

## بهینه‌سازی چند هدفی شبکه‌های عصبی نوع GMDH برای مدلسازی و پیش‌بینی عمر خستگی کامپوزیت‌های GRP

کاوه سلملیان\*<sup>۱</sup>، مجید سلیمانی<sup>۲</sup>

۱- دانشگاه آزاد اسلامی، واحد لنگرود، گروه مکانیک، لنگرود، ایران.

۲- دانشگاه آزاد اسلامی، واحد لاهیجان، گروه مکانیک، لاهیجان، ایران

### چکیده

در این مقاله از الگوریتم تکاملی NSGA-II برای طراحی بهینه‌ای چند هدفی شبکه‌های عصبی نوع GMDH، به منظور مدلسازی و پیش‌بینی عمر خستگی کامپوزیت‌های تک‌جهته GRP توسط داده‌های آزمایشگاهی، استفاده شده است. مهمترین توابع هدف متضاد موجود در شبکه‌های عصبی نوع GMDH، خطای آموزش (TE)، خطای پیش‌بینی (PE) و تعداد نرون‌ها (N) می‌باشند. بهینه‌سازی دو هدفی برای همه ترکیب‌های دوتایی از این توابع هدف و سپس بهینه‌سازی سه هدفی با در نظر گرفتن هر سه تابع هدف به طور همزمان انجام شده است. در هر کدام از این بهینه‌سازی‌ها، جبهه‌های پارتوی بهینه به دست آمده‌اند که در واقع مصالحه بین توابع هدف مربوطه را نشان می‌دهند. نتایج بهینه‌سازی سه هدفی شامل نتایج بهینه‌سازی دو هدفی نیز می‌شود و بدین ترتیب انتخاب‌های بهینه بیشتری از مدل‌های شبکه عصبی GMDH، برای طراحی چند هدفی شبکه‌های عصبی از نقطه نظر خطای آموزش کمینه، خطای پیش‌بینی کمینه و پیچیدگی ساختار کمینه به دست می‌آید.

**کلمات کلیدی:** خستگی، کامپوزیت‌های تک‌جهته GRP، شبکه عصبی نوع GMDH، بهینه‌سازی چند هدفی، پارتو.

### ۱ مقدمه

از کامپوزیت‌های GRP به طور گسترده در ساخت سازه‌های غیر نظامی مثل بدنه پل‌ها، پره توربین‌های بادی، فنرهای برگی وسایل نقلیه، قایق‌های تفریحی و بسیاری دیگر از این سازه‌ها استفاده می‌شود. بعضی از این سازه‌ها مثل فنرهای برگی، اغلب تحت بارهای نوسانی یا ارتعاشاتی قرار می‌گیرند که ممکن است، در نهایت منجر به از کار افتادگی یا شکست خستگی آن سازه شود، بنابراین طراحی چنین سازه‌هایی در برابر شکست خستگی بسیار لازم به نظر می‌رسد. برای مواد هموزن مثل فلزات، اکثر روش‌های موجود طراحی در برابر آسیب خستگی، بر مبنای رشد یک ترک خاص است که در نهایت منجر به شکست نهایی سازه فلزی می‌شود ولی

\* عهده دار مکاتبات

آدرس الکترونیکی: kavhsalmalian@iaul.ac.ir

مکانیزم خستگی در کامپوزیت‌ها به علت انواع مختلف خرابی (ترک‌های ماتریسی، جدایش الیاف از ماتریس، شکست الیاف و...) که ممکن است در آن‌ها ایجاد شود، بسیار پیچیده‌تر از فلزات است. روند آسیب خستگی در کامپوزیت‌های تک‌جهته بر مبنای فیزیک و مکانیزم ترک در سه ناحیه ماتریس، فصل مشترک الیاف - ماتریس و الیاف به طور شماتیک در شکل (۱) نشان داده شده است [۱].

به منظور تحلیل دقیق شکست خستگی ورق‌های کامپوزیتی بر مبنای تحلیل لایه به لایه کامپوزیت، توجه کردن به رفتار خستگی تک‌تک لایه‌ها، از اهمیت بالایی برخوردار است. لایه‌های تشکیل دهنده ورق‌های کامپوزیتی معمولاً بارهای خستگی پیچیده‌ای را متحمل می‌شوند که این بارها با تغییرات در دامنه، مقدار متوسط، فرکانس و شکل موج سیکل تنشی در زمان کارکرد کامپوزیت تشخیص داده می‌شوند [۲]. به دلیل عدم وجود یک معیار شکست کاملاً مشخص که بتواند برای پیش‌بینی شکست خستگی کامپوزیت‌ها استفاده شود، آزمایش‌های گسترده‌ای باید بر روی کامپوزیت‌های الیافی با زوایای مختلف الیاف و شرایط بارگذاری متعدد انجام شود که دارای هزینه و زمان زیادی می‌باشد، بنابراین نیاز به یک مدل ریاضی بر اساس داده‌های آزمایشگاهی کاملاً محسوس می‌باشد. اخیراً استفاده از شبکه‌های عصبی مصنوعی (ANNs) برای مدلسازی داده‌های آزمایشگاهی رواج پیدا کرده است. مدلسازی با استفاده از شبکه‌های عصبی برای فرآیندهایی که خصوصیات زیر را دارا هستند، مناسب‌تر است: پایگاه داده‌های وسیعی در دسترس باشد، پیدا کردن حل دقیق با استفاده از روش‌های ریاضیاتی موجود برای آن‌ها بسیار مشکل باشد و دسته داده‌ها ناکامل، دارای اغتشاش و پیچیده باشند [۳]. از میان روش‌های مختلف شبکه‌های عصبی، الگوریتم دسته‌بندی داده‌های عددی (GMDH) روش خود سامانده‌ای می‌باشد که توسط آن مدل‌های پیچیده بر مبنای برآورد عملکرد آن‌ها روی زوج داده‌های چندورودی-تک‌خروجی تولید می‌شوند. GMDH اولین بار توسط Ivakhneko به عنوان یک روش تحلیل چند متغیره‌ای برای مدلسازی و شناسایی سیستم‌های پیچیده ابداع شد. هدف اصلی GMDH ایجاد یک تابع تحلیلی بر مبنای تابع انتقال درجه دوم می‌باشد که ضرایب آن با استفاده از روش رگرسیون به دست می‌آیند [۴]. مشکل اساسی در طراحی ساختار شبکه‌های عصبی از جمله نوع GMDH، وجود چند تابع هدف است که با یکدیگر در تضادند [۵]. برای مثال، با افزایش پیچیدگی شبکه، خطای مدلسازی کاهش می‌یابد ولی به علت ایجاد مساله Overfitting، توانایی پیش‌بینی شبکه کم می‌شود. بنابراین شبکه‌های عصبی نوع GMDH باید از دید تمامی توابع هدف (خطای مدلسازی، خطای پیش‌بینی و تعداد نرون‌ها که نشان دهنده پیچیدگی شبکه می‌باشد) به طور همزمان بهینه گردند [۶]. در مسایل بهینه‌سازی چند هدفی، توابع هدف متعددی وجود دارند که باید به طور همزمان بهینه شوند. بنابراین یک جواب بهینه وجود ندارد، بلکه مجموعه‌ای از جواب‌های بهینه به نام جواب‌های بهینه شده Pareto ارایه می‌گردند. این تفاوت اساسی بین بهینه‌سازی چند هدفی و تک‌هدفی می‌باشد و طراح با توجه به نیاز و اهمیتی که برای توابع هدف خاص قایل است، یکی از بردارهای طراحی را انتخاب می‌کند. استفاده از ANN برای پیش‌بینی مقاومت خستگی کامپوزیت‌های APC-2 graphit-PEEK توسط Serra و Aymerich انجام شده است که در منبع [۷] آمده است. کامپوزیت‌های تقویت شده با الیاف کربن و شیشه توسط Lee و همکارانش [۸] مورد استفاده قرار گرفته است تا عملکرد ANN در پیش‌بینی شکست

خستگی ورق‌های کامپوزیتی تحت نسبت‌های تنش‌ی متعدد بررسی شود. از ANN برای پیش‌بینی طول عمر خستگی glass fiber/epoxy تک‌جهته با زوایای الیاف مختلف و شرایط بارگذاری متنوع توسط AI-Assaf و El-Kadi استفاده شده است [۹-۱۲].

در این مقاله، از الگوریتم‌های تکاملی به منظور طراحی بهینه‌ای شبکه‌های عصبی نوع GMDH، برای مدل‌سازی و پیش‌بینی عمر خستگی کامپوزیت‌های تک‌جهته GRP استفاده شده است. بدین منظور از الگوریتم تکاملی چند هدفی NSGA-II با مکانیزم حفظ تنوع ژنتیکی جدید که توسط بعضی از مولفین اخیراً ارائه شده است [۱۳ و ۱۴]، برای بهینه‌سازی پارتویی چنین شبکه‌های عصبی GMDH استفاده شده است. مهمترین توابع هدف موجود در شبکه‌های عصبی نوع GMDH که با یکدیگر در تضادند، خطای آموزش (TE)، خطای پیش‌بینی (PE) و تعداد نرون‌ها (N) هستند. تعداد کل داده‌های آزمایشگاهی ۷۴ مجموعه داده می‌باشد که از ۵۰ دسته داده برای برآورد خطای آموزش (TE) و از ۲۴ دسته داده باقیمانده برای ارزیابی خطای پیش‌بینی (PE) استفاده شده است. زوج‌های مختلفی از این توابع هدف، (TE-PE)، (N-TE) و (N-PE) برای بهینه‌سازی دو هدفی پارتویی مدل‌های شبکه عصبی GMDH انتخاب شده‌اند. علاوه بر این، هر سه تابع هدف ذکر شده در یک فرآیند بهینه‌سازی سه هدفی مورد استفاده قرار گرفته‌اند که در نتیجه مجموعه پارتویی کاملی از جواب‌های بهینه مدل‌های GMDH ایجاد می‌شود که می‌توان یکی از آن‌ها را به عنوان مدل نهایی مناسب برای پیش‌بینی عمر خستگی کامپوزیت‌های تک‌جهته GRP انتخاب کرد.

## ۲ مدل‌سازی با استفاده از شبکه‌های عصبی نوع GMDH

با استفاده از الگوریتم GMDH یک مدل به صورت مجموعه‌ای از نرون‌ها که در لایه‌های متوالی قرار دارند، نمایش داده می‌شود که در آن زوج‌های مختلف از نرون‌های هر لایه، می‌توانند توسط یک چند جمله‌ای درجه دوم به هم متصل شوند و نرون‌های لایه‌های بعدی را بسازند. مساله شناسایی یک سیستم، در واقع پیدا کردن یک تابع مانند  $\hat{f}$  است تا این که بتواند به طور تقریبی به جای تابع واقعی  $f$  استفاده شود، تا برای هر بردار ورودی داده شده  $X = (x_1, x_2, x_3, \dots, x_n)$ ، خروجی  $\hat{f}$  را به خروجی واقعی  $y$  نزدیک کند. بنابراین تعداد  $M$  زوج داده چندورودی-تک خروجی، موجود می‌باشد تا این که:

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}), \quad i = 1, \dots, m \quad (1)$$

حال آموزش شبکه عصبی نوع GMDH، برای پیش‌بینی مقادیر خروجی  $\hat{y}_i$  برای هر بردار ورودی داده شده  $X = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{in})$  امکان‌پذیر است و  $\hat{y}_i$  به صورت زیر نمایش داده می‌شود:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}), \quad i = 1, \dots, m \quad (2)$$

ارتباط بین متغیرهای ورودی و خروجی توسط فرم گسسته و پیچیده سری ولترا ایجاد می‌شود:

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (3)$$

که به عنوان چندجمله‌ای Kolmogorov- Gabor شناخته شده است [۱۵ و ۱۶]. این فرم کامل توصیف ریاضی، می‌تواند توسط یک سیستم شامل چند جمله‌ای‌های درجه دوم جزئی دو متغیره، به شکل زیر نمایش داده شود:

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (4)$$

در این روش، از توصیف‌های درجه دوم جزئی به طور بازگشتی استفاده شده است تا این که یک رابطه ریاضی جامع به شکل معادله (۳)، با استفاده از متغیرهای ورودی و خروجی ساخته شود. ضرایب  $a_i$  در معادله (۴) با استفاده از روش رگرسیون محاسبه می‌شوند تا این که اختلاف بین خروجی واقعی،  $y$  و خروجی محاسبه شده  $\hat{y}$ ، برای هر زوج  $x_i$  و  $x_j$  به عنوان متغیرهای ورودی مینیمم شود [۱۵-۱۷]. در ادامه می‌توان دید که یک چند جمله‌ای درختی با استفاده از فرم مرتبه دوم معادله (۴) ساخته می‌شود که ضرایب آن‌ها با استفاده از روش حداقل مربعات به دست آمده است. در این روش، ضرایب هر تابع درجه دوم  $G_i$ ، طوری به دست می‌آید که مقدار خطا (E) در هر مجموعه از زوج داده‌های ورودی - خروجی کمینه شود:

$$E = \frac{\sum_{i=1}^M (y_i - G_i(x_p, x_q))^2}{M} \rightarrow \min \quad (5)$$

در شکل پایه ای الگوریتم GMDH، تمام حالت‌های ممکن از ترکیب دو متغیر مستقل در نظر گرفته می‌شد تا این که چند جمله‌ای رگرسیون را به فرم معادله (۴) بازسازی کند که بهترین آن‌ها بتواند مشاهدات وابسته  $y_i$ ،  $i=1, \dots, m$  را با استفاده از روش حداقل مربعات متناسب کند. در نتیجه تعداد  $\binom{n}{2} = \frac{n(n-1)}{2}$  نرون در لایه اول شبکه پیش خورده، از مشاهدات  $\{(y_i, x_{ip}, x_{iq}); i=1, 2, \dots, M\}$  برای  $p, q \in \{1, 2, \dots, n\}$  های مختلف ساخته خواهد شد. به بیانی دیگر، اکنون این امکان وجود دارد که تعداد  $M$  دسته داده سه تایی  $(i=1, 2, M)$  از مشاهدات  $(y_i, x_{ip}, x_{iq})$ ؛  $p, q \in \{1, 2, \dots, n\}$  به فرم:

$$\left[ \begin{array}{cc|c} x_{1p} & x_{1q} & y_1 \\ \hline x_{2p} & x_{2q} & y_2 \\ \hline \dots & \dots & \dots \\ \hline x_{Mp} & x_{Mq} & y_M \end{array} \right]$$

بازسازی شود. با استفاده از توصیف درجه دوم به شکل معادله (۴) برای هر ردیف از  $M$  داده سه تایی، معادله ماتریسی به صورت زیر به دست می‌آید:

$$A \mathbf{a} = Y \quad (۶)$$

که  $\mathbf{a}$  بردار ضرایب شناسایی شده چند جمله‌ای درجه دوم معادله (۵) می‌باشد:

$$\mathbf{a} = \{a_0, a_1, a_2, a_3, a_4, a_5\}^T \quad (۷)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \quad (۸)$$

$Y$  بردار اندازه خروجی مشاهدات است و می‌تواند به شکل ساده زیر نشان داده شود:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix} \quad (۹)$$

روش حداقل مربعات با استفاده از آنالیز رگرسیون، منجر به حل معادلات متعامد به فرم زیر می‌شود:

$$\mathbf{a} = (A^T A)^{-1} A^T Y \quad (۱۰)$$

که بردار بهترین ضرایب معادله درجه دوم (۴) را برای تمام  $M$  ترکیب سه‌تایی موجود تعیین می‌کند. باید ذکر شود که این فرآیند برای هر نرون از لایه مخفی بعدی، باید بر طبق شکل بندی اتصال شبکه انجام شود. بعضی از جواب‌هایی که به طور مستقیم از SNE به دست می‌آیند، نسبت به گرد شدن خطا و همچنین منفرد شدن این معادلات حساس هستند. بنابراین لزوم استفاده از روش دیگری برای حل معادلات ضروری می‌باشد. روش SVD برای جلوگیری از این مشکلات پیشنهاد می‌شود [۱۸].

## ۲-۱- بکارگیری SVD برای طراحی شبکه‌های عصبی نوع GMDH

روش تجزیه مقادیر منفرد یا SVD، برای حل آن دسته از مسایل حداقل مربعات خطی که تعدادی نقاط منفرد در معادلات متعامد آن‌ها وجود دارد، بسیار مناسب است. در روش SVD، یک ماتریس  $A \in \mathbb{R}^{M \times 6}$ ، به صورت حاصلضرب سه ماتریس، متعامد ستونی  $U \in \mathbb{R}^{M \times 6}$ ، قطری  $W \in \mathbb{R}^{6 \times 6}$ ، با اعضای غیر منفی (مقادیر منفرد) و متعامد  $V \in \mathbb{R}^{6 \times 6}$ ، می‌باشد که به فرم زیر نمایش داده می‌شود:

$$A = U W V^T \quad (۱۱)$$

مساله انتخاب بهینه بردار ضرایب در معادله (۶)، در ابتدا به پیدا کردن معکوس ماتریس قطری  $W$  [۱۹] خلاصه

می‌شود که در آن معکوس عناصر صفر یا تکنیک‌های نزدیک به صفر برابر با صفر قرار داده می‌شود. سپس بردار ضرایب بهینه شده  $\mathbf{a}$  مطابق رابطه زیر محاسبه می‌شود:

$$\mathbf{a} = V [\text{diag}(\sqrt{w_j})] U^T Y \quad (12)$$

استفاده از روش SVD در پیدا کردن ضرایب بهینه چند جمله‌ای درجه دوم،  $\mathbf{a}$ ، قابلیت عملکرد GMDH را در مدل‌سازی بر اساس داده‌های ورودی - خروجی افزایش می‌دهد [20].

### ۳ بهینه‌سازی چند هدفی

بهینه‌سازی چند هدفی که به آن بهینه‌سازی برداری نیز گفته می‌شود (Vector Optimization)، سعی در یافتن برداری از متغیرهای طراحی را دارد که قیود مورد نظر را ارضا نماید و بهترین جواب را برای تمام توابع هدف ارائه دهد. در این نوع از بهینه‌سازی، توابع هدف متعددی وجود دارد که باید به طور همزمان و با هم ماکزیمم یا مینیمم شوند [21-37]. بطور کلی از لحاظ ریاضی می‌توان گفت که این الگوریتم سعی در یافتن برداری شامل متغیرهای طراحی به صورت  $X = [x_1^*, x_2^*, \dots, x_n^*]$  برای بهینه کردن مجموعه‌ای از توابع هدف به شکل زیر را دارد:

$$f(X) = [f_1(X), f_2(X), \dots, f_k(X)]^T \quad (13)$$

برای هر تابع هدف  $m$  قید نامساوی و  $p$  قید مساوی به شکل زیر تعریف می‌شود:

$$g_j(X) \leq 0 \quad j = 1, 2, \dots, m \quad (14)$$

$$h_i(X) = 0 \quad i = 1, 2, \dots, p$$

در عبارت‌های فوق  $X^* \in R^n$  بردار متغیرهای طراحی و  $F(X) \in R^k$  بردار توابع هدف می‌باشند. هنگامی که این توابع با هم در تضاد باشند بهینه کردن یکی می‌تواند باعث نامطلوب شدن نتایج دیگری شود. این بدان معناست که امکان پیدا کردن تنها یک جواب که به ازای آن تمامی توابع هدف را به طور همزمان بهینه کند، ممکن نیست، زیرا با مطلوب کردن مقدار یک تابع هدف با نامطلوبی‌هایی در حداقل یکی از توابع هدف دیگر مواجه می‌شویم. لذا بر پایه این منطق در بهینه‌سازی چند هدفی در جستجوی یک مجموعه جواب (بهینه پارتو) هستیم که هر کدام از اعضای این دسته جواب بتوانند بهترین مقدار را به یک یا چند تابع هدف اختصاص دهند، طوری که کمترین نامطلوبی را در توابع دیگر ایجاد کرده باشند. مسایل بهینه‌سازی چند هدفی که تحت عنوان مسایل Pareto دسته‌بندی می‌شوند با تعاریف زیر شناخته می‌شوند:

### ۳-۱ پارتو غالب (Pareto Dominance)

بردار  $U = [u_1, u_2, \dots, u_k] \in R^k$  بر بردار  $V = [v_1, v_2, \dots, v_k] \in R^k$  غالب (Dominate) می‌شود،  
( $U \prec V$ ) اگر و فقط اگر:

$$\forall i \in \{1, 2, \dots, k\}, u_i \leq v_i \wedge \exists j \in \{1, 2, \dots, k\} : u_j < v_j$$

### ۳-۲ بهینگی پارتو (Pareto Optimality)

یک نقطه  $X^* \in \Omega$  (ناحیه قابل قبول طراحی است که معادلات (۱۴) را ارضا می‌کند) را پارتو بهینه گویند، اگر و تنها اگر:  $F(X^*) \prec F(X)$ .

### ۳-۳ مجموعه پارتو (Pareto set)

در مسایل بهینه سازی چند هدفی، یک مجموعه پارتو  $P^*$  حاوی تمامی بردارهای Pareto بهینه است:

$$P^* = \{X \in \Omega \mid \nexists X' \in \Omega : F(X') \prec F(X)\}.$$

### ۳-۴ جبهه پارتو (Pareto Front)

برای یک مساله بهینه سازی چند هدفی، جبهه پارتو  $PF^*$ ، یک مجموعه از بردار توابع هدف است که از بردار متغیرهای طراحی در مجموعه پارتو  $P^*$  به دست آمده است:

$$PF^* = \{F(X) = (f_1(X), f_2(X), \dots, f_k(X)) : X \in P^*\}$$

به بیانی دیگر جبهه پارتو  $PF^*$  یک مجموعه از بردارهای توابع هدف است که از  $P^*$  نگاشت شده است. روش‌های تکاملی در حل مسایل بهینه‌سازی چند هدفی کاربرد گسترده‌ای دارند. این الگوریتم‌ها با مجموعه‌ای از جمعیت‌های اولیه مسایل را حل می‌کنند، بنابراین بیشتر مشکلات و مسایلی که در بهینه‌سازی چند هدفی توسط روش‌های معمول وجود دارد، به وسیله این الگوریتم‌ها حل گردیده است. به عنوان مثال در این گونه روش‌ها با یک بار اجرای برنامه کلیه بردارهای بهینه به دست می‌آیند، این در حالی است که در روش‌های دیگر معمولاً به ازای هر بار اجرای برنامه تنها یک بردار طراحی به دست می‌آید. الگوریتم مرتب‌سازی نقاط غیر برتر که توسط گلدبرگ (Goldberg) پیشنهاد گردید، به گونه‌های مختلف در چندین الگوریتم بهینه‌سازی چند هدفی مورد استفاده قرار گرفت [۳۰]. نکته حایز اهمیت در این الگوریتم‌ها این است که تنوع ژنتیکی درون جمعیت باید به مقدار کافی حفظ شود، تا از همگرایی زودرس در الگوریتم‌های تکاملی بهینه‌سازی چند هدفی (MOEAs) جلوگیری شود و جواب‌ها در طول بهترین جبهه پارتو توزیع شوند. در سال‌های اخیر روش II NSGA که بر اساس رهیافت پارتو می‌باشد، در بسیاری از زمینه‌های مهندسی مورد استفاده قرار گرفته است [۳۲]. قسمت اصلی الگوریتم II NSGA در شکل (۲) آمده است. این شکل شیوه انتخاب اعضای جمعیت کلی،  $R_t$  را برای بازسازی جمعیت والد نسل بعدی،  $R_{t+1}$ ، نشان می‌دهد. جمعیت کلی  $R_t$ ، شامل جمعیت فعلی نسل حاضر،  $P_t$ ،

به اضافه جمعیت فرزندان،  $Q_t$ ، می‌باشد که توسط عملگرهای ژنتیکی پیوند و جهش از  $P_t$  به دست آمده است. شیوه انتخاب نسل بعد بر مبنای روش مرتب‌سازی غیر برتر است که جمعیت کلی  $R_t$  را برطبق افزایش مرتبه برتری آن‌ها دسته‌بندی می‌کند [۳۲]. بعد از این مرحله، بهترین جبهه‌های پارتو از لیست مرتب‌شده بالا انتقال داده می‌شوند تا جمعیت جدید  $P_{t+1}$  را ایجاد کنند که نصف جمعیت کلی  $R_t$  می‌باشد. باید گفت که تمامی اعضای یک جبهه خاص، به دلیل فاصله‌ای که بینشان وجود دارد و در شکل (۲) نشان داده شده است، نمی‌توانند به عنوان والد برای نسل بعد انتخاب شوند. برای انتخاب تعدادی از مناسب‌ترین اعضای هر جبهه، زیر برنامه CDA (*Crowding Distance Assignment*) مورد استفاده قرار می‌گیرد. این زیر برنامه برای جلوگیری از تجمع اعضای یک جمعیت در یک فاصله کوچک و خالی ماندن بقیه بازه، طراحی شده است، زیرا آن چه برای ما مطلوب است آن است که هنگامی که بهترین Front توسط برنامه به نمایش در می‌آید، اعضای Front روی سطح منحنی کاملاً پخش شده باشند. این زیر برنامه به هر بردار هدف، مشخصه‌ای به نام معیار شلوغی (CD) نسبت می‌دهد. CD مشخص‌کننده فاصله هر بردار هدف با بردارهای همسایه‌اش است. بانسبت دادن این مقدار به بردار هدف در قسمت‌های بعد هنگامی که برنامه از بین اعضای یک Front چند عضو را برای ایجاد جمعیت جدید انتخاب می‌کند، آن اعضایی انتخاب می‌شوند که CD بزرگتری دارند. یعنی فاصله آن‌ها با بردارهای همسایه‌شان در آن Front زیاد است. به این ترتیب کروموزوم‌هایی که به جمعیت جدید منتقل می‌شوند، از قسمت‌های کم جمعیت Front انتخاب شده‌اند. با این عمل توزیع بردارهای هدف روی سطح Front گسترش بیشتری می‌یابد [۲۷]. زیر برنامه CDA یک Front را به عنوان ورودی دریافت می‌کند و به تمامی اعضای آن پارامتری به نام  $I_{distance}$  که مقدار اولیه‌اش برای همه بردارهای طراحی مقدار صفر است، نسبت می‌دهد و سپس بر اساس یکی از توابع هدف، اعضای Front یعنی همان بردارهای هدف را به صورت صعودی مرتب می‌کند. سپس به دو بردار اول و آخر آن مقدار بینهایت را نسبت می‌دهد و برای هر یک از بردارهای میانی مقدار  $I_{distance}$  را محاسبه می‌کند. مقدار  $I_{distance}$  برای هر بردار برابر با مقدار تابع هدف (همان تابع هدفی که بردارها بر اساس آن مرتب شده‌اند) بردار بعدی منهای تابع هدف بردار قبلی می‌باشد. سپس حلقه تکرار می‌شود و این بار بردارهای هدف با توجه به تابع هدف بعدی مرتب می‌شوند.  $I_{distance}$  براساس مقادیر این تابع هدف نیز برای همه بردارها محاسبه می‌شود و در مورد هر بردار به  $I_{distance}$  قبلی که مربوط به تابع هدف قبلی است اضافه می‌شود. زیر برنامه CDA به عنوان عملگر حفظ تنوع در این الگوریتم، کارآیی لازم را مخصوصاً در مسایل بهینه‌سازی با بیش از دو تابع هدف ندارد. زمانی که تعداد توابع هدف بیش از دو تابع باشد و مسایل به فضای چند بعدی انتقال پیدا کنند، محاسبه معیار تراکم کار مشکل و امکان‌ناپذیری خواهد بود. بنابراین در این مقاله از الگوریتم پیشنهادی  $\epsilon$ -elimination به جای معیار CDA استفاده می‌شود [۱۳ و ۱۴]. با اصلاح صورت گرفته بر روی الگوریتم NSGA-II، از آن می‌توان برای هر تعداد تابع هدف استفاده کرد. در این مقاله، از این الگوریتم اصلاح شده برای بهینه‌سازی سه هدفی ساختار شبکه‌های عصبی نوع GMDH استفاده شده است.



## ۴ الگوریتم $\epsilon$ -elimination

در زیر برنامه  $\epsilon$ -elimination که به جای CDA مورد استفاده قرار می‌گیرد، با توجه به نوع مساله ابتدا مقداری برای  $\epsilon$  به عنوان معیار حذف در نظر گرفته می‌شود و همه اعضای درون جمعیت که مقدارشان از  $\epsilon$  به هم نزدیک‌تر باشد، حذف می‌شوند. اگر  $\epsilon$  برابر عدد بزرگی باشد، فاصله بین نقاط روی منحنی پارتو زیاد می‌شود و منحنی پارتو نهایی دقت خود را از دست می‌دهد و اگر این مقدار برابر صفر قرار داده شود، فقط نقاط منطبق بر هم از جمعیت حذف می‌شوند. لازم به ذکر است، طبق این زیر برنامه بردارهایی از جمعیت حذف می‌شوند که هم مقادیر تابع هدفشان نزدیک به هم باشد و هم از متغیرهای نزدیک به هم ایجاد شده باشند. این الگوریتم در شکل (۳) نشان داده شده است. برای جبران کم شدن جمعیت ناشی از حذف بردارهای تکراری و نزدیک به هم، الگوریتم جمعیت جدیدی را به طور اتفاقی ایجاد می‌کند. این جمعیت جدید با جمعیت پالایش شده قبلی جمع می‌شود [۱۳].

## ۵ بهینه سازی چند هدفی شبکه‌های عصبی نوع GMDH برای مدلسازی و پیش بینی عمر خستگی کامپوزیت‌های تک جهته GRP

در این مقاله از نتایج آزمایش‌های خستگی کامپوزیت‌های GRP استفاده شده است. نمونه‌های آزمایشگاهی GRP از جنس الیاف شیشه Scotchply نوع ۱۰۰۳ برای تقویت پلاستیک Epoxy در پنج زاویه مختلف ( $\theta = 0^\circ, 19^\circ, 45^\circ, 71^\circ, 90^\circ$ ) ساخته شده‌اند، که  $\theta$  زاویه بین جهت الیاف و جهت بارگذاری می‌باشد. این نمونه‌های تک جهته، تحت شرایط بارگذاری سیکلی بار-کنترلی و در دمای اتاق آزمایش شده‌اند. نمونه‌های آزمایشگاهی تحت بارگذاری با دامنه تنش ثابت و نسبت‌های تنشی ( $R = \sigma_{\min} / \sigma_{\max} = 0.5, 0.7, 0.9$ ) و در فرکانس بارگذاری ۳/۳ Hz تست شده‌اند [۳۸].

مهمترین پارامترهای موجود در این سیستم چند ورودی-تک خروجی تنش ماکزیمم ( $\sigma_{\max}$ )، تنش مینیمم ( $\sigma_{\min}$ )، تنش شکست کامپوزیت در یک سیکل از بارگذاری ( $\sigma_u$ )، انرژی کرنشی سیکلی یا انرژی جذب شده توسط کامپوزیت تا شکست نهایی [ $W$ ]، نسبت تنش ( $R$ ) و زاویه الیاف نسبت به جهت بارگذاری ( $\theta$ ) می‌باشند. از میان این پارامترها، متغیرهای ( $\log \sigma_{\max}, \sigma_{\max} / \sigma_u, W, R, \theta$ )، به عنوان بهترین و موثرترین ترکیب پارامترهای ورودی شبکه‌های عصبی GMDH، برای مدلسازی عمر خستگی کامپوزیت‌های GRP می‌باشند [۶]. بنابراین بردار ورودی  $X = \{\log \sigma_{\max}, \sigma_{\max} / \sigma_u, W, R, \theta\}$  نشان داده می‌شود. پارامتر خروجی شبکه عصبی GMDH نیز مقدار لگاریتمی عمر خستگی ( $\log N_f$ ) می‌باشد.

از الگوریتم اصلاح شده NSGA-II که در قسمت قبلی به طور کامل معرفی شد، به منظور بهینه سازی چند هدفی شبکه‌های عصبی نوع GMDH برای مدلسازی و پیش بینی عمر خستگی کامپوزیت‌های تک جهته GRP توسط داده‌های آزمایشگاهی استفاده می‌شود. به منظور بررسی توانایی پیش بینی شبکه‌های عصبی نوع GMDH، دسته داده‌های آزمایشگاهی به دو مجموعه آموزش (جهت بدست آوردن ضرایب ساختار شبکه عصبی) و پیش بینی تقسیم می‌شوند. کل داده‌های آزمایشگاهی شامل ۷۴ داده می‌باشد که ۵۰ دسته داده برای

آموزش مدل‌های شبکه عصبی و ۲۴ دسته داده باقیمانده برای بررسی توانایی پیش‌بینی این مدل‌ها مورد استفاده قرار می‌گیرند. به منظور طراحی بهینه‌ای شبکه‌های عصبی GMDH بر اساس بهینه‌سازی چند هدفی که در قسمت قبلی توضیح داده شد، از یک جمعیت ۱۰۰ عضوی با احتمال پیوند ۰/۹۵ و احتمال جهش ۰/۱ استفاده شده است که این جمعیت طی ۴۰۰ نسل فرآیند تکامل را سپری می‌کنند. در بهینه‌سازی چند هدفی شبکه‌های عصبی GMDH، زوج‌های مختلفی از توابع هدف متضاد باهم، (TE-PE)، (TE-N)، و (PE-N) برای بهینه‌سازی دو هدفی شبکه‌های عصبی انتخاب شدند. جبهه پارتوی بدست آمده برای هر کدام از این بهینه‌سازی‌های دو هدفی در شکل‌های (۴)، (۵) و (۶) به ترتیب برای (TE-PE)، (TE-N) و (PE-N) نشان داده شده است. از روی این شکل‌ها می‌توان مشاهده نمود که همه نقاط طراحی نشان داده شده، که در واقع معرف شبکه‌های عصبی GMDH مختلف می‌باشند، از دید هر یک از دو تابع هدف نسبت به یکدیگر غیر برتر هستند. شکل (۴)، نقاط بهینه پارتوی حاصل از بهینه‌سازی دو هدفی با دو تابع هدف خطای آموزش و خطای پیش‌بینی را نشان می‌دهد. در این شکل مدل‌های متناظر با نقاط A و B به ترتیب بهترین خطای پیش‌بینی و بهترین خطای آموزش را دارند. مقادیر خطاها و همچنین ساختار کروموزومی این نقاط بهینه طراحی در جدول (۱) آمده است. لازم به ذکر است که تعداد نرون‌ها (N) در این مورد به عنوان تابع هدف در نظر گرفته نشده است و فقط خطای آموزش و خطای پیش‌بینی برای بهینه‌سازی دو هدفی شبکه‌های عصبی GMDH به عنوان توابع هدف در نظر گرفته شده‌اند. شکل‌های (۵) و (۶) به طور مشابه منحنی‌های پارتوی حاصل از بهینه‌سازی‌های دو هدفی، به ترتیب با دو تابع هدف (TE-N) و (PE-N) را نشان می‌دهند. در این شکل‌ها نقاط D و G دارای بهترین مقادیر بهینه شده برای خطای آموزش و خطای پیش‌بینی (با توجه به تعداد نرون‌ها در هر کدام از این بهینه‌سازی‌های دو هدفی) می‌باشند. از طرف دیگر نقاط E و H دارای ساده‌ترین ساختار برای شبکه‌های عصبی GMDH یعنی یک نرون ( $N=1$ ) می‌باشند. مقادیر توابع هدف به همراه ساختارهای کروموزومی مربوطه برای هر یک از شبکه‌های عصبی GMDH مشخص شده، در جدول (۱) آمده است. از روی این شکل‌ها واضح است که هر کدام از نقاط طراحی بهینه شده (شبکه‌های عصبی GMDH) در هر جبهه پارتو نسبت به هم غیر برتر هستند و می‌توانند توسط طراح برای مدل‌سازی و پیش‌بینی عمر خستگی کامپوزیت‌های GRP انتخاب شوند. از روی این شکل‌ها پیداست که انتخاب یک مدل با مقدار بهتر برای هر تابع هدف در جبهه پارتو، باعث بدتر شدن مقدار تابع هدف دیگر می‌شود. در صورت انتخاب شبکه عصبی نوع GMDH که جز نقاط پارتو نشان داده شده در هر کدام از شکل‌های (۴)، (۵) و (۶) نباشد، مقادیر مربوط به زوج تابع هدف در ناحیه‌ای خارج از جبهه پارتو مورد نظر قرار می‌گیرد که توسط نقاط پارتو حذف می‌گردد. چنین ناحیه‌ای در فضای دو تابع هدف، در واقع در سمت بالا و راست منحنی‌های پارتو در شکل (۴)، (۵) و (۶) قرار می‌گیرد. به طور واضح، واقعیت‌های مهمی در طراحی بهینه‌ای بین دو تابع هدف وجود دارد که توسط بهینه‌سازی پارتویی شبکه‌های عصبی نوع GMDH آشکار شده‌اند. چنین واقعیت‌های مهم طراحی، بدون استفاده از روش بهینه‌سازی چند هدفی پارتویی شبکه‌های عصبی GMDH، هرگز به دست نمی‌آمدند. از شکل‌های (۴)، (۵) و (۶)، نقاط C، F و I نقاطی هستند که واقعیت‌های مهم طراحی بهینه‌ای را آشکار می‌کنند. نقطه C در طراحی بهینه‌ای پارتویی دو هدفی خطای آموزش و خطای

پیش‌بینی، در مقایسه با نقطه A، افزایش بسیار ناچیزی در مقدار خطای پیش‌بینی (حدود ۳ درصد) از خود نشان می‌دهد، در حالی که خطای مدلسازی نقطه C حدود ۱۴ درصد بهتر از نقطه A می‌باشد. بنابراین هنگامی که بخواهیم هر دو تابع هدف خطای آموزش و خطای پیش‌بینی به طور همزمان مینیمم شوند، با مصالحه بین این دو تابع هدف، نقطه C می‌تواند به عنوان یک نقطه بهینه انتخاب شود. ساختار شبکه GMDH متناظر با نقطه C در شکل (۷a) و همچنین نمودار مقایسه‌ای بین داده‌های آزمایشگاهی و مقادیر محاسبه شده عمر خستگی توسط این مدل بهینه در شکل (۸) نشان داده شده است. نقاط F و I از شکل‌های (۵) و (۶)، مصالحه مشابهی بین پیچیدگی ساختار شبکه‌های عصبی (تعداد نرون‌ها) و به ترتیب خطای آموزش و خطای پیش‌بینی را نشان می‌دهند. برای مثال، نقطه I افزایش خیلی کمی در خطای پیش‌بینی در مقایسه با نقطه G از خود نشان می‌دهد، در حالی که تعداد نرون‌های آن حدود ۵۰ درصد کمتر از نقطه G است که نشان دهنده ساختار بسیار ساده‌تر مدل GMDH متناظر با نقطه I می‌باشد. ساختار مربوط به نقطه I و همچنین رفتار خوب این مدل GMDH، بر روی داده‌هایی که برای آموزش و پیش‌بینی جدا شده‌اند، به ترتیب در شکل‌های (۷b) و (۹) نشان داده شده است.

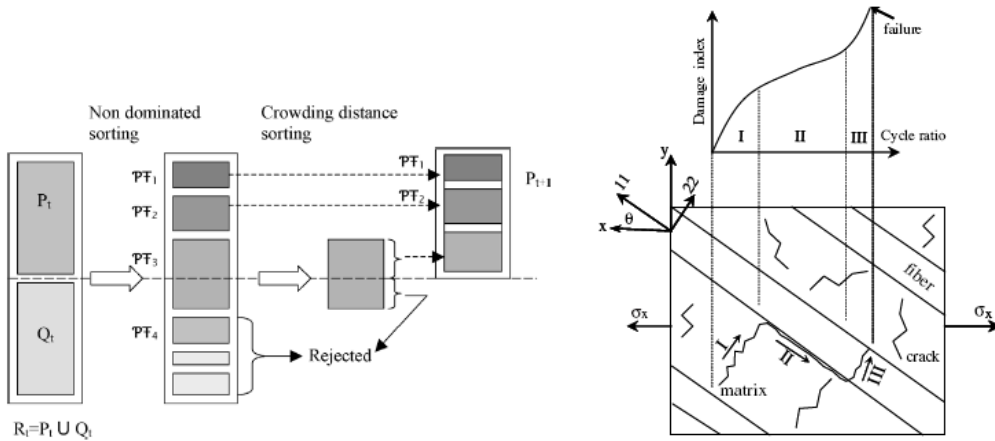
اگر بهینه‌سازی چند هدفی شبکه‌های عصبی نوع GMDH شامل هر سه تابع هدف باشد، انتخاب‌های بهینه بیشتری برای طراح فراهم می‌شود. علاوه بر این، نتایج بهینه‌سازی سه هدفی می‌تواند همه نتایج بهینه‌سازی دو هدفی که در قسمت قبلی بدست آمد را دربر گیرد. شکل (۱۰)، نقاط غیر برتر بهینه‌سازی سه هدفی را در صفحه خطای آموزش و خطای پیش‌بینی به همراه نتایج بهینه‌سازی دو هدفی با همین دو تابع هدف (خطای آموزش و خطای پیش‌بینی) که در قسمت قبلی به دست آمد، نشان می‌دهد. چنین نقاط غیر برتر حاصل از بهینه‌سازی سه هدفی، در صفحه (تعداد نرون‌ها- خطای آموزش) و (تعداد نرون‌ها- خطای پیش‌بینی) به ترتیب در شکل‌های (۱۱) و (۱۲) نشان داده شده است. لازم به ذکر است، تنها یک مجموعه از نقاط پارتو از بهینه‌سازی سه هدفی با سه تابع هدف خطای آموزش، خطای پیش‌بینی و تعداد نرون‌ها حاصل شده است که در صفحات مختلف، به همراه نتایج بهینه‌سازی‌های دو هدفی متناظر نمایش داده شده‌اند. بنابراین، در مورد بهینه‌سازی سه هدفی باید گفت که در هر صفحه تعدادی نقاط بهینه وجود دارند که ممکن است بر دیگر نقاط موجود در همان صفحه برتری داشته باشند، در حالی که اگر هر سه تابع هدف به طور همزمان برای بهینه‌سازی در نظر گرفته شوند، همه این نقاط نسبت به یکدیگر غیر برتر می‌باشند. با جستجوی دقیق در نتایج بهینه‌سازی سه هدفی در هر صفحه، جبهه‌های پارتوی بهینه‌سازی دو هدفی متناظر که در قسمت قبلی به دست آمدند، در این اشکال قابل مشاهده‌اند. به راحتی می‌توان دید که نتایج بهینه‌سازی سه هدفی، جبهه‌های پارتوی هر کدام از بهینه‌سازی‌های دو هدفی را شامل می‌شوند و بنابراین انتخاب‌های بهینه بیشتری در اختیار طراح قرار می‌دهد. در نتیجه، بهینه‌سازی پارتویی شبکه‌های عصبی نوع GMDH نشان می‌دهد که با مصالحه بین توابع هدف خطای آموزش، خطای پیش‌بینی و تعداد نرون‌ها، مدل‌های GMDH متناظر با نقاط پارتو C، F یا I می‌توانند به عنوان مدل‌های بهینه برای مدلسازی و پیش‌بینی عمر خستگی کامپوزیت‌های تک‌جهته GRP انتخاب شوند.

## ۶ نتیجه گیری

از الگوریتم‌های تکاملی بر مبنای رهیافت پارتو، به طور موفقیت آمیز برای بهینه‌سازی چند هدفی شبکه‌های عصبی نوع GMDH استفاده شده است که در نهایت از این شبکه‌های GMDH بهینه شده برای مدل‌سازی و پیش‌بینی طول عمر خستگی کامپوزیت‌های GRP استفاده می‌گردد. بهینه‌سازی‌های چند هدفی باعث پیدایش بردارهای طراحی بهینه در فضای توابع هدف شدند. در این تحقیق، خطای مدل‌سازی، خطای پیش‌بینی و تعداد نرون‌ها، به عنوان مهمترین توابع هدف موجود در شبکه‌های عصبی GMDH که با یکدیگر در تضادند، انتخاب شده‌اند. زوج‌های مختلفی از این توابع هدف برای انواع بهینه‌سازی‌های دو هدفی بررسی شده‌اند. نهایتاً، منحنی‌های پارتو بهینه در هر مورد به دست آمده‌اند که برازش بین هر زوج تابع هدف را نشان می‌دهند و در نتیجه انتخاب‌های بهینه شده و غیر برتر متفاوتی از شبکه‌های عصبی GMDH برای پیش‌بینی عمر خستگی مهیا می‌شود. همان طور که از روی نمودارهای پارتو پیداست، تعدادی از ساختارهای GMDH بهینه (نقاط  $C$ ،  $F$  و  $I$ ) وجود دارند که ارتباطی منطقی را بین توابع هدف ذکر شده نشان می‌دهند. بنابراین، این ساختارها می‌توانند به طور مطمئن به عنوان شبکه‌های عصبی بهینه انتخاب شوند. لازم به ذکر است که بسیاری از این نتایج که به عنوان بردارهای طراحی بهینه ارائه شده‌اند، هرگز بدون استفاده از روش بهینه‌سازی چند هدفی شبکه‌های عصبی به دست نمی‌آمدند. علاوه بر این، هر سه تابع هدف در یک فرآیند بهینه‌سازی سه هدفی بررسی شده‌اند که در نتیجه تعداد بیشتری از انتخاب‌های غیر برتر برای مدل‌های GMDH ایجاد شده است و این نتایج برازش میان خطای مدل‌سازی، خطای پیش‌بینی و تعداد نرون‌ها (پیچیدگی ساختار) را به طور همزمان نشان می‌دهند. از تطابق منحنی‌های پارتو بهینه‌سازی‌های دو هدفی و سه هدفی، مشخص شده است که نتایج بهینه‌سازی سه هدفی شامل نتایج بهینه‌سازی دو هدفی نیز می‌شوند و بنابراین انتخاب‌های بهینه بیشتری برای طراحی چند هدفی شبکه‌های عصبی نوع GMDH مهیا می‌شود.

جدول ۱. مقادیر توابع هدف و ساختارهای کروموزومی شبکه‌های عصبی مختلف مشخص شده در شکل‌های (۴)، (۵) و (۶)

Optimum Design Points	Structure of Networks	No. of. Neu	Training Error (mm)	Prediction Error (mm)	Objectives of Optimization
A	<u>aecdabddadcebbde</u>	۱۳	.۲۵۸۱۴۲	.۱۶۸۹۲۸	(TE, PE)
B	<u>aedeacbdadecaeece</u>	۱۳	.۱۷۸۲۸۷	.۳۸۶۱۲۴	(TE, PE)
C	<u>ccbddaaeaebdbcb</u>	۱۱	.۲۲۲۳۷۰	.۱۷۴۴۱۱	(TE, PE)
D	<u>aedeacbdadecaeece</u>	۱۳	.۱۷۸۲۸۷	.۳۸۶۱۲۴	(TE, N)
E	<u>bd</u>	۱	.۵۹۴۱۶۹	.۶۵۳۰۱۶	(TE, N)
F	<u>ccadaeddeeeaccbd</u>	۸	.۲۱۳۷۵۵	.۲۷۹۳۴۲	(TE, N)
G	<u>caeeccccaaaaeabd</u>	۸	.۳۰۷۶۷۱	.۱۹۳۸۸۳	(PE, N)
H	<u>ab</u>	۱	.۸۹۸۲۸۱	.۵۳۲۱۵۸	(PE, N)
I	<u>aebdaaaa</u>	۴	.۳۲۱۵۵۶	.۲۵۳۷۷۶	(PE, N)




شکل ۲. ساختار کلی الگوریتم NSGA-II

شکل ۱. مکانیزم ترک در سه ناحیه موجود در کامپوزیت‌های تک‌جهته تحت بارگذاری خستگی، (I) ترک ماتریسی، (II) ترک در فصل مشترک ماتریس و الیاف، (III) شکست الیاف [۱]

```


Pseudo-code of ε-elimination
ε-elim=ε-elimination (pop) //pop includes design variables and
                             objective functions.
define ε //Define elimination threshold.
get k (k = 1 for the first front) //Front No.
i = 1
until i + 1 < pop_size
    j = i + 1
    until j < pop_size
        IF { ||F(X(i)), F(X(j))|| < ε ∧ ||X(i), X(j)|| < ε }
            F(X(i)), F(X(j)) ∈ P_k^+ X(i), X(j) ∈ P_k^+
            THEN pop = pop \ pop(j) //Remove the ε-similar individual.
        r_new_ind = make_new_random_individual
        //Generate new random individual.
    pop = pop ∪ r_new_ind //Add the newly generated individual.
end
end
    
```

شکل ۳. الگوریتم جایگزین ε-elimination برای حفظ تنوع ژنتیکی




شکل ۴. جبهه پارتو حاصل از بهینه‌سازی با دو تابع هدف خطای آموزش و خطای پیش‌بینی

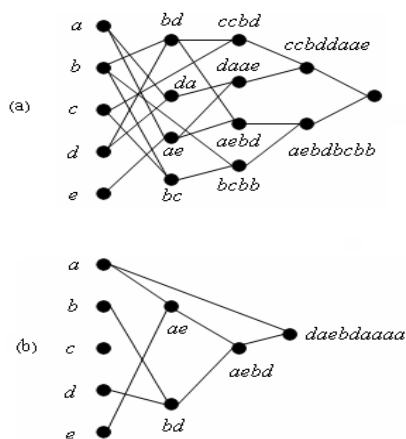
سلیمان و سلیمانی، بهینه‌سازی چند هدفی شبکه‌های عصبی نوع GMDH برای مدل‌سازی و پیش‌بینی عمر محلی کامپوزیت‌های GRP



شکل ۵. جبهه پارتو حاصل از بهینه‌سازی با دو تابع هدف خطای آموزش و تعداد نرون‌ها




شکل ۶. جبهه پارتو حاصل از بهینه‌سازی با دو تابع هدف خطای پیش‌بینی و تعداد نرون‌ها

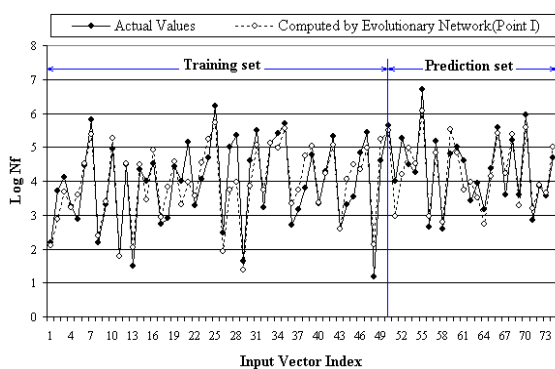


شکل ۷. ساختار شبکه عصبی متناظر با (a) نقطه C از شکل (۴)، (b) نقطه I از شکل (۶)، که در آن a، b، c، d و e به ترتیب متغیرهای ورودی

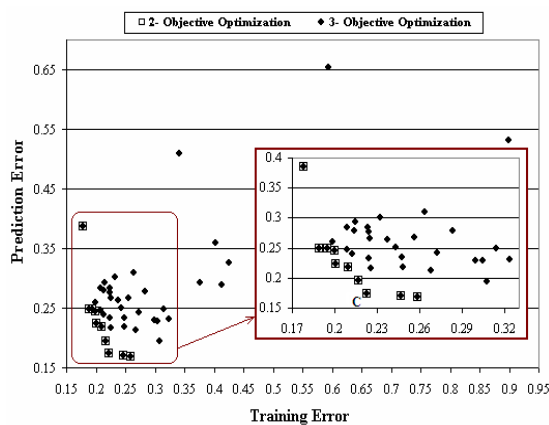
$$R, W, \frac{\sigma_{\max}}{\sigma_{\min}}, \log \sigma_{\max} \text{ و } \theta \text{ هستند}$$



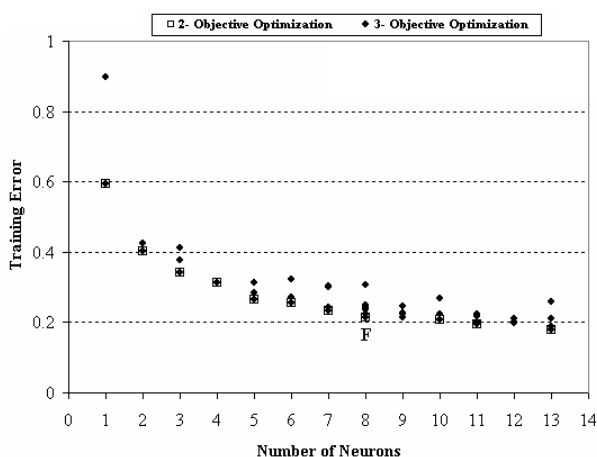
شکل ۸. نمودار مقایسه‌ای بین داده‌های آزمایشگاهی عمر خستگی و مقادیر محاسبه شده توسط مدل GMDH بهینه نقطه C



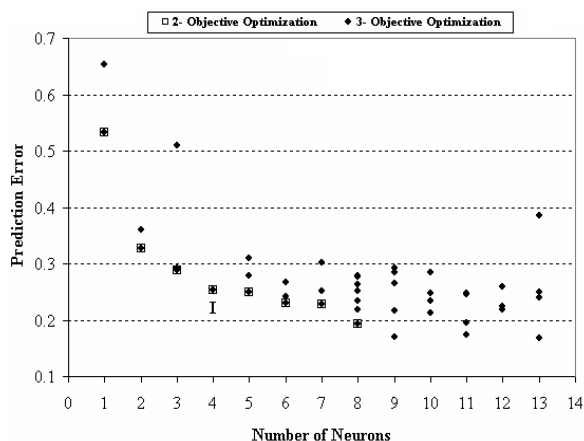
شکل ۹. نمودار مقایسه‌ای بین داده‌های آزمایشگاهی عمر خستگی و مقادیر محاسبه شده توسط مدل GMDH بهینه نقطه I



شکل ۱۰. نقاط پارتوی حاصل از بهینه‌سازی‌های دو هدفی و سه هدفی برای مقادیر خطای آموزش در برابر خطای پیش‌بینی



شکل ۱۱. نقاط پارتوی حاصل از بهینه‌سازی‌های دو هدفی و سه هدفی برای مقادیر تعداد نرون‌ها در برابر خطای آموزش



شکل ۱۲. نقاط پارتوی حاصل از بهینه‌سازی‌های دو هدفی و سه هدفی برای مقادیر تعداد نرون‌ها در برابر خطای پیش‌بینی

## منابع

- [۲] منهای، م. ب.، صیفی پور، ن.، (۱۳۷۷). کاربرد هوش محاسباتی در کنترل. مرکز نشر پروفسور حسابی.
- [۵] نریمانزاده، ن.، درویزه، ا.، جمالی، ع.، (۱۳۸۳)، تعیین بهینه‌ای ساختار شبکه‌های عصبی بهبود یافته از نوع GMDH با استفاده از الگوریتم ژنتیک برای فرآیند جوشکاری انفجاری. کنفرانس مهندسی مکانیک.
- [۶] سلیمان، ک.، (۱۳۸۵). مدل‌سازی و پیش‌بینی عمر خستگی مواد کامپوزیت (FRP) با استفاده از شبکه‌های عصبی GMDH بهینه با چند تابع هدف. پایان‌نامه کارشناسی ارشد دانشگاه گیلان.
- [1] Varvani-Farahani, A., Haftchenari, H., Panbechi, M., (2006). An energy- based fatigue damage parameter for off-axis unidirectional fiber reinforced composites. Composite Structures, in press.
- [3] Kawai, M., (2004). A phenomenological model for off-axis fatigue behavior of unidirectional polymer matrix composites under different stress ratios. Composites, Part A, 35, 955-963.
- [4] Ivakhneko, A. G., (1971). Polynomial Theory of Complex Systems. IEEE Trans. Syst. Man & Cybern, SMC-1, 364-378.
- [7] Aymerich, F., Serra, M., (1998). Prediction of fatigue strength of composite laminates by means of neural networks. Key Engng Mater, 144, 231-40.
- [8] Lee, J. A., Almond, D. P., Harris, B., (1999). The use of neural networks for the prediction of fatigue



- lives of composite materials. *Composites Part A: Applied Science and Manufacturing*, 30(10), 1159–69.
- [9] Al-Assaf, Y., El Kadi, H., (2001). Fatigue life prediction of unidirectional glass fiber/epoxy composite laminae using neural networks. *Composite Structures*, 53(1), 65–71.
- [10] Al-Assaf, Y., El Kadi, H., (2005). Fatigue life prediction of composite materials using polynomial classifiers and recurrent neural networks. *Composite Structures*, Article in press.
- [11] El Kadi, H., Al-Assaf, Y., (2002). Prediction of the fatigue life of unidirectional glass fiber/epoxy composite laminae using different neural network paradigms. *Compos Struct*, 55(2), 239–46.
- [12] El Kadi, H., Al-Assaf, Y., (2002). Energy-based fatigue life prediction of fiberglass/epoxy composites using modular neural networks. *Compos Struct*, 57(1–4), 85–9.
- [13] Atashkari, K., Nariman-zadeh, N., Pilechi, A., Jamali, A., Yao, X., (2005). Thermodynamic Pareto Optimization of Turbo Engines using Multi-objective Genetic Algorithms. *International Journal of Thermal Science*, 44, 1061-1071.
- [14] Nariman-zadeh, N., Atashkari, K., Jamali, A., Pilechi, A., Yao, X., (2005). Inverse Modelling of Multi-objective Thermodynamically Optimized Turbo Engines using GMDH-type Neural Networks and Evolutionary Algorithms. *Engineering Optimization*, Taylor & Francis Group, 37(5), 437-462.
- [15] Farlow, S. J., (1984). Self-organizing Method in Modelling: GMDH type algorithm. Marcel Dekker Inc.
- [16] Mueller, J. A., Lemke, F., (2000). Self-Organising Data Mining. An Intelligent Approach to Extract Knowledge from Data. Pub. Libri, Hamburg.
- [17] Iba, H., deGaris, H., Sato, T., (1996). A numerical Approach to Genetic Programming for System Identification. *Evolutionary Computation*, 3(4), 417-452.
- [18] Fonseca, C. M., Fleming, P. J., (1993). Genetic algorithms for multi-objective optimization: Formulation, discussion and generalization. *Proc. Of the Fifth Int. Conf. On genetic Algorithms*, Forrest S. (Ed.), San Mateo, CA, Morgan Kaufmann, 416-423.
- [19] Press, W. H., Teukolsky, S. A., Vetterling, W. T., Flannery B. P., (1992). *Numerical Recipes in FORTRAN. The Art of Scientific Computing*, 2nd Edition, Cambridge University Press.
- [20] Nariman-Zadeh, N., Darvizeh, A., Darvizeh, M., Gharababaei, H., (2002). Modeling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition. *Journal of Materials Processing Technology*, 128(1), 80-87(8).
- [21] Pareto, V., (1896). *Cours d'economic plitique*. Lausanne, Switzerland, Rouge.
- [22] Rosenberg, R. S., (1967). Simulation of genetic populations with biochemical properties. PhD Thesis, University of Michigan, Ann Harbor, Michigan.
- [23] Schaffer, J. D., (1985). Multiple objective optimization with vector evaluated genetic algorithms. *Proc. of First Int. Conf. On Genetic Algorithms and Their Applications*, Ed. Grefenstette, J.J., 93-100.
- [24] Zitzler, E., Thiele, L., (1998). An evolutionary algorithm for multiobjective optimization: The strength Pareto approach. Tech. Report 43. Computer engineering and communication network Lab, Swiss federal ins. of Tech., Zurich.
- [25] Knowles, J., Corne, D., (1999). The Pareto archived evolution strategy: A new baseline algorithm for multiobjective optimization. *Proc. Of the 1999 congress on Evolutionary Computation*, Piscataway, NJ: IEEE Service Center, 98-105.
- [26] Horn, J., Nafpliotis, N., Goldberg D. E., (1994). A Niche Pareto Genetic Algorithm for Multiobjective Optimization. *Proceedings of the First IEEE Conference on Evolutionary Computation*, IEEE World Congress on Computational Intelligence, Volume 1, pages 82-87, Piscataway, New Jersey, IEEE Service Centre.
- [27] Coello Coello, C. A., (1999). A comprehensive survey of evolutionary based multiobjective optimization techniques. *Knowledge and Information Systems: An Int. Journal*, (3), 269-308.
- [28] Deb, K., (2001). *Multi-objective Optimization using evolutionary algorithms*. John Wiley, UK.
- [29] Khare, V., Yao, X., Deb, K., (2003). Performance Scaling of Multi-objective Evolutionary Algorithms. *Proc. Of Second International Conference on Evolutionary Multi-Criterion Optimization*, (EMO'03), Portugal.
- [30] Goldberg, D. E., (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, New York.
- [31] Toffolo, A., Benini, E., (2003). Genetic Diversity as an Objective in Multi-objective evolutionary Algorithms. *Evolutionary Computation*, 11(2), 151-167, MIT Press.
- [32] Deb, K., Agrawal, S., Pratap, A., Meyarivan, T., (2002). A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE Trans. On Evolutionary Computation*, 6(2), 182-197.

- [33] Coello Coello, C. A., Becterra, R. L., (2003). Evolutionary Multiobjective Optimization using a Cultural Algorithm. IEEE Swarm Intelligence Symp., 6-13.
- [34] Sarker, R., Liang, K. H., Newton, C., (2002). A new continuous optimization multiobjective evolutionary algorithm. European Journal of Operational Research, 140, 12-23.
- [35] Golub G. H., Reinsch C., (1970). Singular Value Decomposition and Least Squares Solutions. Numer. Math., 14(5), 403-420.
- [36] Press, W. H., Teukolsky, S. A., Vetterling, W. T., Flannery B. P., (1992). Numerical Recipes in FORTRAN: The Art of Scientific Computing. 2nd Edition, Cambridge University Press.
- [37] Osyczka, A., (1985). Multicriteria optimization for engineering design. In Design Optimization, Gero, J.S., (ed.), 193-227, Academic Press, NY.
- [38] El Kadi, H., Ellyin, F., (1994). Effect of stress ratio on the fatigue of unidirectional glass fiber/epoxy composite laminae. Composites, 25(10), 917-24.