

## آموزش شبکه عصبی MLP در فشرده‌سازی تصاویر با استفاده از روش GSA

مریم ده‌باشیان<sup>\*</sup> سیدحمید ظهیری<sup>\*\*</sup>

<sup>\*</sup> کارشناس ارشد، مهندسی الکترونیک، دانشگاه بیرجند

<sup>\*\*</sup> استادیار، گروه مخابرات و الکترونیک، دانشکده مهندسی، دانشگاه بیرجند

تاریخ دریافت: ۱۳۸۹/۰۵/۱۷

تاریخ پذیرش: ۱۳۸۹/۰۹/۰۵

### چکیده

یکی از حوزه‌های تحقیقاتی مهم در پردازش تصویر، فشرده‌سازی تصاویر است. تاکنون روش‌های مختلفی برای فشرده‌سازی تصویر ارائه شده‌است، در این میان شبکه‌های عصبی مخاطبان زیادی را به خود جذب کرده‌اند. متداول‌ترین روش آموزشی شبکه‌های عصبی، روش پس انتشار خطاست که همگرایی کند و توقف در بهینه‌های محلی از مهمترین نقاط ضعف آن محسوب می‌شوند. رویکرد جدید محققین، استفاده از الگوریتم‌های ابتکاری در فرایند آموزش شبکه‌های عصبی است. در این مقاله، روش آموزشی نوینی مبتنی بر روش جستجوی گرانشی (GSA) معرفی می‌شود. روش جستجوی گرانشی آخرین و جدیدترین نسخه از انواع روش‌های جستجو و بهینه‌سازی هوش جمعی است. در این روش پاسخ‌های کاندید در فضای جستجو اجرامی هستند که توسط نیروی گرانش بر یکدیگر اثر گذاشته و موقعیتشان تغییر می‌کند. به تدریج اجرام با برازندگی بهتر دارای جرم بیشتری می‌شوند و بر اجرام دیگر تاثیر بیشتری می‌گذارند. در تحقیق حاضر با استفاده از الگوریتم GSA یک شبکه عصبی MLP به منظور فشرده‌سازی تصاویر آموزش داده می‌شود.

برای ارزیابی کارایی فشرده‌ساز ارائه شده عملکرد آن با الگوریتم بهینه‌سازی گروه ذرات و روش متداول پس انتشار خطا در فشرده‌سازی چهار تصویر استاندارد مقایسه می‌شود. نتایج نهایی گویای قابلیت چشمگیر روش GSA در آموزش شبکه‌های عصبی MLP می‌باشد.

**کلید واژگان:** الگوریتم‌های ابتکاری، الگوریتم جستجوی گرانشی، شبکه عصبی چند لایه، فشرده‌سازی تصویر

### ۱- مقدمه

از آنجا که انتقال تصاویر در میان مسیرهای ارتباطی فرایندی پر هزینه می‌باشد هدف اصلی در فشرده‌سازی تصویر کاهش تعداد بیت‌های مورد نیاز برای نمایش یک تصویر است. افزونگی داده مهمترین مورد در فشرده‌سازی تصاویر<sup>۱</sup> دیجیتالی است. از انواع افزونگی داده می‌توان به افزونگی رمزنگاری، افزونگی بین پیکسلی و افزونگی روان بصری اشاره نمود. الگوریتم‌های فشرده‌سازی تصویر سعی در کاهش انواع افزونگی‌های تصویر دارند اما استفاده از کدام نوع الگوریتم، به شدت به اطلاعات موجود در تصویر بستگی دارد. یک الگوریتم کاربردی فشرده‌سازی داده‌های تصویر، بایستی اکثر

مشکل الگوریتم پس انتشار خطا همگرایی دیر و توقف در نقاط بهینه محلی می‌باشد، به همین دلیل تلاش‌های فراوانی برای سرعت بخشیدن به همگرایی و بهبود دقت الگوریتم پس انتشار خطا در آموزش شبکه‌های عصبی صورت گرفته است، از آن جمله می‌توان به استفاده از تطبیق مومنتوم [۹] و نرخ یادگیری متغیر [۱۰] اشاره کرد که به بهبود اندکی منجر شدند. همچنین با بزرگ کردن مصنوعی خطا برای نرون‌های عمل کننده در ناحیه اشباع نتایج بهتری به دست آمدند [۱۱]. با استفاده از روش‌های مختلف مرتبه دوم (برای مثال روش نیوتن، گرادیان مختلط و یا تکنیک بهینه‌سازی Levenberg-Marquardt [۲۱]) بهبود قابل توجهی را می‌توان بر روی عملکرد تشخیص مشاهده کرد، که به‌طور وسیعی به عنوان یکی از مؤثرترین روش‌ها در دقت تشخیص پذیرفته شده است.

در [۱۴-۱۲] برای تسریع در فرایند یادگیری، منطق فازی با الگوریتم‌های یادگیری شبکه عصبی یکپارچه شدند. در [۱۵] نیز از روش بیز<sup>۳</sup> برای آموزش شبکه عصبی استفاده شده است. رویکرد جدید در آموزش شبکه‌های عصبی استفاده از الگوریتم‌های ابتکاری است. روش‌های جستجوی ابتکاری الگوریتم‌هایی هستند که با الهام از فرایندهای فیزیکی و بیولوژیکی در طبیعت به وجود آمده‌اند و غالب آنها به صورت جمعیتی عمل می‌کنند. روش‌های جستجوی ابتکاری بر خلاف روش‌های کلاسیک بر مبنای تصادف عمل کرده و جستجوی فضا را به صورت موازی انجام می‌دهند. تفاوت دیگر آنها در استفاده نکردن از اطلاعات گرادیان فضا است. این نوع روش‌ها تنها از تابع برازندگی برای هدایت جستجو استفاده می‌کنند.

از نمونه‌های این الگوریتم‌ها، الگوریتم ژنتیک با الهام از علم وراثت و تکامل است که در [۱۶] برای محاسبه ضرایب شبکه عصبی از این الگوریتم استفاده شده است. الگوریتم ابتکاری دیگر بازپخت شبیه‌سازی شده<sup>۴</sup> با الهام از مشاهدات ترمودینامیک است، در [۱۷] کارایی بهتر این روش در مقایسه با روش پس انتشار خطا نشان داده شده است. از الگوریتم‌های ابتکاری دیگر می‌توان به بهینه‌سازی گروه ذرات<sup>۵</sup> با تقلید از

ویژگی‌های داده‌ها را حفظ کند و در حالیکه در یک محیط پر اتلاف کار می‌کند، بهره را بیشینه و از پیچیدگی الگوریتمی کمتری نیز برخوردار باشد [۱].

شبکه‌های عصبی مصنوعی در بسیاری از کاربردها همچون فرایندهای کنترلی، دسته‌بندی داده‌ها و خوشه‌بندی اطلاعات مورد استفاده قرار می‌گیرند. همچنین از شبکه‌های عصبی مصنوعی در مسائل فشرده‌سازی تصویر نیز استفاده می‌شود. در [۲] برتری عملکرد شبکه‌های عصبی بر اغلب روش‌های متداول در هنگام مواجهه با داده‌های نویزی یا معیوب نشان داده شده است.

با توجه به تحقیقات انجام شده، شبکه‌های عصبی ابزار مناسبی برای فشرده‌سازی تصویر هستند. زیرا قابلیت پیش-پردازش الگوهای ورودی را برای تولید الگوهای ساده تر با مولفه‌های کمتر دارند. تحقیقات زیادی در مورد استفاده از شبکه‌های عصبی برای فشرده‌سازی تصویر ارائه شده است، از جمله: الگوریتم‌های آموزش تو در تو به همراه شبکه‌های عصبی چند لایه متقارن<sup>۱</sup> [۳]، شبکه‌های SOM [۴]، شبکه‌های تحلیل مولفه‌های اصلی [۵]، شبکه‌های پس انتشار خطا<sup>۲</sup> و الگوریتم استخراج اجزای اصلی واقعی. فهرستی از انواع روش‌های شبکه‌های عصبی جهت فشرده‌سازی تصویر در [۶] و [۷] آمده است.

متداول‌ترین الگوریتم آموزشی شبکه‌های عصبی، الگوریتم پس انتشار خطاست که توسط Romellhart توصیف شده است. در الگوریتم پس انتشار خطا در هر مرحله مقدار خروجی محاسبه شده جدید، با مقدار واقعی مقایسه شده و با توجه به خطای به دست آمده به اصلاح وزن‌های شبکه پرداخته می‌شود، به نحوی که در انتهای هر تکرار اندازه خطای حاصل شده کمتر از میزان به دست آمده در تکرار قبلی باشد.

روش پس انتشار خطا اولین بار توسط Cottrell [۸] مستقیماً برای فشرده‌سازی تصویر بکار رفت و سپس توسط دیگران مطالعه و توسعه یافت. در [۱] فشرده‌سازی تصویر با شبکه عصبی پس انتشار خطا و با استفاده از تابع توزیع تجمعی انجام شده است.

<sup>۳</sup> Bayesian

<sup>۴</sup> Simulated annealing

<sup>۵</sup> Particle swarm optimization (PSO)

<sup>۱</sup> Multi Layer Perseptron (MLP)

<sup>۲</sup> Error Back Propagation

مسائل بهینه‌سازی استفاده می‌شود. در این الگوریتم پاسخ‌های موردنظر موقعیت اجرام در فضای مسئله هستند، میزان اجرام نیز با توجه به تابع هدف تعیین می‌شود.

در ابتدا فضای سیستم مشخص می‌شود که شامل یک دستگاه مختصات چند بُعدی در فضای تعریف مسئله است. پس از تشکیل سیستم، قوانین حاکم بر آن مشخص می‌شوند. فرض می‌شود تنها قانون جاذبه و قوانین حرکت بر این سیستم حاکمند. صورت کلی این قوانین تقریباً شبیه قوانین طبیعت است و به صورت زیر تعریف می‌شوند:

سیستم به صورت مجموعه‌ای از  $m$  جرم تصور می‌شود. موقعیت هر جرم می‌تواند جوابی برای مسئله می‌باشد. موقعیت بُعد  $d$  از جرم  $i$  با  $x_i^d$  نشان داده می‌شود.

$$X_i = (x_i^1, \dots, x_i^d, \dots, x_i^n) \quad \text{for } i = 1, 2, \dots, m \quad (1)$$

نشان دهنده بُعد فضای پاسخ است.  $n$  در رابطه فوق در این سیستم در زمان  $t$ ، به هر جرم  $i$  از سوی جرم  $j$  در جهت بُعد  $d$ ، نیرویی به اندازه  $F_{ij}^d(t)$  وارد می‌شود. مقدار این نیرو طبق رابطه (۲) محاسبه می‌شود.  $G(t)$  ثابت گرانش در زمان  $t$  و  $R_{ij}$  فاصله بین دو جرم  $i$  و  $j$  می‌باشد. برای تعیین فاصله بین اجرام مطابق رابطه (۳) از فاصله اقلیدسی (نرم ۲) استفاده می‌شود.

$$F_{ij}^d(t) = G(t) \frac{M_i(t) \times M_j(t)}{R_{ij}(t) + \varepsilon} (x_j^d(t) - x_i^d(t)) \quad (2)$$

$$R_{ij}(t) = \|X_i(t) - X_j(t)\|_2 \quad (3)$$

در رابطه (۲)،  $\varepsilon$  یک عدد بسیار کوچک است. نیروی وارد بر جرم  $i$  در جهت بُعد  $d$  در زمان  $t$   $(F_i^d(t))$ ، برابر مجموع نیروهایی است که  $k$  جرم برتر جمعیت بر جرم وارد می‌کنند. مقصود از اجرام برتر، عامل‌هایی هستند که دارای برانزنگی بیشتری باشند.

$$F_i^d(t) = \sum_{j \in kbest, j \neq i} rand_j(t) * F_{ij}^d(t) \quad (4)$$

در رابطه فوق  $kbest$  بیانگر مجموعه  $k$  جرم برتر جمعیت است. همچنین در این رابطه  $rand_j$  عددی تصادفی با توزیع یکنواخت در بازه  $[0,1]$  است که برای حفظ خصوصیت تصادفی بودن جستجو در نظر گرفته می‌شود.

طبق قانون دوم نیوتن، هر جرم در جهت بُعد  $d$  شتابی می‌گیرد که متناسب است با نیروی وارد بر جرم  $i$  در آن جهت

رفتار اجتماعی پرندگان اشاره کرد. در [۱۸] کارایی برتر این روش در مقایسه با روش پس انتشار خطا نشان داده شده است. همچنین در [۲۰] از الگوریتم PSO جهت آموزش شبکه‌های عصبی به منظور فشرده‌سازی تصاویر استفاده شده و کارایی برتر این الگوریتم بر روش پس انتشار خطا نشان داده شده است.

به تازگی در حوزه الگوریتم‌های هوش جمعی<sup>۱</sup>، روش بهینه‌سازی و جستجوی جدیدی به نام الگوریتم جستجوی گرانشی<sup>۲</sup> معرفی شده است [۱۹]. این الگوریتم، با الهام از مفاهیم جرم و نیروی جاذبه و با شبیه‌سازی قوانین مربوطه ارائه شده است.

در این مقاله با استفاده از الگوریتم جستجوی گرانشی یک شبکه عصبی MLP به منظور فشرده‌سازی تصاویر آموزش داده می‌شود. برای ارزیابی کارایی شبکه عصبی آموزش دیده، عملکرد آن در فشرده‌سازی چهار تصویر استاندارد در شرایط کاملاً یکسان با دو فشرده‌ساز دیگر که در آنها شبکه عصبی MLP با روش متداول پس انتشار خطا و بهینه‌سازی گروه ذرات آموزش دیده‌اند مقایسه می‌شود.

در بخش ۲ مقاله الگوریتم جستجوی گرانشی معرفی می‌شود. در بخش ۳ نحوه آموزش شبکه عصبی MLP با استفاده از روش GSA معرفی خواهد شد. در بخش ۴ عملکرد فشرده‌ساز طراحی شده ارزیابی می‌شود و بخش ۵ ضمن نتیجه‌گیری و بحث پیرامون نتایج به دست آمده مقاله را به انتها می‌رساند.

## ۲- الگوریتم جستجوی گرانشی

الگوریتم جستجوی گرانشی جدیدترین عضو خانواده الگوریتم‌های هوش جمعی است که از قوانین جاذبه میان اجرام و حرکت نیوتنی الهام گرفته شده است. طبق قانون جاذبه نیوتن، هر جسم به اجسام دیگر نیرو وارد نموده و آنها را به سمت خود جذب می‌کند. به وضوح هر چه این اجسام بزرگ‌تر و نزدیک‌تر باشند، تاثیر این نیرو بیشتر خواهد بود. در نتیجه هر جسم با استفاده از نیروی جاذبه محل و مقدار جرم سایر اجسام را درک می‌کند، بنابراین می‌توان از این نیرو به عنوان رسانه‌ای برای تبادل اطلاعات استفاده کرد. از الگوریتم جستجوی گرانشی در حل

<sup>1</sup> Swarm Intelligence Optimization

<sup>2</sup> Gravitational Search Algorithm (GSA)

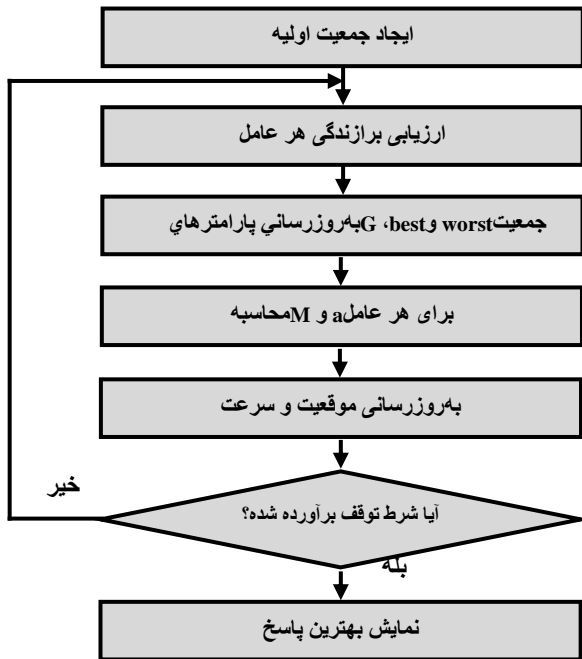
قوی‌ترین و ضعیف‌ترین عامل جمعیت در زمان  $t$  هستند. در نهایت اندازه جرم عامل‌ها طبق رابطه (۱۰) نرمالیزه می‌شود.

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)} \quad (10)$$

در مسائل کمینه‌یابی می‌توان از روابط زیر برای محاسبه بهترین و بدترین عامل‌ها استفاده کرد.

$$best(t) = \min_{j \in \{1, \dots, m\}} fit_j(t) \quad (11)$$

$$worst(t) = \max_{j \in \{1, \dots, m\}} fit_j(t) \quad (12)$$



شکل ۱- فلوچارت الگوریتم جستجوی گرانشی

در ابتدای تشکیل سیستم، هر جسم به صورت تصادفی در یک نقطه از فضا قرار می‌گیرد که جوابی از مسئله است. در هر لحظه از زمان، اجرام ارزیابی شده، سپس تغییر مکان هر جرم پس از محاسبه روابط (۱) تا (۱۲) محاسبه می‌شود. پارامترهای سیستم نیز در هر مرحله به‌روزرسانی می‌شوند. شرط توقف می‌تواند پس از طی مدت زمان مشخصی تعیین شود [۱۹]. در شکل ۱ فلوچارت الگوریتم GSA نشان داده شده است.

ویژگی‌های مثبت الگوریتم GSA همچون همگرایی سریع، عدم توقف در بهینه‌های محلی، کاهش حجم محاسباتی نسبت به الگوریتم‌های تکاملی و عدم نیاز به حافظه در مقایسه با دیگر الگوریتم‌های خانواده هوش جمعی، بستر جدیدی از تحقیقات را فرا روی محققین قرار داده است. از این‌رو با توجه به زمینه-

بخش بر جرم  $i$ . رابطه (۵) شتاب جرم  $i$  در جهت بُعد  $d$  در زمان  $t$  را با  $a_i^d(t)$  نشان می‌دهد.

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (5)$$

سرعت هر جرم برابر مجموع ضربی از سرعت فعلی جرم و شتاب جرم طبق رابطه (۶) تعریف می‌شود. موقعیت جدید بُعد  $d$  از جرم  $i$  طی رابطه ۷ محاسبه می‌شود.

$$V_i^d(t+1) = rand_i * V_i^d(t) + a_i^d(t) \quad (6)$$

$$x_i^d(t+1) = x_i^d(t) + V_i^d(t+1) \quad (7)$$

در روابط فوق  $V_i^d(t)$  سرعت بُعد  $d$  ام عامل  $i$  در زمان  $t$  و  $rand_i$  عددی تصادفی با توزیع یکنواخت در بازه  $[0,1]$  است که برای حفظ خصوصیت تصادفی بودن جستجو در نظر گرفته می‌شود. برای تنظیم ضریب گرانش از رابطه (۸) استفاده می‌شود.

$$G(t) = \beta^{-\alpha \frac{t}{T}} \quad (8)$$

ثابت گرانش پارامتری مناسب برای کنترل دو ویژگی کاوش<sup>۱</sup> و بهره‌وری<sup>۲</sup> در این الگوریتم به‌شمار می‌آید. مقادیر بزرگ آن موجب تقویت توانایی کاوش الگوریتم و مقادیر کوچک آن موجب افزایش توانایی بهره‌وری الگوریتم می‌شود. از آنجا که در مراحل اولیه جستجو لازم است الگوریتم به جستجوی نقاط جدیدی در فضای مسئله پرداخته و در مراحل پایانی با افزایش توان بهره‌وری به بهبود جواب‌های دیده شده بپردازد، گزینه مناسب برای ثابت گرانش بایستی با یک مقدار اولیه بزرگ شروع شده و با گذشت زمان مقدار آن به تدریج کاهش یابد. طبق آزمایش‌های متعدد انجام شده، استفاده از رابطه نمایشی جهت کاهش ثابت گرانش در حل بسیاری از مسائل موثر است.

در رابطه (۹) جرم عامل‌ها بر مبنای تابع هدف آنها تنظیم می‌شود بگونه‌ای که به عامل‌های باشایستگی بیشتر، جرم بیشتری نسبت داده می‌شود.

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)} \quad (9)$$

در این رابطه  $fit_i(t)$  بیانگر میزان برازندگی جرم  $i$  در زمان  $t$  است،  $best(t)$  و  $worst(t)$  به ترتیب بیانگر میزان شایستگی

<sup>۱</sup> Exploration  
<sup>۲</sup> Exploitation

کانال باریک  $n$  بُعدی در لایه مخفی که  $n < m$  نگاشت می‌کنند و مقدار خروجی بهینه‌ای را تولید می‌کند که کوچکترین میانگین مربعات خطا بین ورودی و خروجی را ایجاد می‌کند، در این روش نسبت فشرده‌سازی  $\frac{m-n}{m} \times 100$  است. مجموع ورودی‌ها،  $S_h(i)$  برای نرون  $i$  در لایه مخفی به صورت زیر محاسبه می‌شود:

$$S_h(i) = \sum_{j=1}^N w_h(j,i)x(j) \quad \text{for } 1 \leq i \leq H \quad (14)$$

که در آن  $w_h(j,i)$  وزن اتصال از  $j$  امین نرون ورودی به  $i$  امین نرون در لایه مخفی،  $x(j)$ ،  $j$  امین المان ورودی (مقدار پیکسل) است. به طور مشابه، مجموع ورودی‌ها به  $i$  امین نرون خروجی به صورت زیر است:

$$S_o(i) = \sum_{j=1}^H w_o(j,i)h(j) \quad \text{for } 1 \leq i \leq N \quad (15)$$

جاییکه  $w_o(j,i)$  وزن اتصال از  $j$  امین نرون لایه مخفی به  $i$  امین نرون لایه خروجی است، و  $h(j)$  خروجی  $j$  امین نرون لایه مخفی است. از تابع سیگموئید برای محاسبه مقدار خروجی نرون‌های لایه‌های مخفی و خروجی استفاده می‌شود. زمانی که ورودی و خروجی شبکه عصبی به مقادیری در بازه  $[0,1]$  محدود می‌شود، شبکه کارایی بهتری از خود نشان می‌دهد، از این رو می‌توان سطوح خاکستری در تصویر (که معمولاً در بازه  $0$  تا  $255$  قرار دارند) را بر بزرگترین مقدار پیکسل موجود در تصویر تقسیم کرد و تصویر نرمالیزه شده را به شبکه عصبی اعمال نمود.

برای آموزش شبکه، یک بلوک از تصویر به عنوان ورودی و خروجی مورد انتظار استفاده می‌شود، ساده‌ترین راه برای استخراج چنین بلوکی تولید دو عدد تصادفی است که موقعیت گوشه سمت چپ بلوک را می‌دهد. مقادیر پیکسل‌های بلوک استخراج شده از چپ به راست و بالا به پایین از طریق نگاشت پیکسل به عدد حقیقی به ورودی شبکه اعمال می‌شود. تابع مربعات خطا در طول آموزش مینیمم می‌شود. پس از آموزش، تصویری که باید فشرده شود به بلوک‌های پیوسته بدون همپوشانی پارتیشن بندی می‌شود که هر یک از آنها در یک زمان به شبکه اعمال می‌شوند. خروجی نرون‌های لایه مخفی ویژگی‌های فشرده شده از بلوک ورودی را تشکیل می‌دهند.

های کاربردی مورد استفاده، نسخه‌های متفاوتی از این الگوریتم ارائه شده است که می‌توان به الگوریتم جستجوی گرانشی باینری (BGS) <sup>۱</sup> [۲۲]، الگوریتم جستجوی گرانشی نخبه-گرای پیشرفته (AEGSA) <sup>۲</sup> [۲۳] و الگوریتم جستجوی گرانشی چند هدفه (MOGSA) <sup>۳</sup> [۲۴] اشاره نمود. همچنین این الگوریتم تا به حال در حوزه‌های مختلف بهینه‌سازی همچون داده کاوی، انتخاب ویژگی، مهندسی پزشکی، طراحی خودکار مدارات مجتمع آنالوگ، پردازش تصویر و بسیاری کاربردهای دیگر استفاده شده است. با توجه به مزایای الگوریتم GSA که در بالا به آن اشاره شد، بر آن شدیم تا از قابلیت‌های این الگوریتم در فشرده‌سازی تصویر نیز استفاده نماییم.

### ۳- آموزش شبکه عصبی MLP با استفاده از روش GSA

#### ۳-۱- طراحی شبکه عصبی MLP

در این تحقیق برای فشرده‌سازی تصاویر از شبکه عصبی MLP بهره گرفته شده است. شبکه عصبی MLP از لایه ورودی، لایه‌های مخفی و لایه خروجی که هر کدام شامل تعداد نرون‌های مشخصی است تشکیل می‌شود.

هر دو لایه ورودی و خروجی به‌طور کامل به لایه میانی متصل هستند. ورودی به شبکه، یک بردار  $m$  بُعدی است، یعنی یک بلوک از پیکسل‌هایی که از تصویر استخراج شده‌اند. فشرده‌سازی با تعیین مقدار  $n$  (تعداد نرون‌ها در لایه مخفی) حاصل می‌شود، تعداد نرون‌ها در لایه مخفی کمتر از تعداد نرون‌ها در هر دو لایه ورودی و خروجی است. تصویر ورودی به بلوک‌هایی با اندازه  $k \times k$  تقسیم می‌شود. تمام وزن‌های متصل به نرون‌های لایه مخفی به وسیله  $\{w_{ij}, j=1,2,\dots,n \text{ and } i=1,2,\dots,m\}$  نمایش داده می‌شوند، که می‌توان آن را به صورت یک ماتریس  $m \times n$  نمایش داد. اتصالات از لایه مخفی به لایه خروجی با  $w_{ji}$  نمایش داده می‌شوند، که یک ماتریس  $n \times m$  دیگر است و برابر با ترانزاده ماتریس  $w$  است. فشرده‌سازی تصویر با آموزش دادن شبکه به دست می‌آید، وزن‌های  $w_{ij}$  بردار ورودی  $m$  بُعدی را به یک

<sup>1</sup> Binary Gravitational Search Algorithm

<sup>2</sup> Advanced Elitism Gravitational Search Algorithm

<sup>3</sup> Multi Objective Gravitational Search Algorithm

وزن متناظر با آن استخراج می‌شود.

#### ۴- ارزیابی عملکرد

برای ارزیابی عملکرد شبکه عصبی MLP طراحی شده در فشرده‌سازی تصاویر، از آن برای فشرده‌سازی چهار تصویر استاندارد استفاده می‌شود. برای انجام آزمایش‌ها از چهار تصویر استاندارد به نام‌های Lena, Goldhill, Mandrill و Pepper استفاده می‌کنیم. این تصاویر ۸ بیتی هستند و اندازه هر یک از آنها 512×512 می‌باشد و مقادیر شدت پیکسل آنها بین ۰ تا ۲۵۵ است.



شکل ۱: تصاویر استاندارد مورد استفاده

در شرایط کاملاً یکسان شبکه عصبی مورد نظر جهت فشرده‌سازی تصاویر توسط روش‌های جستجوی گرانشی، بهینه‌سازی گروه ذرات و پس انتشار خطا آموزش داده می‌شود. تمام نتایج برای ۳۰۰۰ بار تکرار هر الگوریتم آورده شده است، همچنین با توجه به تصادفی بودن الگوریتم‌های فوق، تمام آزمایشات برای ۱۰ مرتبه تکرار انجام شده است. مشخصات روش‌های به‌کار گرفته شده برای آموزش به شرح زیر است:

#### • الگوریتم GSA

جمعیت اولیه اجرام در روش GSA برابر ۱۵ می‌باشد. در رابطه (۸)، مقدار  $\alpha$  برابر ۲۰ و مقدار  $\beta$  به صورت خطی از ۱ تا ۳ افزایش می‌یابد.

برای عملی شدن فشرده‌سازی، خروجی نرون‌های لایه مخفی کوانتیزه می‌شود [۲۰].

#### ۲-۳- آموزش شبکه عصبی MLP توسط الگوریتم GSA

در فرایند آموزش شبکه عصبی MLP در فشرده‌سازی تصاویر، هدف نهایی جستجوی بهترین اوزان شبکه عصبی است که به کوچکترین میانگین مربعات خطا (MSE) منتهی شود، مطابق رابطه زیر تعریف می‌شود:

$$MSE = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (u_{ij} - u_{ij}^*)^2 \quad (16)$$

$u_{ij}$  و  $u_{ij}^*$  به ترتیب نشان دهنده تصویر اصلی و تصویر بازسازی شده است.

در این تحقیق استفاده از روش GSA برای یافتن بهترین اوزان شبکه عصبی پیشنهاد می‌شود.

با توجه به تعداد کل نرون‌های شبکه عصبی MLP مورد نظر، بردار وزنی به شکل تصادفی تولید می‌شود.

$$W = [w_1, w_2, w_3, \dots, w_n] \quad (17)$$

در این رابطه  $W_n$  به تعداد کل نرون‌های موجود در شبکه عصبی MLP بستگی دارد.

در روش GSA جمعیت اولیه اجرام (بردارهای وزن) تولید می‌شود. موقعیت هر جرم، مجموعه‌ای از وزن‌های شبکه را برای تکرار جاری الگوریتم و بُعد هر جرم تعداد وزن‌هایی که در شبکه وجود دارد را نشان می‌دهد. اجرام در فضا حرکت می‌کنند و سعی می‌کنند خطا را مینیمم سازند. تغییر موقعیت یک جرم به معنای به‌روزرسانی وزن‌های شبکه در جهت کاهش MSE در تکرار جاری است. در هر تکرار، تمام اجرام موقعیتشان را با محاسبه سرعت جدید به‌روزرسانی و به سمت موقعیت جدید حرکت می‌کنند.

موقعیت جدید مجموعه‌ای از وزن‌های جدید است که برای به دست آوردن MSE جدید استفاده می‌شود. این فرایند برای تمام اجرام تکرار می‌شود. جرم با حداقل MSE به عنوان بهترین جرمی که تاکنون پیدا شده است در نظر گرفته می‌شود. فرایند آموزش تا زمانی ادامه پیدا می‌کند که خطای قابل قبول توسط یک جرم به دست آید یا یک شرط خاتمه مانند تعدادی تکرار پیش فرض، برآورده شود. زمانی که فرایند آموزش خاتمه یافت، به ازای شایسته‌ترین جرم (حداقل MSE)، بردار

• الگوریتم PSO

جمعیت اولیه ذرات برابر ۱۵ می‌باشد، در این الگوریتم  $C_1$  و  $C_2$  مساوی ۱ فرض می‌شوند. همچنین وزن اینرسی  $W$  به صورت خطی از ۰.۹ تا ۰.۲ کاهش می‌یابد.

• روش پس انتشار خطا (EBP)

در این روش  $\eta=0.4$  فرض شده است.

۴-۱- نتایج آزمایشات

برای آزمایش از تصویر Lena به عنوان تصویر آموزش استفاده می‌شود. ابتدا تصویر به بلوک‌هایی با اندازه  $8 \times 8$  تقسیم می‌شود. سپس هر دو شبکه‌ها با این بلوک‌ها که هر کدام یک بردار  $64$  تایی هستند آموزش داده می‌شوند تا زمانیکه شبکه‌ها همگرا شوند. پس از آموزش، هر سه شبکه با تصویر Lena و سه تصویر دیگر آزمایش می‌شوند و میانگین مربعات خطا به ازای هر تصویر به دست می‌آید.

نتایج حاصل از این آزمایشات برای دو نسبت فشردسازی  $1/4$  (یک چهارم) و  $1/8$  (یک هشتم) به ترتیب در جداول ۱ و ۲، و تصاویر به دست آمده در شکل‌های ۴-۲ نشان داده شده است. با توجه به مقدار میانگین MSE به دست آمده در نتایج، به وضوح مشخص است که آموزش شبکه عصبی توسط روش GSA عملکرد بهتری نسبت به دو روش بهینه سازی جمعیت ذرات و پس انتشار خطا در فشردسازی تصاویر دارد.

جدول ۲: مقایسه میانگین MSE به دست آمده از آزمایش شبکه عصبی MLP توسط سه روش GSA، PSO و EBP با نسبت فشردسازی  $1/8$

نام تصویر	GSA	PSO	EBP
Lena	0.0275	0.0562	0.0763
Goldhill	0.0337	0.0697	0.0794
mandrill	0.0454	0.0572	0.0894
pepper	0.0243	0.0521	0.0648



(الف)

(ب)



(ج)

(د)


شکل ۲: تصاویر بازیابی شده Lena با نسبت فشردسازی  $1/4$

(الف) تصویر اصلی (ب) روش GSA (ج) روش PSO (د) روش EBP



(الف)

(ب)



(ج)

(د)

جدول ۱: مقایسه میانگین MSE به دست آمده از آزمایش شبکه عصبی MLP توسط سه روش GSA، PSO و EBP با نسبت فشردسازی  $1/4$

نام تصویر	GSA	PSO	EBP
Lena	0.0156	0.0254	0.0563
Goldhill	0.0132	0.0324	0.0584
mandrill	0.0234	0.0276	0.0663
pepper	0.0123	0.0215	0.0327

و استفاده از انواع ترکیبی آن نتایج بهتری از این روش بهینه-سازی را در کاربردهای مختلف علوم مهندسی نشان دهیم.

## ۶- مراجع


- [1] S. Anna Durai, and E. Anna Saro, "Image Compression with Back-Propagation Neural Network using Cumulative Distribution Function", World Academy of Science, Engineering and Technology, 2006.
- [2] S. Kulkarni, B. Verma and M. Blumenstein, "Image Compression using a Direct Solution Method Based Neural Network", Griffith University, Gold Coast Campus, QLD 4217, Australia.
- [3] D.K Kumar, N. Mahalingam, "Nested neural networks for image compression", In IEEE Region 10 International Conference on Global Connectivity in Energy. 1998.
- [4] C. Amerijckx, M. Verleysen, P. Thissen, and J.Legat, "Image Compression by Self-Organized Kohonen Map", In IEEE Transactions on Neural Networks, Vol. 9, No. 3, May 1998.
- [5] J. MI, and D. S. Huang, "Image Compression Using Principal Component Neural Network", In IEEE International Conference on Control, Automation, Robotics and Vision, 2004.
- [6] Robert D. Dony, Simon Haykin, "Neural Network Approaches to Image Compression", In PROCEEDINGS OF THE IEEE, VOL. 83, NO. 2, FEBRUARY 1995.
- [7] Hamdy S. Soliman, Mohammed Omari, "A neural networks approach to image data compression" In Applied Soft Computing 6, pp. 258-271, 2006.
- [8] G. W. Cottrell, P. Munro and D. Zipser, "Image Data Compression by Back Propagation: An example of Extensional Programming", ICs Report 8702, 1987.
- [9] A. A. Miniani, R. D. Williams, "Acceleration of back-propagation through learning rate and momentum adaptation", Proc. International joint conference on neural networks, San Diego, CA, pp. 676-679, 1990.
- [10] R. A. Jacobs, "Increased rate of convergence through learning rate adaptation", Neural Networks, Vol. 1, No. 4, pp. 295-308, 1988.
- [11] K. Balakrishnan, V. Honavar, "Improving convergence of back propagation by handling flat-spots in the output layer", Proc. Second International Conference on Artificial Neural Networks, Brighton, U.K., pp. 139-144, 1992.
- [12] W. Yan, S. Hongbao, "Improvement of Neural Network learning algorithm and its application in control", Proc. The 3rd World Congress on neural networks, Hefei, Anhui, pp. 971-975, 2000.
- [13] B. Bazartseren, G. Hildebrandt, K. P. Holz, "Short-term water level prediction using neural

شکل ۳: تصاویر بازیابی شده Pepper با نسبت فشرده‌سازی ۱/۴

(الف) تصویر اصلی (ب) روش GSA (ج) روش PSO (د) روش EBP

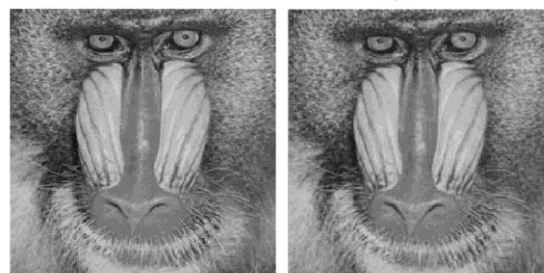
## ۵- نتیجه گیری

شبکه‌های عصبی مصنوعی ساختارهای قدرتمندی برای دسته بندی داده‌ها و یادگیری الگوها دارند. بسیاری از محققین تمایل دارند از این ابزار استفاده نمایند اما با مسئله آموزش شبکه عصبی مواجه می‌شوند. الگوریتم جستجوی گرانشی از جمله جدیدترین الگوریتم‌های ابتکاری است که با الهام از قانون جاذبه و مفهوم جرم در طبیعت بنا نهاده شده است.



(الف)

(ب)



(ج)

(د)

شکل ۴: تصاویر بازیابی شده Mandrill با نسبت فشرده‌سازی ۱/۸

(الف) تصویر اصلی (ب) روش GSA (ج) روش PSO (د) روش EBP

در این مقاله پیشنهاد استفاده از الگوریتم جستجوی گرانشی برای آموزش شبکه عصبی MLP به منظور فشرده‌سازی تصاویر ارائه شده است. به این ترتیب می‌توان با جستجوی بهترین اوزان شبکه عصبی، به بهترین فشرده‌سازی تصاویر دست یافت. از فشرده‌ساز طراحی شده در فشرده‌سازی چهار تصویر استاندارد استفاده شده است.

عملکرد فشرده‌ساز ارائه شده با دو فشرده‌ساز دیگر که در آنها شبکه عصبی MLP با روش متداول پس انتشار خطا و بهینه سازی گروه ذرات آموزش دیده بودند، مورد مقایسه قرار گرفت. نتایج نهایی نشان می‌دهند که روش پیشنهادی بطور چشمگیری میزان فشرده سازی تصویر را نسبت به دیگر روشها بهبود بخشیده است.

در تحقیقات آتی سعی داریم با تکامل و ارتقاء الگوریتم GSA



اکبری، رضا؛ زیارتی، کوروش؛ " استفاده از بهینه‌سازی گروهی ذرات برای آموزش شبکه‌های عصبی و کاربرد آن در فشرده-سازی تصویر"، هشتمین کنفرانس سیستم‌های هوشمند، دانشگاه فردوسی، مشهد، ۱۳۸۶.

[21] M. T. Hagan, M. Menhaj, "Training feed forward networks with the Marquardt algorithm", IEEE transactions on Neural Networks, Vol. 5, No. 6, pp. 989-993, 1994.

[۲۲] راشدی، عصمت؛ نظام‌آبادی پور، حسین؛ سریزدی، سعید؛ الگوریتم جستجوی گرانشی باینری، هشتمین کنفرانس سیستم‌های هوشمند، دانشگاه فردوسی مشهد، ۱۳۸۶.

[۲۳] ده‌باشیان، مریم؛ ظهیری، سیدحمید؛ الگوریتم جستجوی گرانشی نخبه‌گرای پیشرفته، اولین کنفرانس انرژی‌های تجدیدپذیر و تولید پراکنده ایران، دانشگاه بیرجند، ۱۳۸۸.

[۲۴] ده‌باشیان، مریم؛ ظهیری، سیدحمید؛ MOGSA: روشی جدید در بهینه‌سازی چند هدفه مبتنی بر الگوریتم جستجوی گرانشی، شانزدهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، دانشگاه صنعتی شریف، ۱۳۸۹.

networks and neuro-fuzzy approach", neuro computing, Vol. 55, No. 3-4, pp. 439-450, 2003.

[15] M. Engin, "ECG beat classification using neuro-fuzzy network", Pattern Recognition Letters, Vol. 25, pp. 1715-1722, 2004.

[16] P. Kumar, S. N. Merchant, U. B. Desai, "Improving performance in pulse radar detection using Bayesian regularization for neural network training", Digital Signal Processing, Vol. 14, No. 5, pp. 438-448, 2004.

[17] L. L. Rogers, F. U. Dowla, V. M. Johnson, "Optimal field-scale groundwater remediation using neural networks and the genetic algorithm", Environmental Science and Technology, Vol. 29, No. 5, pp. 1145-1155, 1995.

[18] A. L. Arnaud, P. J. L. Adeodato, G. C. Vasconcelos, R. F. O. Neto, "MLP neural networks optimization through simulated annealing in a hybrid approach for time series prediction", Congresso de Sociedade Brasileira de computação, pp. 1110-1113, 2005.

[19] Y. P. Chang, C. N. Ko, "A PSO method with nonlinear time-varying evolution based on neural network for design of optimal harmonic filters", Expert Systems with Applications, Vol. 36, pp. 6809-6816, 2009.

[۲۰] E. Rashedi, H. Nezamabadi-pour, S. Saryazdi, "GSA: A Gravitational Search Algorithm", Information Sciences, Vol. 179, pp. 2232-2248, 2009.