بدون ناظر (unsupervised) صورت می‌گیرد. این شبکه برای دسته‌بندی ورودی‌ها به صورت خودکار استفاده می‌شود. حاصل این شبکه معمولاً یک نمایش گسسته از اطلاعات (map) است که معمولاً ابعادی کوچک‌تر از ابعاد ورودی دارد [۳۹].

۱۱-۷-۳ ماشین بردار پشتیبان (Support Vector Machine)

ماشین بردار پشتیبان (SVM) وظیفه دسته‌بندی یا Classification در داده‌های دودویی را دارد. ورودی این شبکه همیشه بله یا خیر است. ماشین‌های بردار پشتیبان، در بیشتر مواقع به عنوان شبکه‌های عصبی در نظر گرفته نمی‌شوند [۳۹].

در شبکه‌های عصبی MLP و RBF، هدف این است که خطای پیش‌بینی شبکه عصبی کاهش یابد، ولی SVM، کاهش ریسک عملیاتی مربوط به عدم عملکرد صحیح را در نظر می‌گیرد. ساختار شبکه SVM، مشابه شبکه عصبی MLP است و تفاوت اصلی، در نحوه یادگیری شبکه می‌باشد [۳۹].

۱۲-۷-۳ یادگیرنده رقمی ساز بردار (Learning Vector Quantization)

این نوع شبکه عصبی، برای حل مسائل یادگیری نظارت شده استفاده می‌شود. کاربرد مهم LVQ در سیستم‌های هوشمند برای حل مسائل طبقه‌بندی است [۳۹].

۸-۳ الگوریتم‌های آموزش شبکه عصبی مصنوعی چندلایه

برای آموزش شبکه‌های MLP الگوریتم‌های مختلفی وجود دارند که عبارتند از: الگوریتم‌های پس انتشار لونبرگ-مارکواردت^۱، کواسی-نیوتن، پس انتشار اصلاح شده، ژنتیک، ازدحام ذرات و ... ارائه کرده‌اند. در این مطالعه از دو الگوریتم پس انتشار لونبرگ-مارکواردت و ازدحام ذرات استفاده شد، که به معرفی هر یک می‌پردازیم.

۱-۸-۳ الگوریتم پس انتشار لونبرگ-مارکواردت

در مسائلی که تقریب توابع مد نظر است، ثابت شده است که این الگوریتم بهترین عملکرد را دارد [۷]. این الگوریتم برای شبکه‌هایی که دارای تعداد زیادی بردار وزن هستند، سرعت همگرایی بالایی دارد.

¹ Levenberg-Marquardt

در بیشتر شرایط، الگوریتم لونیبرگ-مارکواردت آموزش دقیقی برای شبکه ارائه می‌دهد و قادر به دستیابی MSE کمتر نسبت به دیگر روش‌ها است. [۷].

۲-۸-۳ الگوریتم ازدحام ذرات (PSO)

این الگوریتم، یک الگوریتم بهینه‌سازی مبتنی بر ازدحام است که از رفتار دسته‌جمعی گروه‌هایی از حیوانات مانند پرندگان ساخته شده است [۴۴]. Kennedy و Eberhart در سال ۱۹۹۵ یک تکنیک بهینه‌سازی جهانی، PSO (بهینه‌سازی ازدحام ذرات) را توسعه دادند که یک روش بهینه‌سازی تصادفی گروهی برای توابع غیرخطی پیوسته است [۴۵]. این روش به علت بازدهی بالا در حل مسائل بهینه‌سازی پیچیده، هزینه‌بر و بعضاً غیرممکن، از شهرت بسزایی برخوردار است.

در الگوریتم PSO، ذرات در فضای جستجو جاری می‌شوند. تغییر مکان ذرات در فضای جستجو تحت تأثیر تجربه و دانش خودشان و دیگر ذرات است؛ بنابراین موقعیت دیگر ذرات روی چگونگی جستجوی یک ذره اثر می‌گذارد. نتیجه مدل‌سازی این رفتار اجتماعی فرایند جستجویی است که ذرات به سمت نواحی موفق میل می‌کنند. ذرات از یکدیگر می‌آموزند و بر مبنای دانش بدست آمده به سمت موقعیت ذرات برتر می‌روند.

روش کار این الگوریتم بدین صورت است که ابتدا تعدادی ذره با موقعیت و سرعت تصادفی ایجاد شده، سپس در هر تکرار، ذرات بر حسب بهترین موقعیت گذشته خود و ذرات دیگر حرکت به سوی هدف را اصلاح می‌کنند. پس از تکرارهای متوالی، مسئله به جواب بهینه همگرا می‌شود. اصلاح سرعت و موقعیت هر ذره به ترتیب به وسیله روابط ۴-۴ و ۴-۵ انجام می‌شود [۴۶]:

$$V_i(t+1) = wV_i(t) + C_1r_1(pbest_i(t) - X_i(t)) + C_2r_2(gbest_i(t) - X_i(t)) \quad (3-7)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (3-8)$$

که در آن، gbest بهترین موقعیت ذرات، pbest بهترین موقعیت ذره که تا به حال آن را تجربه کرده است، t تعداد تکرار، w ضریب اینرسی بوده که در بازه [0,1] تعریف می‌شود، r تابع رندوم که اعداد

تصادفی در بازه $[0,1]$ تولید می‌کند. ضرایب $C1$ و $C2$ به ترتیب ضریب آموزش شخصی و ضریب آموزش جمعی بوده و مقدار این دو ضریب در بازه $[0,2]$ تعیین می‌شود.

۳-۹ مزایا و معایب شبکه های عصبی

۳-۹-۱ مزایا

- شبکه‌های عصبی قادر به حل مسائلی هستند که شبیه سازی آن‌ها از طریق منطقی و تکنولوژی‌های استاندارد نرم افزاری مشکل است [۳۸].
- توانایی پردازش موازی دارند و می‌توانند چندین کار را به طور موازی انجام دهند بدون اینکه بر عملکرد سیستم تأثیر بگذارد [۴۷].
- شبکه‌های عصبی توانایی یادگیری و مدل سازی روابط غیرخطی و پیچیده را دارند، که واقعاً مهم است زیرا در زندگی واقعی، بسیاری از روابط بین ورودی و خروجی غیر خطی و همچنین پیچیده است [۴۷].
- شبکه‌های عصبی این توانایی را دارند، هنگامی که داده‌ها به صورت ناقص دریافت شده باشند پاسخ مناسبی ارائه دهند [۴۷].
- توانایی تعمیم پذیری و تطبیق پذیری دارند و قادر هستند برای داده‌هایی که در مدلسازی بکار گرفته نشده‌اند، خروجی قابل قبولی ارائه دهند [۷].

۳-۹-۲ معایب

- شبکه های عصبی بیش از هر الگوریتم یادگیری ماشین سنتی به داده های بسیار بیشتری نیاز دارند.
- قانون مشخصی برای تعیین ساختار مناسب شبکه عصبی وجود ندارد. ساختار مناسب شبکه با تجربه و آزمایش و خطا حاصل می‌شود.

- مشکل دیگر شبکه‌های عصبی، آموزش بیش از حد است، که می‌تواند توان تعمیم‌پذیری شبکه را کاهش دهد [۷].

۱۰-۳ سنجش میزان یادگیری و عملکرد شبکه عصبی

منظور از میزان یادگیری شبکه عصبی این است که تا چه مقدار می‌تواند پس از آموزش شبکه به داده‌های جدید که در طی مدلسازی بکار گرفته نشدند، پاسخ مناسبی بدهد. برای اینکه میزان یادگیری شبکه سنجیده شود، از فاکتورهای مختلفی استفاده می‌شود که چند مورد از این روش‌ها در زیر توضیح داده شده است:

۱۰-۳-۱ میانگین مربع خطاها و ریشه میانگین مربعات خطا

میانگین مربع خطاها (MSE^1) در یک شبکه، اختلاف میانگین مربع بین مقادیر برآورد شده و مقدار واقعی است [۴۹]. MSE اندازه‌گیری کیفیت یک برآوردگر است که همیشه غیر منفی و هرچه به صفر نزدیکتر باشد بهتر است. میانگین مربعات خطا در الگوریتم‌های پس انتشار خطا به عنوان تابع معیار و وزن‌های شبکه به عنوان متغیر تابع در نظر گرفته می‌شوند. هرچه مقدار MSE کمتر باشد، باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد؛ اما نمی‌توان گفت برای داده‌هایی که در طول مدلسازی بکار گرفته نشدند نیز خروجی دقیقی ارائه دهد. اگر مقدار MSE بیش از حد پایین باشد، ممکن است شبکه اطلاعات موجود در دسته آموزش را حفظ کرده باشد و قابلیت تعمیم به داده‌های جدید را نداشته باشد. به همین علت با پایین بودن مقدار MSE ، نمی‌توان قاطعانه گفت که میزان یادگیری و عملکرد شبکه مناسب است. بنابراین، در یک شبکه عصبی مقدار MSE بین خروجی‌های هدف و پیش‌بینی شده توسط شبکه عصبی، از دسته آموزش و آزمایش، با هم می‌-

¹ Mean Square Error

توانند به عنوان معیاری برای سنجش میزان یادگیری و عملکرد شبکه مورد بررسی قرار گیرند [۷].

مقدار MSE مطابق رابطه زیر است [۴۹]:

$$MSE = \frac{\sum_{i=0}^n (Y_i - \hat{Y}_i)^2}{n} \quad (3-9)$$

که در آن Y_i خروجی مطلوب برای مثال i ام از دسته آزمایش، \hat{Y}_i خروجی شبکه برای مثال i ام از دسته آزمایش و n تعداد مثال‌های موجود در دسته آموزشی یا آزمایش است.

ریشه میانگین مربعات خطا (RMSE) معیاری است که اغلب از تفاوت بین مقادیر مطلوب و مقادیر مشاهده شده استفاده می‌شود و از رابطه ۳-۸ بدست می‌آید [۴۹]. همیشه غیر منفی است و مقدار ۰ (تقریباً هرگز در عمل به دست نیامده است) نشان دهنده تناسب کامل با داده‌ها است. باید به این نکته توجه داشت که مقایسه بین انواع مختلف داده نامعتبر است زیرا اندازه‌گیری به مقیاس اعداد استفاده شده بستگی دارد.

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (3-10)$$

۳-۱۰-۲ ضریب همبستگی خطی

ضریب همبستگی ارتباط بین دو متغیر را نشان می‌دهد. سنجش این همبستگی با استفاده از ضریبی به نام ضریب همبستگی خطی (R) انجام می‌شود. ضریب همبستگی نمونه (R) اندازه‌گیری نزدیکی ارتباط نقاط در یک نمودار پراکندگی به یک خط رگرسیون خطی بر اساس آن نقاط است. مقدار ضریب همبستگی مطابق رابطه زیر است [۵۰]:

$$R = \frac{\sum (D_i - \bar{D})(Y_i - \bar{Y})}{\left[\sum (D_i - \bar{D})^2 \sum (Y_i - \bar{Y})^2 \right]^{0.5}} \quad (3-11)$$

که در آن D_i خروجی هدف برای داده i ام از دسته آزمایش، Y_i خروجی پیش‌بینی شده توسط شبکه برای داده i ام از دسته آزمایش، \bar{D}, \bar{Y} به ترتیب میانگین خروجی‌های پیش‌بینی شده توسط شبکه و خروجی‌های هدف و R ضریب همبستگی خطی است.

مقدار R بین -1 تا $+1$ تغییر می‌کند. اگر مقدار برابر با 1 باشد، به معنای همبستگی مثبت کامل، 0 به معنای عدم همبستگی و -1 به معنی همبستگی منفی کامل است. استفاده از این ضریب در شبکه عصبی بین خروجی‌های پیش‌بینی شده توسط شبکه و خروجی هدف از دسته آزمایش می‌تواند به عنوان معیاری برای سنجش میزان یادگیری و عملکرد شبکه باشد. هر چه این مقدار به 1 یا -1 نزدیکتر باشد، میزان یادگیری و عملکرد شبکه بهتر است [۷].

فصل ۴: مدلسازی و تحلیل نتایج

۴-۱ مقدمه

در این مطالعه پیش بینی شاخص خود ترمیمی با استفاده از شبکه‌های عصبی مصنوعی براساس داده‌های برداشت شده از مقالات معتبر آزمایشگاهی انجام شد. در مجموع از ۱۰ مقاله در زمینه خود ترمیمی مخلوط‌های آسفالتی برای برداشت داده‌ها استفاده شد. داده‌های برداشت شده شامل ابعاد نمونه (نمونه‌هایی به قطر ۱۰۰ میلی‌متر و ضخامت‌های ۶۰، ۳۰ و ۲۵ میلی‌متر)، روش تراکم نمونه (دو نوع روش تراکم ژیراتوری و مارشال)، دانه‌بندی مخلوط آسفالتی (درصد عبوری از الک‌های ۱۲.۵، ۴.۷۵ و ۰.۰۷۵ میلی‌متر)، درصد افزودنی‌ها (الیاف فولادی، براده آهن، RAP و سرباره فولاد)، نوع قیر (قیر با درجه نفوذ ۶۰/۷۰ و ۸۰/۱۰۰)، چرخه ترمیم ترک، نوع گرمایش (گرمایش القایی و میکروویو) و زمان گرمایش بودند. در مجموع ۷۱۵ داده برای هر ورودی برداشت شد. علت انتخاب افزودنی‌هایی مانند الیاف فولادی، براده آهن، RAP و سرباره فولاد این بود که این مواد ضایعات صنعت‌های مختلف می‌باشند و برای ارتقاء توسعه پایدار، قابل بازیافت هستند و می‌توان از آن‌ها در ساخت مخلوط‌های آسفالتی استفاده کرد [۱۳]. همچنین به علت استفاده زیاد از این مواد در تحقیقات محققین در زمینه خود ترمیمی مخلوط‌های آسفالتی، داده‌های بیشتری در دسترس بود.

۴-۲ داده‌ها

مدل شبکه عصبی با استفاده از پارامترهایی که بر شاخص خود ترمیمی تأثیر دارند، ایجاد می‌شود. جدول ۴-۱، ورودی‌ها و خروجی شبکه و دامنه تغییرات آن‌ها را نشان می‌دهد. برای ساخت مدل از داده‌های آزمایشگاهی در مقالات معتبر مطالعه شده در زمینه خود ترمیمی مخلوط‌های آسفالتی استفاده شد.

جدول ۱-۴. ورودی ها و خروجی شبکه عصبی و دامنه تغییرات آن ها

ورودی های شبکه	دامنه تغییرات	خروجی شبکه	دامنه تغییرات
ابعاد نمونه ^۱	۱-۳		
روش تراکم نمونه ^۲	۱-۲		
درصد عبوری از الک ۱۲.۵ میلیمتر	۷۶-۹۸ (%)		
درصد عبوری از الک ۴.۷۵ میلیمتر	۳۷-۶۰ (%)		
درصد عبوری از الک ۰.۰۷۵ میلیمتر	۳-۶.۶ (%)		
درصد براده آهن	۰-۸ (%)	شاخص ترمیم	۴-۹۸ (%)
درصد RAP	۰-۳۰ (%)		
درصد سرباره فولاد ^۳	۰-۱۰۰ (%)		
درصد الیاف	۰-۸ (%)		
نوع قیر ^۴	۱-۲		
چرخه ترمیم ترک	۱-۱۰		
نوع گرمایش ^۵	۱-۲		
زمان گرمایش (S)	۱۰-۱۲۰ (S)		

۳-۴ تجزیه و تحلیل آماری داده ها

آمار علم جمع آوری، اکتشاف، مرتب سازی، کدبندی و تجزیه و تحلیل و تفسیر داده ها است که بر اساس آن می توان به ارزیابی منطقی و استنباط نتایج رسید. از تجزیه و تحلیل آماری برای کشف الگوها و روند موجود در اطلاعات می توان استفاده نمود. در واقع تحلیل آماری باعث می گردد که بتوان بصورت علمی در مورد پدیده ها، رویدادها و یا تحقیقات تصمیم گیری نمود. اگر تعداد داده ها زیاد باشد،

^۱ S-100d-60t =1

S-100d-30t=2

S-100d-25t=3

^۲ Gyatory=1

Marshall=2

^۳ سرباره جایگزین بخش درشت دانه (۴.۷۵-۹.۵ میلیمتر) مخلوط شده است.

^۴ 60/70=1

80/100=2

^۵ Induction=1

Microwave=2

استفاده از روش‌های تجزیه و تحلیل آماری زمان‌بر و مشکل است، به همین دلیل نرم افزارهای آماری مختلفی وجود دارند که تجزیه و تحلیل داده‌ها را به سرعت انجام می‌دهند. برخی از مهم‌ترین این نرم افزارها عبارتند از:

- SAS
- S-PLUSE
- MINITAB
- SPSS

در این مطالعه از نرم افزار SPSS استفاده خواهد شد. SPSS برای تجزیه و تحلیل آماری، خصوصاً تحلیل نتایج پرسشنامه‌های تحقیقات میدانی، آزمون فرضیات تحقیق و پایان نامه‌ها استفاده می‌شود.

۴-۳-۱ رگرسیون چندگانه در SPSS

رگرسیون یا به اصطلاح معادله خط برگشت (Regression Line Equation) یک تکنیک آماری است که در بسیاری از حوزه‌های علمی، بخصوص یادگیری ماشین (Machine Learning) و داده‌کاوی (Data Mining) کاربرد دارد. همانطور که از نام این تکنیک مشخص است، به دنبال ساخت مدلی هستیم که به واسطه معادله یک خط نوشته می‌شود و قرار است به کمک داده‌های موجود، ضریب زاویه و همچنین عرض از مبدا چنین خطی را محاسبه کنیم. این خط می‌تواند بیانگر رابطه خطی بین متغیرهای وابسته (Dependent Variable) و متغیرهای مستقل (Independent Variable) باشد. از آنجا که محاسبات برای اجرای رگرسیون خطی، زمان‌بر و طولانی است و باید دقیق باشد، در اغلب موارد از نرم‌افزارهای محاسبات آماری مانند SPSS برای انجام این کار استفاده می‌کنند.

ساده‌ترین مدل رگرسیونی، رگرسیون خطی است که شامل دو نوع خطی ساده و خطی چندگانه می‌باشد. در مدل رگرسیون خطی ساده (Simple Linear Regression) فقط یک متغیر پیش‌بینی -کننده و در مدل رگرسیون خطی چندگانه (Multiple Linear Regression) بیش از یک متغیر

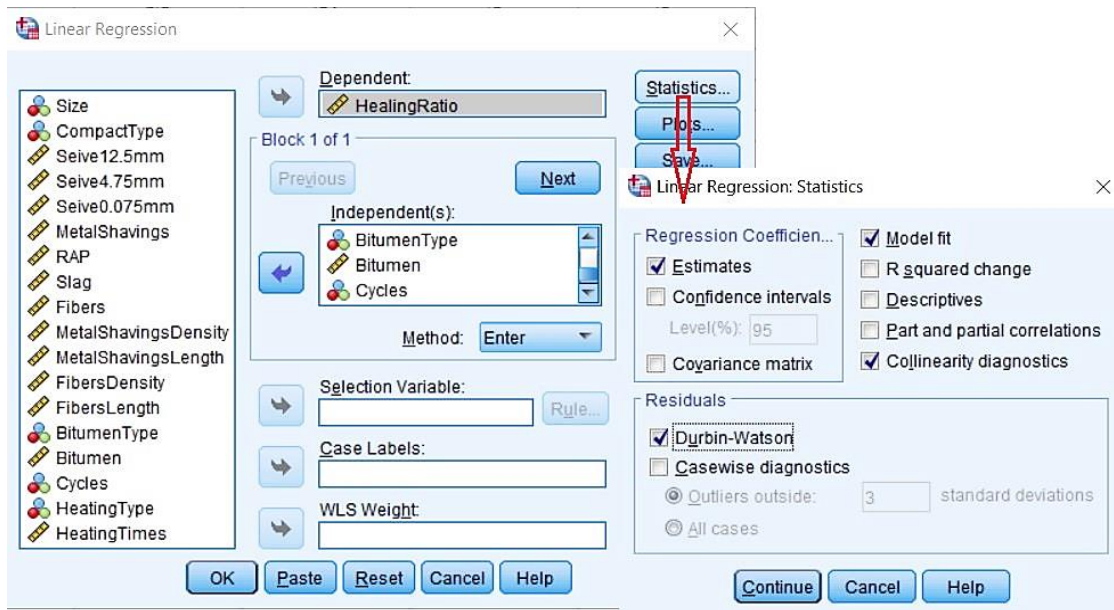
پیش‌بینی‌کننده وجود دارد. در رگرسیون خطی چندگانه به دنبال پیش‌بینی تغییرات بیش از یک متغیر مستقل بر روی یک متغیر وابسته هستیم. به طور کلی برای برآورد پارامترهای مدل رگرسیون خطی چندگانه باید از روش ماتریسی استفاده نمود که این روش‌ها را معمولاً با نرم‌افزار انجام داده و پارامترها را برآورد می‌کنند.

در روش رگرسیون خطی چندگانه (Multiple Linear Regression) پیش‌بینی بیش از یک متغیر مستقل بر روی یک متغیر وابسته انجام می‌گیرد. رابطه خطی بین متغیرهای مستقل (Independent Variable) و متغیر وابسته (Dependent Variable) به صورت زیر است:

$$y=B_0+B_1x_1+\dots+B_nx_n+e \quad (4-1)$$

که در آن، x_1 تا x_n متغیرهای مستقل، y متغیر وابسته، B_1 تا B_n ضرایب مدل رگرسیونی، B_0 مقدار ثابت و e جمله خطای مدل رگرسیونی است.

به منظور تحلیل رگرسیون چندگانه در SPSS از فهرست Analysis گزینه Regression و دستور Linear را اجرا می‌کنیم. متغیر Healing Ratio را در کادر dependent و بقیه متغیرها را در کادر Independents وارد می‌کنیم. برای انجام محاسبات و نمایش نتایج مربوط به برآورد ضرایب (Estimates) و مدل برازش شده (Model fit) در این مدل با فشردن دکمه statistics گزینه‌ها را مطابق با شکل ۴-۱ انتخاب می‌کنیم. بررسی مربوط به وجود رابطه خطی بین متغیرهای مستقل که به همخطی معروف است به کمک انتخاب گزینه Colinearity diagnostics میسر می‌شود. از آنجاییکه یکی از شرط‌های مهم در برآورد پارامترهای رگرسیون خطی به روش OLS یا رگرسیونی کمترین مربعات (Ordinary Least Square)، نرمال بودن باقی‌مانده‌ها است. در اینجا برای آزمون تصادفی و استقلال باقی‌مانده‌ها از آزمون Durbin-Watson استفاده کرده‌ایم.



شکل ۱-۴. رگرسیون چندگانه در SPSS

۱-۳-۴ تفسیر خروجی ها

- در ابتدا جدولی با نام Variables Entered/Removed مدل را معرفی کرده است (شکل ۲-۴). همان طور که در شکل ۲-۴ مشخص است، متغیرهای مستقل و وابسته معرفی شده‌اند.

Variables Entered/Removed^a

Model	Variables Entered	Variables Removed	Method
1	heating time (s), Cycles, عبوری از الک 12.5 , coarse steel slag, metal shavings content, RAP content, steel fibers content, ابعاد نمونه, bitumen type, عبوری از الک 0.075, heating type, عبوری از الک 4.75 , روغن تراکم نمونه ^b	.	Enter

a. Dependent Variable: healing ratio

b. All requested variables entered.

شکل ۲-۴. متغیرهای موجود در مدل

همانطور که در پایین جدول مشاهده می‌شود، متغیر شاخص ترمیم (Healing Ratio) متغیر وابسته است.

ستون اول جدول، شماره مدل را مشخص کرده است. از آنجایی که همه متغیرها در مدل لحاظ شده‌اند، فقط یک مدل ایجاد کرده است.

ستون دوم مربوط به متغیرهای مستقل مورد استفاده در مدل است.

ستون سوم، مربوط به متغیرهای خارج شده در مدل است. این مورد زمانی که از رگرسیون سلسله مراتبی یا گام به گام استفاده شده باشد، معنی خواهد داشت.

ستون چهارم به مشخص کردن نحوه ورود متغیرها در مدل رگرسیون پرداخته است. از آنجایی که شیوه ورود متغیرها به صورت استفاده از گزینه ورود همه متغیرها در تعریف مدل انتخاب شده، همه متغیرها در مدل نقش داشته، در نتیجه گزینه Enter در این ستون دیده می‌شود.

- تفسیر نتایج رگرسیون در SPSS توسط جدولی که به Model Summary معروف است، صورت می‌گیرد که ویژگی مربوط به برازش مدل رگرسیونی را نشان می‌دهد (شکل ۳-۴).

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	.721 ^a	.520	.511	.122295	1.222

a. Predictors: (Constant), heating time(s), Cycles, 12.5 عبوری از الک coarse steel slag, metal shavings content, RAP content, steel fibers content, bitumen type, 0.075 عبوری از الک روتن تراکم نمونه عبوری از الک 4.75

b. Dependent Variable: healing ratio

شکل ۳-۴. خلاصه برازش مدل

ستونی که با حرف R مشخص شده، مقدار ضریب همبستگی پیرسون (Pearson Coefficient of Correlation) را نشان می‌دهد. این ضریب، نشانگر همبستگی خطی بین متغیرهای وابسته و مقدار پیش‌بینی شده توسط مدل است. هر چه این ضریب به ۱ (یا -۱) نزدیکتر باشد، مدل توانسته سهم

بیشتری از تغییرات متغیر وابسته را نشان دهد. البته مقدار نزدیک به ۱ برای ما مقدار مطلوب تلقی می‌شود. اگر مقدار ضریب همبستگی به ۱- برسد، به این معناست که رابطه بین متغیر وابسته و مقدار پیش‌بینی شده توسط مدل، معکوس است که این امر بسیار به ندرت پیش می‌آید. در جدول بالا این مقدار برابر ۰.۷۲۱ است که قابل قبول است.

ستون دوم، R Square یا ضریب تعیین (Coefficient of Determination) را نشان می‌دهد که همان مربع ضریب همبستگی است. مقدارهای نزدیک به یک، برازش بهتر و همچنین سهم بیشتر در بیان تغییرات متغیر وابسته را توسط مدل کمترین مربعات خطا (OLS) نشان می‌دهند. یعنی ۵۲٪ تغییرات (پراکندگی) که برای متغیر وابسته (شاخص ترمیم) در نظر داریم توسط مدل رگرسیونی پوشش داده می‌شود، به عبارتی می‌توان گفت در ۵۲٪ مواقع پیش‌بینی نزدیک به واقعیت انجام شده است.

ستون سوم، Adjusted R Square یا ضریب تعیین اصلاح یا تعدیل شده است. این ضریب پیش‌بینی می‌کند اگر نمونه‌های دیگری نیز گرفته شود، ضریب تعیین اصلاح شده، ۵۱.۱٪ خواهد بود.

ستون چهارم، خطای استاندارد برآورد (Std. Error of the Estimate) که به آن میانگین ریشه مربع خطا نیز می‌گویند را نشان می‌دهد. در حقیقت این مقدار، انحراف معیار اصطلاح خطا است و ریشه مربعات باقیمانده (یا خطا) را نشان می‌دهد. از این مقدار برای برآورد واریانس متغیر وابسته نیز می‌توان استفاده کرد. در مورد ارزیابی دو مدل، با ضرایب تعیین تقریباً یکسان، مدلی انتخاب می‌شود که خطای استاندارد مقادیر خطا (باقیمانده) کمتری داشته باشد.

در انتهای جدول نیز ستون Durbin-Watson آماره مربوطه را با مقدار ۱.۲۲۲ نشان می‌دهد. یکی از فرض‌هایی که در رگرسیون مورد توجه می‌باشد، استقلال خطاها (تفاوت بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط معادله رگرسیون) از یکدیگر است. اگر خطاها با یکدیگر همبستگی داشته باشند، فرض استقلال خطاها رد می‌شود و امکان استفاده از رگرسیون وجود ندارد. به منظور بررسی استقلال خطاها (استقلال مقادیر باقی‌مانده) از یکدیگر از آزمون دوربین واتسون استفاده می‌شود. آماره

دوربین واتسون بین ۰ تا ۴ می باشد. اگر بین باقیمانده‌ها همبستگی متوالی وجود نداشته باشد، مقدار این آماره باید به ۲ نزدیک باشد. اگر به صفر نزدیک باشد نشان دهنده همبستگی مثبت و اگر به ۴ نزدیک باشد نشان دهنده همبستگی منفی می باشد.

- تجزیه و تحلیل واریانس مدل رگرسیونی در جدول ANOVA، در شکل ۴-۴ نشان داده شده است (شکل ۴-۴).

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	10.483	13	.806	51.259	.000 ^b
	Residual	11.027	701	.016		
	Total	21.510	714			

a. Dependent Variable: healing ratio

b. Predictors: (Constant), heating time(s), عبوری از الک 0.075, عبوری از الک 4.75, metal shavings content, Cycles, ابعاد نمونه, coarse steel slag, bitumen type, RAP content, steel fibers content, heating type, رونس تراکم نمونه, عبوری از الک 12.5

شکل ۴-۴. آنالیز واریانس

- در جدول آنالیز واریانس، منابع تغییرات، در سه بخش تفکیک شده‌اند:
- (۱) تغییرات یا پراکندگی که توسط مدل رگرسیون بیان شده‌اند. در این جدول با عبارت Regression مشخص شده است.
 - (۲) تغییراتی که براساس باقیمانده‌های (خطا) حاصل از مدل رگرسیونی مشخص شده است که با عبارت Residual در جدول قابل مشاهده است.
 - (۳) تغییرات یا پراکندگی کل که براساس مجموع مربعات فاصله مقادیر متغیر وابسته از میانگین‌شان ساخته می‌شود. سطری که مربوط به عبارت Total است، تغییرات کل را نشان می‌دهد.

مقدار F که در جدول بالا قابل مشاهده است، از تقسیم MSR^1 (میانگین تغییراتی که توسط مدل رگرسیونی پیش‌بینی شده) به MSR^2 (میانگین مربعات باقیمانده) حاصل می‌شود. این نسبت، نشانگر سهمی است که مدل رگرسیونی نسبت به باقیمانده‌ها در بیان پراکندگی کل دارد. هر چه این مقدار بزرگتر باشد، مدل رگرسیونی مناسب‌تر خواهد بود. ملاک بزرگ بودن F باید براساس جدول توزیع F با درجه آزادی $Reg (df)$ و Res سنجیده شود، اما چون به توزیع جدول F دسترسی نداریم می‌توانیم از همان Sig استفاده کنیم. هر چه مقدار F بزرگتر باشد، Sig به صفر نزدیکتر می‌شود. مقدار کوچکتر از 0.05 ، برای Sig ، نشانگر ارائه مدل مناسب رگرسیون است و می‌توان نتیجه گرفت، متغیرهای مستقل، متغیر وابسته را پیش‌بینی می‌کنند. مقدار 0.05 ، همان خطای نوع اول یا سطح آزمون در نظر گرفته می‌شود. در مثال ما مقدار F بزرگ و Sig بسیار کوچک است. بنابراین مدل ارائه شده به خوبی شاخص ترمیم را به عنوان متغیر وابسته، توصیف می‌کند.

- ضرایب مدل و ویژگی‌های مربوط به آزمون در جدول $Coefficients$ ، نشان داده شده است (شکل ۴-۵).

¹ Mean Square Regression

² Mean Square Residual

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-.125	.186		-.671	.502		
	ابعاد نمونه	.159	.025	.474	6.426	.000	.128	7.820
	روشن تراکم نمونه	.683	.084	1.305	8.161	.000	.027	36.753
	عبوری از الک 12.5	-4.618	.392	-1.653	-11.775	.000	.035	28.324
	عبوری از الک 4.75	5.248	.448	1.906	11.720	.000	.026	37.996
	عبوری از الک 0.075	-24.015	2.440	-1.673	-9.841	.000	.024	41.531
	درصد براده آهن	-1.491	.373	-.140	-3.996	.000	.570	1.754
	درصد RAP	-.021	.081	-.012	-.267	.790	.370	2.703
	درصد سرباره فولاد	.202	.042	.185	4.789	.000	.465	2.151
	درصد الباف فولادی	-1.257	.240	-.201	-5.239	.000	.473	2.112
	نوع هبر	.296	.022	.705	13.343	.000	.249	4.010
	چرخه نرمش ترک	-.030	.002	-.428	-14.991	.000	.852	1.174
	نوع گرمایش	.453	.036	.678	12.574	.000	.240	4.172
	زمان گرمایش (s)	.008	.001	.631	13.774	.000	.331	3.017

a. Dependent Variable: شاخص خود نرمشی

شکل ۵-۴. برآورد ضرایب و خصوصیات مربوط به آزمون آن ها

ستون B، ضرایب رگرسیون و ستون Std. Error، انحراف معیار برآوردگرهای هر یک از ضرایب رگرسیونی است. به کمک این دو معیار می توان به کمک یک آزمون t، فرض صفر بودن این ضرایب را اجرا کرد.

ستون های t و Sig به آزمون فرض ضرایب پرداخته اند. هر چه مقدار t بزرگ باشد، فرض صفر بودن ضریب، ضعیف تر شده و نقش آن متغیر در مدل سازی، بیشتر است. این بزرگی را به کمک مقدار Sig نیز مشخص می کنند. اگر مقدار Sig کوچکتر از ۰.۰۵ باشد، فرض صفر که بیانگر بی اثر بودن متغیر در مدل است، رد می شود. در این مثال Sig مربوط به همه متغیرها به جز مقدار ثابت و درصد RAP کمتر از ۰.۰۵ می باشد و فرض صفر برای این متغیرها رد می شود، یعنی در مدل باقی می ماند، ولی با اطمینان ۰.۹۵ درصد می توان گفت ضرورتی برای وجود مقدار ثابت و درصد RAP در مدل وجود ندارد.

مدل ارائه شده توسط این برازش رگرسیونی به صورت زیر خواهد بود:

$$\text{Healing ratio} = -0.125 + 0.159 \times D + 0.683 \times CT - 4.618 \times S12.5 + 5.248 \times S4.75 - 24.015 \times S0.075 - 1.491 \times M - 0.021 \times R + 0.202 \times S - 1.257 \times F + 0.296 \times BT - 0.03 \times C + 0.453 \times HT + 0.008 \times T \quad (4-2)$$

توضیح متغیرهای رگرسیونی رابطه ۴-۲ در جدول ۴-۲ آورده شده است.

جدول ۴-۲. توضیح متغیرهای رگرسیونی

متغیر	علامت اختصاری
Dimension (ابعاد نمونه)	D
Compact Type (روش تراکم نمونه)	CT
Sieve 12.5 mm (عبوری از الک ۱۲.۵ میلیمتر)	S12.5
Sieve 4.75 mm (عبوری از الک ۴.۷۵ میلیمتر)	S4.75
Sieve 0.075 mm (عبوری از الک ۰.۰۷۵ میلیمتر)	S0.075
Metal Shaving (درصد براده آهن)	M
Rap (درصد آسفالت بازیافتی)	R
Slag (درصد سرباره فولاد)	S
Steel Fiber (درصد الیاف فولادی)	F
Bitumen Type (نوع قیر)	BT
Cycle (چرخه ترمیم ترک)	C
Heating Type (نوع گرمایش)	HT
Heating Time (زمان گرمایش)	T

- بررسی توزیع باقیمانده‌ها در شکل ۴-۶ نشان داده شده است. اگر باقیمانده‌ها، توزیع نرمال با میانگین صفر و واریانس ۱ داشته باشند، یکی دیگر از شرایط رگرسیونی برقرار می‌باشد. در شکل ۴-۶ چنین شرطی مشاهده می‌شود.

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	.14182	.79292	.46343	.121167	715
Residual	-.442421	.344266	.000000	.124276	715
Std. Predicted Value	-2.654	2.719	.000	1.000	715
Std. Residual	-3.527	2.745	.000	.991	715

a. Dependent Variable: healing ratio

شکل ۶-۴. توزیع باقی مانده ها

همان طور که از شکل بالا مشخص است، میانگین برابر با صفر و انحراف استاندارد برابر با ۱ می باشد. بنابراین مدل ایجاد شده مناسب است.

۴-۴ فرآیند مدلسازی توسط شبکه عصبی مصنوعی

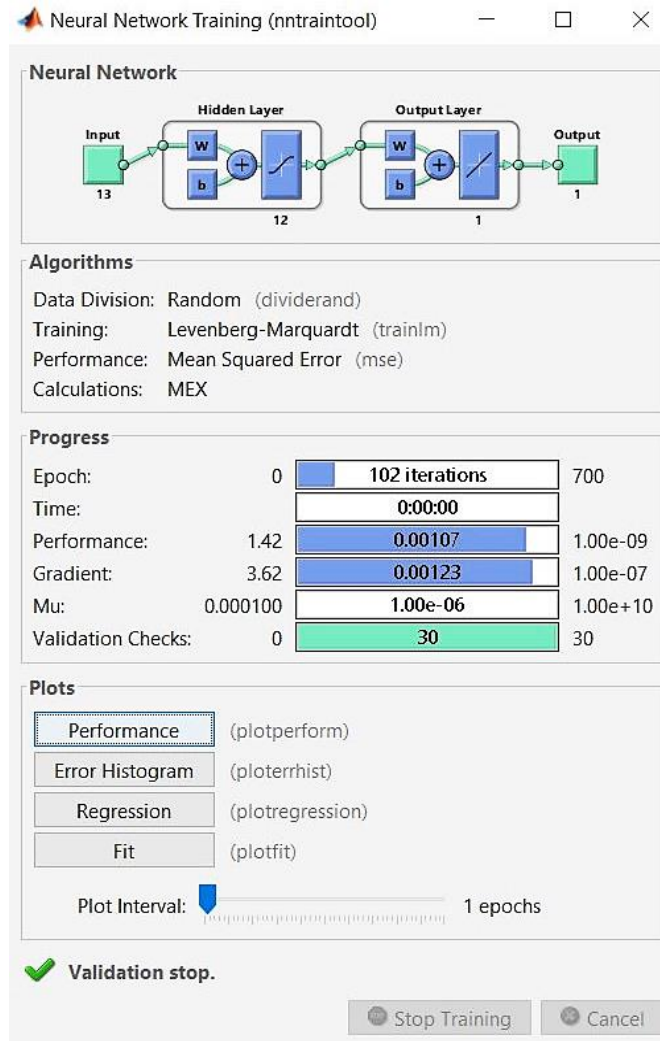
شبکه‌های عصبی کاربردهای وسیعی دارند. مهم‌ترین کاربرد شبکه‌های عصبی، پیش‌بینی و تقریب توابع است. شبکه‌های پرسپترون چند لایه (MLP) و شبکه‌های با تابع شعاعی پایه (RBF) از پرکاربردترین شبکه‌ها در تقریب توابع هستند. در این مطالعه به دلیل قابلیت بالای شبکه‌های MLP و RBF در پیش‌بینی، این دو مدل می‌توانند یک راه حل مناسب و سریع در پیش‌بینی شاخص خود ترمیمی باشند.

۴-۴-۱ شبکه عصبی چند لایه (MLP)

برای ساخت مدل از داده‌های آزمایشگاهی در مقالات مطالعه شده در زمینه خود ترمیمی مخلوط‌های آسفالتی استفاده خواهد شد. مدلسازی توسط نرم افزار متلب صورت می‌گیرد. مراحل کار به این ترتیب است که ابتدا پارامترهای تأثیرگذار در تعیین خود ترمیمی به عنوان ورودی (Input) و داده‌های آزمایشگاهی شاخص خود ترمیمی به عنوان هدف (Target) وارد نرم افزار می‌شوند. شبکه مورد نظر، یک لایه ورودی، یک لایه پنهان و یک لایه خروجی دارد. تعداد عنصرهای موجود در لایه ورودی در حقیقت همان تعداد متغیرهای ورودی معرفی شده به شبکه هستند. لایه پنهان حاوی تعدادی نورون

(سلول عصبی) است که بر رفتار شبکه اثر می‌گذارد. تعیین تعداد لایه‌های پنهان و نورون‌ها به عهده‌ی کاربر است که با سعی و خطا تعداد بهینه لایه‌ها و نورون‌ها را مشخص کند. لایه خروجی شبکه عصبی نیز بیانگر خروجی مسئله است که شبکه باید آن را پیش‌بینی کند.

شبکه عصبی از تعداد زیادی عناصر پردازشی به نام نورون تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. نورون یک واحد اساسی سیستم عصبی می‌باشد و یک واحد پردازشگر ساده است که سیگنال را از دیگر نورون‌ها دریافت کرده و پردازش می‌کند، شبکه‌ای بین نورون‌ها ایجاد می‌شود و توسط الگوریتم آموزشی، شبکه آموزش می‌بیند. پنجره آموزش شبکه عصبی (nntraintool) در متلب در شکل ۴-۷ نشان داده شده است. معماری شبکه مورد نظر در قسمت بالا، توضیحات الگوریتم استفاده شده برای آموزش شبکه در قسمت بعد، تعداد تکرارهای شبکه، خطای عملکردی و... در قسمت سوم و نمودارهای تابع عملکرد خطا، هیستوگرام خطا و رگرسیون در قسمت آخر نشان داده شده است.



شکل ۷-۴. پنجره آموزش شبکه عصبی در متلب

در این مطالعه تعداد مختلفی شبکه عصبی با یک، دو و سه لایه پنهان و تعداد نورون‌های مختلف در لایه(ها)ی پنهان طراحی گردید. تابع فعالسازی لایه(ها)ی پنهان، از نوع تابع سیگموئید (tansig) می-باشد. تابع فعالساز لایه خروجی شبکه عصبی نیز از نوع، تابع انتقال خطی (purelin) است. لایه خروجی دارای یک یا چند نورون می‌باشد. تعداد نورون‌های لایه خروجی، همان متغیر خروجی می-باشد که شبکه باید آن را پیش‌بینی کند. همچنین ۷۰٪ داده‌ها برای آموزش (مجموعه داده‌های مورد استفاده برای یادگیری یا تعیین وزن‌ها و بایاس‌های شبکه)، ۱۵٪ داده‌ها برای صحت سنجی (مجموعه داده‌های مورد استفاده برای تأیید عملکرد شبکه و بهینه سازی روش آموزش و ۱۵٪ دیگر برای آزمایش (مجموعه داده‌های مورد استفاده برای تنظیم ساختار شبکه و ارزیابی عملکرد شبکه) در نظر


گرفته شد. پس از ساخت هر مدل، میانگین مربعات خطاها (MSE) و ضریب همبستگی بدست می‌آید تا شبکه بهینه تعیین شود.

در جدول ۳-۴ مقادیر ضریب همبستگی و میانگین مربعات خطا برای شبکه‌های دارای یک، دو و سه لایه پنهان و تعداد نورون‌های مختلف لایه پنهان آورده شده است، لازم به ذکر است فرآیند آموزش شبکه چندبار انجام شده و مقادیر R و MSE موجود در جدول‌ها از میانگین گیری بدست آمده است.


جدول ۳-۴. ضریب همبستگی و میانگین مربعات خطای لایه‌ها و نورون‌های مختلف

سه لایه پنهان		دو لایه پنهان		یک لایه پنهان		تعداد نورون لایه (ها)ی پنهان
میانگین مربعات ضریب همبستگی	خطا (MSE) (R)	میانگین مربعات ضریب همبستگی	خطا (MSE) (R)	میانگین مربعات ضریب همبستگی	خطا (MSE) (R)	
۰/۰۰۵۵۲	۰/۹۱۰۲	۰/۰۰۴۶	۰/۹۱۵۲	۰/۰۰۴۸۲	۰/۹۲۷۶	۴
۰/۰۰۴۱۶	۰/۹۳۰۴	۰/۰۰۳۶۸	۰/۹۳۷۲	۰/۰۰۴۲۸	۰/۹۳۷۴	۶
۰/۰۰۴	۰/۹۳۱۲	۰/۰۰۳۶۶	۰/۹۳۹۶	۰/۰۰۳۳۸	۰/۹۴۱۲	۸
۰/۰۰۳۹۲	۰/۹۳۱۶	۰/۰۰۳۶۸	۰/۹۳۷۸	۰/۰۰۳۶۲	۰/۹۳۹۴	۱۰
۰/۰۰۴۱۴	۰/۹۳۲۶	۰/۰۰۳۸۴	۰/۹۴۲	۰/۰۰۳۱۸	۰/۹۵۲	۱۲
۰/۰۰۳۵۸	۰/۹۴۱۴	۰/۰۰۳۲۲	۰/۹۵۰۲	۰/۰۰۳۱۲	۰/۹۵۱۴	۱۴
۰/۰۰۳۵۴	۰/۹۳۶۸	۰/۰۰۳۲۸	۰/۹۴۶	۰/۰۰۳	۰/۹۴۹۸	۱۶
۰/۰۰۳۲۸	۰/۹۴۱۴	۰/۰۰۳۰۴	۰/۹۴۳۶	۰/۰۰۳۱۲	۰/۹۴۷	۱۸
۰/۰۰۳۹۸	۰/۹۳۴۸	۰/۰۰۳۶	۰/۹۴۶۶	۰/۰۰۳	۰/۹۴۴۲	۲۰
۰/۰۰۴۰۲	۰/۹۳۳۸	۰/۰۰۴۱۸	۰/۹۳۰۸	۰/۰۰۳۸۴	۰/۹۳۶	۲۲
۰/۰۰۳۹۴	۰/۹۳۱۴	۰/۰۰۴۱۸	۰/۹۳۳۴	۰/۰۰۳۹۲	۰/۹۳۷۴	۲۴

در شکل ۴-۸ و شکل ۴-۹ روند تغییرات ضریب همبستگی و میانگین مربعات خطا برحسب تعداد نورون لایه(ها)ی پنهان، برای شبکه عصبی با یک، دو و سه لایه مخفی رسم شده است.




شکل ۴-۸. روند تغییرات ضریب همبستگی برحسب تعداد نورون های لایه های پنهان



شکل ۴-۹. روند تغییرات میانگین مربعات خطا برحسب تعداد نورون های لایه های پنهان

از شکل ۴-۸ می‌توان به این نتیجه رسید که شبکه‌های با یک یا دو لایه پنهان نسبت به شبکه‌های با سه لایه پنهان، عملکرد بهتری دارند، در نتیجه توانایی شبیه‌سازی آن‌ها بیشتر است. در شکل ۴-۹ نیز شبکه‌های عصبی با یک یا دو لایه پنهان، داده‌های ورودی را بهتر یاد گرفته و در نتیجه میزان خطا کمتر است. با زیاد شدن تعداد لایه‌های پنهان (سه لایه و بیشتر) فقط پیچیدگی شبکه زیاد شده و زمان بیشتری نسبت به شبکه یک و دو لایه صرف آموزش دادن آن می‌شود.

با توجه به نتایج بالا برای ادامه روند کار از یک شبکه عصبی یک لایه استفاده شد، که در شکل ۴-۱۰ نشان داده شده است. معماری شبکه مورد نظر دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است. تعداد نورون‌های لایه پنهان نیز با توجه به شکل ۴-۸، ۱۲ نورون انتخاب شد.



شکل ۴-۱۰. ساختار شبکه عصبی MLP


۱-۴-۱-۱ نتایج حاصل از آموزش شبکه عصبی چندلایه (MLP)

- نمودار همبستگی

شکل ۴-۱۱ نمودار همبستگی داده‌های آموزش، صحت سنجی و آزمایش را نشان می‌دهد. محور x ، مقادیر هدف (شاخص خود ترمیمی) و محور y ، مقادیر خروجی که توسط شبکه عصبی پیش‌بینی شده را نشان می‌دهند. خط برازش شده با توجه به مقادیر هدف و مقادیر پیش‌بینی شده توسط شبکه عصبی رسم شده است که هرچه بر خط مبنا که به صورت خط چین نشان داده شده است، منطبق‌تر باشد، دقت شبکه بیشتر است.

ضریب همبستگی شدت ارتباط بین مقادیر هدف و مقادیر پیش‌بینی شده توسط شبکه عصبی را نشان می‌دهد. سنجش این همبستگی با استفاده از ضریبی به نام ضریب همبستگی خطی (R) انجام می-

شود. مقدار این ضریب بین -۱ تا ۱ تغییر می کند که ۱ به معنای همبستگی مثبت کامل، ۰ به معنای عدم همبستگی و -۱ به معنی همبستگی منفی کامل است.

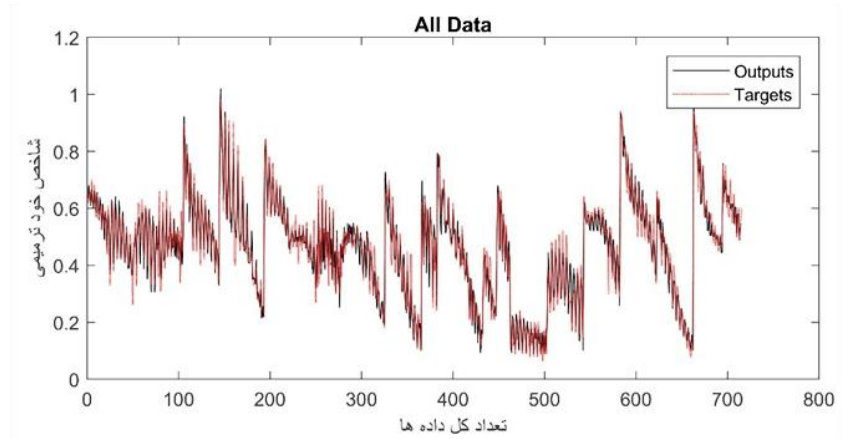
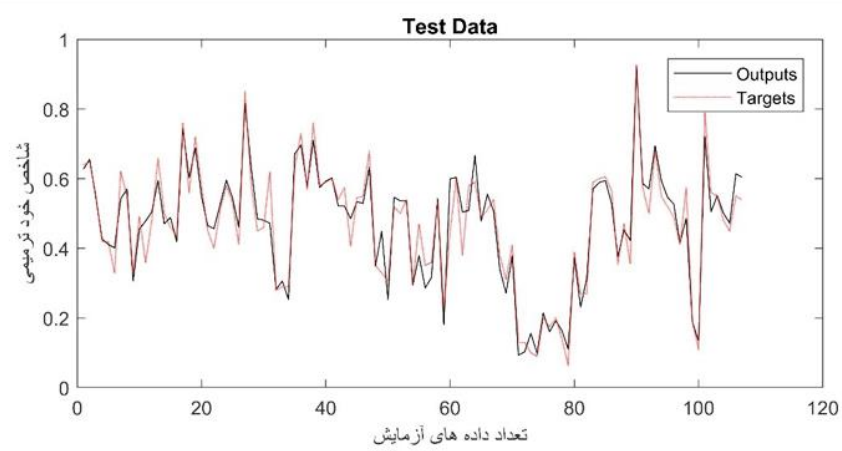




شکل ۱۱-۴. همبستگی داده های آموزش، صحت سنجی، آزمایش و تمام داده های شبکه عصبی MLP

در این شبکه عصبی ضریب همبستگی بین خروجی های هدف و شبکه عصبی برای داده های آموزش برابر ۰/۹۸۱، صحت سنجی برابر ۰/۹۵۹، آزمایش برابر ۰/۹۶۰ و برای همه داده ها ۰/۹۷۵ است، که نتایج خوبی را نشان می دهد. میزان یادگیری و عملکرد شبکه عصبی زمانی بهتر است که ضریب همبستگی به یک نزدیکتر باشد.

- مقایسه نتایج آزمایشگاهی با نتایج بدست آمده از شبکه عصبی





در کدهای برنامه با استفاده از توابع موجود در نرم افزار متلب می توان داده های هدف و شبیه سازی شده در برنامه را به صورت منحنی رسم و با انطباق بر یکدیگر خطای شبیه سازی را مشاهده کرد. در شکل ۲۶-۴، محور x تعداد داده هاست و محور y مقادیر داده های هدف (شاخص خود ترمیمی) و خروجی شبکه (نتایج مدلسازی) را نشان می دهد.



شکل ۱۲-۴. مقایسه نتایج آزمایشگاهی با نتایج به دست آمده از شبکه عصبی MLP

• میانگین مربعات خطا و ریشه میانگین مربعات خطا

میانگین مربعات خطا (MSE) در شبکه عصبی، روشی برای برآورد میزان خطاست که در واقع تفاوت بین مقادیر هدف و آنچه تخمین زده شده، است. هر چه مقدار MSE کمتر باشد، باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد و هرچه مقدار آن به صفر نزدیکتر باشد، نشان دهنده میزان کمتر خطاست. ریشه میانگین مربعات خطا (RMSE) همیشه غیر منفی است و مقدار ۰ (تقریباً هرگز در عمل به دست نیامده است) نشان‌دهنده تناسب کامل با داده‌ها است. شکل ۱۳-۴ نمودار خطا را نشان می‌دهد.



شکل ۱۳-۴. میانگین مربع خطاها و ریشه میانگین مربعات خطا شبکه عصبی MLP

شکل ۱۳-۴ اختلاف بین داده‌های هدف (شاخص خود ترمیمی) و خروجی شبکه (نتایج مدلسازی) (شکل ۱۲-۴) را نشان می‌دهد. نقاط اکسترمم و مینیمم نیز نشان‌دهنده این است که در آن نقاط اختلاف داده‌های هدف و خروجی شبکه بیشتر از نقاط دیگر است. در این تحقیق مقادیر MSE و RMSE برای داده‌های آموزش، اعتبارسنجی، آزمایش و تمام داده‌ها نزدیک صفر (نتایج عددی در جدول ۴-۴) و نتایج قابل قبول است.





در جدول ۴-۴، خلاصه نتایج شبکه عصبی پرسپترون چندلایه آورده شده است.

جدول ۴-۴. MSE، RMSE و R بین مقادیر واقعی و پیش‌بینی شده داده‌های آموزش، اعتبارسنجی و آزمایش شبکه عصبی MLP

	MSE	RMSE	R
آموزش	۰/۰۰۱۱۰	۰/۰۳۳	۰/۹۸۱
اعتبارسنجی	۰/۰۰۲۴۴	۰/۰۴۹	۰/۹۵۹
آزمایش	۰/۰۰۲۲۲	۰/۰۴۷	۰/۹۶۰
تمام داده‌ها	۰/۰۰۱۴۷	۰/۰۳۸	۰/۹۷۵

• توزیع خطای پیش‌بینی شبکه

شکل ۱۴-۴ توزیع خطای پیش‌بینی شبکه از کل مجموعه داده‌ها (آموزش، اعتبارسنجی و آزمایش) را نشان می‌دهد. پراکندگی هرچه متمرکزتر باشد شبکه عملکرد بهتری دارد (پراکندگی مرتبط است با میزان خطای کل شبکه عصبی). هرچه مقدار سیگما کمتر باشد نمودار متمرکزتر و عملکرد شبکه بهتر خواهد شد.




شکل ۱۴-۴. توزیع خطای پیش بینی شبکه عصبی MLP

در شکل ۱۴-۴ مقدار μ ، میانگین خطا و σ ، انحراف معیار خطا می‌باشد. مقدار سیگما تقریباً باید برابر RMSE باشد، هنگامی که میانگین نزدیک صفر باشد این دو مقدار تقریباً برابر هستند. منحنی قرمز رنگ در نمودارها، توزیع نرمال می‌باشند و هرچه میله‌ها شبیه منحنی رفتار کنند، به این معنا است که خطاها رفتار نرمال دارند، به معنای دیگر هرچه منحنی نوک تیزتر باشد، مقدار سیگما کمتر، در نتیجه RMSE و MSE نیز کوچکتر خواهند شد. همانطور که در شکل مشخص است برابری قابل قبول در مقایسه چنین توزیع خطا در هر مجموعه داده (آموزش، اعتبار سنجی و آزمایش) مشاهده شد که نشان می‌دهد تقسیم بندی پایگاه داده مناسب است و هر مجموعه داده نماینده کل مجموعه داده است.

• هیستوگرام خطا


شکل ۱۵-۴ هیستوگرام خطا را نشان می‌دهد که هرچه تمرکز نزدیک به صفر باشد، شبکه عملکرد بهتری دارد. برای رسم هیستوگرام خطا، بازه‌ی (Range) خطا برای مدل به تعدادی فاصله‌ی هم اندازه (bin) تقسیم شده است (برای این مطالعه 20 bin در نظر گرفته شد) و فراوانی (تعداد) مشاهدات در هر فاصله به صورت ارتفاع یک میله نمایش داده می‌شود.



شکل ۱۵-۴. هیستوگرام خطا شبکه عصبی MLP

• روند تغییرات تابع عملکرد خطا

شکل ۱۶-۴ تغییرات خطای عملکرد در طول آموزش شبکه را نشان می‌دهد. محور x، تکرار و محور y، میانگین مربعات خطا را نشان می‌دهد. این نمودار میانگین مربع خطا در هر تکرار را نشان می‌دهد. هرچه شیب منحنی بیشتر باشد، یعنی خطاها با افزایش تکرار، کاهش می‌یابد. هنگامی که به خطای تعریف شده در شبکه برسد، آموزش شبکه متوقف می‌شود. با توجه به شکل زیر، با افزایش تکرار رفت و برگشت (اپوک‌ها) خطای شبکه کاهش می‌یابد. در این شبکه بعد از ۷۲ اپوک به بهترین مقدار برای خطای اعتبارسنجی رسیده و بعد از ۱۰۲ اپوک آموزش شبکه متوقف شده است.



شکل ۱۶-۴. روند تغییرات تابع عملکرد خطا شبکه عصبی MLP

با توجه به شکل ۱۶-۴ منحنی‌های آموزش، صحت سنجی و آزمایش مشابه یکدیگر هستند، بنابراین می‌توان نتیجه گرفت خطای مهمی در آموزش شبکه رخ نداده است. تعداد پارامترهای مؤثر بر عملکرد شبکه‌های عصبی زیاد است. بهینه کردن و محاسبات شبکه‌های عصبی اغلب وقت گیر و زمان بر است.

شبکه باید به خوبی آموزش ببیند تا نتایج موفقیت آمیزی داشته باشد. مشکل عمده در آموزش شبکه‌های عصبی مشکل Overfitting است. این مشکل زمانی به وجود می‌آید که شبکه عصبی فقط روی داده‌های آموزش عملکرد مناسبی دارد و برای سایر داده‌ها نتایج خوبی ارائه نمی‌کند و سبب می‌شود منحنی صحت سنجی شیب افزایشی و منحنی آزمایش شیب کاهشی داشته باشد و دو منحنی از یکدیگر دور شوند.

۲-۱-۴-۴ مدل ریاضی شبکه عصبی MLP

هر یک از نورون‌ها در لایه‌های مخفی و خروجی از دو قسمت تشکیل شده است، یکی مربوط به جمع وزن‌ها و بایاس‌ها و دیگری تابع انتقال برای پردازش خروجی است. برای شبکه سه لایه مورد استفاده در این تحقیق، خروجی شبکه (خودترمیمی)، به شرح زیر محاسبه می‌شود:

$$HI = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk} + \sum_{i=1}^m W_{ik} P_i \right) \right] \quad (۴-۳)$$

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk} بایاس نورون k در لایه پنهان، W_{ik} وزن بین ورودی i و نورون k لایه پنهان، P_i پارامتر ورودی و f_T تابع فعالساز (تابع فعالساز از نوع سیگموئید (tansig)) می‌باشد.

مثال ۱-۴. با توجه به مقادیر وزن‌ها و بایاس‌های بدست آمده از آموزش شبکه توسط نرم افزار متلب و رابطه (۴-۳)، مقدار شاخص خود ترمیمی را با استفاده از کد نوشته شده در متلب برای تعدادی داده جدید آزمایشگاهی محاسبه می‌کنیم و نتایج آن به صورت جدول ۴-۵ است.


جدول ۵-۴. مقایسه شاخص خود ترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی برای شبکه عصبی

MLP														
ورودی‌ها							خروجی							
ابعاد نمونه	روش تراکم نمونه	عبوری از الک	عبوری از الک	عبوری از الک	درصد الیاف فولادی	درصد براده آهن	درصد RAP	نوع قیر	چرخه ترمیم ترک	نوع گرمایش	زمان گرمایش (ثانیه)	HI آزمایشگاهی	HI بدست آمده از فرمول	درصد خطا
۳	۲	۸۴٪	۴۷٪	۵٪	۰٪	۲٪	۰٪	۱	۲	۲	۴۰	۶۹٪	۷۲.۶٪	۵.۳٪
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۰٪	۲	۱	۲	۴۰	۸۷٪	۸۵.۴٪	۱.۷۷٪
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۳۰٪	۲	۲	۲	۴۰	۶۱٪	۶۷.۹٪	۱۱.۳٪
۱	۲	۸۳٪	۵۸٪	۵٪	۰٪	۳٪	۰٪	۲	۲	۱	۱۲۰	۸۲٪	۷۹.۹٪	۲.۵۴٪
۲	۲	۸۴٪	۴۷٪	۵٪	۲٪	۰٪	۰٪	۲	۱	۲	۴۰	۹۵٪	۹۳.۳٪	۱.۷۷٪

همانطور که از جدول بالا مشخص است مقادیر محاسبه شده توسط فرمول عملکرد قابل قبولی دارند.

۳-۴-۱-۳ بررسی قدرت تعمیم شبکه عصبی MLP

برای اعتبار بیشتر مدل توسعه یافته و بدست آوردن برآورد بی طرفانه از خطای تعمیم، داده‌های اضافی که هرگز در طول توسعه مدل ANN استفاده نشده بود، به شبکه ارائه شدند. همانطور که در شکل ۴-۲۹ مشاهده می‌شود، در نمودار مقایسه، مقادیر هدف (مقادیر بدست آمده از نتایج آزمایشگاهی) و مقادیر خروجی (مقادیر بدست آمده از شبکه عصبی) نزدیک یکدیگر هستند، مقدار MSE برابر ۰.۰۰۳۲۴ و مقدار RMSE برابر ۰.۰۵۶ می‌باشد، که هر دو مقدار نزدیک صفر است، بنابراین شبکه قادر به پیش بینی مناسب برای داده‌هایی که در مدلسازی بکار گرفته نشده‌اند، است.



شکل ۱۷-۴. نتایج حاصل از مقایسه شبیه سازی شبکه عصبی MLP با نتایج تجربی

۴-۴-۱-۴ بررسی شبکه عصبی با تعداد متغیرهای متفاوت

به منظور ارزیابی تأثیر متغیرهای مختلف در نظر گرفته شده، در این قسمت شبکه عصبی با تعداد متغیرهای مختلف آموزش داده شده و نتایج آن در جدول ۶-۴ ارائه شده است.

جدول ۶-۴. نتایج شبکه عصبی چندلایه با تعداد متغیرهای مختلف


شماره مدل	ورودی‌ها	آموزش			اعتبار سنجی			آزمایش		
		MSE	RMSE	R	MSE	RMSE	R	MSE	RMSE	R
۱	ابعاد نمونه، روش تراکم نمونه، دانه-بندی مخلوط آسفالتی، درصد براده آهن، درصد RAP، سرباره فولاد، درصد الیاف فولادی، نوع قیر، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش	۰/۰۰۱۱۰	۰/۰۳۳	۰/۹۸۱	۰/۰۰۲۴۴	۰/۰۴۹	۰/۹۵۹	۰/۰۰۲۲۲	۰/۰۴۷	۰/۹۶۰

درصد براده آهن، درصد RAP، درصد سرباره فولاد، درصد										
۲	الیاف فولادی، نوع قیر، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش	۰/۰۰۲۰۲	۰/۰۴۴	۰/۹۶۷	۰/۰۰۴۳۷	۰/۰۶۶	۰/۹۲۱	۰/۰۰۳۳۳	۰/۰۵۷	۰/۹۴۳
درصد براده آهن، درصد RAP، درصد سرباره فولاد، درصد										
۳	الیاف فولادی، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش	۰/۰۰۵۳۷	۰/۰۷۳	۰/۹۰۹	۰/۰۰۵۳۲	۰/۰۷۲	۰/۹۱۶	۰/۰۰۶۸۲	۰/۰۸۲	۰/۸۸
درصد براده آهن، درصد الیاف فولادی، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش										
۴	فولادی، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش	۰/۰۰۲۷۵	۰/۰۵۲	۰/۹۶۴	۰/۰۰۲۳	۰/۰۴۸	۰/۹۷۳	۰/۰۰۲۴۴	۰/۰۴۹	۰/۹۶۷

با توجه به جدول ۴-۶ مدل‌های ۱، ۲ و ۴ نتایج خوبی داشتند و می‌توان با تعداد کمتر متغیرهای مؤثر شبکه را آموزش داد.

۴-۴-۲ شبکه عصبی چندلایه (MLP) بهینه سازی شده با الگوریتم ازدحام ذرات (PSO)

از شبکه عصبی با معماری ۱-۱۲-۱۲-۱۳ استفاده شد (شکل ۱۸-۴)، که ۱۳ و ۱ به ترتیب تعداد متغیرهای ورودی و خروجی و ۱۲ تعداد نورون‌های لایه‌های پنهان می‌باشد. تابع انتقال لایه‌های پنهان از نوع سیگموئید و تابع انتقال لایه خروجی از نوع انتقال خطی می‌باشد. برای بهینه کردن وزن‌ها و بایاس‌های شبکه عصبی از الگوریتم بهینه‌سازی ازدحام ذرات استفاده شد و پارامترهایی که برای این الگوریتم در کد برنامه نویسی در نظر گرفته شد، در جدول ۴-۷ نشان داده شده است.



شکل ۱۸-۴. ساختار شبکه عصبی MLP بهینه سازی شده با PSO

جدول ۷-۴. پارامترهای الگوریتم بهینه سازی ازدحام ذرات




پارامترها	
تعداد ذرات	۳۰۰
تعداد تکرارها	۱۰۰
ضریب آموزش شخصی (C_1)	۲
ضریب آموزش جمعی (C_2)	۲
ضریب اینرسی (w)	۱

۱-۲-۴-۴ نتایج حاصل از آموزش شبکه عصبی MLP بهینه سازی شده با الگوریتم

PSO

• نمودار همبستگی




شکل ۱۹-۴ همبستگی داده‌های آموزش، صحت سنجی و آزمایش را نشان می‌دهد. در این شبکه عصبی ضریب همبستگی بین خروجی‌های هدف و شبکه عصبی برای داده‌های آموزش برابر $0/813$ ، آزمایش برابر $0/786$ و برای همه داده‌ها $0/804$ است، که نتایج متوسطی را نشان می‌دهد. میزان یادگیری و عملکرد شبکه عصبی زمانی بهتر است که ضریب همبستگی به یک نزدیکتر باشد.



شکل ۱۹-۴. همبستگی داده های آموزش، آزمایش و تمام داده های شبکه عصبی MLP بهینه سازی شده با PSO

- مقایسه نتایج آزمایشگاهی با نتایج بدست آمده از شبکه عصبی در کدهای برنامه با استفاده از توابع موجود در نرم افزار متلب می توان داده های هدف و شبیه سازی شده در برنامه را به صورت منحنی رسم و با انطباق بر یکدیگر خطای شبیه سازی را مشاهده کرد. در شکل ۲۰-۴، محور x تعداد داده هاست و محور y مقادیر داده های هدف (شاخص خود ترمیمی) و

خروجی شبکه (نتایج مدلسازی) را نشان می‌دهد.






شکل ۲۰-۴. مقایسه نتایج آزمایشگاهی با نتایج به دست آمده از شبکه عصبی MLP بهینه سازی شده با PSO

- میانگین مربعات خطا و ریشه میانگین مربعات خطا

شکل ۲۱-۴ میانگین مربعات خطا و ریشه میانگین مربعات خطا را نشان می‌دهد. هر چه مقدار MSE

کمتر باشد، باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد. ریشه

میانگین مربعات خطا (RMSE) همیشه غیر منفی است و هرچه به صفر نزدیک تر باشد نشان دهنده تناسب کامل با داده‌ها است.



شکل ۲۱-۴. میانگین مربع خطاها و ریشه میانگین مربعات خطا شبکه عصبی MLP بهینه سازی شده با PSO

شکل ۲۱-۴ اختلاف بین داده‌های هدف (شاخص خود ترمیمی) و خروجی شبکه (نتایج مدلسازی) را نشان می‌دهد. نقاط اکسترمم و مینیمم نیز نشان دهنده این است که در آن نقاط اختلاف داده‌های

هدف و خروجی شبکه بیشتر از نقاط دیگر است. در این تحقیق مقادیر MSE و RMSE برای داده‌های آموزش، اعتبارسنجی، آزمایش و تمام داده‌ها (نتایج عددی در جدول ۸-۴)، نتایج متوسطی را ارائه کرده است.

در جدول ۸-۴، خلاصه نتایج شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO آورده شده است.




جدول ۸-۴. MSE، RMSE و R بین مقادیر واقعی و پیش بینی شده داده های آموزش و آزمایش

شبکه عصبی MLP بهینه سازی شده با PSO

	MSE	RMSE	R
آموزش	۰/۰۴۸۴	۰/۲۲۰	۰/۸۱۳
آزمایش	۰/۰۵۸۰	۰/۲۴۱	۰/۷۸۶
تمام داده‌ها	۰/۰۵۱۳	۰/۲۲۶	۰/۸۰۴

• توزیع خطای پیش بینی شبکه

شکل ۲۲-۴ توزیع خطای پیش بینی شبکه از کل مجموعه داده‌ها را نشان می‌دهد.



شکل ۲۲-۴. توزیع خطای پیش بینی شبکه عصبی MLP بهینه سازی شده با PSO

در شکل ۲۲-۴ مقدار μ ، میانگین خطا و σ ، انحراف معیار خطا می باشد. مقدار سیگما تقریباً باید برابر RMSE باشد، هنگامی که میانگین نزدیک صفر باشد این دو مقدار تقریباً برابر هستند. منحنی قرمز رنگ در نمودارها، توزیع نرمال می باشد و هرچه میله ها شبیه منحنی رفتار کنند، به این معنا است که خطاها رفتار نرمال دارند، به معنای دیگر هرچه منحنی نوک تیزتر باشد، مقدار سیگما کمتر، در

نتیجه RMSE و MSE نیز کوچکتر خواهند شد. همانطور که در شکل مشخص است میزان خطا در بازه بزرگی ایجاد شده است.

۲-۲-۴-۲ مدل ریاضی شبکه عصبی MLP بهینه سازی شده با PSO

هر یک از نورون‌ها در لایه‌های مخفی و خروجی از دو قسمت تشکیل شده است، یکی مربوط به جمع وزن‌ها و بایاس‌ها و دیگری تابع انتقال برای پردازش خروجی است. برای شبکه سه لایه مورد استفاده در این تحقیق، خروجی شبکه (خودترمیمی)، به شرح زیر محاسبه می‌شود:

$$HI = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{HK1} + \sum_{i=1}^m W_{ik1} \cdot f_T \left(B_{HK2} + \sum_{i=1}^z W_{ik2} \cdot P_i \right) \right) \right] \quad (4-4)$$

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{HK1} بایاس نورون k در لایه پنهان اول، B_{HK2} بایاس نورون k در لایه پنهان دوم، W_{ik1} وزن بین ورودی i و نورون k لایه پنهان اول، W_{ik2} وزن بین نورون k لایه پنهان اول و دوم، P_i پارامتر ورودی و f_T تابع فعالساز (تابع فعالساز از نوع سیگموئید (tansig)) می‌باشد.


مثال ۲-۴. با توجه به مقادیر وزن‌ها و بایاس‌های بدست آمده از آموزش شبکه توسط نرم افزار متلب و رابطه (۴-۴)، مقدار شاخص خود ترمیمی را با استفاده از کد نوشته شده در متلب برای تعدادی داده جدید آزمایشگاهی محاسبه می‌کنیم و نتایج آن به صورت جدول ۹-۴ است.

جدول ۹-۴. مقایسه شاخص خود ترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی برای شبکه عصبی MLP بهینه سازی شده با PSO

درصد خطا	خروجی		ورودی‌ها											
	HI بدست آمده از فرمول	HI آزمایشگاهی	زمان گرمایش (ثانیه)	نوع گرمایش	چرخه ترمیم ترک	نوع قیر	درصد RAP	براده آهن	درصد الیاف فولادی	عبوری از الک	عبوری از الک	عبوری از الک	روش تراکم نمونه	ابعاد نمونه
۱۲.۲٪	۶۱.۵٪	۶۹٪	۴۰	۲	۲	۱	۰٪	۲٪	۰٪	۵٪	۴۷٪	۸۴٪	۲	۳
۱۴.۵٪	۹۹.۶٪	۸۷٪	۴۰	۲	۱	۲	۰٪	۰٪	۴٪	۳٪	۶۰٪	۹۸٪	۱	۳
۳۳.۱٪	۸۱.۲٪	۶۱٪	۴۰	۲	۲	۲	۳۰٪	۰٪	۴٪	۳٪	۶۰٪	۹۸٪	۱	۳
۱۹.۱٪	۹۷.۷٪	۸۲٪	۱۲۰	۱	۲	۲	۰٪	۳٪	۰٪	۵٪	۵۸٪	۸۳٪	۲	۱
۱۵.۴۷٪	۸۰.۳٪	۹۵٪	۴۰	۲	۱	۲	۰٪	۰٪	۲٪	۵٪	۴۷٪	۸۴٪	۲	۲

همانطور که از جدول بالا مشخص است مقادیر محاسبه شده توسط فرمول عملکرد خوبی نداشته و درصد خطا نسبتاً بالا می‌باشد.


۳-۲-۴-۴ بررسی قدرت تعمیم شبکه عصبی MLP بهینه سازی شده با PSO برای اعتبار بیشتر مدل توسعه یافته و بدست آوردن برآورد بی طرفانه از خطای تعمیم، داده‌های اضافی که هرگز در طول توسعه مدل ANN استفاده نشده بود، به شبکه ارائه شدند. همانطور که در شکل ۲۹-۴ مشاهده می‌شود، در نمودار مقایسه، مقادیر هدف (مقادیر بدست آمده از نتایج آزمایشگاهی) و مقادیر خروجی (مقادیر بدست آمده از شبکه عصبی) در بعضی قسمت‌ها خطای زیادی را نشان می‌دهد، بنابراین شبکه قادر به پیش بینی مناسب برای داده‌هایی که در مدلسازی بکار گرفته نشده‌اند، نمی‌باشد. مقادیر MSE و RMSE نیز به ترتیب برابر ۰.۰۵۵۸ و ۰.۲۳۶ می‌باشد.



شکل ۲۳-۴. نتایج حاصل از مقایسه شبیه سازی شبکه عصبی MLP بهینه سازی شده با PSO با نتایج تجربی

۳-۴-۳ شبکه عصبی شعاعی پایه (RBF)

شبکه‌های عصبی شعاعی پایه دارای کاربردهای زیادی هستند، از جمله تقریب توابع، پیش‌بینی سری زمانی و طبقه بندی. شبکه RBF دارای سه لایه است. لایه اول مربوط به ورودی‌های شبکه است، لایه دوم یک لایه پنهان است که شامل توابع RBF است و لایه آخر مربوط به خروجی نهایی شبکه است. از تابع گوسی به عنوان تابع انتقال در واحدهای محاسباتی استفاده می‌شود. معماری شبکه عصبی RBF استفاده شده در این پژوهش در شکل ۲۴-۴ نشان داده شده است که شامل سه لایه است (لایه ورودی، لایه پنهان و لایه خروجی). تعداد نورون‌های لایه پنهان نیز براساس سعی و خطا، ۱۰۰ نورون انتخاب شد.






شکل ۲۴-۴. ساختار شبکه عصبی RBF

شبکه‌های RBF معمولاً به وسیله‌ی یک الگوریتم دو مرحله‌ای آموزش داده می‌شوند. در مرحله‌ی اول، مراکز تابع گوسی در لایه‌ی پنهان تعیین می‌شود. اکثر این روش‌ها ابتدا پارامترهای لایه میانی (مرکز و واریانس تابع گوسی هر نورون) را به دست می‌آورند و در مرحله‌ی دوم وزن‌ها و بایاس‌های لایه خروجی با روش کمترین مربعات تخمین زده می‌شوند.

۱-۳-۴-۴ نتایج حاصل از آموزش شبکه عصبی شعاعی پایه (RBF)

- نمودار همبستگی

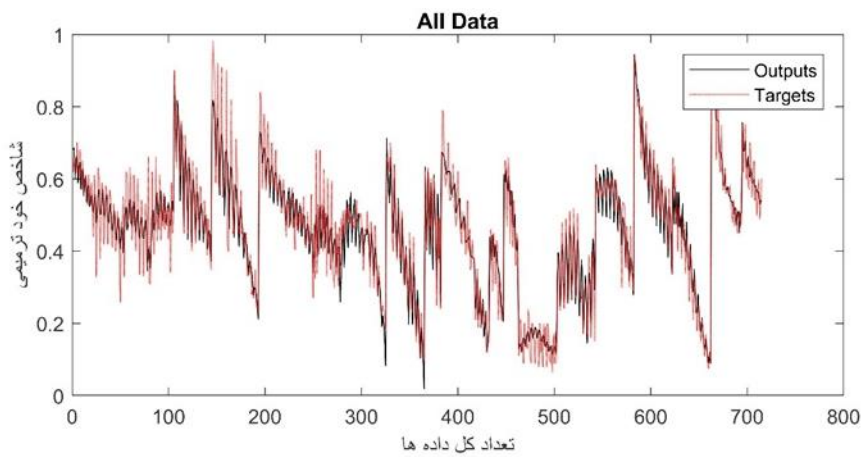


شکل ۴-۲۵ همبستگی داده‌های آموزش، صحت سنجی و آزمایش را نشان می‌دهد. در این شبکه عصبی ضریب همبستگی بین خروجی‌های هدف و شبکه عصبی برای داده‌های آموزش برابر ۰/۹۴۷، آزمایش برابر ۰/۹۳۹ و برای همه داده‌ها ۰/۹۴۴ است، که نتایج خوبی را نشان می‌دهد. میزان یادگیری و عملکرد شبکه عصبی زمانی بهتر است که ضریب همبستگی به یک نزدیکتر باشد.



شکل ۲۵-۴. رگرسیون داده های آموزش، آزمایش و تمام داده های شبکه عصبی RBF

- مقایسه نتایج آزمایشگاهی با نتایج بدست آمده از شبکه عصبی در کدهای برنامه با استفاده از توابع موجود در نرم افزار متلب می توان داده های هدف و شبیه سازی شده در برنامه را به صورت منحنی رسم و با انطباق بر یکدیگر خطای شبیه سازی را مشاهده کرد. در شکل ۲۶-۴، محور x تعداد داده هاست و محور y مقادیر داده های هدف (شاخص خود ترمیمی) و


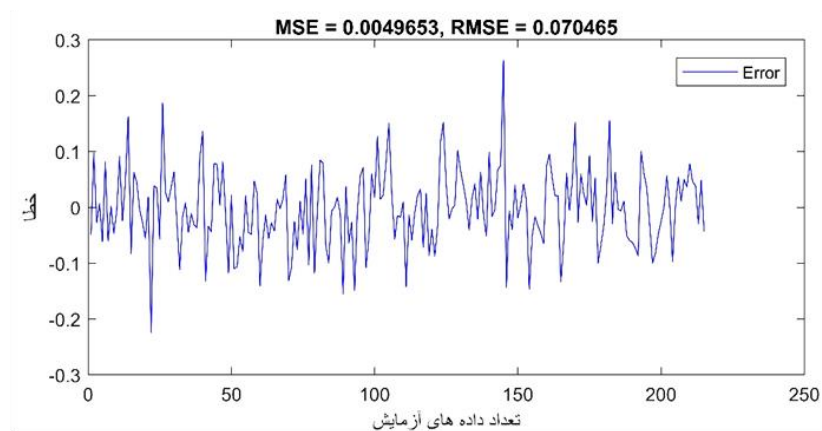

خروجی شبکه (نتایج مدل‌سازی) را نشان می‌دهد.



شکل ۲۶-۴. مقایسه نتایج آزمایشگاهی با نتایج به دست آمده از شبکه عصبی RBF

• میانگین مربعات خطا و ریشه میانگین مربعات خطا

شکل ۲۷-۴ میانگین مربعات خطا و ریشه میانگین مربعات خطا را نشان می‌دهد. هر چه مقدار MSE کمتر باشد، باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد. ریشه میانگین مربعات خطا (RMSE) همیشه غیر منفی است و هرچه به صفر نزدیک‌تر باشد نشان‌دهنده تناسب کامل با داده‌ها است.



شکل ۲۷-۴. میانگین مربع خطاها و ریشه میانگین مربعات خطا شبکه عصبی RBF

شکل ۲۷-۴ اختلاف بین داده‌های هدف (شاخص خود ترمیمی) و خروجی شبکه (نتایج مدل‌سازی) را نشان می‌دهد. نقاط اکسترمم و مینیمم نیز نشان‌دهنده این است که در آن نقاط اختلاف داده‌های هدف و خروجی شبکه بیشتر از نقاط دیگر است. در این تحقیق مقادیر MSE و RMSE برای داده‌های آموزش، اعتبارسنجی، آزمایش و تمام داده‌ها نزدیک صفر (نتایج عددی در جدول ۱۰-۴) و نتایج قابل قبول است.

در جدول ۱۰-۴، خلاصه نتایج شبکه عصبی شعاعی پایه آورده شده است.


جدول ۱۰-۴. MSE، RMSE و R بین مقادیر واقعی و پیش بینی شده داده‌های آموزش و آزمایش

شبکه عصبی RBF

	MSE	RMSE	R
آموزش	۰/۰۰۲۶۳	۰/۰۵۱	۰/۹۴۷
آزمایش	۰/۰۰۴۹۶	۰/۰۷۰	۰/۹۳۹
تمام داده‌ها	۰/۰۰۳۳۳	۰/۰۵۷	۰/۹۴۴

• توزیع خطای پیش بینی شبکه

شکل ۲۸-۴ توزیع خطای پیش بینی شبکه از کل مجموعه داده‌ها را نشان می‌دهد. همانطور که در شکل مشخص است برابری قابل قبول در مقایسه چنین توزیع خطا در هر مجموعه داده مشاهده شد که نشان می‌دهد تقسیم بندی پایگاه داده مناسب است و هر مجموعه داده نماینده کل مجموعه داده است.



شکل ۲۸-۴. توزیع خطای پیش بینی شبکه عصبی RBF

در شکل ۲۸-۴ مقدار μ ، میانگین خطا و σ ، انحراف معیار خطا می باشد. مقدار سیگما تقریباً باید برابر RMSE باشد، هنگامی که میانگین نزدیک صفر باشد این دو مقدار تقریباً برابر هستند. منحنی قرمز رنگ در نمودارها، توزیع نرمال می باشند و هرچه میله ها شبیه منحنی رفتار کنند، به این معنا است که خطاها رفتار نرمال دارند، به معنای دیگر هرچه منحنی نوک تیزتر باشد، مقدار سیگما کمتر، در

نتیجه RMSE و MSE نیز کوچکتر خواهند شد. همانطور که در شکل مشخص است برابری قابل قبول در مقایسه چنین توزیع خطا در هر مجموعه داده (آموزش، اعتبار سنجی و آزمایش) مشاهده شد که نشان می‌دهد تقسیم بندی پایگاه داده مناسب است و هر مجموعه داده نماینده کل مجموعه داده است.

۲-۳-۴-۲ مدل ریاضی شبکه عصبی RBF

هر یک از نورون‌ها در لایه‌های مخفی و خروجی از دو قسمت تشکیل شده است، یکی مربوط به جمع وزن‌ها و بایاس‌ها و دیگری تابع انتقال برای پردازش خروجی است. برای شبکه سه لایه مورد استفاده در این تحقیق، خروجی شبکه (خودترمیمی)، به شرح زیر محاسبه می‌شود:

$$HI = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk} + \sum_{i=1}^m W_{ik} P_i \right) \right] \quad (۴-۵)$$

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk} بایاس نورون k در لایه پنهان، W_{ik} وزن بین ورودی i و نورون k لایه پنهان، P_i پارامتر ورودی و f_T تابع فعالساز (تابع فعالساز از نوع گوسی (radbas)) می‌باشد.

مثال ۳-۴. با توجه به مقادیر وزن‌ها و بایاس‌های بدست آمده از آموزش شبکه توسط نرم افزار متلب و رابطه (۴-۵)، مقدار شاخص خود ترمیمی را با استفاده از کد نوشته شده در متلب برای تعدادی داده جدید آزمایشگاهی محاسبه می‌کنیم و نتایج آن به صورت جدول ۴-۱۱ است.

جدول ۱۱-۴. مقایسه شاخص خود ترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی برای شبکه عصبی


RBF

ابعاد نمونه	روش تراکم نمونه	ورودی‌ها						خروجی					درصد خطا	
		عبوری از الک	عبوری از الک	عبوری از الک	درصد الیاف فولادی	درصد براده آهن	درصد RAP	نوع قیر	چرخه ترمیم ترک	نوع گرمایش	زمان گرمایش (ثانیه)	HI آزمایشگاهی		HI بدست آمده از فرمول
۳	۲	۸۴٪	۴۷٪	۵٪	۰٪	۲٪	۰٪	۱	۲	۲	۴۰	۶۹٪	۶۶.۴٪	۳.۷٪
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۰٪	۲	۱	۲	۴۰	۸۷٪	۸۲.۶٪	۵.۰۵٪
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۳۰٪	۲	۲	۲	۴۰	۶۱٪	۷۲.۵٪	۱۸.۸٪
۱	۲	۸۳٪	۵۸٪	۵٪	۰٪	۳٪	۰٪	۲	۲	۱	۱۲۰	۸۲٪	۸۴.۳٪	۲.۸٪
۲	۲	۸۴٪	۴۷٪	۵٪	۲٪	۰٪	۰٪	۲	۱	۲	۴۰	۹۵٪	۹۰.۹٪	۴.۳٪

همانطور که از جدول بالا مشخص است مقادیر محاسبه شده توسط فرمول عملکرد قابل قبولی دارند.

۳-۳-۴-۴ بررسی قدرت تعمیم شبکه عصبی RBF

برای اعتبار بیشتر مدل توسعه یافته و بدست آوردن برآورد بی طرفانه از خطای تعمیم، داده‌های اضافی که هرگز در طول توسعه مدل ANN استفاده نشده بود، به شبکه ارائه شدند. همانطور که در شکل ۴-۲۹ مشاهده می‌شود، در نمودار مقایسه، مقادیر هدف (مقادیر بدست آمده از نتایج آزمایشگاهی) و مقادیر خروجی (مقادیر بدست آمده از شبکه عصبی) نزدیک یکدیگر هستند، مقدار MSE برابر ۰.۰۰۴۵۲ و مقدار RMSE برابر ۰.۰۶۷ می‌باشد، که هر دو مقدار نزدیک صفر است، بنابراین شبکه قادر به پیش بینی مناسب برای داده‌هایی که در مدلسازی بکار گرفته نشده‌اند، است.



شکل ۲۹-۴. نتایج حاصل از مقایسه شبیه سازی شبکه عصبی RBF با نتایج تجربی

۴-۴-۴ مقایسه نتایج شبکه عصبی MLP، شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO و شبکه عصبی RBF

نتایج مدل سازی شبکه عصبی MLP، شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO و شبکه عصبی RBF برای داده های آزمایش (TEST) در جدول ۴-۱۲ ارائه شده است.

جدول ۴-۱۲. نتایج مدل سازی شبکه های عصبی برای داده های آزمایش

شبکه های عصبی مورد استفاده در این مطالعه	داده های آزمایش			
	MSE	RMSE	R	σ
شبکه عصبی MLP	۰.۰۰۲۲۲	۰.۰۴۷	۰.۹۶۰	۰.۰۴۷
شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO	۰.۰۵۸۰	۰.۲۴۱	۰.۷۸۶	۰.۲۳۹
شبکه عصبی RBF	۰.۰۰۴۹۶	۰.۰۷۰	۰.۹۳۹	۰.۰۷۰

همانطور که از جدول ۴-۱۲ مشاهده می شود، عملکرد شبکه عصبی MLP، نسبت به شبکه عصبی RBF و شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO بهتر است و مقدار ضریب همبستگی ($R=0.960$) بیشتری نسبت به دو نوع شبکه عصبی دیگر دارد، همچنین مقدار σ برای شبکه عصبی MLP کمتر از دو شبکه دیگر است و در نتیجه مقدار MSE و RMSE کمتری نیز خواهد داشت که

باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد، ریشه میانگین مربعات خطا (RMSE) همیشه غیر منفی است و هرچه به صفر نزدیک‌تر باشد نشان‌دهنده تناسب کامل با داده‌ها است. برای هر سه نوع شبکه عصبی مقدار سیگما برابر با RMSE می‌باشد که نشان می‌دهد میانگین نزدیک صفر است و توزیع خطای پیش‌بینی شبکه عملکرد خوبی دارد.

۴-۴-۵ مقایسه نتایج قدرت تعمیم شبکه عصبی MLP، شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO و شبکه عصبی RBF

مقادیر MSE و RMSE برای داده‌های آزمایشگاهی که در مدل‌سازی شبکه‌های عصبی بکار گرفته نشدند، در جدول ۴-۱۳ ارائه شده است.

جدول ۴-۱۳. مقایسه نتایج MSE و RMSE داده‌های اضافی برای بررسی قدرت تعمیم شبکه‌های

عصبی		
شبکه‌های عصبی مورد استفاده در این مطالعه	MSE	RMSE
شبکه عصبی MLP	۰.۰۰۳۲۴	۰.۰۵۶
شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO	۰.۰۵۵۸	۰.۲۳۶
شبکه عصبی RBF	۰.۰۰۴۵۲	۰.۰۶۷

همانطور که از مقادیر MSE و RMSE طبق جدول ۴-۱۳ و درصد خطای شبکه‌ها طبق جداول ۴-۵، ۴-۹ و ۴-۱۱ مشخص است، شبکه‌های عصبی MLP و RBF نسبت به شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO، در برابر داده‌های اضافی قدرت تعمیم خوب و درصد خطای پایینی داشته و قادر به پیش‌بینی مناسب برای داده‌هایی که در مدل‌سازی بکار گرفته نشده‌اند، هستند.

۴-۴-۶ عوامل مؤثر بر خودترمیمی با توجه به وزن‌های شبکه عصبی MLP، شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO و شبکه عصبی RBF

با توجه به وزن‌های بدست آمده از نتایج آموزش شبکه عصبی MLP، شبکه عصبی MLP بهینه سازی

شده با الگوریتم PSO و شبکه عصبی RBF ورودی‌هایی که بیشترین تأثیر را بر خودترمیمی داشتند، در جدول ۱۴-۴ ارائه شدند.

جدول ۱۴-۴. متوسط وزن های بدست آمده از آموزش شبکه های عصبی

شبکه عصبی MLP		شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO		شبکه عصبی RBF	
عوامل مؤثر بر خودترمیمی	وزن‌ها	عوامل مؤثر بر خودترمیمی	وزن‌ها	عوامل مؤثر بر خودترمیمی	وزن‌ها
زمان گرمایش	۱۲.۵۵۵۲	زمان گرمایش	۶.۳۹۸۵	الیاف فولادی	۹.۵۹۵۳
الیاف فولادی	۱۲.۲۵۸۹	سرباره فولاد	۵.۸۷۶۰	زمان گرمایش	۸.۷۴۸۹
براده آهن	۹.۳۰۳۶	دانه بندی	۵.۸۱۳۲	سرباره فولاد	۸.۱۸۲۴
نوع قیر	۸.۱۸۴۰	چرخه ترمیم ترک	۵.۵۵۴۸	چرخه ترمیم ترک	۷.۹۶۹۸
سرباره فولاد	۸.۰۰۴۶	نوع قیر	۵.۳۰۷۹	براده آهن	۷.۹۱۲۴
چرخه ترمیم ترک	۶.۱۷۲۲	نوع گرمایش	۵.۰۶۸۳	دانه بندی	۷.۷۷۶۸
دانه بندی	۵.۹۰۷۳	الیاف فولادی	۴.۷۴۵۹	نوع قیر	۷.۶۶۱۴
نوع گرمایش	۵.۷۳۹۶	براده آهن	۴.۵۶۰۸	نوع گرمایش	۶.۶۹۱۸
درصد رپ	۵.۶۳۳۷	درصد رپ	۴.۴۱۳۵	درصد رپ	۶.۶۶۱۰
ابعاد نمونه	۴.۹۲۹۵	روش تراکم نمونه	۴.۰۳۰۶	روش تراکم نمونه	۵.۲۴۴۶
روش تراکم نمونه	۳.۷۵۳۸	ابعاد نمونه	۳.۷۶۰۲	ابعاد نمونه	۴.۱۶۶۳

در جدول بالا وزن‌ها از مجموع وزن‌های هر نورون ورودی بدست آمده‌اند. هرچه وزن هر ورودی بیشتر باشد، میزان اثرگذاری آن بر خودترمیمی بیشتر خواهد بود. همانطور که مشاهده می‌شود، ضایعات فلزی، زمان گرمایش، چرخه ترمیم ترک و نوع قیر از مهم‌ترین عوامل مؤثر بر خودترمیمی هستند.

فصل ۵ : نتیجه گیری

۵-۱ نتیجه گیری

در این مطالعه داده‌های خود ترمیمی بدست آمده از مقالات با استفاده از شبکه‌های عصبی چندلایه (MLP)، شبکه عصبی چندلایه با الگوریتم بهینه ساز ازدحام ذرات (PSO)، شبکه عصبی شعاعی پایه (RBF) و تجزیه و تحلیل آماری با نرم افزار SPSS تحلیل شد و نتایج این روش‌ها با یکدیگر مقایسه شد. نتایج زیر از این تحقیق بدست آمد:

- با بهره‌گیری از شبکه‌های عصبی مصنوعی می‌توان شاخص خود ترمیمی مخلوط‌های آسفالتی را با داشتن عوامل مؤثر بر شاخص خود ترمیمی با دقت بالا پیش‌بینی کرد.
- از بین مدل‌های ارزیابی شده در این مطالعه، دقت پیش‌بینی شاخص خود ترمیمی مدل شبکه عصبی MLP با ضریب همبستگی ۰/۹۶۰، مدل شبکه عصبی RBF با ضریب همبستگی ۰/۹۳۹، مدل شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO با ضریب همبستگی ۰/۷۸۶ و در آخر رگرسیون چندگانه با SPSS با ضریب همبستگی ۰/۷۲۱ بود که شبکه عصبی MLP دارای بیشترین دقت در پیش‌بینی و رگرسیون چندگانه دارای کمترین دقت در پیش‌بینی است.
- معماری بهینه شبکه عصبی مصنوعی چندلایه به منظور پیش‌بینی شاخص خود ترمیمی به صورت ۱-۱۲-۱۳ است، که نشان‌دهنده ۱۳ ورودی، ۱۲ نورون در لایه پنهان و ۱ خروجی (شاخص خود ترمیمی) می‌باشد.
- برای اعتبار بیشتر مدل، داده‌های اضافی که هرگز در طول توسعه مدل ANN استفاده نشده بودند، به شبکه ارائه شدند. شبکه‌های عصبی MLP و RBF برای شبیه‌سازی داده‌هایی که در طول مدل‌سازی بکار گرفته نشدند در مقایسه با شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO عملکرد مناسبی داشتند.

۲-۵ پیشنهادات

پیشنهاداتی که برای ادامه تحقیقات آینده توصیه می‌گردد، عبارتند از:

(۱) آموزش شبکه با استفاده از دیگر الگوریتم‌های بهینه‌سازی (مانند الگوریتم فاخته، الگوریتم رقابت استعماری و ...) و مقایسه نتایج آن‌ها با روش‌های ارائه شده در این مطالعه.

(۲) ساخت تعدادی نمونه در آزمایشگاه و مقایسه نتایج آزمایش با نتایج شبکه عصبی برای بررسی معتبر بودن روش شبکه عصبی مصنوعی.

مراجعه

1. Norambuena-Contreras, J., et al., Mechanical and Self-Healing Properties of Stone Mastic Asphalt Containing Encapsulated Rejuvenators. *Journal of Materials in Civil Engineering*, 2019. 31(5): p. 04019052.
2. A. González, J. Norambuena-Contreras, L. Storey, E. Schlangen, Self-healing properties of recycled asphalt mixtures containing metal waste: An approach through microwave radiation heating, *Journal of Environmental Management*, Volume 214, 2018, Pages 242-251.
3. Y. Huang, *Pavement Analysis and Design*, second ed., Pearson Prentice Hall, Upper Saddle River, NJ, 2004.
4. EAPA, European Asphalt Association, [Online], Available: <<http://www.eapa.org/asphalt.php>>, (accessed: 01-Aug-2017).
5. A. González, J. Norambuena-Contreras, L. Storey, E. Schlangen, Effect of RAP and fibers addition on asphalt mixtures with self-healing properties gained by microwave radiation heating, *Construction and Building Materials*, Volume 159, 2018, Pages 164-174.
6. Gulisano, F., Crucho, J., Gallego, J. and Picado-Santos, L. (2020)., Microwave Healing Performance of Asphalt Mixture Containing Electric Arc Furnace (EAF) Slag and Graphene Nanoplatelets (GNPs).
۷. طاهرخانی، ح. و ابراهیمی مقدم، ا. (۱۳۹۱)؛ "پیش بینی عمر خستگی مخلوط های آسفالتی با استفاده از شبکه های عصبی".
8. S. Adlinge, A.K.Gupt, *Pavement Deterioration and its Causes*, IOSR Journal of Mechanical & Civil Engineering, Pages 09-15.
9. A. Garcia, Self-healing of open cracks in asphalt mastic, *Fuel* 93 (1) (2012) 264–272.
10. S. Xu, X. Liu, A. Tabaković, E. Schlangen, A novel self-healing system: Towards a sustainable porous asphalt, *Journal of Cleaner Production*, Vol 259, 2020.
۱۱. حسامی، س.، حسامی، ا. و قلی پور گودرزی، م. (۱۳۹۵)؛ "بررسی اثر گرمایش القایی بر خود ترمیمی مخلوط های آسفالتی حاوی مواد رسانای الکتریکی".
12. Ajam, H., et al., Mechanical and healing properties of asphalt mixes reinforced with different types of waste and commercial metal particles. *Cleaner Production*, 2018.
13. Fakhri, M., et al., An evaluation of the mechanical and self-healing properties of warm mix asphalt containing scrap metal additives. *Journal of Cleaner Production*, 2020. 253: p. 119963.
14. Li, H., Yu, J., Liu, Q., Li, Y., Wu, Y., and Xu, H., Induction Heating and Healing Behaviors of Asphalt Concretes Doped with Different Conductive Additives, *Advances in Materials Science and Engineering*, vol. 2019.
15. A. Garcia-Hernández, S. Salih, I. Ruiz-Riancho, J. Norambuena-Contreras, R. Hudson-Griffiths, B. Gomez-Mejide, Self-healing of reflective cracks in asphalt mixtures by the action of encapsulated agents, *Construction and Building Materials*, Vol 252, 2020.
16. Phan, T., Park, D. and Le, T., Crack healing performance of hot mix asphalt containing steel slag by microwaves heating, *Construction and Building Materials*, Vol 180, 2018, p. p 503-511.
17. Gallego, J., et al., Heating asphalt mixtures with microwaves to promote self-healing. *Construction and Building Materials*, 2013. 42: p. 1-4.
18. Norambuena-Contreras, J. and A. Garcia, Self-healing of asphalt mixture by microwave and induction heating. *Materials & Design*, 2016. 106: p. 404-414.

19. Pooyan Ayar, P., Moreno-Navarro, F. and Rubio-Gámez, C., The healing capability of asphalt pavements: a state of the art review, *Journal of Cleaner Production*, Vol 113,2016,p.p 28-40.
20. Kim, Y.R., Little, D.N., Benson, F.C., 1990. Chemical and mechanical evaluation of healing mechanisms in asphalt concrete. *J. Assoc. Asphalt Paving Technol.* 59, 240e275.
21. A. Bhasin, S. Palvadi, D. Little, Influence of Aging and Temperature on Intrinsic Healing of Asphalt Binders, *Transp. Res. Rec.* 2207 (2011) 70–78.
22. Bo Liang, Fang Lan, Kai Shi, Guoping Qian, Zhengchun Liu, Jianlong Zheng, Review on the self-healing of asphalt materials: Mechanism, affecting factors, assessments and improvements, *Construction and Building Materials*, Volume 266, Part A, 2021.
23. NL Agency, Self healing materials concept and application, 2nd edn. NL Agency, Dutch Ministry of Economic Affairs, Agriculture and Innovation, The Hague, (2011).
24. Butt, Azhar, A., Birgisson, B., and Niki Kringos, N., Optimizing the highway lifetime by improving the self healing capacity of asphalt, *Procedia-Social and Behavioral Sciences* 48 (2012): 2190-2200.
25. J. Norambuena-Contreras, A. Gonzalez, J.L. Concha, I. Gonzalez-Torre, E. Schlangen, Effect of metallic waste addition on the electrical, thermophysical and microwave crack-healing properties of asphalt mixtures, *Construction and Building Materials*, Volume 187,2018,Pages 1039-1050.
26. González, A., J. Valderrama, and J. Norambuena-Contreras, Microwave crack healing on conventional and modified asphalt mixtures with different additives: an experimental approach. *Road Materials and Pavement Design*, 2019. 20(sup1): p. S149-S162.
27. J. Norambuena-Contreras, A. Garcia, Self-healing of asphalt mixture by microwave and induction heating, *Materials & Design*, Volume 106, Pages 404-414, 2016.
28. J. Norambuena-Contreras and A. González, Influence of the Microwave Heating Time on the Self-Healing Properties of Asphalt Mixtures, 2017.
29. Lou ,B., et al., Effect of metallic-waste aggregates on microwave self-healing performances of asphalt mixtures. *Construction and Building Materials*, 2020.
30. Ziming Liu, et al., Induction Heating and Fatigue-Damage Induction Healing of Steel Fiber-Reinforced Asphalt Mixture. *J. Mater. Civ. Eng.*, 2019.
31. Saltan, M., Mesut, T. and Mustafa, K. (2002)., Artificial neural networks application for flexible pavements thickness modeling. *Turkish Journal of Eng Env Sci*, vol. 26, pp. 243-248.
32. X, Mei., M, Gunaratne. and J. J, Lu., Neural Network for Rapid Depth Evaluation of Shallow Cracks in Asphalt Pavements. *Computer-Aided Civil and Infrastructure Engineering.*, 2004, p.223–230
33. Gopalakrishnan, K., Manik, A. and Khaitan, S.K., Runway Stiffness Evaluation Using an Artificial Neural Systems Approach, *International Journal of Intelligent Technology (Published by World Enformatika Society)*, Vol. 1, No. 3, 2006 (b)., pp. 204-210.
34. Huang, C, Najjar, Y. M. and Ramonschi, S. A. (2007)., Predicting asphalt concrete fatigue life using artificial neural networks approach. 86th Transportation Research Board meeting, Washington D. C.
35. G. Sollazzo, T.F. Fwa, G. Bosurgi, An ANN model to correlate roughness and structural performance in asphalt pavements, *Construction and Building Materials*, Volume 134, 2017, Pages 684-693.
۳۶. عامری، م. و ملایم، م. (۱۳۸۲)؛ "تحلیل و طراحی روسازی های انعطاف پذیر با شبکه های عصبی مصنوعی".
37. Ajith, Abraham, *Artificial Neural Networks, Handbook of Measuring System Design*, 2005.
۳۸. آریا نژاد، اصغرپور، جیل عاملی و درگاهی مراغه، د. (۱۳۷۸)؛ "تصمیم گیری چند شاخصه با استفاده از شبکه های عصبی".

39. Kenji Suzuki, *Artificial Neural Networks - Methodological Advances and Biomedical Applications*, ISBN 978-953-307-243-2, 2011.
40. <https://www.mathworks.com/>
41. R. Dey and F. M. Salem, "Gate-variants of Gated Recurrent Unit (GRU) neural networks," 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS), 2017, pp. 1597-1600.
42. Hai-Jing Song, D.L. Zhou, Group theory on quantum Boltzmann machine, *Physics Letters A*, Volume 399, 2021.
43. Mateus Roder, Leandro Aparecido Passos, Gustavo H. de Rosa, Victor Hugo C. de Albuquerque, João Paulo Papa, Reinforcing learning in Deep Belief Networks through nature-inspired optimization, *Applied Soft Computing*, Volume 108, 2021.
44. P. Mondal, A. Nandi and N. D. Jana, "An Improved Particle Swarm optimization based Neural Network Training for Classification," 2019 IEEE Region Symposium (TENSYP), 2019, pp. 681-686.
45. V. G. Gudise and G. K. Venayagamoorthy, "Comparison of particle swarm optimization and backpropagation as training algorithms for neural networks," *Proceedings of the 2003 IEEE Swarm Intelligence Symposium. SIS'03 (Cat. No.03EX706)*, 2003, pp. 110-117.
46. Shafiei Najd, M., Hassanzadeh, Y., Alami, M., Abdi Kordani, A. Meteorological Drought Analysis Using Particle Swarm Optimization Algorithm- Artificial Neural Networks Based on MSPI Index. *Water and Soil Science*, 2018; 28(2): 107-120.
47. Maad M. Mijwil, *Artificial Neural Networks Advantages and Disadvantages*, 2018.
48. N. Kamboozia, H. Ziari, H. Behbahani, Artificial neural networks approach to predicting rut depth of asphalt concrete by using of visco-elastic parameters, *Construction and Building Materials*, Volume 158, Pages 873-882, 2018.
49. Madan M.Gupta, Liang Jin, and Noriyasu Homma, *Static and Dynamic Neural Network*, A John Wiley & Sons, INC., Publication, Hobokon, New Jersey.
50. Hecht-Neilsen, R., *Neurocomputing*, Adisson Wesely Publishing Company, 1990.

Abstract

Roads are one of the most important assets of any country and a large part of the country's budget is spent annually on repair and maintenance operations. A large part of the cost of road repair and maintenance operations is spent on repairing cracks. The self-healing potential of asphalt is one of the factors that can increase the useful life of asphalt pavement. When the pavement is at a higher temperature, the repair increases, so the repair of the asphalt mixture itself is temperature dependent. Microwave heating and induction heating are used to increase self-healing capacity by increasing the temperature. Also, to increase heating efficiency and improve self-healing, different types of metal wastes (steel fiber, metal shaving, steel slag, etc.) are added to the asphalt mixture.

Due to the fact that laboratory activities are time consuming and costly, the use of artificial neural networks in predicting laboratory results in recent decades has been considered by researchers. In pavement engineering, artificial neural networks have been used to predict the fatigue life of asphalt mixtures, to predict the nonlinear modulus of pavement layers, etc.

The purpose of this study is to consider the factors affecting the self-healing index (such as type of additive, percentage of additive, gradation of aggregate, type of bitumen, crack repair cycle, etc.) as inputs of artificial neural network in MATLAB software and self-healing index as output, to achieve a suitable neural network and use this network to predict self-healing index. Multilayer perceptron neural network (MLP), multilayer perceptron neural network with particle swarm optimized algorithm (PSO), radial basis function neural network (RBF) and statistical analysis with SPSS software have been used in this study and the results of these methods together were compared. The results showed that multilayer perceptron neural network (MLP) has better performance in predicting self-healing index than other methods.

Keywords: Self-healing, Steel fiber, Metal shaving, Steel slag, Microwave heating, Induction heating, Artificial neural network.



Shahrood University of
Technology

Faculty of Civil Engineering

M.Sc. Thesis in Highway and Transportation Engineering

Prediction of healing ratio of asphalt mixtures using multilayer artificial neural network

By: Mahsa Rouhi Fariman

Supervisor:

Dr. Seyyed Ali Hosseini

Advisor:

Eg. Abbas Mohammadi

September 2021