

مدل سازی انرژی ضربه‌ی فولادهای مرتبه‌ای با استفاده از شبکه‌های عصبی مصنوعی

علی نظری^{*۱}

چکیده	اطلاعات مقاله
<p>در این مقاله، انرژی ضربه‌ی فولادهای مرتبه‌ای در دماهای مختلف با استفاده از شبکه‌های عصبی مصنوعی مدل‌سازی شده است. فولادهای مرتبه‌ای با استفاده از چیدمان‌ها و ضخامت‌های مختلف فولادهای ساده کربنی و زنگ‌نزن، به عنوان الکتروود اولیه فرآیند ذوب دوباره سرباره‌ای الکتریکی، تولید می‌شوند. نفوذ اتم‌های مختلف از درون قطعات اولیه فولادی به یکدیگر سبب تولید نواحی مرتبه‌ای فریتی و آستنیتی می‌گردد. شش نوع مدل با استفاده از شبکه‌های عصبی مصنوعی که تفاوت آنها در تعداد لایه‌های مخفی و نورون‌های هر لایه بود، ارائه شد. پارامترهای ورودی عبارتند از نوع فولاد مرتبه‌ای، حالت ترک، ضخامت ناحیه مرتبه‌ای فریتی، ضخامت ناحیه مرتبه‌ای آستنیتی، فاصله ترک از لایه‌های بینیتی یا مارتنزیتی و دما. مجموعاً ۱۴۰ سری داده آزمایشی جمع‌آوری، به ۹۸، ۲۱ و ۲۱ سری به طور تصادفی تقسیم و به ترتیب توسط مدل‌های پیشنهادی آموزش داده، ارزیابی و آزمایش شدند. نتایج نشان دادند که مدلی حاوی ۲ لایه مخفی دارای به ترتیب ۱۴ و ۱۲ نورون در لایه‌های مخفی اول و دوم سبب حصول بهترین نتایج خواهد شد. این شبکه دارای ضریب همبستگی، خطای مطلق و خطای ریشه مجموع مربعات به ترتیب ۰/۱۶۱۷۵ و ۰/۵۴۸۲ در فاز آموزش، ۰/۹۹۸۲، ۴/۴۶۶۶ و ۳/۴۳۴۷ در فاز ارزیابی و ۰/۹۹۵۵، ۱۰/۹۴۶۲ و ۵/۲۷۱۶ در فاز آزمایش است. اگرچه نتایج حاصل از مدل‌های دیگر نیز نشان دادند که شبکه‌های عصبی مصنوعی برای مدل‌سازی انرژی ضربه‌ی فولادهای مرتبه‌ای در محدوده مورد بررسی مناسبند.</p>	<p>واژگان کلیدی: انرژی ضربه، فولادهای مرتبه‌ای، شبکه‌های عصبی مصنوعی، تعداد لایه‌های مخفی، تعداد نورون‌ها.</p>

۱- مقدمه

مرتبه‌ای، کامپوزیت‌های حاصل از دو یا چند ماده هستند؛ البته تغییر تدریجی نیز باید در آنها وجود داشته باشد تا از کامپوزیت‌های معمولی قابل تشخیص باشند [۲]. واژه مواد مرتبه‌ای را می‌توان جهت اتصال انواع مواد، پوشش‌های مرتبه‌ای و حتی قطعات مرتبه‌ای به کار برد. مثال‌هایی از مواد مرتبه‌ای طبیعی شامل استخوان، دندان، چوب [۳]، خاک‌ها و سنگ‌های رسوبی [۴] است. اخیراً، محققین کامپوزیت‌های مرتبه‌ای تمرکز خود را برای

مواد مرتبه‌ای (Functionally graded materials) دسته‌ای از مواد پیشرفته مهندسی هستند که تغییر تدریجی ترکیب شیمیایی در آنها باعث تغییر در خواص مکانیکی در کل حجم قطعه می‌گردد [۱]. عمدتاً مواد

* پست الکترونیک نویسنده مسئول: alinazari84@aut.ac.ir


۱. استادیار، دانشگاه آزاد اسلامی، واحد ساوه، گروه مهندسی مواد و متالورژی، ساوه، ایران

بررسی و مدل‌سازی شده است که از آن جمله می‌توان به مدل‌سازی انرژی ضربه در حالت تقسیم‌کننده ترک (Crack divider configuration) [۷]، شبیه‌سازی انرژی ضربه با استفاده از روش اجزای محدود (Finite element method) [۸] و مدل‌سازی چقرمگی شکست در حالت توقف‌گر ترک (Crack arrester configuration) [۹] اشاره نمود. در مقاله حاضر، انرژی ضربه‌ی فولادهای مرتبه‌ای در دماهای مختلف و حالت‌های مختلف قرارگیری شیار نمونه‌ی ضربه‌ی چارپی با استفاده از شبکه‌های عصبی مصنوعی (Artificial neural networks) مدل‌سازی شده است. شبکه‌های عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده‌ی پردازنده‌های کوچک و بسیار زیادی سپرده که به صورت شبکه‌ای به هم پیوسته و موازی با یکدیگر رفتار می‌کنند تا یک مسئله را حل نمایند. در این شبکه‌ها به کمک دانش برنامه نویسی، ساختار داده‌ای طراحی می‌شود که می‌تواند همانند نورون عمل کند. به این ساختار داده گره گفته می‌شود. سپس با ایجاد شبکه‌ای بین این گره‌ها و اعمال یک الگوریتم آموزشی به آن، شبکه را آموزش می‌دهند. در این حافظه یا شبکه‌ی عصبی گره‌ها دارای دو حالت فعال (روشن یا ۱) و غیرفعال (خاموش یا ۰) اند و هر یال (سیناپس یا ارتباط بین گره‌ها) دارای یک وزن می‌باشد. یال‌های با وزن مثبت، موجب تحریک یا فعال کردن گره غیر فعال بعدی می‌شوند و یال‌های با وزن منفی، گره متصل بعدی را غیر فعال یا مهار (در صورتی که فعال بوده باشد) می‌کنند [۱۰] و [۱۱].


مسائل مختلف مهندسی با استفاده از شبکه‌های عصبی مصنوعی مدل‌سازی شده است. از آن جمله می‌توان به تحلیل رواسازی انعطاف‌پذیر راه‌ها [۱۲]، بررسی استحکام فشاری ژئوپلیمرها [۱۳]، مدل‌سازی مقاومت به ضربه‌ی کامپوزیت‌های لایه‌ای آلومینیوم-اپوکسی [۱۴]، پیش‌بینی پروفیل ریزسختی فولادهای مرتبه‌ای [۱۵] و خواص

دست‌یابی به خواص حرارتی، مکانیکی، الکتریکی و غیره، جهت بهبود کارهای ساختمانی، دمای بالا و سایر کاربردهای ویژه معطوف نموده‌اند [۵]. نیروی محرکه‌ی اصلی جهت توسعه‌ی مواد مرتبه‌ای ایجاد تغییر جزئی در ترکیب و خواص محل اتصال دو ماده مختلف است تا تنش در محل اتصال آن‌ها نسبت به فصل مشترک دو ماده و همچنین استحکام فصل مشترک و احتمال جدا شدن آن‌ها کمتر شود.

برای اولین بار با استفاده از روش ذوب دوباره‌ی سرباره‌ای الکتریکی آفزاده و شاحسینی [۶] کامپوزیت‌های لایه‌ای به صورت فولادهای مرتبه‌ای (Functionally graded steels) با استفاده از الکترودهای اولیه متشکل از فولاد زنگ‌زن و فولاد ساده‌ی کربنی تولید شد. شیب موجود در این‌گونه کامپوزیت‌ها از نوع ترکیب شیمیایی بوده که موجب تغییر در ریزساختار می‌گردد و به جای داشتن ترکیبی مشخص در فصل مشترک، تغییر شیب آهسته از جزئی به جزء دیگر وجود دارد. در طی فرآیند ذوب، فازهای مختلفی به دلیل نفوذ ایجاد می‌گردد و هنگام نفوذ عناصر آلیاژی، نواحی مختلفی با مشخصات انتقالی متفاوت ایجاد می‌شوند. بنابراین می‌توان شاهد ساختارهایی متفاوت چون فریت-پرلیت، بینیت، مارتنزیت و آستنیت بود. هنگامی که الکتروده اولیه حاوی دو قطعه از فولادهای ساده کربنی (α) و زنگ‌زن آستنیتی (γ) باشد، ریزساختار و مورفولوژی کامپوزیت، $\alpha\beta\gamma$ خواهد بود:



و به طور مشابه؛



که در روابط فوق α ، β و γ به ترتیب فریت، بینیت و آستنیت در کامپوزیت حاصل، el الکتروده، com کامپوزیت و R ذوب دوباره هستند. خواص مختلفی از این فولادهای مرتبه‌ای در کارهای قبلی

مختلف بتن‌های [۲۰-۱۶] متنوع اشاره نمود.

در مقاله حاضر، با استفاده از شش مدل پیشنهادی بر پایه‌ی شبکه‌های عصبی مصنوعی، انرژی ضربه‌ی فولادهای مرتبه‌ای در حالت‌های مختلف قرارگیری شیار (توقف‌گر و تقسیم‌کننده ترک) در دماهای مختلف مدل‌سازی شده است. برای این منظور ۱۴۰ سری داده از کار قبلی [۲۱] جمع‌آوری، به ۲۱ و ۲۱ داده به طور تصادفی تقسیم‌بندی و توسط مدل‌های مختلف عصبی به ترتیب آموزش داده شده مورد ارزیابی قرار گرفته و آزمایش شدند. نوع فولاد مرتبه‌ای، حالت ترک، ضخامت ناحیه مرتبه‌ای فریتی، ضخامت ناحیه مرتبه‌ای آستنیتی، فاصله ترک از لایه‌های بینیتی یا مارتنزیتی و پارامترهای ورودی بودند که برای پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای به عنوان خروجی مورد استفاده قرار گرفتند. تفاوت شش مدل پیشنهادی در تعداد لایه‌های مخفی و نورون‌های مورد استفاده در آنها بود.

۲- جمع‌آوری داده‌ها

داده‌های آزمایشی از کار قبلی [۲۱] جمع‌آوری شدند. برای به دست آوردن این داده‌ها از فولادهای مرتبه‌ای $\alpha\beta\gamma$ و $\gamma M\gamma$ استفاده شد. برای تهیه‌ی کامپوزیت $\alpha\beta\gamma$ ، از الکترودهای دو قطعه‌ای $\alpha\gamma$ استفاده و ارتفاع هر قطعه برابر ۱۰۰ میلی‌متر در نظر گرفته شد. جهت تهیه‌ی کامپوزیت‌های $\gamma M\gamma$ از الکترودهای سه قطعه‌ای $\gamma\alpha\gamma$ استفاده شد. در این الکترودهای سه قطعه‌ای، ارتفاع قطعه‌ی میانی برابر ۲۵ میلی‌متر و ارتفاع دو قطعه‌ی بالایی و پایینی برابر ۸۷/۵ میلی‌متر در نظر گرفته شد. سطح کلیه‌ی شمش‌های کامپوزیتی پس از تولید توسط دستگاه تراش صاف شد. سپس نمونه‌ها تحت عملیات پرس گرم در دمای ۹۸۰ درجه‌ی سانتی‌گراد قرار گرفتند تا ضخامت آن‌ها کاهش یابد. دستگاه پرس مورد استفاده، پرس‌ی هیدرولیکی با ظرفیت ۱۲۰۰ تن بود. پس از پرس، ارتفاع کامپوزیت‌ها به حدود ۳۱ میلی‌متر رسید و پس از آن با استفاده از سنگ مغناطیسی، از بالا و پایین نمونه‌ها

لایه‌برداری صورت گرفت تا ارتفاع نهایی به ۳۰ میلی‌متر برسد [۲۱].

از شمش‌های پرس شده‌ی $\alpha\beta\gamma$ ، ۹۰ سری نمونه با ابعاد $۱۰ \times ۳۰ \times ۵۵$ میلی‌متر تهیه شد. هر سری نمونه خود شامل ۳ نمونه بود. در ده سری از نمونه‌ها، شیار با ابعاد داده شده در شکل ۳-۳ (طول و عمق ۲ میلی‌متر، شعاع رأس $۰/۲۵$ میلی‌متر و زاویه‌ی ۴۵ درجه) با استفاده از وایرکات در جهت عمود بر لایه‌ها در حالت تقسیم‌کننده‌ی ترک که در شکل ۱-الف نشان داده شده است ایجاد شد. لازم به ذکر است که حالت تقسیم‌کننده‌ی ترک عبارتی است که در مورد کامپوزیت‌های لایه‌ای و در زمانی که استحکام پیوند لایه‌ها ضعیف‌تر از استحکام لایه‌های منفرد است به کار می‌رود. در این حالت ترک به درون فصل‌مشترک‌ها رشد نموده و تقسیم می‌شود. در کامپوزیت‌های حاضر به دلیل اتصال نفوذی اتصال لایه‌های ایجاد شده چنان قوی است که تقسیم شدن ترک وجود ندارد. عبارت تقسیم‌کننده‌ی ترک به کار رفته در مورد کامپوزیت‌های حاضر تنها تداعی کننده‌ی حالت هندسی تقسیم‌کننده‌ی ترک است و به مفهوم تقسیم شدن ترک نیست. این مفهوم هندسی برای حالت توقف‌گر ترک نیز که در ادامه توضیح داده خواهد شد فقط به مفهوم هندسی آن اشاره دارد. پس از ایجاد شیار، ۱۰ میلی‌متر از بالا و ۱۰ میلی‌متر از پایین نمونه‌ها بریده شدند، تا ابعاد استاندارد نمونه‌ی چارپی حاصل شود. در ۴۰ سری از نمونه‌ها شیار در ناحیه‌ی آلفا و در ۴۰ سری دیگر، شیار در ناحیه‌ی گامای کامپوزیت قرار گرفت (حالت توقف‌گر ترک که در شکل ۱-ب نشان داده شده است). شیارها به گونه‌ای ایجاد شدند که فاصله‌ی رأس آن‌ها به ترتیب ۰، ۱، ۲ و ۳ میلی‌متر از لایه‌ی بینیت باشد (۱۰ سری با فاصله ۰، ۱۰ سری با فاصله ۱، ۱۰ سری با فاصله ۲ و ۱۰ سری با فاصله ۳ میلی‌متر از لایه‌ی بینیت). برای این کار، با دانستن محل لایه‌های بینیت (با استفاده از متالوگرافی و ریزسختی‌سنجی)، ابتدا نمونه‌ی استاندارد $۱۰ \times ۱۰ \times ۵۵$ میلی‌متری تهیه و سپس شیار در آن ایجاد

شد [۲۱].


از شمش پرس شده‌ی $\gamma M\gamma$ ، 50 سری نمونه با ابعاد $10 \times 30 \times 55$ میلی‌متر تهیه شد. مشابه کامپوزیت $\alpha\beta\gamma$ ، هر سری نمونه شامل ۳ نمونه بود. همانند فرآیندی که برای کامپوزیت $\alpha\beta\gamma$ گفته شد، 10 سری از نمونه‌ها در حالت تقسیم‌کننده‌ی ترک و 40 سری از نمونه‌ها نیز در حالت توقف‌گر ترک تهیه شدند. به علت تقارن خواص کامپوزیت $\gamma M\gamma$ ، در حالت توقف‌گر ترک، شیار تنها از یک سمت در کامپوزیت ایجاد شد و محل آن به گونه‌ای در نظر گرفته شد که فاصله‌ی رأس آن از لایه‌ی مارتنزیتی به ترتیب 0 ، 1 ، 2 و 3 میلی‌متر باشد (10 سری با فاصله 0 ، 10 سری با فاصله 1 ، 10 سری با فاصله 2 و 10 سری با فاصله 3 میلی‌متر از لایه‌ی مارتنزیت) [۲۱].

آزمایش‌های ضربه‌ی چارپی مطابق استاندارد ASTM E23 در دماهای بین $573-123$ کلوین و با فاصله‌های دمایی 50 کلوین (کلاً 10 دمای آزمایشی) صورت پذیرفت. برای هر 10 سری از نمونه‌ها با موقعیت شیار مشخص، آزمایش‌های ضربه‌ی چارپی در دماهای بیان شده صورت گرفتند [۲۱].



پس از انجام آزمایش بر روی نمونه‌ها، میانگین نتایج حاصل از آزمایش برای ۳ نمونه‌ی هر سری، به عنوان انرژی ضربه‌ی آن سری نمونه در نظر گرفته شد [۲۱].

۳- تئوری شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی برای مدل‌سازی مغز انسان توسعه داده شدند [۲۲]. اگرچه شبکه‌های عصبی مصنوعی در مقایسه با مغز انسان کوچک بوده و قابلیت‌های بسیار کمتری دارند، با این حال ابزاری بسیار قدرتمند در سازماندهی اطلاعات و دانش هستند چراکه شباهت زیادی به مغز انسان دارند. بنابراین یک شبکه عصبی مصنوعی می‌تواند ابزار قدرتمندی در مهندسی باشد [۲۳].



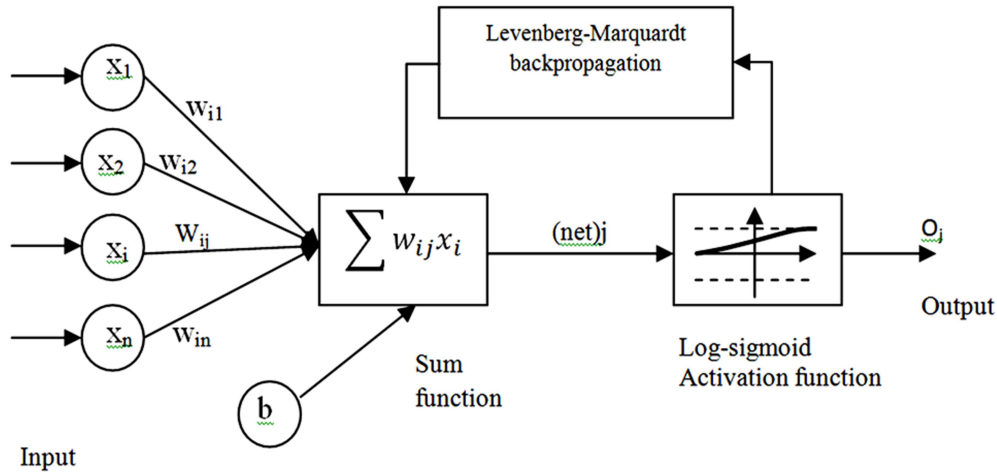
(الف)



(ب)

شکل ۳-۵- نحوه‌ی قرارگیری شیار در دو حالت الف) تقسیم‌کننده‌ی ترک و ب) توقف‌گر ترک [۲۱]

مک کالوچ و پتس [۲۴] برای اولین بار اعصاب مصنوعی را تعریف نموده و مدل‌های عصبی همانند شکل ۲ را ارائه نمودند. شبکه مورد استفاده مک کالوچ و پتس [۲۴] پایه‌ای برای تقریباً تمامی مدل‌های شبکه‌ی عصبی در



شکل ۲- ساختار کلی یک شبکه عصبی مصنوعی [۲۴]

ورودی $(net)_j$ با استفاده از معادله (۳) به صورت زیر محاسبه می‌شوند:

$$(net)_j = \sum_{i=1}^n W_{ij}x_i + b \quad (3)$$

که در آن $(net)_j$ جمع وزن داده شده به عصب j ام برای ورودی حاصل از لایه قبلی با n عصب، W_{ij} وزن بین عصب j ام در لایه قبلی، x_i خروجی عصب i ام در لایه قبلی [۲۷]، b عدد ثابت به عنوان جمع خروجی و Σ تابع جمع است.

عملگر، تابعی است که ورودی خالص حاصل از تابع جمع را پروسه کرده و خروجی عصبی را تعیین می‌کند. معمولاً برای مدل‌های انتشار رو به جلو (Feed forward) چند لایه، عملگر سیگموئید استفاده می‌شود. خروجی عصب j ام با استفاده از معادله (۴) توسط عملگر سیگموئید به صورت زیر محاسبه می‌شود:

$$O_j = f(net)_j = \frac{1}{1 + e^{-\alpha(net)_j}} \quad (4)$$

که α ثابتی است که جهت کنترل شیب ناحیه شبه خطی استفاده می‌شود. غیرخطی بودن سیگموئید در هر لایه بجز لایه ورودی فعال می‌شود [۲۷]. عملگر ارائه شده توسط معادله (۴) خروجی‌ها را به صورت $(0,1)$ می‌دهد. در صورت لزوم، خروجی این تابع می‌تواند به صورت $(-1,1)$ تنظیم شود. وقتی که عملگر سیگموئید به صورت تابع پیوسته‌ای ارائه می‌شود، معمولاً به صورت

آینده شد. پس از آن، روزنبلات [۲۵] ماشینی را طراحی نموده و نام آن را پرسپترون گذاشت که همانند ذهن انسان عمل می‌نمود. پرسپترون‌های روزنبلات [۲۵] شامل واحدهای حسی بودند که به تک لایه‌ای از اعصاب مک کالوچ و پتس [۲۴] متصل می‌شدند. راملهارت و همکاران [۲۶] الگوریتم یادگیری برای شبکه‌های پرسپترون ایجاد نمودند که دارای واحدهای مخفی بود. الگوریتم یادگیری آنها بازگشت به عقب (Back Propagation) نامیده می‌شود و هم اینک پرکاربردترین الگوریتم یادگیری است. در نتیجه‌ی این مطالعات، به همراه پیشرفت در علوم کامپیوتر، استفاده از شبکه‌های عصبی از سال ۱۹۸۰ به بعد کاربرد فزاینده‌ای یافت [۲۷].

همان‌گونه که در شکل ۲ دیده می‌شود، یک عصب مصنوعی از ۵ قسمت اصلی تشکیل شده است: ورودی‌ها، وزن‌ها، تابع جمع، عملگر و خروجی‌ها. ورودی‌ها اطلاعاتی هستند که از اعصاب دیگر یا دنیای خارج وارد می‌شوند. وزن‌ها، مقادیری هستند که نتیجه یک مجموعه ورودی یا جزء فرآیندی دیگری در لایه قبلی را روی این جزء فرآیند بیان می‌کنند. تابع جمع، تابعی است که اثر ورودی‌ها و وزن‌ها بر کل اجزای فرآیند را محاسبه می‌کنند. این تابع، ورودی خالصی که به عصب می‌رسد را محاسبه می‌نماید [۲۸]. جمع‌های وزن داده شده‌ی اجزای

شده در این مقاله را به طور نمونه نشان می‌دهد. در این کار، الگوریتم آموزشی انتشار رو به جلو- بازگشت به عقب استفاده شد. این الگوریتم که یکی از پرکاربردترین الگوریتم‌های موجود برای آموزش پرسپترون‌های چندلایه است، گرادیانی نزولی است که برای حداقل نمودن خطای موجود در یک الگوی آموزشی با تنظیم وزن‌ها در زمانی کوتاه مورد استفاده قرار می‌گیرد [۲۹]. از تابع فعال‌سازی تانژانت سیگموئید در لایه‌های مخفی و نورون‌های لایه خروجی استفاده شد. سرعت‌های مقدار حرکت و یادگیری تعیین شده و مدل‌ها با تکرارهای زیاد و سقف ۱۰۰۰ تکرار، آموزش داده شدند. آموزش مدل‌های پیشنهادی بر پایه‌ی شبکه‌های عصبی مصنوعی زمانی متوقف گردید که مقدار خطای مطلق به حداقل برسد. جدول ۳ مشخصات پارامترهای در نظر گرفته در مدل‌سازی‌های صورت گرفته در این مقاله را نشان می‌دهد.

کارایی یک مدل بر پایه شبکه‌های عصبی مصنوعی به ساختار شبکه و تنظیم پارامترهای آن بستگی دارد. یکی از مشکلات موجود در زمینه‌ی مدل‌سازی با شبکه‌های عصبی مصنوعی یافتن ساختار بهینه با استفاده از تعیین تعداد بهینه‌ی لایه‌های مخفی و نورون‌ها است که فقط می‌تواند توسط سعی و خطا پیگیری شود. همچنین تنظیم اولیه‌ی وزن‌ها و پارامترهای مربوطه می‌تواند به مقدار زیادی بر کارایی مدل‌های پیشنهادی اثرگذار باشد. با این حال، هنوز فرآیندی مشخص و تعریف شده‌ای برای به دست آوردن شبکه‌ی بهینه و تنظیم پارامترهای مربوطه از طریق سعی و خطا وجود ندارد. به همین جهت این فرآیند می‌تواند بسیار وقت‌گیر باشد [۳۰]. در این مقاله، از جعبه‌ابزار Neural Networks موجود در نرم‌افزار Matlab جهت مدل‌سازی‌های پیشنهادی استفاده شد. برای غلبه بر مشکلات ذکر شده در فرآیند بهینه‌سازی، برنامه‌ای در Matlab ایجاد شده است که در آن تعداد لایه‌های مختلف و نورون‌های متفاوت در هر لایه‌ی مخفی امتحان می‌شوند و هرگاه مقدار خطای ریشه‌ی مجموع

غیرخطی تعریف می‌شود چرا که مشتق‌های آن را می‌توان به سادگی نسبت به متغیر z (net) تعیین نمود [۲۷]. انتشار لونبرگ-مارکوئردت (Levenberg-Marquardt Back Propagation)، اغلب سریع‌ترین الگوریتم انتشار موجود است و به عنوان اولین انتخاب در حل مسائل قویاً توصیه می‌شود اگرچه نسبت به الگوریتم‌های دیگر به حافظه بیشتری نیاز دارد [۲۹].

۴- پارامترهای شبکه‌های عصبی مصنوعی مورد استفاده در مدل‌سازی انرژی ضربه‌ی فولادهای مرتبه‌ای

در این تحقیق، مدل‌های ایجاد شده بر پایه‌ی شبکه‌های عصبی دارای شش نورون در لایه ورودی و یک نورون در لایه خروجی بودند. مقادیر لایه‌های ورودی عبارتند از نوع فولاد مرتبه‌ای (F)، وضعیت ترک (C)، ضخامت ناحیه‌ی مرتبه‌ای آلفا (A)، ضخامت ناحیه‌ی مرتبه‌ای گاما (G)، فاصله شیار تا لایه‌ی بینیتی یا مارتنزیتی (D) و دما (T). مقدار لایه خروجی برابر انرژی ضربه (CVN) در دماهای مختلف آزمون در نظر گرفته شد. محدوده‌ی داده‌های ورودی و خروجی به همراه مشخصات آماری آنها در جدول ۱ نشان داده شده است. در مجموع شش مدل با تعداد لایه‌های مخفی و نورون‌های متفاوت در نظر گرفته شد. جدول ۲ مدل‌های پیشنهاد شده در این مقاله را به همراه تعداد لایه‌های مخفی و نورون‌های آنها نشان می‌دهد. از مجموع آزمایش‌های صورت گرفته، ۱۴۰ سری داده جمع‌آوری شده و به طور تصادفی در هر مدل‌سازی به ۹۸، ۲۱ و ۲۱ سری تقسیم‌بندی گردید و در نهایت با استفاده از هر شش مدل پیشنهادی به ترتیب آموزش داده شده، ارزیابی گردیده و امتحان شدند. نورون‌های لایه‌های مجاور کاملاً توسط وزن‌ها ارتباط دارند. سرانجام، نورون‌های لایه‌ی خروجی، پیش‌بینی را به عنوان نتیجه انجام می‌دهند. شکل ۳، ساختار یکی از مدل‌های ارائه

جدول ۱- محدوده‌ی داده‌های ورودی و خروجی به همراه مشخصات آماری آنها

مشخصات آماری	نوع فولاد مرتبه‌ای (F)	وضعیت ترک (C)	ضخامت ناحیه‌ی مرتبه‌ای آلفا (A)	ضخامت ناحیه‌ی مرتبه‌ای گاما (G)	فاصله‌ی شیار تا لایه‌ی بینیتی یا مارتنزیتی (D)	دما (T)	انرژی ضربه (CVN)
حداقل (Minimum)	۱	۳	۱۲۳	۰	۰	۲	۹
حداکثر (Maximum)	۲	۴	۵۷۳	۱۰	۷/۴	۸/۵	۱۳۵
میانگین (Average)	۱/۴	۳/۹	۳۴۸	۲/۷	۳	۶	۸۰/۷
محدوده (Range)	۱	۱	۴۵۰	۱۰	۷/۴	۶/۵	۱۲۶
میانه (Median)	۱	۴	۳۴۸	۲	۳/۵	۵/۹	۸۵/۵
واریانس (Variance)	۰/۲	۰/۱	۲۰۷۷۳/۴	۱۰	۶/۷	۵	۱۵۴۷/۹
درجه اوج (Kurtosis)	-۱/۶۶	۲/۲۹	-۱/۲۳	۱/۳۲	-۱/۴۴	-۱/۳۲	-۱/۲۹
چولگی (Skewness)	۰/۶	-۲/۰۶	۰	۱/۶۱	۰/۰۴	-۰/۲۳	-۰/۳۴
انحراف استاندارد (Standard deviation)	۰/۴۸	۰/۳۵	۱۴۴/۱۳	۳/۱۶	۲/۶	۲/۲۳	۳۴/۳۹
خطای استاندارد (Standard error)	۰/۰۴	۰/۰۳	۱۲/۱۸	۰/۲۷	۰/۲۲	۰/۱۹	۳/۳۲

جدول ۲- مدل‌های پیشنهادی به همراه تعداد لایه‌های مخفی و نورون‌های آنها

مدل	تعداد لایه‌های مخفی	تعداد نورون‌های لایه‌ی اول	تعداد نورون‌های لایه‌ی دوم	تعداد تکرار مدل‌سازی جهت کسب نتیجه‌ی بهینه
ANN-I	۱	۱۰	۶	۳۵۴
ANN-II	۱	۱۴	۱۰	۵۸۹
ANN-III	۱	۱۶	۱۲	۴۲۳
ANN-IV	۲	۱۰	۶	۲۹۲
ANN-V	۲	۱۴	۱۰	۱۰۶
ANN-VI	۲	۱۶	۱۲	۱۹۹

آزمایش با استفاده از مربع ضریب همبستگی (R^2)، درصد خطای مطلق میانگین (Mean absolute percentage error, MAPE)، خطای ریشه‌ی مجموع مربعات (RMSE) و p-مقدار مورد بررسی قرار گرفت. مقادیر R^2 ، MAPE و RMSE را به ترتیب می‌توان از روابط (۵)، (۶) و (۷) به دست آورد [۲۹]:

$$R^2 = 1 - \left(\frac{\sum_i (t_i - o_i)^2}{\sum_i (o_i)^2} \right) \quad (۵)$$

$$MAPE = \frac{1}{n} \sum_i \left| \frac{t_i - o_i}{t_i} \right| \times 100 \quad (۶)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_i (t_i - o_i)^2} \quad (۷)$$

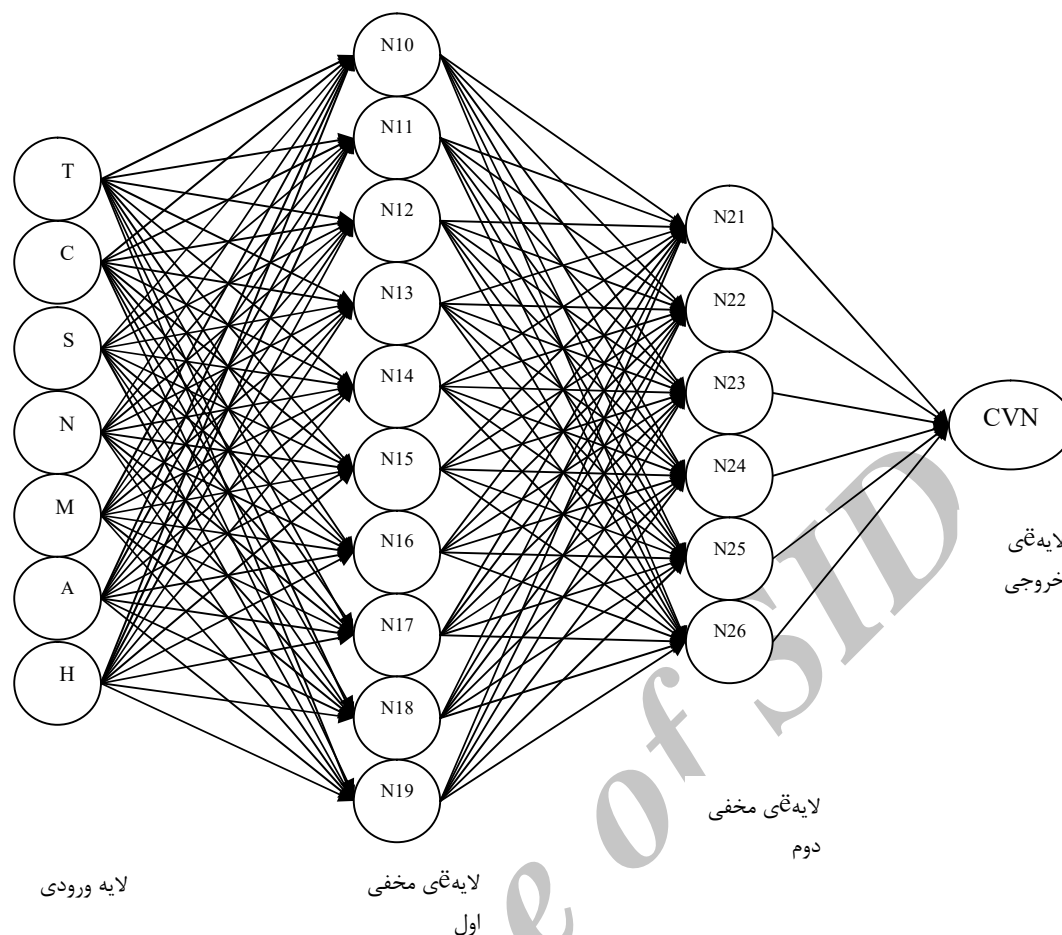
که در روابط فوق t ، o و n به ترتیب مقدار هدف، مقدار خروجی و تعداد داده‌های مورد استفاده در هر یک از

مربعات (Root Mean Squared Error) در هر سه فاز آموزش، ارزیابی و آزمایش به حداقل خود برسد، مدل‌سازی کامل خواهد شد. از آنجایی که در هر بار مدل‌سازی با تعداد لایه‌ها و نورون‌های مشخص، داده‌های مختلفی مورد آموزش قرار می‌گیرند، از بین آنها نیز زمانی انتخاب مدل بهینه صورت خواهد گرفت که بالاترین کارایی حاصل شود.

۵-ارائه بحث و نتایج حاصل از مدل‌سازی

با شبکه‌های عصبی مصنوعی

در این مقاله کارایی مدل‌های پیشنهادی بر پایه‌ی شبکه‌های عصبی مصنوعی در مراحل آموزش، ارزیابی و



شکل ۲- ساختار مدل‌های عصبی ANN-I و ANN-III


p -مقدار هر یک از مدل‌ها در مراحل آموزش، ارزیابی و آزمایش به دست آمد.

شکل‌های ۴ الی ۹ تمام نتایج حاصل از مراحل آموزش، ارزیابی و آزمایش توسط شش مدل پیشنهادی به همراه خطای حاصل را نشان می‌دهند. جدول ۳ نیز مقادیر R^2 ، MAPE، RMSE و p -مقدار را برای مراحل آموزش، ارزیابی و آزمایش شش مدل پیشنهادی نشان می‌دهد. شکل‌های ۴ الی ۹ نشان می‌دهند که هر شش مدل پیشنهادی توانایی پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای مورد بررسی در دماهای آزمایش شده را دارند. همچنین p -مقدارهای جدول ۴ نشان می‌دهند که تمامی مدل‌ها به خوبی آموزش داده شده و خطاهای ایجاد شده در مراحل ارزیابی و آموزش از نظر آماری چندان با اهمیت نیستند.


جدول ۲- پارامترهای مورد استفاده در مدل‌های عصبی پیشنهادی

پارامتر	مقدار
تعداد لایه‌های ورودی	۶
تعداد لایه‌های خروجی	۱
سرعت اندازه‌ی حرکت	۰/۸۸
سرعت یادگیری	۰/۷۰
خطای بعد از یادگیری	۰/۰۰۰۰۵۰
چرخه‌ی یادگیری	۳۰/۰۰۰


مراحل آموزش، ارزیابی و آزمایش هستند. برای محاسبه p -مقدار، ابتدا توسط برنامه Microsoft Excel برای هر سری از خروجی‌ها مقدار آزمون t به دست آمد. سپس با مراجعه به وبسایت زیر: <http://graphpad.com/quickcalcs/PValue1.cfm>



(الف)




(ب)




(پ)


شکل ۴- ارتباط بین مقادیر انرژی ضربه‌ی عملی و اندازه‌گیری شده به همراه اختلاف آنها در الف) فاز آموزش، ب) فاز ارزیابی و پ) فاز آزمایش مدل ANN-I



(الف)




(ب)




(پ)


شکل ۵- ارتباط بین مقادیر انرژی ضربه‌ی عملی و اندازه‌گیری شده به همراه اختلاف آنها در الف) فاز آموزش، ب) فاز ارزیابی و پ) فاز آزمایش مدل ANN-II



(الف)




(ب)




(پ)


شکل ۶- ارتباط بین مقادیر انرژی ضربه‌ی عملی و اندازه‌گیری شده به همراه اختلاف آنها در (الف) فاز آموزش، (ب) فاز ارزیابی و (پ) فاز آزمایش مدل ANN-III



(الف)




(ب)




(پ)


شکل ۷- ارتباط بین مقادیر انرژی ضربه‌ی عملی و اندازه‌گیری شده به همراه اختلاف آنها در (الف) فاز آموزش، (ب) فاز ارزیابی و (پ) فاز آزمایش مدل ANN-IV



(الف)




(ب)




(پ)


شکل ۸- ارتباط بین مقادیر انرژی ضربه‌ی عملی و اندازه‌گیری شده به همراه اختلاف آنها در الف) فاز آموزش، ب) فاز ارزیابی و پ) فاز آزمایش مدل ANN-V



(الف)



(ب)



(پ)

شکل ۹- ارتباط بین مقادیر انرژی ضربه‌ی عملی و اندازه‌گیری شده به همراه اختلاف آنها در (الف) فاز آموزش، (ب) فاز ارزیابی و (پ) فاز آزمایش مدل ANN-VI

جدول ۴- مقادیر R^2 ، MAPE و RMSE به همراه p-مقدار مدل‌های پیشنهادی در فازهای آموزش، ارزیابی و آزمایش


مدل	R^2			MAPE			RMSE			p-مقدار		
	آموزش	ارزیابی	آزمایش	آموزش	ارزیابی	آزمایش	آموزش	ارزیابی	آزمایش	ارزیابی	آزمایش	
ANN-I	۰/۹۹۳۱	۰/۸۹۴۳	۰/۹۹۵۷	۷/۸۵۸۱	۸/۹۷۸۵	۱۸/۲۴۳۳	۷/۸۱۴۶	۶/۶۶۳۹	۱۲/۱۱۱۲	۰/۷۶۰۹	۰/۶۸۷۱	۰/۹۹۴۱
ANN-II	۰/۹۹۴۹	۰/۹۹۲۷	۰/۹۹۲۳	۵/۲۵۸۳	۹/۵۱۶۵	۱۱/۰۴۳۴	۶/۲۳۴۰	۷/۷۵۵۹	۱۳/۵۶۲۱	۰/۷۹۹۷	۰/۷۱۷۸	۰/۸۸۲۵
ANN-III	۰/۹۹۶۸	۰/۹۳۶۵	۰/۹۶۷۹	۴/۴۸۰۷	۹/۶۲۱۰	۸/۵۳۹۲	۴/۸۱۹۳	۱۱/۸۱۲۵	۱۰/۵۳۳۴	۰/۹۸۵۳	۰/۷۳۲۶	۰/۹۴۳۷
ANN-IV	۰/۹۹۹۹	۰/۹۹۱۹	۰/۸۴۴۶	۱/۰۳۹۶	۱/۵۴۲۹	۵/۶۹۸۹	۰/۸۳۷۳	۸/۷۲۱۳	۵/۳۴۶۸	۰/۷۲۲۲	۰/۷۲۵۴	۰/۸۵۵۰
ANN-V	۱/۰۰۰۰	۰/۹۹۸۲	۰/۹۹۵۵	۰/۶۱۷۵	۴/۴۶۶۶	۱۰/۹۴۶۲	۰/۵۴۸۲	۳/۴۳۴۷	۵/۲۷۱۶	۰/۶۶۵۲	۰/۸۵۴۰	۰/۹۴۴۹
ANN-VI	۰/۹۹۸۷	۰/۹۸۹۷	۰/۸۹۲۶	۰/۵۷۵۳	۱۱/۰۵۳۰	۹/۲۲۱۹	۳/۳۲۷۳	۸/۵۰۵۴	۸/۴۶۲۲	۰/۶۷۵۶	۰/۸۸۵۴	۰/۹۰۵۵

و ANN-VI (دارای دو لایه مخفی) کارایی بالاتری نسبت به مدل‌های ANN-I، ANN-II و ANN-III (دارای یک لایه مخفی) است. این نتایج نشان می‌دهند که برای مدل‌سازی انرژی ضربه‌ی فولادهای مرتبه‌ای مورد بررسی در این مقاله، استفاده از دو لایه مخفی در مدل‌سازی باعث ایجاد نتایج بهتری می‌شود. این در حالی است که تأثیر تعداد نورون‌های انتخابی در مقایسه با تعداد لایه‌های مخفی چندان زیاد نیست.


یکی دیگر از روش‌های ارزیابی کارایی مدل‌های پیشنهادی بر پایه‌ی شبکه‌های عصبی مصنوعی، ارائه‌ی نمودارهایی است که در آن نسبت مقدار عملی یک ویژگی مدل شده به مقدار پیشنهادی آن برای تمام داده‌های موجود در فازهای آموزش، ارزیابی و آزمایش رسم می‌گردد. شکل‌های ۱۰-الف، ۱۰-ب و ۱۰-پ نسبت انرژی ضربه‌ی عملی به انرژی ضربه‌ی حاصل از مدل‌سازی کلیه‌ی شش مدل پیشنهادی را به ترتیب برای فازهای آموزش، ارزیابی و آزمایش نشان می‌دهند. همان‌گونه که مشخص است، کلیه‌ی مدل‌های ارائه شده در این مقاله به خوبی توانسته‌اند مقادیر انرژی ضربه‌ی فولادهای مرتبه‌ای را در دماهای مختلف آزمایش پیش‌بینی نمایند. این امر به خصوص در مورد مدل‌های دارای دو لایه مخفی (یعنی ANN-IV، ANN-V و ANN-VI) مشهود است. به طور کلی، نتایج و بررسی کارایی مدل‌های پیشنهادی نشان می‌دهند که به خوبی می‌توان انرژی ضربه‌ی فولادهای مرتبه‌ای را در دماهای مختلف توسط مدل‌های بر پایه‌ی شبکه‌های عصبی مصنوعی پیش‌بینی نمود.

بهترین مقادیر R^2 ، MAPE و RMSE در مدل‌های پیشنهادی مطابق جدول ۴ به ترتیب برابر ۱، ۰/۶۱۷۵ و ۰/۵۴۸۲ همگی در فاز آموزش مدل ANN-V هستند. نامناسب‌ترین مقادیر R^2 ، MAPE و RMSE در مدل‌های پیشنهادی مطابق جدول ۴ به ترتیب برابر ۰/۸۴۴۶، ۱۸/۲۴۳۳ و ۱۳/۵۶۲۱ هستند. این مقادیر به ترتیب مربوط فاز آزمایش مدل‌های ANN-I، ANN-IV و ANN-II هستند. کلیه مقادیر به دست آمده‌ی R^2 ، MAPE و RMSE در مدل‌های پیشنهادی نشان می‌دهند که کلیه‌ی آنها به خوبی آموزش دیده و توانایی پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای در محدوده‌ی مورد بررسی در این مقاله را دارند.


با توجه به جدول ۴ و مقادیر ماکزیمم و مینیمم R^2 ، MAPE و RMSE می‌توان گفت که بهترین مدل پیشنهادی، مدل ANN-V با R^2 ، MAPE و RMSE به ترتیب برابر ۱، ۰/۶۱۷۵ و ۰/۵۴۸۲ در فاز آموزش، ۰/۹۹۸۲، ۴/۴۶۶۶ و ۳/۴۳۴۷ در فاز ارزیابی و ۰/۹۹۵۵، ۱۰/۹۴۶۲ و ۵/۲۷۱۶ در فاز آزمایش است. اگرچه مقدار RMSE در فاز آزمایش مدل‌های ANN-III، ANN-IV و ANN-VI کمتر از مقدار مربوطه در مدل ANN-V است، اما از آنجایی که به غیر از مورد ذکر شده تمام مقادیر نشان‌دهنده‌ی کارایی این مدل بهتر از سایر مدل‌های پیشنهادی است، می‌توان این مدل را به عنوان مدل بهینه معرفی نمود. مدل ANN-V دارای دو لایه مخفی و به ترتیب ۱۴ و ۱۰ نورون در لایه‌های مخفی اول و دوم است. به طور کلی مدل‌های ANN-IV، ANN-V



(الف)



(ب)



(پ)

شکل ۱۰- کارایی مدل‌های پیشنهادی برحسب نسبت انرژی ضربه‌ی عملی به انرژی ضربه‌ی پیش‌بینی شده‌ی فولادهای مرتبه‌ای در الف) فاز آموزش، ب) فاز ارزیابی و پ) فاز آزمایش

۶- نتیجه‌گیری

در مقاله‌ی حاضر، شش مدل بر پایه‌ی شبکه‌های عصبی مصنوعی جهت پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای در دماهای مختلف ارائه شد. تفاوت مدل‌ها در تعداد لایه‌های مخفی و نورون‌های موجود در این لایه‌ها بود. نتایج حاصل نشان دادند که بهترین مدل، دارای دو لایه‌ی مخفی و به ترتیب ۱۴ و ۱۰ نورون در لایه‌های مخفی اول و دوم با R^2 ، MAPE و RMSE به ترتیب برابر ۱، ۰/۶۱۷۵ و ۰/۵۴۸۲ در فاز آموزش، ۰/۹۹۸۲، ۰/۹۹۵۵ و ۰/۹۴۶۲ و ۵/۲۷۱۶ در فاز آزمایش است. از طرف دیگر بهترین مقادیر R^2 ، MAPE و RMSE در مدل‌های پیشنهادی به ترتیب برابر ۱، ۰/۶۱۷۵ و ۰/۵۴۸۲ همگی در فاز آموزش این مدل بودند. بنابراین می‌توان پیشنهاد نمود که ارائه‌ی مدل‌هایی با دو لایه‌ی مخفی می‌تواند راهکار مناسبی برای پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای در دماهای مختلف باشد.

در مقاله‌ی حاضر، شش مدل بر پایه‌ی شبکه‌های عصبی مصنوعی جهت پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای در دماهای مختلف ارائه شد. تفاوت مدل‌ها در تعداد لایه‌های مخفی و نورون‌های موجود در این لایه‌ها بود. نتایج حاصل نشان دادند که بهترین مدل، دارای دو لایه‌ی مخفی و به ترتیب ۱۴ و ۱۰ نورون در لایه‌های مخفی اول و دوم با R^2 ، MAPE و RMSE به ترتیب برابر ۱، ۰/۶۱۷۵ و ۰/۵۴۸۲ در فاز آموزش، ۰/۹۹۸۲، ۰/۹۹۵۵ و ۰/۹۴۶۲ و ۵/۲۷۱۶ در فاز آزمایش است. از طرف دیگر بهترین مقادیر R^2 ، MAPE و RMSE در مدل‌های پیشنهادی به ترتیب برابر ۱، ۰/۶۱۷۵ و ۰/۵۴۸۲ همگی در فاز آموزش این مدل بودند. بنابراین می‌توان پیشنهاد نمود که ارائه‌ی مدل‌هایی با دو لایه‌ی مخفی می‌تواند راهکار مناسبی برای پیش‌بینی انرژی ضربه‌ی فولادهای مرتبه‌ای در دماهای مختلف باشد.

۷- مراجع

- [1] Sankar, B.V. (2001). An elasticity solution for functionally graded beams, *Composites Science and Technology* (Elsevier), Vol. pp. 689–696.
- [2] Li, H., Lambros, J., Cheeseman, B.A., Santare, M.H. (2000). Experimental investigation of the quasi-static fracture of functionally graded materials, *International Journal of Solids and Structures*, Vol. 37, pp. 3715-3732, 2000.
- [3] Nagata, F. (1999). Intelligent modelling mechanisms and design concepts of FGMs in natural composites, *Materials Science Forum*, Vol. 308-311, pp. 331-337.
- [4] Gibson, R.E. (1967). Some results concerning displacements and stresses in a nonhomogeneous elastic half space, *Geotechnique*, Vol. 17, pp. 58-67.
- [5] Ferrari, M., Rooney, F., Nadeau, J.C., (1999). Optimal FGMs and plain awful composites, *Materials Science Forum*, Vol. 308-311, pp. 989-994.
- [6] Aghazadeh, J.-M., Shahosseini, M.H. (2005). Transformation Characteristics of Functionally Graded Steels Produced By Electrosag Remelting, *Metallurgical and Materials Transactions A* (Springer), Vol. 36A, pp. 3471-3476.
- [7] Nazari, A., Aghazadeh, J.-M. (2010). Modelling impact resistance of functionally graded steels with crack divider configuration, *Materials Science and Technology* (Maney), Vol. 26, pp. 1377-1383.
- [8] Nazari, A., Aghazadeh, J.-M., Hamid, M.-V., Abedi, M. (2011). Simulation of impact energy in functionally graded steels, *Computational Materials Science* (Elsevier), Vol. 50, pp. 1187–1196.
- [9] Nazari, A., Aghazadeh, J.-M., Riahi, S. (2011). Modeling fracture toughness of functionally graded steels in crack arrester configuration, *Computational Materials Science* (Elsevier), Vol. 50, pp. 1578–1586.
- [10] Pala, M., Ozbay, O., Oztas, A., Yuce, M.I. (2005). Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural networks, *Construction and Building Materials* (Elsevier) Vol. 21, pp. 384–394.
- [11] Akkurt, S., Ozdemir, S., Tayfur, G., Akyol, B. (2003). The use of GA-ANNs in the modelling of compressive strength of cement mortar, *Cement and Concrete Research* (Elsevier), Vol. 33, pp. 973–979.
- [۱۲] شفاابخش، غ، نادرپور، ح، فصیحی، ف. (۱۳۸۹). انتخاب الگوریتم بهینه شبکه عصبی در تحلیل روسازی های انعطاف پذیر راه ها، *مجله مدل سازی در مهندسی، دانشگاه سمنان، سال هشتم، شماره ۲۱*.
- [13] Nazari, A., Pacheco-Torgal, F. (2012). Predicting compressive strength of different geopolymers by artificial neural networks, *Ceramics International* (Elsevier), DOI:

- 10.1016/j.ceramint.2012.08.070.
- [14] Nazari, A., Sedghi, A., Didehvar, N. (2012) Modeling impact resistance of aluminum-epoxy laminated composites by artificial neural networks, *Journal of Composite Materials* (sage), Vol. 46, pp. 1593–1605.
- [15] Bohlooli, H., Nazari, A., Kaykha, M.M. (2012) Microhardness profile prediction of functionally graded steels by artificial neural networks, *International Journal of Damage Mechanics* (Sage), Vol. 21, pp. DOI: 10.1177/1056789511432653.
- [16] Topcu, I.B., Saridemir, M. (2008). Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic, *Computational Materials Science* (Elsevier) Vol. 42, pp. 74–82.
- [17] Dias, W.P.S., Pooliyadda, S.P. (2001). Neural networks for predicting properties of concretes with admixtures, *Construction and Building Materials* (Elsevier), Vol. 15, pp. 371–379.
- [18] Bai, J., Wild, S., Ware, J.A., Sabir, B.B. (2003). Using neural networks to predict workability of concrete incorporating metakaolin and fly ash, *Advances in Engineering Software*, Vol. 34, pp. 663–669.
- [19] Lai, S., Serra, M. (1997) Concrete strength prediction by means of neural network, *Construction and Building Materials* (Elsevier), Vol. 11, pp. 93–98.
- [20] Sebastia, M., Olmo, I.F., Irabien, A. (2003). Neural network prediction of unconfined compressive strength of coal fly ash–cement mixtures, *Cement and Concrete Research*, Vol. 33, pp. 1137–1146.
- [21] Nazari, A., Milani, A.A. (2011), Modeling ductile to brittle transition temperature of functionally graded steels by fuzzy logic, *Journal of Materials Science* (Springer), Vol. 46, pp. 6007–6017.
- [22] Mukherjee, A. Biswas, S.N. (1997). Artificial neural networks in prediction of mechanical behavior of concrete at high temperature, *Nuclear Engineering Design* (Elsevier), Vol. 178, pp. 1–11.
- [23] Ince, R. (2004). Prediction of fracture parameters of concrete by artificial neural networks, *Engineering Fracture Mechanics* (Elsevier), Vol. 71, pp. 2143–2159.
- [24] McCulloch, W.S., Pitts, W. (1943). A logical calculus of the ideas immanent in neural nets, *Bulletin of Mathematics Biophysics*, Vol. 5, pp. 115–137.
- [25] Rosenblatt, F. (1962). *Principles of neuro dynamics: perceptrons and the theory of brain mechanisms*, Washington, DC, Spartan Book.
- [26] Rumelhart, D.E., Hinton, G.E., William, R.J. (1986). Learning internal representation by error propagation, In: Rumelhart DE, McClelland JL, editors. *Proceeding parallel distributed processing foundation*, Vol. 1. Cambridge: MIT Press.
- [27] Liu, S.W., Huang, J.H., Sung, J.C., Lee, C.C. (2002). Detection of cracks using neural networks and computational mechanics, *Computer Methods in Applied Mechanics and Engineering* (Elsevier), Vol. 191, pp. 2831–2845.
- [28] Anderson, J.A. (1983). Cognitive and psychological computation with neural models, *IEEE Transactions on Systems and Manufacturing Cybernetics*, V.SMC-13, Vol. 5, pp. 799–814.
- [29] Suratgar, A.A., Tavakoli, M.B., Hoseinabadi, A. (2005). Modified Levenberg–Marquardt method for neural networks training, *World Academy of Science, Engineering and Technology*, Vol. 6, pp. 46–48.
- [30] Guzelbey, I.H., Cevik, A., Erklig, A. (2006). Prediction of web crippling strength of cold-formed steel sheetings using neural Networks, *Journal of Constructional Steel Research* (Elsevier), Vol. 62, pp. 962-973.