

مدل سازی تأثیر درصد مصالح سنگی شکسته در مقاومت مارشال آسفالت با بکارگیری شبکه های عصبی مصنوعی

ابوالفضل حسنی، دانشیار، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران
علی حیدری پناه، دانشجوی دکتری، دانشکده فنی - مهندسی، دانشگاه تربیت مدرس، تهران، ایران
E-mail:hassani@modares.ac.ir

چکیده

درصد مصالح سنگی شکسته یکی از مهم ترین عوامل مؤثر در مقاومت فشاری آسفالت و عملکرد آن است. تأثیر آن در مقاومت مارشال آسفالت به کمک آزمایش مارشال قابل ارزیابی است و به نظر می رسد که تاکنون مدل سازی ریاضی خاصی برای آن انجام نشده است. در این تحقیق تأثیر درصد مصالح سنگی شکسته در مقاومت فشاری بتن آسفالتی توسط شبکه های عصبی مصنوعی پرسپترون چند لایه پیشرو و الگوریتم آموزش انتشار به عقب، با تکنیک بهینه سازی عددی لونیگ-مارکوات، مدل سازی شده است.

به این منظور در صدهای عبوری از الگ های شماره ۲۰۰۵۰، ۳۰، ۸، ۴، و ۱/۲ اینچ، درصد مصالح سنگی شکسته و درصد قیر به عنوان ورودی های شبکه و مقاومت مارشال، خروجی شبکه در نظر گرفته شده است. سپس حداکثر توان تعمیم پذیری هر شبکه با تعداد مشخص نرون (۳۶۸۱۰) در لایه پنهان برای شبیه سازی داده های جدید تعیین شده است. بررسی های انجام شده نشان می دهند که توان شبیه سازی شبکه ها به میزان آموزش بسیار حساس بوده و با افزایش آموزش از یک حد معین، شبکه دچار آموزش بیش از حد شده و توان تعمیم پذیری آن به شدت کاهش می یابد، بنابر این دستیابی به بیشترین توان شبیه سازی، مستلزم تلاش فراوان خواهد بود. مقایسه این مقادیر بیشینه نشان می دهد که با افزایش تعداد نرونهای لایه پنهان تا ۸ عدد، توان شبیه سازی شبکه ها به حداکثر رسیده و افزایش بیشتر نرونهای لایه پنهان تأثیر قابل توجهی بر توان شبیه سازی شبکه ندارد. در مرحله بعد با انجام تحلیل حساسیت توسط شبکه ای که بیشترین توان شبیه سازی را داراست، روند تغییرات مقاومت مارشال نسبت به درصد مصالح شکسته مدل سازی شده است. نتایج به دست آمده نشان می دهند که مقاومت مارشال آسفالتی با افزایش درصد مصالح شکسته، افزایش می یابد که با روند نظری مطابقت دارد.

واژه های کلیدی: شبکه های عصبی مصنوعی، انتشار به عقب، تحلیل حساسیت، مقاومت مارشال، در صد مصالح سنگی شکسته

۱. مقدمه

آسفالت به شمار می رود. مصالح سنگی بتن آسفالتی شامل مصالح سنگی درشت دانه، ریز دانه و فیلر است. یکی از عوامل مؤثر در مقاومت مارشال و قابلیت باربری لایه های آسفالتی

بتن آسفالتی از یک استخوان بندی مصالح سنگی خوب دانه بندی شده با فضای خالی مناسب که قیر سطح دانه ها را اندود کرده و آنها را به یکدیگر چسبانده است تشکیل شده و مرغوب ترین نوع

در مرحله بعد با مقايسه خروجى هاى شبكه و مقادير واقعى، مقدار خطا محاسبه مى شود و سپس با پس انتشار خطا از نرونهاى خروجى به سمت ورودى وزن هاى شبكه اصلاح مى شوند، به گونه اى كه خطاى آموزش شبكه کاهش يابد. به همين دليل اين روش، انتشار به عقب ناميده مى شود [۲ و ۳]. چرخه هاى رفت و برگشت آن قدر تكرر مى شود تا MSE كمينه شود. الگوريتم انتشار به عقب همانند قانون آموزش كمينه ميانگين مربعات (LMS) يك الگوريتم بيشترين کاهش (SD) است.

اين الگوريتم در واقع روش LMS را به شبكه هاى چند لايه اى با توابع غيرخطى تعميم مى دهد [2]. طى فرايند آموزش در اين روش دسته اى از نمونه هاى رفتار درست و دلخواه شبكه به آن، ارايه مى شود:

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_q, t_q\} \quad (1)$$

كه در آن:

p_q بردار ورودى شبكه و t_q بردار هدف نظير آن است. هنگامى كه يك ورودى به شبكه داده مى شود، خروجى شبكه با هدف مقايسه مى شود.

الگوريتم بايد با پس انتشار خطا پارامترهاى شبكه را به گونه اى تنظيم كند كه MSE كمينه شود [2].

$$F(\mathbf{x}) = E[e^2] = E[(t - a)^2] \quad (2)$$

در رابطه ۲، \mathbf{x} بردار وزن ها و باياس ها است. در صورتى كه شبكه چندى خروجى داشته باشد رابطه به صورت زير تعميم مى يابد:

$$F(\mathbf{x}) = E[\mathbf{e}^T \mathbf{e}] = E[(\mathbf{t} - \mathbf{a})^T](\mathbf{t} - \mathbf{a}) \quad (3)$$

كه در آن :

$$\mathbf{x} = \text{بردار وزن ها و باياس ها}$$

$$\mathbf{e} = \text{بردار خطا}$$

$$t = \text{بردار هدف}$$

$$\mathbf{a} = \text{بردار خروجى}$$

همانند الگوريتم LMS، ميانگين مربع خطا به صورت زير تخمين زده مى شود [۳]:

$$\hat{F}(\mathbf{x}) = (\mathbf{t}(k) - \mathbf{a}(k))^T \quad (4)$$

$$(\mathbf{t}(k) - \mathbf{a}(k)) = \mathbf{e}^T(k) \mathbf{e}(k)$$

در صد شكستگى مصالح سنگى درشت دانه است [1]. هرچه اين پارامتر بيشتر باشد، زاويه اصطكاك داخلى بين مصالح سنگى افزايش يافته و دانه هاى آنها بيشتر در يكدیگر قفل و بست شده و در نتيجه مقاومت مارشال بتن آسفالتى افزايش مى يابد. بنا بر اين در صد مصالح شكسته يكي از معيار هاى مهم در طرح و كنترل كيفى آسفالت است و به نظر مى رسد كه مدل رياضى خاصى براى تأثير آن در مقاومت مارشال ارايه نشده است. در اين تحقيق تأثير آن در مقاومت مارشال، به كمك شبكه هاى عصبى مصنوعى مدل سازى شده است.

استفاده از شبكه هاى عصبى مصنوعى (ANNs) در زمينه هاى مختلف مهندسى راه و ترابرى مانند طراحى روسازى، طرح اختلاط، مديريت تعمير و نگهدارى راه، مهندسى ترافيك و ساير زمينه ها در حال حاضر در حال توسعه و پيشرفت است. گروه تحقيقاتى آيين نامه آشتو ۲۰۰۲ كه ادامه توسعه پروژه شارپ 1-37A بر مبنای طراحى مكانىستىك است، شبكه هاى عصبى مصنوعى را براى راهنماى طراحى روسازى بتنى آشتو ۲۰۰۲ مورد استفاده قرار داده است.

شبكه هاى عصبى مصنوعى مورد استفاده در اين تحقيق از نوع پرسپترون چندى لايه پيشرو با الگوريتم آموزش انتشار به عقب لونبرگ - ماركوآت (LMBP) است [2]. براى مدل سازى تغييرات مقاومت مارشال نسبت به درصد مصالح شكسته، ابتدا يك مدل شبكه عصبى مصنوعى براى تخمين مقاومت مارشال آسفالت بر اساس عوامل مؤثر در آن ايجاد شده است. سپس روند تغييرات مقاومت مارشال با درصد مصالح سنگى شكسته، با انجام تحليل حساسيت، شبیه سازى شده است. كليه آناليزها به كمك جعبه ابزار شبكه هاى عصبى مصنوعى نرم افزار MATLAB انجام اند.

۲. الگوريتم انتشار به عقب

آموزش شبكه فرايندى است كه طى آن وزن ها و باياس هاى شبكه به گونه اى تغيير مى كنند كه خطاى آموزش MSE^۲

كمينه شود. اين فرايند از سه مرحله تشكيل شده است.

مرحله اول انتشار ورودى ها از نرون هاى ورودى به سمت نرونهاى خروجى است.

که در رابطه ۴ :

۲-۱ الگوریتم انتشار به عقب لونیبرگ- مارکوات

الگوریتم لونیبرگ- مارکوات در واقع یک تغییر بر روی روش نیوتن است که برای کمینه کردن توابعی که جمع مربعات سایر توابع غیر خطی هستند طراحی شده است. این تکنیک به صورت زیر شکل می گیرد:

(۹)

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k) \quad (10)$$

$$\Delta \mathbf{x}_k = -[\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k)$$

در روابط ۹ و ۱۰:

J = ماتریس ژاکوبین

I = ماتریس واحد

v = بردار خطا

F = گرادیان = $\nabla F(\mathbf{x})$

ویژگی بسیار مفید الگوریتم آن است که زمانی که μ_k افزایش می یابد، الگوریتم لونیبرگ - مارکوات به عملکرد الگوریتم بیشترین کاهش (SD) با نرخ آموزش کم، نزدیک می شود:

(۱۱) برای مقادیر بزرگ μ_k

$$\mathbf{x}_{k+1} \cong \mathbf{x}_k - \frac{1}{\mu_k} \mathbf{J}^T(\mathbf{x}_k)$$

$$\mathbf{v}(\mathbf{x}_k) = \mathbf{x}_k - \frac{1}{2\mu_k} \nabla F(\mathbf{x})$$

و زمانی که μ_k به صفر کاهش می یابد، الگوریتم تبدیل به روش گوس نیوتن می شود [۲]. برای شروع μ_k مقدار کوچکی مثلاً $\mu_k = 0.001$ در گرفته می شود.

این پارامتر در کد نویسی با μ نشان داده می شود. اگر مقدار $F(\mathbf{x})$ پس از اولین مرحله کمتر نشده باشد، این مرحله به جای μ_k ، با حاصلضرب آن در یک عدد بزرگ تر از یک $(\mu\text{-inc})$ ، مثلاً $\mu = 10$ تکرار می شود.

نهایتاً $F(\mathbf{x})$ باید کاهش یابد چون گام کوچکی در جهت بیشترین کاهش برداشته شده است. اگر $F(\mathbf{x})$ کاهش نیافت، برای گام بعدی μ_k را بر μ تقسیم می کنیم ($\mu\text{-dec}$)، بنابراین الگوریتم به روش گوس- نیوتن نزدیک شده که این روش، همگرایی سریع تری را ایجاد می کند.

خطا در تکرار k ام جایگزین برآورد خطا شده است. الگوریتم بیشترین کاهش SD برای MSE به صورت زیر است:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad (5)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (6)$$

در روابط ۵ و ۶:

$w_{i,j}^m$ = وزن نرون i ام لایه m که خروجی نرون j ام لایه $m-1$ را دریافت می کند
 b_i = بایاس نرون i ام لایه m
 α = نرخ آموزش

شاخص عملکرد شبکه MSE طی فرآیند آموزش بهینه می شود. در این جا منظور از بهینه کردن $F(\mathbf{x})$ یافتن مقداری برای \mathbf{x} است که $F(\mathbf{x})$ به ازای آن کمینه شود.

روشهای بهینه سازی عبارتند از:

۱- الگوریتم بیشترین کاهش

۲- روش نیوتن

۳- روش گرادیان مجازی

تمامی روشهای فوق بر مبنای تکرار شکل می گیرند. الگوریتم با یک حدس اولیه برای \mathbf{X} مانند \mathbf{X}_0 آغاز می شود و با معادله ای به شکل زیر مقدار جدید \mathbf{X} به دست می آید.

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k \quad (7)$$

$$\Delta \mathbf{x}_k = (\mathbf{x}_{k+1} - \mathbf{x}_k) = \alpha_k \mathbf{p}_k \quad (8)$$

در روابط ۷ و ۸، بردار \mathbf{p}_k بیانگر جهت جستجو و مقدار عددی مثبت α_k نرخ آموزش است که طول هر گام را مشخص می کند و \mathbf{x}_k بردار وزنهای و بایاسهای شبکه در چرخه یا تکرار k ام است.

الگوریتم های فوق در انتخاب جهت جستجو \mathbf{p}_k تفاوت دارند. در این تحقیق از روش بهینه سازی عددی لونیبرگ- مارکوات استفاده شده است [2].

هر شبكه با تعداد مشخص نرون در لايه پنهان در سطوح مختلف آموزش، مورد ارزيابى قرار گرفته است كه روند آن در قسمت هاى ۴-۱ و ۴-۲ تشریح شده است.

۴-۱ آموزش و تعميم پذيرى

در اين تحقيق شبكه هاى با ۸۰،۵۳ و ۱۰ نرون در لايه پنهان طراحى شده اند. ۸۵ عدد از داده ها براى آموزش اين شبكه ها و ۲۵ عدد ديگر براى ارزيابى توان تعميم پذيرى آنها مورد استفاده قرار گرفته اند. فرآيند تعيين شبكه اى كه داراى بيشترين توان تعميم پذيرى يا شبیه سازى است به شرح زير است:

۱- در مرحله اول براى هر شبكه با تعداد مشخص نرون در لايه پنهان، تغييرات توان تعميم پذيرى با خطاى آموزش (MSE) ارزيابى شده و نتايج حاصل در جدولهاى ۲ تا ۵ و نمودارهاى ۲ تا ۵ در قسمت ۴-۲ ارايه شده اند. براى هر شبكه با تعداد معين نرون در لايه پنهان، بيشينه توان تعميم پذيرى به كمك نمودارهاى فوق تعيين شده است.

۲- در مرحله دوم با مقايسه بيشينه مقادير تعميم پذيرى فوق، شبكه اى كه داراى بيشترين توان تعميم پذيرى است تعيين و براى انجام تحليل حساسيت در قسمت ۵ مورد استفاده قرار گرفته است. براى ارزيابى ملموس تر، فرآيند آموزش شبكه با سه نرون در لايه پنهان در نمودار ۱ نشان داده شده است. خط پيوسته نشان دهنده خطاى آموزش است. همان طور كه ديده مى شود با افزايش چرخه هاى آموزش (epochs)، خطاى آموزش کاهش مى يابد.

خط منقطع نشان دهنده خطاى شبیه سازى ۲۵ داده جديد است. همان طور كه مشاهده مى شود با شروع آموزش، خطاى شبیه سازى آغاز به کاهش مى كند تا به كمينه مقدار خود مى رسد كه در اين نقطه شبكه داراى بيشترين توان تعميم پذيرى است. پس از آن با ادامه آموزش، خطاى شبیه سازى افزايش يافته و توان شبیه سازى کاهش مى يابد و اصطلاحاً شبكه، آموزش بيش از حد پيدا مى كند [6].

فرآيند تغييرات خطاى شبیه سازى با نوسانات موضعى همراه است. همان طور كه در شكل ۱ مشاهده مى شود بيشترين توان تعميم پذيرى شبكه در چرخه هاى نخستين آموزش حاصل مى شود.

ويژگى قابل توجه و منحصر به فرد الگوريتم لونبرگ - ماركوآت آن است كه سرعت روش نيوتن را با تضمين همگرابى روش بيشترين کاهش، همراه مى كند [2].

۳. تهيه داده ها

به منظور تهيه داده هاى مورد نياز براى آموزش و ارزيابى توان تعميم پذيرى شبكه ها، نمونه هاى بتن آسفالتى از آسفالت پخش شده در سطح راه و قبل از تراكم، جمع آورى شده است. نمونه ها شامل ۸۶ نمونه بيندر با حداكثر اندازه اسمى ۱۹ و ۲۴ ميليمتر نمونه توپكا با حداكثر اندازه اسمى ۱۲/۵ ميليمتر و قير آنها از نوع خالص با درجه نفوذ ۷۰-۶۰ است. با انجام ۱۱۰ آزمائش مقاومت مارشال و ۱۱۰ آزمائش جداسازى و ۱۱۰ آزمائش تعيين درصد مصالح شكسته بر روى اين نمونه ها، مقاومت مارشال، درصد قير، منحنى دانه بندى، و درصد مصالح سنگى شكسته آنها تعيين شده است.

۸۵ سري از داده هاى به دست آمده براى آموزش شبكه ها و ۲۵ سري براى ارزيابى توان تعميم پذيرى آنها مورد استفاده قرار گرفته است [5].

۴. مدل شبكه عصبى مصنوعى

مقاومت مارشال بتن آسفالتى به عوامل مختلفى چون خصوصيات و دانه بندى مصالح سنگى، نوع و درصد قير مصرفى بستگى دارد. براى ايجاد مدل، درصد هاى عبورى از الك هاى ۲۰۰، ۳۰، ۴، ۸، و ۱/۲ اينچ، درصد مصالح سنگى شكسته و درصد قير مجموعاً ۸ متغير، به عنوان ورودى هاى شبكه و مقاومت مارشال به عنوان خروجى شبكه در نظر گرفته شده است، بنا بر اين تعداد نرون هاى لايه ۰ يا لايه ورودى ۸ عدد و تعداد نرون هاى لايه خروجى ۱ عدد است [5]. ورودى ها و خروجى شبكه و محدوده تغييرات آنها در جدول (۱) نشان داده شده است.

براى نرون هاى لايه ميانى از تابع انتقال تانژانت سيگمويد و نرون هاى لايه پنهان از تابع انتقال خطى استفاده شده است. براى عملكرد بهتر شبكه، تمامى داده هاى ورودى و خروجى بين ۱ و -۱ نرمال شده اند.

براى تعيين تعداد مناسب نرون ها در لايه ميانى شبكه هاى متعدد با تعداد مختلف نرون در لايه پنهان طراحى شده و توان شبیه سازى

۴-۲ نمودارهای تعمیم پذیری

در این قسمت برای شبکه های دارای ۳، ۶، ۸ و ۱۰ نرون در لایه پنهان حداکثر توان تعمیم پذیری تعیین شده است. به این منظور برای هر شبکه با تعداد مشخص نرون در لایه پنهان، توان تعمیم پذیری در سطوح مختلف آموزش (خطای آموزش) تعیین شده و نتایج در جدولهای ۲ تا ۵ ارائه شده اند.

در این جدولها اولین ستون از سمت چپ نشان دهنده نام شبکه است. ستون دوم مقدار اولیه انتخاب شده برای پارامتر μ است که در قسمت ۱-۲ تشریح شد و در کد های برنامه با μ نشان داده می شود. ستونهای سوم و چهارم، μ -inc و μ -dec، پارامتر های تنظیم کننده سرعت آموزش شبکه هستند که در قسمت ۱-۲ تشریح شده اند. ستون پنجم پارامتر GOAL، خطای آموزش تعیین شده برای توقف آموزش است. ستون ششم یا MSE، نشان دهنده خطای آموزشی است که شبکه در آن متوقف شده است و performance نیز نامیده می شود.

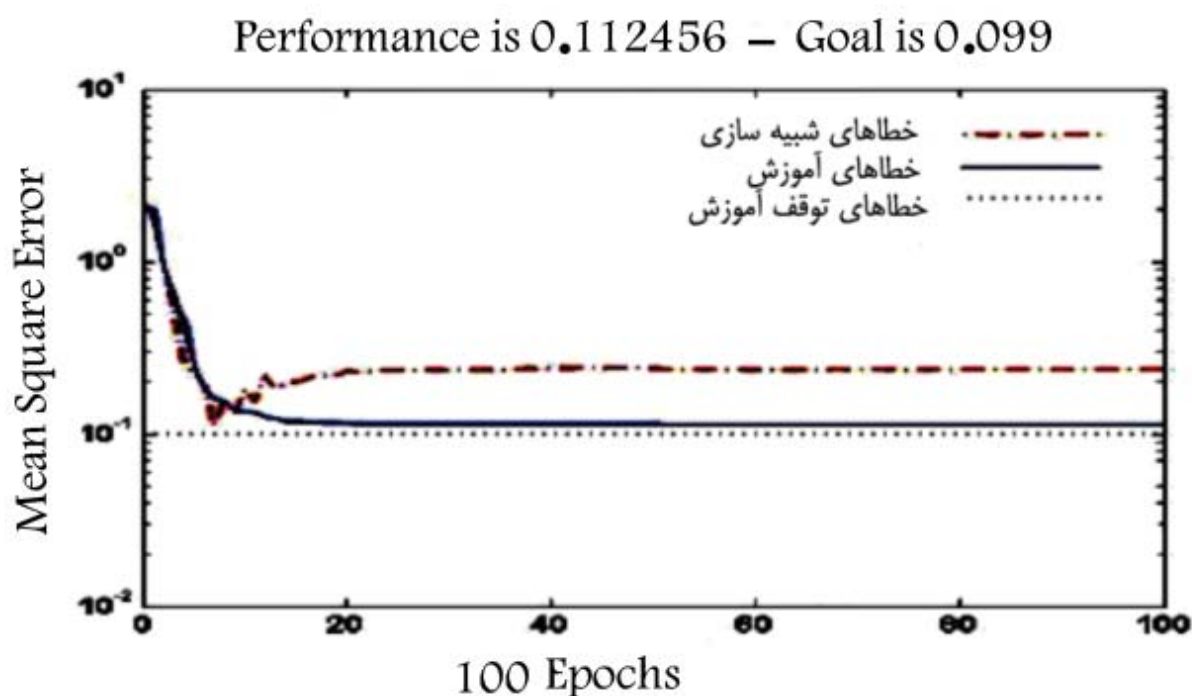
همانگونه که در شکل ۱ مشاهده می شود، بیشترین توان تعمیم پذیری در چرخه های اولیه آموزش حاصل می شود، بنابراین برای متوقف کردن آموزش در سطح مورد نظر (MSE=GOAL)، در بسیاری از موارد سرعت آموزش باید تا حد امکان کند شود که برای این منظور پارامتر های μ -inc و μ -dec نزدیک به ۱ در نظر گرفته شده اند. تحلیل های انجام

شده نشان می دهند که توان تعمیم پذیری شبکه ها به خطای آموزش بسیار حساس است و روند آموزش به مقدار اولیه وزنها نیز بستگی دارد.

با توجه به این که مقدار دهی اولیه وزنها به صورت اتفاقی است و نیز بیشترین توان تعمیم پذیری در چرخ های اولیه آموزش حاصل می شود و با توجه به حساس بودن توان تعمیم پذیری شبکه ها به خطای آموزش، با وجود کند کردن روند آموزش، توقف آموزش در حدود نزدیک به خطای مورد نظر (GOAL) دشوار بوده و برای هر شبکه مستلزم آموزش مجدد برای دفعات متعدد با مقادیر مختلف وزن های اولیه است.

ستون آخر نشان دهنده ضریب همبستگی است که نشان دهنده توان تعمیم پذیری شبکه است. نحوه محاسبه آن به این گونه است که پس از اتمام آموزش هر شبکه با ۸۵ داده، ۲۵ داده جدید به شبکه ارائه می شود. سپس با انجام رگرسیون خطی بین نتایج شبیه سازی شبکه و مقادیر واقعی یا هدف، ضریب همبستگی R محاسبه شده است.


هر چه این ضریب به ۱ نزدیک تر باشد توان تعمیم پذیری شبکه بیشتر است. برای ارزیابی تغییرات توان شبیه سازی هر شبکه با تعداد مشخص نرون در لایه پنهان، نمودار تغییرات ضریب همبستگی در برابر خطای آموزش ترسیم و نتایج در نمودارهای شماره ۲ تا ۵ ارائه شده است.



نمودار ۱. روند آموزش و تغییرات خطای شبیه سازی برای شبکه دارای ۳ نرون در لایه پنهان

جدول ۲. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای ۳ نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT3P11	۱/۵	۱/۵	۰/۵	۰/۱۴	۰/۱۴۱۰۸۱	۰/۵۶۱
RT3P10	۱/۵	۱/۵	۰/۵	۰/۱	۰/۱۳۰۹۳۷	۰/۶۲۱
RT3P3	۱/۵	۱/۵	۰/۵	۰/۱	۰/۱۲۲۰۳۸	۰/۵۴۲
RT3P4	۱/۵	۱/۵	۰/۵	۰/۱۱	۰/۱۱۶۱۲۳	۰/۶۵۴۶
RT3P5	۱/۵	۱/۵	۰/۵	۰/۰۷	۰/۰۵۷۳۰	۰/۷۰۴۲
RT3P6	۰/۰۰۱	۱۰	۰/۱	۰/۹	۰/۰۸۸۴۹	۰/۵۴۹
RT3P7	۱/۵	۱/۵	۰/۵	۰/۰۹۹	۰/۰۷۵۶۳۹۵	۰/۶۷۱
RT3P8	۲	۰/۰۱	۰/۹۸	۰/۹	۰/۰۳۳۱۵۹۱	۰/۴۰۶



نمودار ۲. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۳ نرون در لایه پنهان

جدول ۳. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای ۶ نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT6P1	۲	۰/۹۸	۱/۰۱	۰/۰۹۹	۰/۰۸۶۸۳۱	۰/۳۸۸
RT6P7	۲	۰/۹	۱/۱	۰/۴	۰/۰۹۱۸۶	۰/۶۳۷۳
RT6P3	۲	۰/۹	۱/۱	۰/۹۷	۰/۰۹۳۳۰۰۵	۰/۶۹۵
RT6P4	۲	۰/۹	۱/۱	۰/۰۹۷	۰/۰۹۴۱۲۷۶	۰/۷۱۳
RT6P6	۲	۰/۹	۱/۱	۰/۰۹۸	۰/۰۹۵۴۳۴	۰/۵۱۹
RT6P2	۲	۰/۹	۱/۱	۰/۰۹۹	۰/۰۹۷۲۶۸۵	۰/۵۷۱
RT6P5	۲	۰/۹	۱/۱	۰/۰۹۸	۰/۰۹۷۵۳۸۱	۰/۶۹۹
RT6P8	۲	۰/۹	۱/۱	۰/۱	۰/۰۹۸۳۲۴۴	۰/۷۰۹
RT6P9	۲	۰/۹	۱/۱	۰/۱۱	۰/۱۰۵۹۷۶	۰/۶۱
RT6P10	۲	۰/۹	۱/۱	۰/۱۱	۰/۱۱۹۳۲۳	۰/۶۳۴



نمودار ۳. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۶ نرون در لایه پنهان

جدول ۴. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای ۸ نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT8P1	۰/۰۰۱	۰/۱	۱۰	۳.۷۰۹e-۲۹	۳.۷۰۹e-۲۹	۰/۰۱۰۹
RT8P11	۲	۰/۹۸	۱/۰۱	۰/۰۸	۰/۰۷۸۹۹۹۷۰	۰/۴۸
RT8P10	۲	۰/۹۸	۱/۰۱	۰/۰۹	۰/۰۸۵۵۸۹	۰/۷۵۶۱
RT8P3	۲	۰/۹۸	۱/۰۱	۰/۰۹۱	۰/۰۸۶۹۹۹۶	۰/۶۸۴
RT8P4	۲	۰/۹۸	۱/۰۱	۰/۰۹۱	۰/۰۸۸۰۱۲۳	۰/۵۸۶
RT8P5	۲	۰/۹۸	۱/۰۱	۰/۰۹	۰/۰۸۹۰۱۱۶	۰/۷۶۸
RT8P6	۲	۰/۹۸	۱/۰۱	۰/۰۹۲	۰/۰۹۰۴۶۸۴	۰/۷۲۶
RT8P7	۲	۰/۹۸	۱/۰۱	۰/۱	۰/۰۹۶۸۰۵	۰/۵۷۸
RT8P8	۲	۰/۹۸	۱/۰۱	۰/۰۹۵	۰/۰۹۴۱۶۷۷	۰/۷۳۷



نمودار ۴. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۸ نرون در لایه پنهان

جدول ۵. پارامترهای آموزش و نتایج شبیه سازی برای شبکه های دارای ۱۰ نرون در لایه پنهان


Network	μ	mu_inc	mu_dec	Goal	MSE	R
RT10P1	۱/۵	۱/۰۱	۰/۹۹	۰	۰/۰۶۴۰۹۲۵	۰/۵۸۵
RT10P4	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۰۷۷۳۲	۰/۴۸۸
RT10P5	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۰۸۷۰۹۵	۰/۶۸
RT10P3	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۰۹۰۹۵	۰/۷۴۳
RT10P7	۱/۵	۱/۰۱	۰/۹۹	۰/۰۹۳	۰/۰۹۲۶۶۳۴	۰/۶۵
RT10P5	۱/۵	۱/۰۱	۰/۹۹	۰/۰۹۳	۰/۰۹۸۳۴۰۹	۰/۶۸۳
RT10P6	۱/۵	۱/۰۱	۰/۹۹	۰/۰۸	۰/۱۰۱۱۹۷	۰/۶۸۳



نمودار ۵. تغییرات ضریب همبستگی (توان شبیه سازی) با خطای آموزش برای شبکه های دارای ۱۰ نرون در لایه پنهان

جدول ۶. تغییرات مقاومت مارشال یک نمونه بتن آسفالتی برای در صد های مختلف مصالح سنگی شکسته

شماره ۲۰۰	شماره ۵۰	شماره ۳۰	شماره ۸	شماره ۴	۱/۲ اینچ	قیر (درصد)	شکستگی (در صد)	مقاومت فشاری (کیلوگرم)
۵	۱۳	۲۳	۴۳	۶۶	۹۳	۴/۷۹	۴۵	۱۲۵۸/۹
"	"	"	"	"	"	"	۵۰	۱۲۶۲/۱
"	"	"	"	"	"	"	۵۵	۱۲۶۴/۸
"	"	"	"	"	"	"	۶۰	۱۲۶۷
"	"	"	"	"	"	"	۶۵	۱۲۶۸/۸
"	"	"	"	"	"	"	۷۰	۱۲۷۰/۷
"	"	"	"	"	"	"	۷۵	۱۲۷۳/۵
"	"	"	"	"	"	"	۸۱	۱۲۷۹/۶
"	"	"	"	"	"	"	۸۵	۱۲۸۶/۵
"	"	"	"	"	"	"	۹۰	۱۲۹۹/۱
"	"	"	"	"	"	"	۹۵	۱۳۱۶/۷
"	"	"	"	"	"	"	۱۰۰	۱۳۳۸/۵



نمودار ۶. تغییرات مقاومت مارشال نمونه بتن آسفالتی به صورت تابعی از تغییرات در صد مصالح سنگی شکسته

۵. تحلیل حساسیت

برای مدل سازی روند تغییرات مقاومت مارشال بتن آسفالتی با درصد مصالح سنگی شکسته، تحلیل حساسیت توسط شبکه RT8P5 که دارای بیشترین توان شبیه سازی است، انجام شده است. روند کار به این صورت است که برای یک نمونه آسفالتی، برای درصد های مختلف مصالح شکسته شده، سایر ورودی های شبکه مانند درصد قیر مصرفی و درصد های عبوری از الک های ۲۰۰، ۵۰، ۳۰، ۸، ۴ و ۱/۲ ثابت در نظر گرفته شده و مقاومت مارشال نمونه برای این ورودی ها و درصد های مختلف مصالح شکسته شده، توسط شبکه RT8P5 محاسبه شده است که نتایج در جدول ۶ و نمودار ۶ نشان داده شده اند. همان طور که در نمودار ۶ مشاهده می شود با افزایش درصد مصالح شکسته، مقاومت فشاری آسفالت نیز افزایش می یابد.

از دیدگاه نظری نیز افزایش درصد مصالح شکسته، موجب افزایش زاویه اصطکاک داخلی بین مصالح سنگی و در نتیجه افزایش مقاومت مارشال مخلوط آسفالتی می شود، بنابراین فرآیند شبیه سازی با روند نظری مطابقت دارد.

۶. نتایج

در این تحقیق ابتدا یک مدل شبکه عصبی مصنوعی LMBP برای تخمین مقاومت مارشال آسفالت ارایه شده که برای آموزش آن از ۸۵ و برای ارزیابی آن از ۲۵ سری داده استفاده شده است. سپس با انجام تحلیل حساسیت روند تغییرات مقاومت فشاری آسفالت با درصد مصالح شکسته مدل سازی شده که نتایج حاصل به شرح زیرند:

۱- برای هر شبکه با تعداد مشخص نرون در لایه پنهان، با افزایش چرخه ها و کاهش خطای آموزش، توان تعمیم پذیری شبکه، تا رسیدن به حداکثر مقدار خود افزایش می یابد و پس از آن، شبکه آموزش بیش از حد پیدا کرده و توان تعمیم پذیری آن کاهش می یابد، به گونه ای که برای شبکه

RT8P1 با ۸ نرون در لایه پنهان، در خطای آموزش ۲۹-۱۰×۳/۷۱ ضریب همبستگی $R=0/0109$ حاصل می شود.

۲- تحلیل های انجام شده نشان می دهند که توان تعمیم پذیری شبکه ها نسبت به تغییرات خطای آموزش بسیار حساس است. به علاوه حداکثر توان تعمیم پذیری در چرخه های اولیه آموزش حاصل می شود و از سوی دیگر روند آموزش به مقدار اولیه وزن ها نیز بستگی دارد.

بنابراین با وجود کند کردن روند آموزش، متوقف کردن آن در مقادیر نزدیک به مقدار مورد نظر، دشوار بوده و برای هر شبکه مستلزم آموزش مجدد با مقادیر مختلف وزنه های اولیه، برای دفعات متعدد است.

۳- برای مدل سازی انجام شده در این تحقیق، افزایش تعداد نرونها تا ۸ عدد توان تعمیم پذیری شبکه را افزایش داده و افزایش بیشتر، تغییر قابل توجهی در آن ایجاد نمی کند. با استفاده از ۸ نرون در لایه پنهان، بیشینه توان شبیه سازی برای شبکه RT8P5 با ضریب همبستگی $R=0/0768$ در خطای آموزش ۱۱۶-۰/۸۹۰۱۱۶ حاصل می شود که با توجه به تعداد کم داده های آموزشی و تعدد عوامل مؤثر، مناسب است.

۴- روند شبیه سازی شده تغییرات مقاومت مارشال آسفالت نسبت به درصد مصالح سنگی شکسته با انجام تحلیل حساسیت، نشان می دهد که با افزایش درصد مصالح شکسته، مقاومت مارشال آسفالت افزایش می یابد.

از دیدگاه نظری، افزایش درصد مصالح شکسته موجب افزایش زاویه اصطکاک داخلی بین مصالح سنگی و در نتیجه افزایش مقاومت مارشال آسفالت می شود، بنابراین روند شبیه سازی شده با روند نظری مطابقت دارد.

۷. مراجع

5. Heidaripناه, A. (2003) "Estimation of Marshal stability of asphalt concrete using artificial neural networks", M.Sc. Thesis, University of Kerman, Iran.

6. MATLAB 7 (2004) "Neural network toolbox user's guide", Math Works Inc.

1. Wright, K Paul and Dixon, K Karen (2004) "Highway engineering", John Wiley & Sons Inc., 7th. edition.

2. Hagan, Martin, T. and Demuth, Howard B. (2000) "Neural network design", Mark Beale MHB, Inc. PWS Publishing Company.

۳. كاوه ع، ثروتى، ه. (۱۳۷۸) "شبكه هاى عصبى مصنوعى در تحليل و طراحى سازه ها"، مركز تحقيقات ساختمان و مسكن، نشریه شماره ك- ۳۲۰، چاپ دوم.

پانویس ها

1. Artificial Neural Networks
2. Levenberg - Marquadt Back Propagation
3. Mean Square Error
4. Least Mean Square
5. Steepest Decent
6. Overfitting

4. Topping, B.H.V. and Bahreininejad, A. (1997) "Neural computing for structural mechanics", Sax-Coburg Publications.

Effect of Crushed Aggregates Percentage on Marshal Stability of Asphalt Concrete, Using Artificial Neural Networks

A. Hasani, Associate Professor, Department of Engineering, Tarbiat Modares University, Tehran, Iran

A. Heidaripanah, Ph.D. Student, Department of Engineering, Tarbiat Modares University, Terhan, Iran

E-mail: hassani@modsares.ac.ir

ABSTRACT

In this research the variation of Marshal stability with percentage of crushed aggregates is simulated using Artificial Neural Networks (ANNs) with Levenberg-Marquardt Back Propagation (LMBP) training algorithm. To develop the model, the percentage of crushed aggregates, percentage passing through sieves 50, 20, 4, 8, 30 and 1/2 inch and percentage of asphalt content considered as network inputs and Marshal stability as network output so the number of input layer neurons is eight and the output layer neuron is one. The tangent sigmoid transfer function is selected for hidden layer neurons and linear transfer function for output layer. The inputs and outputs are normalized between -1 and 1, to improve the performance of the networks. At the first stage, the maximum generalization ability of each network with specified number of neurons (3, 5, 8, and 10) in hidden layer is determined. Comparing these maximum values reveals that the network with 8 neurons in the hidden layer has the maximum generalization ability. At the second stage, the variation of Marshal stability with percentage of crushed aggregates is simulated by applying sensitivity analysis on the network with maximum generalization ability. MATLAB 7 has been used as main software in this research. In order to collect the required data needed to design networks and evaluate the generalization ability of them, a database of 110 Asphalt concrete specimens are selected before compaction from the road surface. The specimens include Binder and Topeka with 0-19 mm gradation. The Binder Type is asphalt cement with the penetration grade 60/70. Having done the Marshal stability, extraction, percentage of crushed aggregate tests, the Marshal stability, the asphalt content, the gradation curve, the percent of crushed aggregates are derived. The optimum number of hidden layer neurons is determined based on 85 data for training and 25 data to assess the generalization ability of the networks.

The training of the network with 3 neurons in the hidden layer is depicted in Fig. 1. In this figure the dashed line indicates the simulation error for new data versus the training cycles and the solid line indicates the training error or performance (MSE) versus the training cycles (epochs). Based on Fig. 1, the maximum generalization ability of the network happens in the initial training cycles so the training rate of the networks must be minimized and training parameters of the networks, μ -inc, μ -dec are selected close to 1.0 to reduce the training rate. In order to assess the variation of generalization ability of the network, a curve representing R versus MSE is expressed for each network with a specified number of neurons (3, 5, 8 and 10) in hidden layer, e.g. that which is shown in the Fig. 2. Comparing the maximum relative coefficients shows that the maximum generalization ability is achieved for T8P4 network with 8 neurons in hidden layer ($R=0.768$), so the optimum value for the neurons is selected to be 8. Based on the investigations made in this paper, increasing the number of hidden layer neurons more than 8 has negligible effect on generalization ability also, due to the sensitivity of network generalization ability to training error, in spite of

reducing the training rate, the determination of maximum generalization ability requires designing and training of various networks.

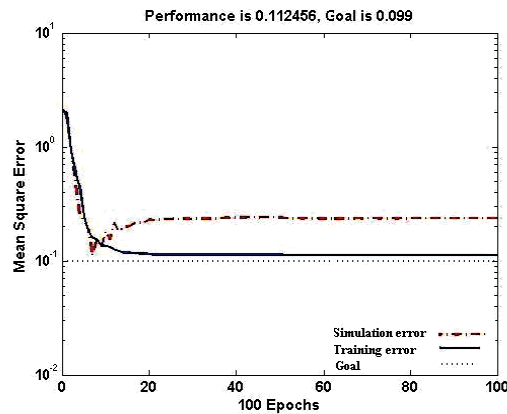


Fig.1. Variation of training and simulation error versus training cycles

Table 2. Simulation results for the networks with 3 neurons in the hidden layer

Network	μ	mu inc	mu dec	Goal	MSE	R
RT3P11	1.5	1.5	0.5	0.14	0.141081	0.561
RT3P10	1.5	1.5	0.5	0.1	0.130937	0.621
RT3P3	1.5	1.5	0.5	0.1	0.122038	0.542
T3P4	1.5	1.5	0.5	0.11	0.116123	0.6546
T3P5	1.5	1.5	0.5	0.07	0.5730	0.7042
T3P6	0.001	10	0.1	0.09	0.08849	0.549
T3P7	1.5	1.5	0.5	0.099	0.0756395	0.671
T3P8	2	1.01	0.98	0.9	0.00331591	0.406




Fig.2. Variation of simulation ability (R) with training error (MSE) for the networks with 3 neurons in the hidden layer

To simulate the Marshal stability variation with percentage of crushed aggregates by ANNs, for an asphalt specimen, all T8P2 network inputs are considered constant except percentage of crushed aggregates. Based on T8P2 simulation results, any increase in the percentage of crushed aggregates of specimens increases the Marshal stability.

This research is concluded to the following results:

- 1- For a network with specified number of neurons in hidden layer, by reducing training error, the generalization ability of network increases as it reaches its maximum value, and furthermore the network over fits and generalization ability is reduced considerably.
- 2- The generalization ability of network is sensitive to the training error therefore in spite of reduction of the training rate, stopping the training around the goal is difficult and requires initializing and retraining networks for several times.
- 3- Increasing the number of neurons in hidden layer up to 8, increases the network generalization ability with negligible variation if considered more than 8 in this study.

- 4- The simulation of Marshal stability variation trend with percentage of crushed aggregates by applying sensitivity analysis on ANNs is compatible with theory.

Keywords: Asphalt concrete, Marshal stability, artificial neural networks, crushed aggregates