

بهینه سازی سازه ها با استفاده از شبکه های عصبی مصنوعی

عباس ایرانمنش
استادیار

علی کاوه
استاد

دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران

و
مرکز تحقیقات ساختمان و مسکن

چکیده

در این تحقیق، اصولی براساس شبکه های عصبی بسط و توسعه داده شده است که حاوی ترکیبی از توانایی های داده پردازشی اطلاعات شبکه های عصبی و روش های عددی بهینه سازی سازه ها می باشد. در روش ارائه شده، دو شبکه عصبی آموزش داده می شوند، یکی برای قیود و دیگری برای مشتقات قیود، و بهینه سازی سازه ها با بکارگیری این شبکه های عصبی مصنوعی انجام می گیرد. تمامی پارامترهای مورد نیاز همانند ماتریس های وزن در شبکه های عصبی مصنوعی و با محاسبات مربوط به قیود و مشتقات مربوطه به طور خودکار، در ضوابط توسعه داده شده محاسبه می گردند. چند مثال عددی برای نمایش توانایی های روش ارائه شده مطرح گردیده است.

Structural Optimization Using Artificial Neural Networks

A. Kaveh
Professor

A. Iranmanesh
Assistant Professor

Iran University of Science and Technology
and
Building and Housing Research Centre

Abstract

In this paper, a strategy is presented to combine the capabilities of optimization methods and the power of the data processing in artificial neural networks. Two neural nets are trained using counterpropagation algorithm for the constraints and derivatives of the constraints. All parameters such as weight matrices and the computations corresponding to constraints are carried out automatically. Examples are included to illustrate the capabilities and accuracy of the developed networks.

مقدمه

اصولاً شبکه عصبی مصنوعی یک سیستم داده پردازشی مشابه با مغز انسان است. همانند یک مدل بیولوژیک که شامل مجموعه زیادی از نرون‌های مرتبط به هم است، شبکه‌های عصبی مصنوعی از مجموعه زیادی از واحدهای داده پردازشی اطلاعات به نام نرون مصنوعی تشکیل شده‌اند. یک شبکه عصبی مصنوعی به مفهوم ریاضی مسئله‌ای را حل نمی‌نماید، بلکه با داشتن خصوصیات داده پردازشی اطلاعات، قادر به تعیین پاسخ تقریبی یک مسئله داده شده است. شبکه‌های عصبی مصنوعی به طور گسترده‌ای در نگاشت توابع پیچیده غیرخطی، داده پردازشی مربوط به تصاویر و گروه‌بندی اطلاعات و سایر موارد به کار گرفته شده‌اند [۱-۲].

هر چند پیشرفت‌های قابل توجهی در فن‌آوری محاسبات در سال‌های اخیر حاصل آمده است، لیکن حل بسیاری از مسائل با مقیاس بزرگ هنوز به وقت رایانه قابل توجهی نیاز دارند. بنابراین دستیابی به روش‌های محاسباتی که از سرعت بالا برای حل یک مسئله خاص برخوردار بوده و دارای جواب نسبی قابل اعتمادی باشد، مورد توجه است.

محققان بسیاری به توسعه و کاربری شبکه‌های عصبی مصنوعی به عنوان یک تحلیل‌کننده سریع در بهینه‌سازی سازه‌ها پرداخته‌اند [۳-۹]. دو شبکه عصبی مصنوعی که در تقریب زدن توابع بکار گرفته می‌شوند، عبارتند از: شبکه عصبی با انتشار پسرفتی (Back Propagation) و شبکه عصبی با انتشار متقابل (Counter Propagation). یکی از معایب عمده شبکه عصبی با انتشار پسرفتی سرعت کند همگرایی آن است، خصوصاً زمانی که بررسی مسائل با مقیاس بزرگ مورد نظر باشد، زیرا تعداد واحدهای ورودی و خروجی قابل توجه هستند. برای رفع این مشکل از شبکه‌های عصبی با انتشار متقابل اصلاح شده استفاده شده است که به سادگی و با سرعت آموزش داده می‌شود [۱۰].

در این تحقیق، دو شبکه عصبی براساس شبکه عصبی با انتشار متقابل اصلاح شده آموزش داده شده است. شبکه عصبی اول برای قیود و شبکه عصبی دوم برای مشتقات قیود به کار رفته‌اند. شبکه‌های عصبی آموزش یافته در مرحله بهینه‌سازی سازه‌ها، نیاز به قیود و مشتقات مربوطه پاسخ سریع می‌دهند. روش پیشنهادی کلی بوده و قابل استفاده در بهینه‌سازی خرپاهای مستوی و فضایی می‌باشد و نتایج حاصل

تقریب بسیار خوبی از جواب بهینه متغیرهای طراحی است. برای نشان دادن کارآئی شبکه‌های عصبی با انتشار متقابل اصلاح شده و روش ارائه شده مثال‌هایی در مورد بهینه‌سازی وزن خرپاهای مستوی و فضایی نسبت به قیودی همانند محدودیت در تنش عضوها و همچنین محدودیت در جابجایی گره‌های خرپا اجرا شده است.

شبکه عصبی اصلاح شده با انتشار متقابل

توپولوژی یک شبکه عصبی با انتشار متقابل در شکل (۱) نشان داده شده است. این شبکه عصبی ترکیبی از دو الگوریتم می‌باشد: نگاشت خود معلم کوهنن (Kohonen) و شبکه خروجی گروسبرگ (Grossberg). این شبکه عصبی همانند یک جدول مرجع عمل می‌نماید، بدین معنی که نزدیکترین پاسخ به بردار ارائه شده از این جدول مرجع انتخاب می‌گردد. شبکه عصبی با انتشار متقابل در دو مرحله آموزشی داده می‌شود. در مرحله اول بردارهای ورودی در نرون‌های لایه کوهنن گروه‌بندی می‌گردند. در تعریف اولیه این شبکه عصبی، گروه‌بندی نرون‌های لایه کوهنن براساس حاصلضرب عددی و یا فاصله اقلیدسی صورت می‌گرفت. در این مرحله پس از آنکه تمامی مجموعه بردارهای آموزشی به شبکه ارائه گردیدند، وزن‌های مرتبط بین لایه ورودی و نرون‌های لایه کوهنن تثبیت می‌گردند. در مرحله دوم آموزش، فقط نرون برنده J در لایه کوهنن فعال باقی می‌ماند. وزن‌های مرتبط بین نرون J و نرون‌های لایه خروجی به طریقی اصلاح می‌گردند که بردار y حاصل از نرون‌های لایه خروجی Y تقریبی از بردار ورودی Y باشد. مشکل اساسی این الگوریتم معرفی مقادیر اولیه ماتریس‌های وزن می‌باشد که ممکن است پس از آموزش به سمت مقادیر بهینه میل ننمایند. به علاوه گروه‌بندی نرون‌های لایه کوهنن براساس حاصلضرب عددی و بردار و یا فاصله اقلیدسی که تعبیر هندسی آن منطبق شدن دو بردار برهم می‌باشد، یکسان بودن طول دو بردار را تضمین نمی‌نماید. برای رفع این عیب در شبکه عصبی با انتشار متقابل اصلاح شده، گروه‌بندی واحدهای لایه کوهنن براساس قدر مطلق تعریف شده زیر انجام می‌شود:

$$D = \sum_{i=1}^n |x_i - v_i| \quad (1)$$

$$z_j = 1.0 \quad (6)$$

در نتیجه خروجی شبکه به واقع بردار وزن نرون J مرتبط به نرون های واحد خروجی است. این نوع شبکه همانند یک جدول مرجع با n ورودی عمل می نماید. دقت این نوع شبکه با بالا رفتن تعداد نرون های لایه کوهنن افزایش می یابد، اما در مورد مسائل با مقیاس بزرگ منتهی به شبکه های عصبی بسیار گسترده می گردد که نامناسب می باشد. برای برطرف نمودن این مشکل، یک شبکه عصبی مفسر به شرح زیر معرفی می گردد. پس از آموزش شبکه براساس مطالب مطرح شده، زوج بردارهایی برای بررسی در عملکرد شبکه ارائه می گردند. در چنین شرایطی اجازه داده می شود یک و یا بیش از یک نرون در لایه کوهنن برنده گردند. تعداد این نرون ها به طریقی تعیین می شود که خطای شبکه کمینه گردد.

$$E = \frac{\sum_{i=1}^k (y_i - y'_i)}{\sum_{i=1}^k y_i} \times 100 \quad (7)$$

در اینجا y'_i جواب پیش بینی شده توسط شبکه و y_i جواب واقعی و k تعداد زوج بردارهایی است که با آنان عملکرد شبکه مورد بررسی قرار گرفته است. در این حالت، وقتی که یک بردار به شبکه ارائه گردد، یک بردار وزن و یا ترکیبی از چندین بردار وزن براساس تعداد نرون های برنده، خروجی شبکه را تعیین می نمایند. در صورتی که تعداد نرون های برنده بیش از یکی باشد پاسخ آنها به صورتی است که:


$$\sum_{j=1}^{N_{win}} z_j = 1.0 \quad (8)$$

به طوری که N_{win} تعداد نرون های برنده است. پاسخ تحریک نرون های خروجی برابر است با:

$$y' = \sum_{j=1}^{N_{win}} w_{jk} z_j \quad (9)$$

به هنگام عملکرد شبکه، برای هر نرون لایه کوهنن مقدار D_i ($i = 1, \dots, p$) براساس فاصله اقلیدسی محاسبه می شود و سپس مجموعه ای از N نرون ($N = 1, \dots, N_{win}$) به طوری انتخاب می گردند که مقدار D_N مربوطه کمینه باشد. نرون های برنده با توجه به

که در این رابطه D معیاری جهت نشان دادن نزدیکی بردار ورودی x به بردار وزن v می باشد. با انتخاب مقدار اختیاری برای D ، تعداد واحدهای لایه کوهنن به طور پویا تعیین می گردند. انتخاب مقدار D بستگی به نوع مسئله دارد، با این وجود با در نظر گرفتن مقدار کوچک برای D منتهی به بزرگ شدن شبکه می گردد [5].



شکل (1) توپولوژی شبکه عصبی با انتشار متقابل.

در مرحله آموزش با معرفی نخستین بردار آموزشی، اولین نرون لایه کوهنن تشکیل گردیده و این بردار در واقع بردار وزن مرتبط بین نرون های لایه ورودی و نرون لایه کوهنن است. برای بردارهای آموزشی بعدی اگر چنانچه J امین بردار ورودی به اندازه D از نرون های تعریف شده قبلی لایه کوهنن فاصله داشته باشد، یک نرون جدید تشکیل می گردد و در غیر این صورت نزدیکترین بردار وزن به بردار ورودی اصلاح می شود. در مرحله آموزش، بردارهای وزن v_{ij} مرتبط بین نرون های لایه ورودی و لایه کوهنن و بردارهای وزن w_{ij} مرتبط بین لایه کوهنن و لایه خروجی تعیین می گردند.

در شبکه های عصبی با انتشار متقابل معمولی زمانی که برداری به شبکه ارائه می گردد، نرونهای لایه کوهنن با یکدیگر رقابت نموده و نرون با کوچکترین فاصله اقلیدسی با بردار ورودی x برنده می شود. بنابراین خروجی نرون برنده J برابر است با:

$$y' = w_{jk} z_j \quad (5)$$

به طوری که:

(۱۱) خواهد بود.

$$U = K^{-1} P \quad (13)$$

ماتریس سختی عضو k_i ، در مختصات کلی سازه با استفاده از ماتریس سختی عضو k_i^0 در مختصات محلی و ماتریس دوران T حاصل می‌گردد.

$$k_i = T^t k_i^0 T \quad (14)$$

همچنین جابجایی‌های گرهی مربوط به هر عضو را می‌توان به دستگاه مختصات محلی برد:

$$u^0 = Tu \quad (15)$$

نیروهای ایجاد شده در هر عضو برابر است با:

$$f = k_i^0 u^0 \quad (16)$$

در نهایت قیود مربوط به تنش‌ها با استفاده از این نیروها قابل محاسبه هستند. با گرفتن مشتق از معادله (۱۱) نسبت به متغیر طراحی X_i ($i = 1, 2, \dots, n$) داریم:

$$\frac{\partial K}{\partial X_i} U + K \frac{\partial U}{\partial X_i} = \frac{\partial P}{\partial X_i} \quad (17)$$

یا

$$\frac{\partial K}{\partial X_i} = K^{-1} \left[\frac{\partial P}{\partial X_i} - \frac{\partial K}{\partial X_i} U \right] \quad (18)$$

با فرض اینکه نیروها مستقل از متغیرهای طراحی X_i باشند، اولین عبارت داخل کروشه صفر خواهد بود. همچنین با استفاده از معادله (۱۲) داریم:

$$\frac{\partial K}{\partial X_i} = \sum_{j=1}^{NE} \frac{\partial k_j}{\partial X_i} \quad (19)$$

پس از اینکه مشتقات جابجایی‌ها نسبت به متغیرهای طرح X_i تعیین گردید، با در دست داشتن این اطلاعات در مختصات محلی، امکان محاسبه مشتق نیروها و در نهایت تنش‌ها نسبت به متغیرهای طرح X_i وجود خواهد داشت. به عنوان مثال، برای اولین عضو یک خرپا دو قید زیر اعمال می‌گردد:

مقادیر محاسبه شده D_N از مقدار کمینه مرتب می‌گردند. نرون با کوچکترین مقدار D_N که نزدیکترین بردار با بردار ورودی است، باید سهم بیشتری در این شرایط داشته باشد. برای این استدلال رابطه زیر پیشنهاد می‌گردد:

$$z_j = \frac{\sum_{N=1}^{N_{win}} D_N - D_j}{D_j \times \sum_{N=1}^{N_{win}} D_N} \times 100 \quad (10)$$

در رابطه فوق z_j سهم هر یک از نرون‌های برنده است که در معادله (۹) به کار گرفته می‌شود. نزدیکترین نرون به بردار ورودی از لایه کوهن، D_j دارای کوچکترین مقدار است که منتهی به بزرگترین z_j می‌گردد. دلیل اضافه نمودن D_j در مخرج این رابطه به واسطه تشدید این آثار است.

محاسبه قیود و مشتقات مربوط به روش تحلیلی

ایجاد شرایط بهینه سازه‌ها، مستلزم تعیین قیود مربوط به تنش‌ها و جابجایی‌ها می‌باشد. محاسبه مشتقات قیود همگی در مرحله اول منتهی به تعیین مشتق جابجایی‌ها نسبت به متغیرهای طرح می‌باشد، زیرا اکثر قیود متداول (محدودیت در تنش‌ها) مستقیماً به جابجایی‌ها مرتبط می‌گردند [۱۱]. به کار گرفتن روش سختی برای محاسبه تغییر شکل‌ها مستلزم حل دستگاه معادلات زیر است:

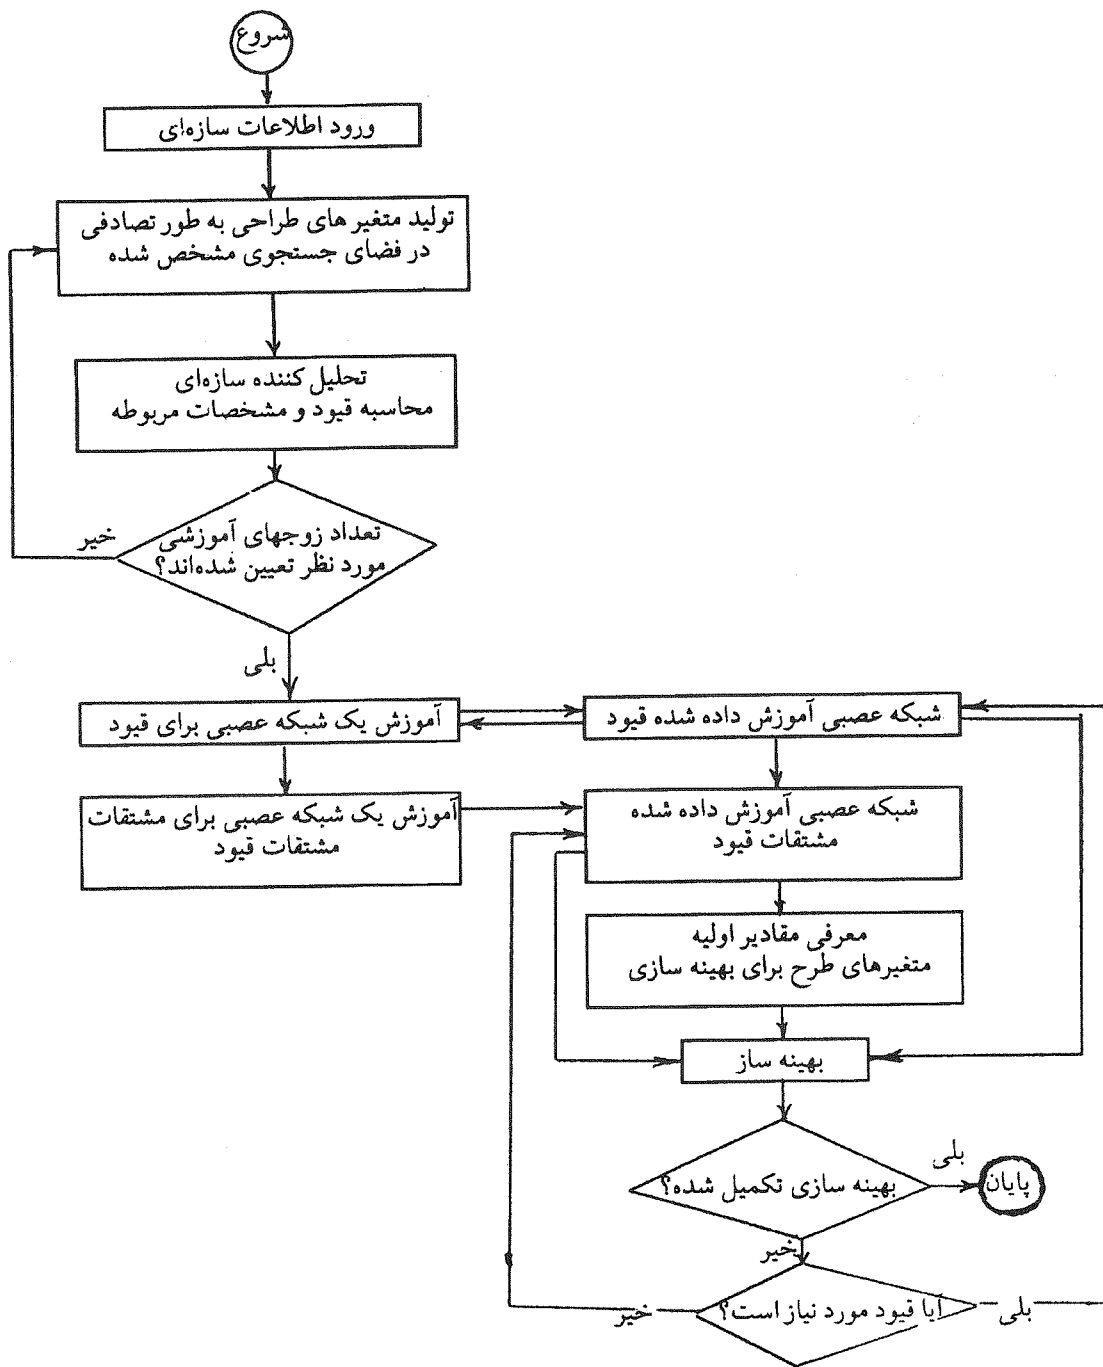
$$KU = P \quad (11)$$

به طوری که ماتریس سختی سیستم K ، از تلفیق ماتریس‌های سختی عضوها، k_i ، حاصل می‌شود:

$$K = \sum_{i=1}^{NE} k_i \quad (12)$$

NE تعداد عضوهای سازه است، و P و U به ترتیب بردارهای نیرو و جابجایی می‌باشند.

ماتریس متقارن سختی سازه تابعی از متغیرهای طراحی تعریف کننده سازه است. همچنین بردار نیرو ممکن است تابعی از متغیرهای طراحی باشد. به عنوان مثال اگر چنانچه وزن خود سازه نیز در محاسبات منظور گردد، تعیین تغییر مکانها مستلزم حل دستگاه معادلات




شکل (۲) ساختار بهینه ساز براساس شبکه های عصبی.

استفاده از شبکه های عصبی آموزش داده شده بدین صورت انجام می گیرد که قیود و مشتقات مربوطه به هنگام نیز از طریق شبکه های عصبی در زمان کوتاهی در اختیار بهینه ساز قرار می گیرند.

نتایج عددی

برای نشان دادن توانایی های شبکه های عصبی مصنوعی در بهینه سازی مثال هایی به شرح زیر ارائه شده است:

مثال ۱: خرپای ده عضوی همان طوری که در شکل ۲ نشان داده شده است، مورد بررسی قرار می گیرد. هدف کمینه نمودن وزن این سازه است. مثال مزبور توسط محققان متعددی در بهینه سازی سازه ها به کارگرفته شده است [۱۳ و ۳].



شکل (۳) خرپای ده عضوی.

برای مقایسه نتایج به دست آمده با مراجع موجود، فرضیات زیر در نظر گرفته شده اند:

- $P = 444000 \text{ N (100kips)}$
- $\rho = 0.0027 \text{ kg/cm}^3 (10^{-4} \text{ k/in}^3)$
- $E = 6.9 \times 10^6 \text{ N/cm}^2 (10,000 \text{ ksi})$
- $\sigma_{ALL}^{\pm} \leq 17200 \text{ N/cm}^2 (25 \text{ ksi})$
- $\delta_{ALL} \leq 5 \text{ cm (2.0in)}$
- $L = 915 \text{ cm (360in)}$

با در نظر گرفتن سطح مقطع عضوها به عنوان متغیرهای طرح $X_{10}, X_9, X_8, X_7, X_6, X_5, X_4, X_3, X_2, X_1$ و نمایش تابع هدف با OBJ داریم:

$$g_1 = \frac{\sigma_1}{\sigma^+} - 1 \quad (20)$$

$$g_2 = \frac{\sigma_1}{\sigma^-} - 1 \quad (21)$$

به طوری که σ^+ و σ^- به ترتیب محدوده مجاز تنش های کششی و فشاری است. مشتق نسبت به متغیرهای طراحی X_i به شرح زیر محاسبه می گردند:

$$\frac{\partial u_1^0}{\partial X_i} = T \frac{\partial u_i}{\partial X_i} \quad (22)$$

اکنون مشتق قیود اولین عضو خرپای مثال فوق نسبت به متغیر طرح X_1 برابر است با:

$$f_1 = \frac{A_1 E}{L_1} u_1^0 \quad (23)$$

$$\frac{\partial f_1}{\partial X_i} = \frac{f_1}{A_1} + \frac{A_1 E}{L_1} \times \frac{\partial u_1^0}{\partial X_i} \quad (24)$$

$$\frac{\partial \sigma_1}{\partial X_i} = \frac{\partial}{\partial X_i} \frac{f_1}{A_1} = \frac{1}{A_1} \frac{\partial f_1}{\partial X_i} - \frac{f_1}{A_1^2} \quad (25)$$

استدلال ذکر شده در فوق، در نرم افزار تهیه شده به صورت کلی در نظر گرفته شده است، به طوری که تمامی قیود و مشتقات مربوطه به سهولت محاسبه می گردند.

ساختار بهینه ساز براساس شبکه های عصبی مصنوعی

هدف اصلی روش بهینه سازی این مقاله، بکارگیری شبکه های عصبی در بهینه یابی سازه ها و کاهش زمان محاسبات با مقایسه با روش های متداول است. اجرای این هدف در سه مرحله صورت می گیرد. در اولین مرحله، متغیرهای طراحی به صورت تصادفی در فضای جستجویی که توسط استفاده کننده مشخص می شود، ایجاد می گردند. قیود و مشتقات مربوطه برای هر مجموعه از متغیرهای تصادفی ایجاد شده محاسبه می گردند. در مرحله دوم، دو شبکه عصبی با کارگیری شبکه عصبی، با انتشار متقابل براساس اطلاعات ایجاد شده (قیود و مشتقات مربوطه) آموزش داده می شوند. ماتریس های وزن به طور خودکار، در مرحله آموزش محاسبه می گردند. در مرحله نهایی، بهینه سازی با

مشاهده می شود خطای حاصل افزایش یافته، اما با افزایش تعداد زوج های آموزشی در مرحله آموزش شبکه های عصبی این مقدار خطا کاهش می یابد. به علاوه امکان دارد که با انتخاب مقدار کوچکتری برای D اندازه شبکه های عصبی را افزایش داده که منجر به کاهش خطا می گردد.

در بررسی دیگری آثار تغییرات تعداد نرون های لایه رقابتی شبکه های عصبی در پاسخ بهینه ساز مورد توجه قرار گرفت. برای شرایط 1000 زوج آموزشی، پارامتر D که وظیفه گروه بندی نرون های لایه رقابتی را به عهده دارد از 1.0 تا 3.5 تغییر داده شد که منجر به تغییرات نرون های لایه رقابتی از 500 به 4 گردید. پاسخ بهینه ساز برای چنین شرایطی تا $D = 2.7$ (20 نرون لایه رقابتی) بسیار نزدیک به جواب دقیق است (خطایی کمتر از 5 درصد). با افزایش D پاسخ بهینه ساز فاصله قابل توجهی با جواب دقیق خواهد داشت. بنابراین لازم است که در بکارگیری بهینه ساز، پارامتر D به صورتی انتخاب گردد که منجر به تعداد مناسب نرون های لایه رقابتی گردد.

مثال ۲: خرپای ۲۵ عضوی همانطوری که در شکل ۴ نشان داده شده است، مورد بررسی قرار می گیرد. هدف کمینه نمودن وزن سازه است و در حل مسئله فرضیات زیر در نظر گرفته شده است:

$$P = 3 \times 10^5 \text{ N}$$


$$\rho = 7.85 \times 10^{-3} \text{ kg/cm}^3$$

$$E = 2.1 \times 10^7 \text{ N/cm}^2$$

$$\sigma_{ALL}^+ \leq 1.3 \times 10^4 \text{ N/cm}^2$$

$$\sigma_{ALL}^- \leq 1.04 \times 10^4 \text{ N/cm}^2$$

$$\delta_{ALL} \leq 1.0 \text{ cm}$$



شکل (۲) خرپای ۲۵ عضوی.

$$OBJ = \sum_{i=1}^{NE} \rho_i A_i L_i$$

و یا

$$OBJ = 2.4705 (X_1 + X_2 + X_3 + X_4 + X_5 + X_6) + 3.4938 (X_7 + X_8 + X_9 + X_{10})$$

در ابتدا حل دقیق مسئله با بکارگیری روش های عددی بهینه سازی به دست آمده تا بتوان نتایج حاصل را با مراجع در دسترس و همچنین با نتایج حاصل از بهینه سازی با استفاده از شبکه های عصبی مقایسه نمود. جواب بهینه عبارت است از $OBJ = 2291 \text{ kg}$ به طوری که سطوح مقطع بهینه عبارتند از:

$$A^* = (167.4, 0.1, 160.4, 109.4, 0.1, 0.1, 57.7, 141.2, 147.2, 0.1)$$

در بهینه سازی با استفاده از شبکه های عصبی، برای آموزش شبکه های عصبی در ابتدا سطح مقطع اعضا به طور اتفاقی (Random) در فضای جستجوی $A^* \pm 0.2A^*$ که توسط استفاده کننده مشخص می گردد، ایجاد می گردند و سپس شبکه های عصبی براساس زوج های ایجاد شده آموزش می بینند. برای تعیین آثار تعداد زوج های آموزشی بر روی نتایج حاصل، تعداد زوج های آموزشی در دفعات مختلف تغییر داده شده اند و خلاصه محاسبات در جدول شماره (۱) نشان داده شده است.

همانطوری که از جدول (۱) ملاحظه می گردد حداکثر خطای ایجاد شده در شرایط مختلف از ۴/۶٪ تجاوز نمی نماید که قابل تحمل است.

در بررسی دیگری فضای جستجو از $A^* \pm 0.2A^*$ به $A^* \pm 0.4A^*$ افزایش داده شد تا آثار آن را بر روی نتایج حاصل از بهینه ساز تعیین گردد. نتایج این بررسی در جدول شماره ۲ نمایش داده شده است. همانگونه که

جدول (۱) پاسخ بهینه ساز با استفاده از شبکه های عصبی هنگامی که تعداد زوج های آموزشی افزایش می یابد.

NEURO OPTIMIZER	شبکه های عصبی براساس زوج های آموزشی مختلف آموزش داده شده اند					
متغیرهای طرح	جواب دقیق	200 N = 158	300 N = 206	400 N = 247	500 N = 298	1000 N = 443
X_1	۱۶۷/۴	۱۷۸/۶	۱۷۴/۸	۱۶۹/۶	۱۷۳/۴	۱۷۵/۲
X_2	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
X_3	۱۶۰/۴	۱۷۰/۶	۱۶۶/۸	۱۶۱/۶	۱۶۵/۴	۱۶۷/۲
X_4	۱۰۹/۴	۱۰۹/۶	۱۰۵/۸	۱۰۰/۶	۱۰۴/۴	۱۰۶/۲
X_5	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
X_6	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
X_7	۵۷/۷	۵۴/۶	۵۲	۴۸/۵	۵۱/۱	۵۲/۳
X_8	۱۴۱/۲	۱۳۸/۸	۱۳۳/۴	۱۲۵/۹	۱۳۱/۴	۱۳۳/۹
X_9	۱۴۷/۲	۱۴۵/۸	۱۴۰/۴	۱۳۲/۹	۱۳۸/۴	۱۴۰/۹
X_{10}	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
OBJ (kgs)	۲۲۹۱	۲۳۲۰	۲۲۴۵	۲۱۴۱	۲۲۱۷	۲۲۵۲
E	۰/۰	۲/۱	۳/۲	۴/۶	۳/۶	۳/۱

$D = 1/5$ پارامتر گروه بندی کننده نرون های لایه رقابتی
 $E =$ میانگین خطا
 $N =$ تعداد نرون های لایه رقابتی که توسط شبکه های عصبی ایجاد شده
 $A^* \pm 0.2A^*$ فضای جستجو

جدول (۲) پاسخ بهینه ساز با استفاده از شبکه های عصبی هنگامیکه که فضای جستجو افزایش می یابد .

NEURO OPTIMIZER	شبکه های عصبی براساس زوج های آموزشی مختلف آموزش داده شده اند					
متغیرهای طرح	جواب دقیق	200 N = 158	300 N = 206	400 N = 247	500 N = 298	1000 N = 443
X_1	۱۶۷/۴	۲۰۴/۲	۱۹۰/۷	۱۹۱/۸	۱۸۴/۲	۱۹۷/۲
X_2	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
X_3	۱۶۰/۴	۱۹۴/۲	۱۸۰/۷	۱۸۱/۸	۱۷۴/۲	۱۸۷/۲
X_4	۱۰۹/۴	۱۲۴/۲	۱۱۰/۷	۱۱۱/۸	۱۰۴/۲	۱۱۷/۲
X_5	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
X_6	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
X_7	۵۷/۷	۵۶/۷	۴۴/۴	۴۵/۴	۲۸/۷	۵۰/۴
X_8	۱۴۱/۲	۱۶۰/۶	۱۴۱/۴	۱۴۲/۹	۱۳۲/۴	۱۵۰/۷
X_9	۱۴۷/۲	۱۶۲/۶	۱۴۴/۴	۱۴۵/۹	۱۳۵/۴	۱۵۲/۷
X_{10}	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱
OBJ (kgs)	۲۲۹۱	۲۶۲۴	۲۲۴۵	۲۲۸۶	۲۲۱۵	۲۴۸۰
E	۰/۰	۸/۲	۵/۲	۵/۴	۷/۱	۶/۶

$D = ۱/۵$ پارامتر گروه بندی کننده نرون های لایه رقابتی

$E =$ میانگین خطا

$N =$ تعداد نرون های لایه رقابتی که توسط شبکه های عصبی ایجاد شده

$A^* \pm 0.4A^*$ فضای جستجو

جدول (۳) پاسخ بهینه ساز با استفاده از شبکه های عصبی به هنگامی که تعداد زوج های آموزشی افزایش می یابد.

NEURO OPTIMIZER	شبکه های عصبی براساس زوج های آموزشی مختلف آموزش داده شده اند					
متغیرهای طرح	جواب دقیق	200 N = 182	300 N = 268	400 N = 247	500 N = 298	1000 N = 443
X ₁	۱۰۳	۱۱۰/۱	۱۰۷/۷	۱۰۷/۳	۱۰۴/۸	۱۰۴/۸
X ₂	۱۰۳	۱۱۰/۱	۱۰۷/۷	۱۰۷/۳	۱۰۴/۸	۱۰۴/۸
X ₃	۱۰۳	۱۱۰/۱	۱۰۷/۷	۱۰۷/۳	۱۰۴/۸	۱۰۴/۸
X ₄	۷۳	۷۵/۲	۷۳/۱	۷۲/۷	۷۰/۵	۷۰/۵
X ₅	۹۱	۹۵/۱	۹۲/۵	۹۲/۱	۸۹/۴	۸۹/۴
X ₆	۱۰۲	۱۰۸/۹	۱۰۶/۵	۱۰۶/۲	۱۰۳/۶	۱۰۳/۶
X ₇	۰/۱	۰/۱۱	۰/۱۲	۰/۱۲	۰/۱۲	۰/۱۲
X ₈	۰/۱	۰/۱۱	۰/۱۲	۰/۱۲	۰/۱۲	۰/۱۲
X ₉	۷۳	۷۵/۲	۷۳/۱	۷۲/۷	۷۰/۵	۷۰/۵
X ₁₀	۰/۱	۰/۱۲	۰/۱۲	۰/۱۲	۰/۱۲	۰/۱۲
X ₁₁	۴۵	۴۹/۵	۴۸/۶	۴۸/۵	۴۷/۶	۴۷/۶
X ₁₂	۱۹	۲۱	۲۰/۸	۲۰/۸	۲۰/۶	۲۰/۶
X ₁₃	۳۴	۳۷	۳۶/۴	۳۶/۲	۳۵/۷	۳۵/۸
OBJ (kgs)	۶۰۸۵/۳	۶۴۷۳/۸	۶۳۲۹/۵	۶۳۰۸/۱	۶۱۵۶/۳	۶۱۵۸/۲
E	۰/۰	۶/۴	۴/۰	۳/۷	۱/۲	۱/۲

$D = 1/5$ پارامتر گروه بندی کننده نرون های لایه رقابتی
 $E =$ میانگین خطا
 $N =$ تعداد نرون های لایه رقابتی که توسط شبکه های عصبی ایجاد شده
 $A \pm 0.2A^*$ فضای جستجو

نتیجه گیری

در این تحقیق اصولی براساس شبکه های عصبی بسط و توسعه یافته که در بهینه سازی سازه ها به کار گرفته شده است. اگر چه مدل سازی براساس شبکه های عصبی عمدتاً منتهی به یک پاسخ کیفی است، با این وجود بکارگیری آنها در بهینه سازی مطلوب و جواب های به دست آمده منطقی و جذاب است. شبکه های عصبی با انتشار متقابل اصلاح شده که در این تحقیق به کار گرفته شده اند مرحله آموزش بسیار سریع دارند. بدین معنی که در یک و یا حداکثر دو مرتبه ارائه زوج آموزشی تربیت شبکه ها کامل می شود. در مرحله بهینه سازی به هنگام نیاز به قیود و یا مشتقات مربوطه، دو شبکه عصبی آموزش داده شده با پاسخ سریع این نیاز را برطرف می نمایند. مثال های عددی ارائه شده توانایی های روش مطرح شده رابه خوبی نشان می دهد.

تشکر و قدردانی

از مرکز تحقیقات ساختمان و مسکن، برای پشتیبانی مالی این تحقیق، و نیز از همکاری خانم نسرين نزاكتی برای تایپ مقاله تشکر و قدردانی می شود.

با توجه به تقارن موجود و انتخاب سطح مقطع اعضا به عنوان متغیرهای طرح $X_1, X_2, \dots, X_{12}, X_{13}$ و نشان دادن تابع هدف با OBJ خواهیم داشت:

$$OBJ = \sum_{i=1}^{NE} \rho_i A_i L_i$$

$$OBJ = 7.85 (X_1 + X_2 + X_3) + 9.4316 (X_4 + X_{11}) + 8.4548 (X_5) + 7.9202 (X_6) + 5.2282 (X_7) + 8.3682 (X_8) + 4.71 (X_9) + 11.4738 (X_{10} + X_{13}) + 12.262 (X_{12})$$

برای مقایسه نتایج حاصل از بهینه سازی با استفاده از شبکه های عصبی، در مرحله اول جواب دقیق با استفاده از روش های متداول بهینه سازی به دست آمده است. برای تضمین به داشتن جواب کمینه واقعی (Global)، عملیات بهینه سازی از نقاط مختلف در فضای طراحی صورت گرفته است. همانند مثال ۱ بهینه سازی با استفاده از شبکه های عصبی در فضای جستجوی انجام گرفته و نتایج حاصل در جدول (۳) نشان داده شده است. همانطوری که در این جدول ملاحظه می گردد با افزایش تعداد زوج های آموزشی، خطای ایجاد شده از ۶/۴ به ۱/۲ درصد کاهش می یابد.

مراجع

- [1] R. Hecht-Nielsen, Neurocomputing, Addison-Wesley Publishing Company, USA, 1990.
- [2] L. Fausett, Fundamentals of Neural Networks, Prentice Hall Company, USA, 1994.
- [3] Z. Szewczyk and P. Hajela, Neural network approximations in a simulated annealing based optimal structural design, J. Structural Optimizatin, 5 (1993) 159-165.
- [4] L. Berke and P. Hajela, Applications of artificial neural nets in structural mechanics, J. Structural Optimization, 4 (1992) 90-98.
- [5] P. Hajela and L. Berke, Neural networks in structural analysis and design an overview, J. Computing Systems in Engineering, 1992.
- [6] M. Kishi, T. Kodera, Y. Iwao, and R. Hosodsa, Structural optimization by neuro optimizer, Reliability and Optimization of Structural Systems, 1993, V (b-12), Elsevier Science Publishers, pp. 113-120.
- [7] H. Adeli and H.S. Park, Counterpropagation neural networks in structural engineering", J. Structural Engineering, 121 (1995) 1205-1211.
- [8] Z. P. Szewczyk and A.K. Noor, A hybrid neuro-computing/numerical strategy for nonlinear structural analysis, J. Comput, Struct, 58 (1996) 661-677.
- [9] H. M. Chen, K.H. Tsai, G.Z. Qi, J.C.S. Yang and F. Amini, Neural network for structure control, J of Computing in Civil Engineering, 9 (1995) 168-175.
- [10] A. Kaveh and A. Iranmanesh, Modified counterpropagation neural networks as a fast interpolator in structural anlysis, submitted for publication, 1998.
- [11] G. N. Vanderplaats, Numerical Optimization Techniques for Engineering Design, McGraw-Hill Book Company, USA, 1984.
- [12] R. T. Haftka and Z. Gurdal, Elements of Structural Optimization., 3rd edition, Kluwer Academic Publishers, Netherlands, 1991.
- [13] M. R. Ghasemi and E. Hinton, Truss optimization using genetic algorithms, Advances in Computational Structures Technology, Edit. BHV Topping, Civil-Comp Press, Edinburgh, 1996, pp. 59-57.