

پیش بینی بار در بازار برق با استفاده از مدل هیبرید شبکه عصبی و الگوریتم بهبود یافته جستجوی گرانشی

اویس عابدی نیا^{۱*} و نیما امجدی^۲

اطلاعات مقاله	چکیده
دریافت مقاله: خرداد ۱۳۹۲ پذیرش مقاله:	
واژگان کلیدی: الگوریتم بهبود یافته جستجوی گرانشی، پیش بینی بار، بازار برق، شبکه عصبی.	با توجه به روند جدید استقلال شرکت های توزیع و الزام حضور آن ها در بازار برق و با سمت گیری و تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی، و بالا بودن ضریب خطای پیش بینی بار مصرفی آن ها در حال حاضر، یافتن روشی به منظور پیش بینی دقیق بار مصرفی مشترکین ضروری به نظر می رسد. در این مقاله، از روشی ترکیبی شبکه عصبی و الگوریتم بهبود یافته جستجوی گرانشی استفاده شده است. الگوریتم پیشنهادی وزن ها و بایاس ها شبکه عصبی را بهینه کرده و درصد برآورد کمترین مربعات خطای پیش بینی می باشد. به منظور ارائه کارایی مناسب آن، روش پیشنهادی در حل مساله پیش بینی بار در بازار برق کوتاه مدت در مقایسه با سایر روش ها بررسی شده است. هم چنین روش پیشنهادی با در نظر گرفتن الگوریتم کلاسیک جستجوی گرانشی و اجتماع ذرات پرندگان مقایسه شده است. بازار نیویورک به عنوان مورد مطالعاتی در این مقاله مورد آزمایش قرار گرفته است. نتایج نشان از دقت بالا و خطای کمتر در پیش بینی می دهد.

۱- مقدمه

با توجه به این که انرژی الکتریکی در مقیاس وسیع قابل ذخیره نبوده و مدیریت تولید و توزیع انرژی الکتریکی باید براساس تطبیق عرضه بر تقاضای انرژی برق، اقدام به برنامه ریزی، بهره برداری و سرمایه گذاری بهینه نماید، لذا در برنامه ریزی آینده یک سیستم قدرت، پیش بینی بار از اهمیت ویژه ای برخوردار می باشد. این پیش بینی باید براساس میزان خطای بسیار کم ارائه شود. دقت نتایج این پیش بینی بر هزینه تولید و میزان خاموشی در سیستم قدرت تاثیر گذار می باشد [۱].

روش های پیش بینی بار به روش های خیلی کوتاه، کوتاه، متوسط و بلند مدت تقسیم می شوند [۱-۳]. به عنوان مثال در پیش بینی بلند مدت، بار برای یک و یا چند سال آینده پیش بینی می شود. با توجه به اهمیت موضوع، تاکنون روش های متعددی در این زمینه ارائه شده است که می توان آن ها را به دو دسته تقسیم بندی نمود. در دسته اول مبتنی بر روش سری زمانی و دسته دوم براساس شبکه عصبی مصنوعی می باشد. در هر دو دسته با توجه به افزایش قابلیت آن ها، بهبودهای مختلفی در جهت کاهش خطای پیش بینی قیمت برق انجام گرفته است. در روش سری زمانی می توان به برآزش دینامیکی و تابع تبدیل [۲]، خود برآزش جمعی میانگین متحرک [۳]، خود برآزش واریانس شرطی [۴]،

* پست الکترونیک نویسنده مسئول: oveis.abedinia@gmail.com

۱- دانشجوی دکتری، دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان.

۲- استاد، دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان.

² Auto regressive integrated moving average model (ARIMA)

این بهینه‌سازی می‌تواند با الگوریتم‌های متعددی انجام شود ولی، اغلب این روش‌ها دارای نقاط ضعف در جستجوی محلی و کلی بوده که تنظیم مناسب پارامترهای شبکه عصبی به کمک آن‌ها به خوبی انجام نخواهد گرفت. در روش پیشنهادی کاندیدهای پاسخ در فضای جستجو اجرامی هستند که توسط نیروی گرانش بر یکدیگر اثر گذاشته و موقعیت آن‌ها تغییر می‌کند. اجرام با برزندگی بهتر دارای جرم بیشتری بوده و بر اجرام دیگر تاثیر بیشتری دارند [۸]. روش پیشنهادی بر روی بازار نیویورک به‌عنوان سیستم واقعی با اطلاعات موجود، مورد بحث و بررسی قرار گرفته است. نتایج نشان از کارایی مناسب این روش در پیش‌بینی بار در دوره‌های تعریف شده می‌باشد.

این مقاله شامل قسمت‌های زیر می‌باشد: بخش ۲ به معرفی مدل پیشنهادی برای انتخاب ورودی‌ها خواهد پرداخت. بخش ۳ به معرفی شبکه عصبی به‌عنوان موتور پیش‌بینی کننده پرداخته است. الگوریتم پیشنهادی در بخش ۴ ارائه شده است. بخش ۵ نتایج حاصل از شبیه‌سازی و نتیجه‌گیری در بخش ۶ ارائه شده‌اند.

۲- روش انتخاباتی با در نظر گرفتن عدم

قطعیت

همان‌طور که ذکر گردید انتخاب مولفه‌های ورودی یکی از مهمترین مراحل برای روش‌های پیش‌بینی به کمک شبکه عصبی است. در این مرحله باید تصمیم‌گیری شود که کدام دسته از متغیرهای ورودی سیستم دارای بیشترین ارزش در پیش‌بینی می‌باشند [۹]. این روش در مرجع [۱۰] ارائه شد. به این منظور، معیار آنتروپی $H(X)$ برای مجموعه اعداد نامنظم X براساس توزیع احتمالاتی $P(X)$ به صورت زیر قابل بیان می‌باشد:

$$H(X) = -\int P(X) \log_2(P(X)) dX \quad (1)$$

اگر مقادیر X_1, X_2, \dots, X_n به‌عنوان مقادیر تصادفی ورودی با تابع احتمالاتی $P(X_1), P(X_2), \dots, P(X_n)$ تعریف شوند. در این صورت $H(X)$ به صورت زیر قابل بازنویسی خواهد بود:

روش ترکیبی خود برآزش جمعی میانگین متحرک و خود برآزش واریانس شرطی [۵]، و رشد سالیانه و همبستگی [۶] اشاره نمود. اگر چه این روش‌ها بخاطر سادگی در پیاده‌سازی و خطی بودن مورد توجه قرار گرفته‌اند اما در سیستم غیرخطی کارایی کافی نداشته و خطای پیش‌بینی را به‌طور چشم‌گیری افزایش می‌دهند.

در سال‌های اخیر، شبکه‌های عصبی در پیش‌بینی بار کاربردهای مختلفی داشته است. شبکه‌های عصبی دارای مزیت‌هایی از قبیل سرعت بالا در محاسبات موازی، مصونیت در برابر ریپل هارمونیک ورودی، قابلیت حذف نویز، مقاومت در برابر تغییر پارامترها و قابلیت تعلیم می‌باشند [۷]. یک شبکه عصبی شامل تعداد زیادی سلول عصبی یا عناصر پردازشی می‌باشد که توسط وزن‌های سیناپسی به یکدیگر متصل می‌شوند. به‌طور کلی ساختار شبکه‌های عصبی را می‌توان به دو دسته کلی شبکه‌های پیش‌خور و شبکه‌های برگشتی تقسیم‌بندی نمود. شبکه‌های پیش‌خور دارای ساختار ساده‌ای هستند و مشکل پایداری شبکه‌های برگشتی را ندارند. شبکه‌های پیش‌خور دارای انواع متفاوتی هستند که از مهم‌ترین آن‌ها می‌توان به شبکه پرسپترون چند لایه (MLP^1) و شبکه با توابع پایه شعاعی (RBF^2) اشاره کرد.

علی‌رغم ارائه روش‌های متفاوت، هم‌چنان فقدان یک تکنیک مناسب برای مرتب‌سازی داده‌های ورودی در آن‌ها نمایان است. لذا در این مقاله با بهره‌گیری از شبکه عصبی پرسپترون چند لایه از الگوریتم انتخاباتی برای مرتب‌سازی داده‌ها بهره گرفته شده است تا بهترین گزینه‌ها با بیشترین همبستگی برای آموزش وارد شبکه عصبی شوند. هم‌چنین با توجه به این نکته که تنظیم مناسب پارامترهای شبکه عصبی کاری دشوار است، از الگوریتم بهبود یافته جستجوی گرانشی برای تنظیم وزن‌ها و بایاس‌های شبکه عصبی بهره گرفته شده است که باعث آموزش بهتر شبکه عصبی و کاهش تابع برآزش‌گذاری یعنی حداقل کردن متوسط خطای خروجی می‌شود.

¹ Multi Layer Perceptron

² Radial Basis Function


$$MI(X, Y) = H(X) - H(X/Y) \quad (۷)$$

$$MI(X, Y) = H(Y) - H(Y/X) \quad (۸)$$

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (۹)$$

$$MI(X, Y) = MI(Y, X) \quad (۱۰)$$

$$MI(X, X) = H(X) \quad (۱۱)$$



شکل ۱. توزیع و انتخاب براساس تابع تقابلی

حال فرض کنیم متغیر Y میزان عدم قطعیت آن در نظر گرفته شود در این صورت اگر بین X و Y مقدار تابع تقابلی زیاد باشد می‌توان برای X هم عدم قطعیت محاسبه نمود. حال فرض کنید داده‌های ورودی به صورت Y_1, Y_2, \dots, Y_N تعریف شوند، در این صورت برای متغیر Y_m که بیشترین تقابل براساس رابطه $MI(X, Y_m)$ با متغیر هدف X داشته باشد، X بهترین داوطلب برای پیش‌بینی می‌باشد. به‌عنوان مثال برای پیش‌بینی قیمت با تعداد کاندید ۲۰۰ ساعت قبل که به صورت $P_{h-1}, P_{h-2}, \dots, P_h$ تعریف شده است نیاز به $h-24, h-48, h-72, \dots, h-192$ ساعت قبل داریم.

۳- شبکه عصبی پیشنهادی

یکی از مسائل مهم در شبکه‌های عصبی، اعمال داده‌های آموزشی مناسب به ورودی آن می‌باشد. به‌گونه‌ای که آموزش داده آن با به‌کارگیری یک دسته از ورودی‌ها دسته خروجی‌های دلخواه تولید شود. هر کدام از این دسته‌های ورودی و یا خروجی دلخواه را می‌توان به صورت یک بردار در نظر گرفت. آموزش با به‌کار بستن متوالی بردارهای ورودی و تنظیم وزن‌های شبکه، مطابق با یک روش از پیش تعیین شده انجام می‌گیرد. طی آموزش شبکه، وزن‌های شبکه به تدریج به مقادیرهایی همگرا می‌شود که به‌ازای آن‌ها با اعمال بردار ورودی، بردار خروجی دلخواه تولید می‌گردد. شبکه‌های عصبی

$$H(X) = -\sum_{i=1}^n P(X_i) \log_2(P(X_i)) \quad (۲)$$

براساس دو رابطه فوق آنتروپی اغلب یک مقدار از عدم قطعیت را در نظر می‌گیرد. به‌منظور شفاف شدن بحث، فرض نمایم که متغیر X وجود از بیماری D را نشان می‌دهد. بنابراین اگر عدم قطعیت وجود نداشته باشد در این صورت $[P(X=D)=1, P(X=\bar{D})=0]$ و یا اگر اصلاً وجود ندارد در این صورت $[P(X=D)=0, P(X=\bar{D})=1]$ در نتیجه آنتروپی برابر با صفر می‌باشد. اگر وجود یا عدم وجود بیماری به صورت عدم قطعیت اعمال شود در این صورت $[P(X=D)=P(X=\bar{D})=0.5]$ و مقدار آنتروپی برابر با یک خواهد شد. به‌طور کلی اگر هر یک N بیماری دارای احتمال $[P(X)=1/N]$ باشد در این صورت $H(X)$ دارای بیشترین مقدار $\log_2(N)$ می‌باشد. برای تعمیم این بحث، مجموع آنتروپی با دو عضو X و Y به صورت زیر قابل بیان خواهد بود:

$$H(X, Y) = -\sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2(P(X_i, Y_j)) \quad (۳)$$

با در نظر گرفتن عدم قطعیت برای یک سری از داده‌ها، مقدار عدم قطعیت سایر متغیرها به صورت زیر تعریف می‌شوند:

$$H(Y/X) = \sum_{i=1}^n P(X_i) H(Y/X = X_i) = -\sum_{i=1}^n P(X_i) \sum_{j=1}^m P(Y_j/X_i) \log_2(P(Y_j/X_i)) = (۴)$$

$$-\sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2(P(Y_j/X_i))$$

بنابراین مقدار کل آنتروپی به صورت زیر قابل بیان می‌باشد:

$$H(X, Y) = H(X) + H(Y/X) = H(Y) + H(X/Y) \quad (۵)$$

به‌منظور مرتب‌سازی داده‌ها روش تقابلی به صورت فرموله می‌شود:

$$MI(X, Y) = \sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2 \left(\frac{P(X_i, Y_j)}{P(X_i)P(Y_j)} \right) \quad (۶)$$

مقدار عددی بزرگ برای فرمول بالا نشان از همبستگی بالا بین دو عضو X و Y می‌باشد و برعکس. نحوه فرمول‌بندی برای روش تقابلی و آنتروپی در شکل ۱ نشان داده شده است.

1-1, 2, ..., l-1 و برای هر نرون i در لایه l خطا با استفاده از رابطه زیر محاسبه می‌شود:

$$\theta_i^l = f' (T_i^l) \sum_j (w_{i,j}^{l+1} * \theta_j^{l+1}) \quad (15)$$

وزن اتصالی نرون i در لایه l و نرون j در لایه (l-1) با رابطه زیر تنظیم می‌شود:

$$w_{i,j}^l = w_{i,j}^{l-1} + \alpha * \theta_i^l * o_j^{l-1} \quad (16)$$

α ثابت یادگیری است که بستگی به سرعت یادگیری شبکه عصبی مورد انتظار دارد.

الگوریتم شبکه عصبی ضرورتاً متوسط مربع خطا بین خروجی MLP و خروجی مطلوب را با استفاده از روش کم‌ترین شیب، حداقل می‌کند. بنابراین الگوریتم بهبود یافته جستجوی گرانشی برای انتخاب بهینه این مقادیر در این مقاله مورد استفاده قرار گرفته است. این روش در ادامه توضیح داده خواهد شد.

خروجی پیشگویی شده $\hat{O} = \bar{P}_{i+k}$ با خروجی مطلوب $O = P_{i+k}$ مقایسه شده و مقادیر خطا برای محاسبه وزن‌های جدید اتصالات بین نرون‌های همه لایه‌های ورودی، خروجی و مخفی با کمک معادله (۱۴) محاسبه می‌شود. روند یادگیری بر روی تمام ورودی‌های دسته داده یادگیری چندین مرتبه تکرار می‌شود، تا زمانی که میانگین مربع خطا $\sum (d_i^l - o_i^l)^2$ بین خروجی شبکه عصبی و خروجی مطلوب به آستانه خاصی برسد. مدل شبکه عصبی چند لایه (MLP) آموزش دیده با دسته داده آموزشی را می‌توان برای پیشگویی مکان پایانه به کار برد. بردارهای دسته آموزشی به‌طور متوالی به کار برده می‌شوند، خطاها محاسبه و وزن‌ها به ازای هر بردار تنظیم می‌شوند تا این‌که خطا برای کل دسته آموزشی به یک مقدار کوچک قابل قبول برسد. مدل پیشنهادی در شکل ۲ ارائه شده است.

به‌کارگرفته شده در این مقاله شبکه عصبی MLP است [۱۱].

یک شبکه پرسپترون چند لایه تحت تعدادی از زوج‌های آموزشی، آموزش داده می‌شود. بدین صورت که با به‌کار بردن یک بردار ورودی، خروجی شبکه محاسبه و با بردار هدف متناظر خود مقایسه و تفاوت بین خروجی محاسبه شده و خروجی دلخواه که خطا نامیده می‌شود، محاسبه می‌شود، سپس وزن‌ها مطابق با الگوریتمی که تمایل به حداقل رساندن خطا را دارد تغییر می‌یابند و تنظیم می‌شوند [۱۲].

روند یادگیری مدل MLP با در نظر گرفتن L لایه با M نرون ورودی با استفاده از الگوریتم یادگیری LM در این قسمت به‌طور مختصر شرح داده می‌شود. هر لایه از MLP شامل بیشتر از یک نرون است. خروجی لایه L^{th} به‌عنوان ورودی لایه $(L+1)^{\text{th}}$ تغذیه می‌شود و نرون‌ها در لایه L^{th} به نرون‌ها در لایه $(L+1)^{\text{th}}$ با وزن تطبیقی متصل می‌شوند. فرض می‌کنیم جمع ورودی‌های نرون i^{th} در اولین لایه مخفی h، T_j است. بنابراین برای نرون‌های M در لایه ورودی با صفر در نظر گرفتن بایاس T_j برابر با رابطه زیر می‌شود.

$$T_j = \sum_{i=1}^M w_{i,j}^{h,j} * \text{output}_i \quad (12)$$


که $w_{i,j}^{h,j}$ وزن اتصالی نرون‌ها در لایه ورودی به نرون j در لایه مخفی است و output_i خروجی نرون i در لایه ورودی است. با در نظر گرفتن تابع سیگموئید به‌عنوان تابع تحریک خواهیم داشت:

$$\text{out} = f_{(T_j)} = (1 - e^{-T_j})^{-1} \quad (13)$$

برای نرون خاص i فرض می‌کنیم خروجی لایه l، o_i^l است، درحالی‌که خروجی مطلوب d_i^l است. بنابراین، خطا با استفاده از رابطه محاسبه می‌شود:

$$\theta_i^l = f' (T_i^l) |d_i^l - o_i^l| \quad (14)$$

T_i^l ورودی کلی نرون i^{th} در لایه خروجی l^{th} و f' مشتق تابع $f_{(o)}$ را بیان می‌کنند. برای لایه‌های



شکل ۲: مدل بهینه‌سازی شبکه عصبی MLP

نمی‌سپارد. با وجود این دیده می‌شود که عملکردی به‌خوبی الگوریتم‌های حافظه دار دارد. اما الگوریتم جستجوی گرانشی پیچیدگی محاسباتی بالاتری نسبت به الگوریتم‌هایی مانند جمعیت ذرات داشته و از سوی دیگر پیچیدگی محاسباتی آن نسبت به الگوریتم وراثتی پایین‌تر است. یک راه برای کاهش پیچیدگی الگوریتم فوق در [۱۵] معرفی شده است. در آن‌جا با کاهش خطی تعداد عامل‌های تاثیرگذار در محاسبه شتاب عامل‌ها، به اجرام با شایستگی بیشتر اجازه تعیین اندازه حرکت سایر اعضا را می‌دهد تا این‌که در انتها تنها یک عامل بر سایر اعضا نیرو وارد کند. در نتیجه رابطه (۱۷) به شکل رابطه زیر تصحیح می‌شود.

$$F_i^d(t) = \sum_{j=1, j \neq i}^N \text{rand}_j F_{ij}^d(t) \quad (17)$$

به‌طوری‌که:

$$F_i^d(t) = \sum_{j \in kbest, j \neq i} \text{rand}_j(t) F_{ij}^d(t) \quad (18)$$

در این رابطه $kbest$ بیان‌گر مجموعه k جرم برتر جمعیت است.

البته در آن‌جا نیز تاکید شده است که در اجرای این پیشنهاد باید بسیار مراقب بود چرا که با اعمال چنین سیاستی توان کاوش ۴ الگوریتم کاهش و توان بهره‌وری ۵ آن افزایش می‌یابد. از آن‌جایی که الگوریتم در لحظه شروع جستجو به کاوش زیاد فضای جستجو نیاز دارد، اجرای بدون کنترل راه‌کار پیشنهادی باعث گرفتار شدن الگوریتم در بهینه‌های محلی خواهد شد.

۴- الگوریتم جستجوی گرانشی

الگوریتم جستجوی گرانشی (GSA) یک الگوریتم وابسته به هوش جمعی و بدون حافظه می‌باشد [۸]. این الگوریتم بهینه‌سازی با الگوبرداری از قوانین و حرکت عوامل در یک سیستم مصنوعی در زمان گسسته طراحی شده است که در آن، فضای سیستم همان محدوده تعریف مساله می‌باشد. توضیحات کامل این روش در مراجع [۱۴-۱۳] ارائه شده است.

الگوریتم جستجوی گرانشی نخبه‌گرای پیشرفته

الگوریتم جستجوی گرانشی باید به‌گونه‌ای هدایت شود که موقعیت اجرام با گذشت زمان بهبود پیدا کند. استراتژی به‌کار گرفته شده برای این منظور مبنی بر تنظیم جرم عامل‌ها است. طبق روابط ارائه شده، تمام عامل‌ها متناسب با جرم‌شان روی هم تاثیر می‌گذارند و اثرگذاری آن‌ها روی عامل‌های همسایه بیشتر است. تاثیر عامل‌های با جرم سنگین‌تر بیشتر است و شعاع تاثیرگذاری بزرگ‌تری دارند. بنابراین به اجرامی که تابع برآزش بهتری دارند، جرم گرانشی بهتری نسبت داده می‌شود. در نتیجه هر جرم به اندازه شایستگی خود، سایر اجرام را به سمت خود دعوت می‌کند. بنابراین با گذشت زمان اجرام به سمت موقعیت‌های مناسب‌تر می‌روند.

از آن‌جاکه این الگوریتم حافظه دار نیست، به‌همین دلیل هیچ یک از موقعیت‌های دیده شده قبلی را به خاطر

سنگین‌ترین جرم ممکن در فضای الگوریتم جستجو دست خواهد یافت.

برای این که الگوریتم فرصت کافی برای کاوش و بهره‌وری در میان تمام اجرام را داشته و تمام عامل‌ها فرصت رشد داشته باشند بهتر است T_{first} را حدوداً نصف T_{total} در نظر گرفت. در بعضی از کاربردهای خاص که سیستم به سختی به پاسخ بهینه دست می‌یابد بایستی T_{first} را حدود دو سوم مدت کلی اجرای الگوریتم فرض کرد.

▪ روش کلی پیش‌بینی

برای حل مساله پیش‌بینی بار ابتدا فرض نمایید که پیش‌بینی برای روز d انجام می‌گیرد. همچنین فرض کنید اطلاعات گذشته سری داده‌های بار برای ۲۴ ساعت روز $d-1$ به صورت $p_h; h=1, \dots, T$ قابل دسترسی باشد که در آن T معمولاً بین حدود یک هفته الی چند ماه قبل را شامل می‌شود. با توجه به فرضیات گفته شده، مدل ایجاد شده در گام‌های زیر قابل پیگیری می‌باشد.

گام اول: ابتدا با توجه به میزان پراکندگی داده‌ها نرمالایز شده که این کار یک معیار مناسب برای سبک-سنگین کردن داده‌ها براساس میزان طول و همواری آن‌ها می‌باشد.

گام دوم: استفاده از الگوریتم انتخاباتی پیشنهادی برای مرتب کردن داده‌ها با بیشترین همبستگی.

گام سوم: استفاده از شبکه عصبی برای آموزش هر بخش در جهت پیش‌بینی اطلاعات ساعت‌های $T+1, \dots, T+24$ برای هر ماتریس تجزیه شده از داده‌های اولیه و ارائه نتایج حاصل از پیش‌بینی با یکدیگر به منظور دستیابی به اطلاعات اولیه.

گام چهارم: در این مرحله به آموزش بهتر شبکه عصبی از طریق کاهش خطای خروجی به کمک بروزرسانی وزن‌ها و بایاس‌ها با استفاده از الگوریتم بهبود یافته جستجوی گرانشی پرداخته می‌شود.

گام پنجم: در این بخش با کمک تابع هدف معرفی شده که بر مبنای کاهش خطای خروجی می‌باشد، بهینه کردن وزن‌ها و بایاس‌ها برای شبکه عصبی به منظور آموزش بهتر آن انجام می‌گیرد. تابع هدف مورد استفاده در این مقاله درصد خطای مطلق متوسط ($MAPE$)^۲ است که براساس

در این جا الگوریتم جدیدی به نام الگوریتم جستجوی گرانشی نخبه‌گرای پیشرفته (AEGSA)^۱ معرفی می‌شود. طبق نتایج تجربی الگوریتم‌های مبتنی بر هوش جمعی در زمان‌های اولیه اجرای الگوریتم تمام فضای پاسخ را مورد جستجو قرار می‌دهند اما با گذشت زمان از قدرت کاوش الگوریتم کاسته شده و بر قدرت بهره‌وری آن افزوده می‌شود تا به کمک یافته‌های جمعیت عامل‌ها به سمت نقاط بهینه حرکت کنند.

در این الگوریتم ابتدا به سیستم در یک دوره زمانی فرصت کافی داده می‌شود تا به کاوش و بهره‌وری فضای جستجو در میان تمام اجرام پردازد (T_{first}). نحوه تعریف ثابت گرانش از اهمیت ویژه‌ای برخوردار است، از آن‌جا که لازم است در مراحل اولیه الگوریتم به جستجوی نقاط جدیدی پردازد یک مقدار بزرگ به آن نسبت داده می‌شود که این مسئله سبب تقویت توان کاوش الگوریتم می‌شود سپس با گذشت زمان ثابت گرانش کوچک و کوچک‌تر می‌شود تا در مراحل پایانی با افزایش توان بهره‌وری به بهبود جواب‌های دیده شده پردازد.

پس از گذشت دوره زمانی T_{first} بدترین جرم ممکن شناخته شده و حذف می‌شود، از این مرحله به بعد سیستم وارد دوره زمانی T_{second} می‌شود. در این دوره زمانی سیستم به مدت T_{step} به تنظیم جرم اجرام باقیمانده می‌پردازد. پس از این مدت، دوباره بدترین جرم شناخته شده و از میان اجرام حذف می‌شود و این روال به همین شکل ادامه می‌یابد. با توجه به سه فاکتور (۱) تنظیم مناسب توان کاوش و بهره‌وری (۲) کاهش پیچیدگی الگوریتم (۳) بهبود پاسخ بهینه نسبت به الگوریتم، فرمول تجربی زیر ارائه شد:

$$T_{total} = [(m-1) - m_{best}] \times T_{step} + [T_{first} + 1] \quad (۱۹)$$

$$T_{second} = T_{total} - T_{first} \quad (۲۰)$$

m تعداد کل اجرام m_{best} تعداد اجرام برتر (پاسخ‌های بهینه) در پایان اجرای الگوریتم می‌باشد.

با توجه به به‌کاربرد مورد نظر، می‌توان تعداد اجرام برتر نهایی (تعداد پاسخ بهینه) را برای سیستم مشخص کرد. بهترین حالت زمانی است که m_{best} را برابر با یک در نظر گرفت در این صورت الگوریتم بعد از مدت T_{total} به

² Mean absolute percentage error

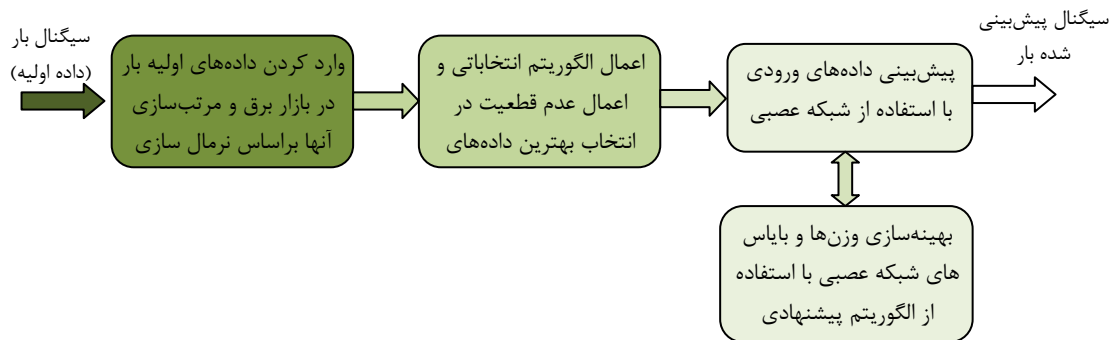
¹ Advanced Elitism gravitational Search Algorithm

گام ششم: بررسی شرط خاتمه که در صورت تحقق نپذیرفتن شرط خاتمه به گام دوم برخواهد گشت. شکل ۳ فلوجارت الگوریتم پیشنهادی را برای حل مساله پیش‌بینی را نشان می‌دهد.

تعداد روزهای مورد مطالعه (N) به صورت زیر قابل فرموله شدن می‌باشد:

$$MAPE = \frac{100\%}{N} \sum_{h=1}^N \frac{|\hat{P}_h - P_h|}{\bar{P}} \quad (21)$$

که، P_h مقدار واقعی و \hat{P}_h مقدار پیش‌بینی شده می‌باشد.



شکل ۳. ساختار کلی سیستم پیش‌بینی ارائه شده


الگوریتم در پیش‌بینی بهتر در مقایسه با سایر روش‌های موجود می‌باشد. هم‌چنین نتایج مناسب به دست آمده، نشان از موفقیت الگوریتم انتخاباتی در مرتب‌سازی داده‌ها دارد. روش ارائه شده علاوه بر این که به تنهایی دقت بالایی دارد، به دلیل سادگی آن، استفاده از آن برای جای‌گزینی پیش‌بینی اولیه در روش‌هایی که به پیش‌بینی اولیه نیاز داشته باشند و نیز در کنار سایر روش‌های پیش‌بینی، برای بهبود بیشتر دقت پیش‌بینی بسیار مناسب است.

۵- نتیجه‌گیری

پیش‌بینی بار یکی از مهم‌ترین مطالعات در برنامه‌ریزی و تصمیم‌گیری سیستم‌های قدرت بوده که نقش بسزایی در امنیت و اقتصاد سیستم بازی می‌کند. در این مقاله، طراحی و اجرای یک مدل از الگوریتم بهبودیافته جستجوی گرانشی و شبکه عصبی مساله پیش‌بینی بار در بازار برق نیویورک را مورد مطالعه قرار دادیم. نتایج به دست آمده از شبیه‌سازی‌ها نشان از قابلیت بالای این

جدول ۱: نتایج به دست آمده برای سیستم مورد مطالعه نیویورک در سال ۲۰۰۴

روش‌های مورد مقایسه	ماه زمستان		ماه تابستان	
	MAE (MW)	MAPE%	MAE (MW)	MAPE%
ISO [۱]	۱۶۳/۰۵	۲/۸۶	۲۴۵/۴۷	۳/۵۵
SVM [۱]	۱۴۳/۲۱	۲/۳۸	۲۰۷/۷۴	۳/۰۳
HNN [۱]	۱۰۶/۹۷	۱/۸۲	۱۶۲/۲	۲/۲۹
روش پیشنهادی با جستجوی گرانشی کلاسیک	۱۰۵/۴۵	۱/۸۲	۱۶۳/۸۷	۲/۲۸
روش پیشنهادی با اجتماع ذرات پرنده‌گان	۱۰۳/۷۶	۱/۸۱	۱۶۰/۷۶	۲/۲۷
روش پیشنهادی	۱۰۱/۲۲	۱/۸۰	۱۵۸/۳۳	۲/۲۵



شکل ۴. نتایج شبیه‌سازی ۲۴ ساعته برای سیستم نیویورک در ۱۱م جولای ۲۰۰۴

۶- مراجع

- [1] Amjady, N., Keynia, F. (2009). "Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm". *Energy*, Vol. 34, No. 1, pp. 46-57.
- [2] Alfares, HK., Nazeeruddin, M. (2002). "Electric load forecasting: literature survey and classification of methods". *Int J Syst Sci*, vol. 33, no. 1, pp. 23-34.
- [3] Amjady, N. (2001). "Short-term hourly load forecasting using time-series modeling with peak load estimation capability". *IEEE Trans on Power Syst*, vol. 16, no. 3, pp. 498-505.
- [4] Bollerslev, T. (1986). "Generalized autoregressive conditional heteroskedasticity". *J Econom*, vol. 31, no. 3, pp. 307-27.
- [5] Amjady, N. (2007). "Short-term Bus Load Forecasting of Power Systems by a New Hybrid Method". *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 333-341.
- [6] Al-Hamadi, H.M. Soliman, S.A. (2005). "Long Term/Mid Term Electric Load Forecasting Based on Short-term Correlation and Annual Growth". *Electrical Power Systems Research*, vol. 74, no. 3, pp: 353-361.
- [7] Chen, Y., Luh, PB., Guan, C., Zhao, Y., Michel, LD., Coolbeth, MA. (2010). "Short-term load forecasting: similar day-based wavelet neural networks". *IEEE Trans Power Syst*, vol. 25, no. 1, pp. 322-30.
- [8] Shayanfar, H.A., Abedinia, O., Naderi, Mohammad. S., Ghasemi, A. (2011). "GSA to Tune Fuzzy Controller for Damping Power System Oscillation". In: *Proceedings of the international conference on artificial intelligence, Las Vegas, Nevada*, pp: 713-719.
- [9] Amjady, N., Keynia, F. (2009). "Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm". *IEEE Transaction on Power System*, vol. 24, no. 1, pp. 12-20.
- [10] Amjady, N. (2002). "Electric Power Systems: Advanced Forecasting Techniques and Optimal Generation Scheduling". Chapter 4, *CRC Press, Taylor & Francis*.
- [11] Kim, C., Yu, I., Song, Y.H. (2002). "Prediction of system marginal price of electricity using wavelet transform analysis". *Energy Conversion and Management*, vol. 43, pp. 1839-1851.
- [12] Lin, W.M., Hong J., Ming-Tang, T. (2010). "Electricity price forecasting using Enhanced Probability Neural Network". *Energy Conversion and Management*, vol. 51, pp. 2707-2714.
- [13] Abedinia, O., Ghasemi, A., Baziyar, R., Yousefi, A. (2012). "Multi-objective GSA for solve the EED problem based fuzzy method". *17th Electric Power Distribution Conference, Tehran, Iran*.

- [14] Bazyar, R., Ghasemi, A., Abedinia, O., Yousefi, A. (2011). "The economic distribution of power and CHPED heat using improved SPGSA". International Power System Conference (PSC), Tehran, Iran.
- [15] Rashedi, E., Nezamabadi-pour, H., Saryazdi, S., Farsangi, MM. (2007). "Allocation of static var compensator using gravitational search algorithm". First Joint Congress on Fuzzy and Intelligent Systems, Ferdowsi University of Mashhad, pp. 29-31.
- [16] Fan S, Chen L. (2006). "Short-term load forecasting based on an adaptive hybrid method". IEEE Trans Power Syst, vol. 21, no. 1, pp. 392-401.