

Investing Neural Network Training with Metaheuristic Algorithms in order to Prediction of Iran Stock Index

Seyed Ahmad Mirzaei (Corresponding author)

Department of Financial Management, Esfarayen Branch, Islamic Azad University,
Esfarayen, Iran.

S.Ahmad.Mirzai@gmail.com

Zahra Nikdel

Department of Financial Management, Neyshabur Branch, Islamic Azad University,
Neyshabur, Iran.

Zakiyeh Nikdel

Department of Computer, Neyshabur Branch, Islamic Azad University, Neyshabur,
Iran.

Abstract

Prediction and analysis of stock market movements are an important topic for researchers, traders and have got an important role in today's economy. Variety in policies, such as government policies and economic policies affect the stock market and cause stock price changes. The predicting stock price movement on a daily basis due to the non-linear and chaotic stock price movements is a difficult task. There are several ways for predicting in stock market. Artificial intelligence techniques have been widely used to predict data with nonlinear and chaotic structure. One of these techniques is neural network. If neural network is trained correctly, then it has minimum error in predicting. In this research, we will train the multilayer perceptron neural network with 8 metaheuristic algorithms and we predict Tehran Exchange Dividend Price Index (TEDPIX). The Results show that grey wolf optimization has the minimum error in training of neural network.

Keywords: Prediction, Neural Network, Metaheuristic Algorithms, Stock Market.

تاریخ دریافت مقاله:

۱۴۰۰/۰۹/۱۳

تاریخ پذیرش مقاله:

۱۴۰۰/۱۰/۲۴

بررسی آموزش شبکه عصبی با استفاده از الگوریتم‌های فراابتکاری به منظور پیش‌بینی شاخص کل در بورس ایران

سید احمد میرزائی (نویسنده مسئول)

گروه مدیریت مالی، واحد اسفراین، دانشگاه آزاد اسلامی، اسفراین، ایران.

s.ahmad.mirzai@gmail.com

زهرا نیکدل

گروه مدیریت مالی، واحد نیشابور، دانشگاه آزاد اسلامی، نیشابور، ایران.

زکیه نیکدل

گروه کامپیوتر، واحد نیشابور، دانشگاه آزاد اسلامی، نیشابور، ایران

چکیده

پیش‌بینی و تحلیل حرکات بازار سهام موضوع بسیار مهم برای محققان، معامله‌گران و تحلیل‌گران بازار می‌باشد و نقش مهمی در اقتصاد امروز دارد. تنوع در سیاست‌هایی مانند سیاست‌های دولتی و سیاست‌های اقتصادی بر بازار سرمایه تأثیر می‌گذارند و باعث تغییرات قیمتی سهام می‌شوند. پیش‌بینی حرکات بازار به صورت روزانه، به دلیل غیرخطی بودن و آشوبناک بودن حرکات قیمت سهام کار بسیار مشکلی می‌باشد. روش‌های مختلفی برای پیش‌بینی در بورس وجود دارد. تکنیک‌های هوش مصنوعی به صورت گسترده برای پیش‌بینی داده‌های با ساختار غیرخطی و آشوبناک به کار گرفته شده‌اند. یکی از این تکنیک‌ها استفاده از شبکه‌های عصبی می‌باشد. در صورتی که شبکه عصبی به درستی آموزش داده شود، خطای کمتری در پیش‌بینی خواهد داشت. در این پژوهش با استفاده از هشت الگوریتم فراابتکاری اقدام به آموزش شبکه عصبی پرسپترون چندلایه خواهیم کرد و به پیش‌بینی شاخص کل بورس تهران خواهیم پرداخت. نتایج به دست آمده از این پژوهش نشان داد که الگوریتم بهینه‌سازی گرگ خاکستری دارای کمترین خطا در آموزش شبکه عصبی دارد.

واژه‌های کلیدی: پیش‌بینی، شبکه عصبی، الگوریتم‌های فراابتکاری، بازار سهام

۱. مقدمه

طی دو دهه گذشته، ارزیابی و پیش‌بینی آینده بورس و قیمت‌ها، موضوع بسیار جذابی برای تحلیل‌گران و پژوهش‌گران بوده است (چاندار، ۲۰۲۱). فرضیه بازار کارا^۱ بیان می‌کند که قیمت روز بازار به صورت کامل تمامی اخبار منتشرشده اخیر را منعکس می‌کند. تنوع در سیاست‌هایی مانند سیاست‌های دولتی و سیاست‌های اقتصادی بر بازار سرمایه تأثیر می‌گذارند و باعث تغییرات قیمتی سهام می‌شوند (کوپرا و همکاران، ۲۰۱۹). از این رو پیش‌بینی قیمت سهام و شاخص بورس به صورت روزانه، به دلیل غیرخطی بودن و آشوبناک بودن حرکات قیمت سهام، کار بسیار مشکلی می‌باشد (چاندار، ۲۰۲۱). تکنیک‌های هوش مصنوعی به صورت گسترده برای پیش‌بینی داده‌های با ساختار غیرخطی و آشوبناک به کار گرفته شده‌اند (میرزائی و دعائی، ۱۳۹۸). یکی از این تکنیک‌ها، شبکه‌های عصبی می‌باشد. شبکه‌های عصبی به صورت گسترده در بسیاری از زمینه‌ها مانند پیش‌بینی ورشکستگی، ارزیابی ریسک اعتباری و سایر حوزه‌های اقتصادی به کار گرفته است (مقدم و همکاران، ۲۰۱۶). یکی از پرکاربردترین شبکه‌های عصبی، شبکه‌های عصبی پرسپترون چندلایه^۴ می‌باشد (چن و همکاران، ۲۰۱۵). اثربخشی یک شبکه عصبی به شدت به استراتژی نوع آموزش بستگی دارد (حیدری و همکاران، ۲۰۱۹). دو نوع رویکرد کلی برای آموزش شبکه‌های عصبی وجود دارد. رویکرد اول استفاده از روش‌های گرادیان نزولی^۵ است و رویکرد دوم استفاده از الگوریتم‌های فراابتکاری^۶ می‌باشد (اجها و همکاران، ۲۰۱۷). منظور از آموزش شبکه عصبی، تنظیم بهینه پارامترهای شبکه عصبی یعنی وزن‌ها و بایاس‌های شبکه عصبی می‌باشد. در ادامه به بررسی تعدادی از پژوهش‌های اخیر که در این زمینه صورت گرفته است، می‌پردازیم.

^۱efficient market hypothesis

^۲nonlinear

^۳chaotic

^۴multilayer perceptron neural network

^۵gradient-descent-based

^۶metaheuristic algorithms

بهرامی و همه‌خانی (۱۳۹۵) با استفاده از شاخص‌های بازار سرمایه به‌عنوان نشان‌دهنده روند بازار و در قالب شبکه عصبی به تحلیل سری‌های زمانی قیمت سهام و شاخص کل، مالی و صنعت پرداختند. محققان نشان دادند که رفتار سری زمانی قیمت روزانه سهام شرکت‌ها و شاخص‌ها در بورس تهران تصادفی نیست اما اینفرایند غیر تصادفی دارای پیچیدگی‌های زیادی است و هنگامی که از شبکه‌های عصبی جهت پیش‌بینی استفاده می‌شود، در طراحی مدل شبکه عصبی نیاز به استفاده از شبکه با تعداد لایه‌ها و نرون‌های میانی متناسب می‌باشد.

رحیمی گرکانی (۱۳۹۶) در پژوهشی با عنوان «شناسایی اثربخش‌ترین مدل پیشگویی قیمت سهام شرکت‌های فعال در بازار بورس اوراق بهادار ساختاریافته با شبکه عصبی مصنوعی» با استفاده از شبکه عصبی و با استفاده از الگوریتم‌های پس انتشار خطا، الگوریتم بهینه‌سازی انبوه ذرات (ابرهارت و کندی، ۱۹۹۵) و الگوریتم رقابت استعماری (آتشیز گرگری و لوکاس، ۲۰۰۷) و با به‌کارگیری داده‌های روزانه شاخص کل و همچنین قیمت روزانه ۱۴ سهم انتخاب‌شده از بورس اوراق بهادار تهران شبکه عصبی را آموزش داده است و اقدام به پیش‌بینی قیمت سهام و شاخص کل کرده است. در این پژوهش محقق به این نتیجه رسیده است که الگوریتم بهینه‌سازی انبوه ذرات با اختلاف کمی نسبت به الگوریتم رقابت استعماری، خطای کمتری در آموزش شبکه عصبی داشته است. در این پژوهش از داده‌های بنیادی برای ورودی به شبکه عصبی استفاده شده است.

میرزائی و دعائی (۱۳۹۸) یک مدل برای پیش‌بینی قیمت و شاخص سهام ارائه کردند. مدل ارائه‌شده آن‌ها در مرحله اول و با استفاده از الگوریتم ژنتیک (هلند، ۱۹۷۵) و شبکه عصبی پرسپترون چندلایه، اقدام به انتخاب بهترین ویژگی‌ها می‌نماید. بهترین ویژگی‌ها، ویژگی‌هایی می‌باشند که میزان میانگین مربعات خطا در شبکه عصبی پرسپترون چندلایه را کاهش دهند. در مرحله دوم و با استفاده از ویژگی‌های انتخاب‌شده در مرحله اول، داده‌ها وارد سه پیش‌بینی‌کننده متفاوت

شبکه عصبی، شامل شبکه عصبی پرسپترون چندلایه و شبکه عصبی فازی (جنگ، ۱۹۹۳) و شبکه عصبی با توابع پایه‌ای شعاعی^۲ می‌شود و در نهایت با میانگین‌گیری از خروجی‌های سه شبکه عصبی، خروجی نهایی محاسبه می‌شود. به مرحله دوم پژوهش، یادگیری ترکیبی^۳ نیز گفته می‌شود. آن‌ها نشان دادند مدل ارائه شده خطای پیش‌بینی را کاهش داد.

گورسن و همکاران (۲۰۱۱) در مقاله‌ای با عنوان «استفاده از مدل‌های شبکه عصبی - مصنوعی در پیش‌بینی شاخص بازار» به بررسی عملکرد شبکه‌های عصبی پرسپترون چندلایه و ترکیب شبکه‌های عصبی پرداخته‌اند. پژوهشگران با استفاده از شبکه‌های عصبی پرسپترون چندلایه اقدام به پیش‌بینی شاخص نزدکاز سال ۲۰۰۸ لغایت ۲۰۰۹ به صورت سری زمانی کرده‌اند. نتیجه این تحقیق نشان داد که مدل‌های شبکه عصبی توانایی بالای در پیش‌بینی حرکات بازار را دارا می‌باشد.

هدایتی‌مقدم و همکاران (۲۰۱۶) با استفاده از شبکه عصبی پرسپترون چندلایه اقدام به پیش‌بینی شاخص بورس نزدک^۴ انجام داده‌اند. محققان با استفاده از اطلاعات قیمت پایانی اقدام به ساخت سری زمانی کرده و در مرحله بعد قیمت پایانی روز بعد را پیش‌بینی می‌کنند. محققان در یک آزمایش با استفاده از اطلاعات تاریخی قیمت ۴ روز قبل و در آزمایش دوم با استفاده از اطلاعات تاریخی قیمتی ۹ روز قبل قیمت در روز بعد را محاسبه کردند. در نهایت محققان به این نتیجه رسیدند که در پیش‌بینی شاخص با استفاده از شبکه عصبی تفاوت چندانی بین اطلاعات قیمتی ۴ روز قبل با ۹ روز قبل وجود ندارد. همچنین در این پژوهش محققان به بررسی تعداد لایه‌ها و توابع مختلف فعال‌سازی^۵ و توابع مختلف آموزش شبکه عصبی پرداخته‌اند.

^۱adaptive network based fuzzy inference system

^۲radial basis function neural network

^۳ensemble learning

^۴nasdaq index

^۵activation function

یانگ و همکاران (۲۰۱۷) با استفاده از اطلاعات قیمتی ۱۰ روز اخیر مربوط به قیمت باز شدن، بسته شدن، بیشترین قیمت و کمترین قیمت به طراحی یک شبکه عصبی عمیق با ۴۰ ورودی کرده‌اند و اقدام به پیش‌بینی قیمت پایانی روز بعد کرده‌اند.

قاسمیه و همکاران (۲۰۱۷) با استفاده از شبکه عصبی شاخص نزدکرا پیش‌بینی کردند. محققان با استفاده از اطلاعات قیمت پایانی اقدام به ساخت سری زمانی کرده و در مرحله بعد قیمت پایانی روز بعد را پیش‌بینی کردند. محققان در یک آزمایش با استفاده از اطلاعات تاریخی قیمت ۴ روز قبل و در آزمایش دوم با استفاده از اطلاعات تاریخی قیمتی ۹ روز قبل قیمت در روز بعد را محاسبه کردند. در نهایت محققان به این نتیجه رسیدند که در پیش‌بینی شاخص با استفاده از شبکه عصبی تفاوت چندانی بین اطلاعات قیمتی ۴ روز قبل با ۹ روز قبل وجود ندارد. همچنین در این پژوهش محققان به بررسی تعداد لایه‌ها و توابع مختلف فعال‌سازی و توابع مختلف آموزش شبکه عصبی پرداخته‌اند.

سنپاتی و همکاران (۲۰۱۸) با استفاده از الگوریتم انبوه ذرات اقدام به آموزش شبکه عصبی آدالاین^۱ پرداخته است. محققان با استفاده از مدل ارائه شده اقدام به پیش‌بینی قیمت باز شدن سهام در بورس بمبئی کرده‌اند.

کوپرا و همکاران (۲۰۱۹) با استفاده از شبکه عصبی و با استفاده از توابع فعال‌سازی متفاوت و تعداد نورون‌های متفاوت در لایه‌های مختلف شبکه عصبی اقدام به پیش‌بینی کرده‌اند. داده‌های ورودی به شبکه عصبی قیمت باز شدن، بیشترین قیمت و کمترین قیمت می‌باشد و خروجی شبکه عصبی قیمت پایانی می‌باشد. محققان در این پژوهش به این نتیجه رسیدند که تعداد نورون زیاد باعث افزایش صحت نمی‌شود و حداکثر تعداد ۱۰ نورون در لایه مخفی مناسب پیش‌بینی در این زمینه می‌باشد.

^۱adaline neural network

چاندر (۲۰۲۱) با استفاده از الگوریتم بهینه‌سازی گرگ خاکستری (میرجلیلی، ۲۰۱۴) اقدام به آموزش شبکه عصبی المان^۲ کرده است. محقق با در این پژوهش اقدام به پیش‌بینی شاخص بورس نزدک و یک روز کاری بعد کرده است. به‌منظور ارزیابی عملکرد مدل ارائه‌شده، با سایر مدل‌ها مقایسه شده است. نهایتاً محقق به این نتیجه رسیده است که آموزش شبکه عصبی المان با استفاده از الگوریتم گرگ خاکستری عملکرد بهتری داشته است. در این پژوهش فقط به بررسی شبکه عصبی المان پرداخته شده است و شبکه عصبی پرسپترون چندلایه بررسی نشده است.

در این پژوهش، قصد داریم با استفاده از الگوریتم‌های فراابتکاری که اخیراً معرفی شده است به آموزش شبکه عصبی پرسپترون چندلایه بپردازیم و اقدام به پیش‌بینی شاخص کل بورس ایران^۳ کنیم. هشت الگوریتم‌های فراابتکاری که در این پژوهش بررسی شده‌اند شامل الگوریتم ژنتیک، الگوریتم بهینه‌سازی انبوه ذرات، الگوریتم سیاه‌چاله (حاتملو، ۲۰۱۳)، الگوریتم سنجاکک (میرجلیلی، ۲۰۱۶)، الگوریتم بهینه‌سازی ملخ (سارمی، ۲۰۱۷)، الگوریتم گرگ خاکستری، الگوریتم سینوس-کسینوس (میرجلیلی، ۲۰۱۶) و الگوریتم بهینه‌سازی نهنگ (میرجلیلی و لويس، ۲۰۱۶) می‌باشند.

طرح کلی مقاله به این صورت می‌باشد: در بخش ۲ ابتدا به مبانی نظر پرداخته‌ایم. در بخش ۳ شیوه پژوهش را بیان کرده‌ایم. در بخش ۴ نتایج تجربی به دست آمده را نشان داده‌ایم و در پایان نیز به نتیجه‌گیری و پیشنهادهایی برای کارهای آینده پرداخته‌ایم.

^۱grey wolf optimizer

^۲elman neural network

^۳Tehran Exchange Dividend Price Index

^۴black hole optimization algorithm

^۵dragonfly algorithm

^۶grasshopper optimization algorithm

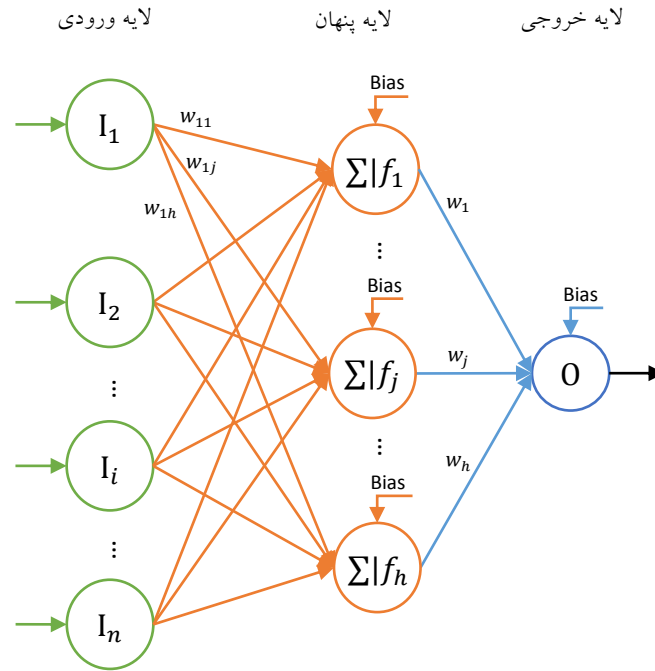
^۷sine cosine algorithm

^۸whale optimization algorithm

۲. مبانی نظری

۱-۲ شبکه‌های عصبی پرسپترون چندلایه

شبکه عصبی مصنوعی یک سیستم اطلاعاتی است که از رفتار مغز انسان برای ایجاد راه‌حل کلی ایده می‌گیرد. شبکه‌های عصبی پرسپترون دارای سه لایه می‌باشند: لایه ورودی، لایه خروجی و لایه پنهان (مقدم و همکاران، ۲۰۱۶). یک شبکه عصبی ابتدا با گرفتن ورودی‌ها و با اعمال ضرایب وزن در آنها، آنها را در لایه‌های مختلف خود منتشر می‌کند. ورودی‌های وزن‌دار شده که از توابع فعال‌سازی نرون‌ها عبور کرده‌اند، به لایه‌ی خروجی می‌رسند و خروجی‌های شبکه را تشکیل می‌دهند. دو روش برای آموزش شبکه عصبی وجود دارد. روش اول استفاده از گرادیان نزولی و روش دوم استفاده از الگوریتم‌های فراابتکاری می‌باشد (اجها و همکاران، ۲۰۱۷). شکل ۱ ساختار یک شبکه عصبی پرسپترون چندلایه را نشان می‌دهد. همان‌گونه که در شکل ۱ دیده می‌شود هر نرون در هر لایه به تمامی نرون‌های لایه‌ی بعد متصل می‌باشد.



شکل ۱- ساختار شبکه عصبی پرسپترون چند لایه

عملکرد یک نرون j بر اساس رابطه (۱) محاسبه می شود.

$$y_j = f_j \left(\sum_{i=1}^n W_{ij} I_i + b_j \right) \quad \text{رابطه (۱)}$$

که n تعداد ورودی، I_i متغیر ورودی i ، b_j مقدار بایاس نرون j می باشد. W_{ij} نشان دهنده وزن اتصال از نرون i به نرون j می باشد، f_j تابع فعال سازی می باشد و y_j خروجی نرون j می باشد. توابع فعال سازی مختلفی می تواند در شبکه های عصبی استفاده گردد. جدول ۱ تعدادی از توابع فعال سازی رایج که در شبکه های عصبی استفاده می شود نشان داده است.

جدول ۱- توابع فعال‌سازی رایج در شبکه‌های عصبی

رابطه	تابع فعال‌سازی	ردیف
$\text{tansig}(n) = 2/(1 + \exp(-2 * n)) - 1$	Hyperbolic tangent sigmoid transfer function	۱
$\text{logsig}(n) = 1/(1 + \exp(n))$	Log-sigmoid transfer function	۲
$\text{purelin}(n) = n$	Pure linear transfer function	۳
$\text{radbas}(n) = \exp((-n)^2)$	Radial basis transfer function	۴

۲-۲ الگوریتم‌های فرا ابتکاری

در سال‌های اخیر به صورت گسترده‌ای از الگوریتم‌های تکاملی و فرا ابتکاری برای حل مسائل گوناگون و بهینه‌سازی استفاده شده است. مهم‌ترین موضوعی که باعث رشد استفاده از این الگوریتم‌ها شده است، سادگی پیاده‌سازی و کاربردپذیری آن‌ها در مسائل مختلف است. الگوریتم‌های تکاملی، جواب‌های باکیفیت بالا و زمان قابل قبولی را ارائه می‌کنند. همین قابلیت باعث می‌شود تا بتوان از آن‌ها با کمترین زمان محاسبه برای یافتن پاسخ‌هایی نزدیک به بهینه استفاده کرد.

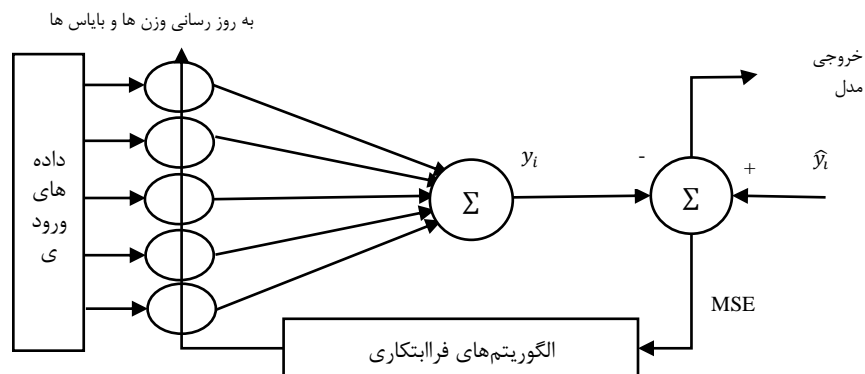
در این پژوهش ما به بررسی هشت الگوریتم فراابتکاری به منظور آموزش شبکه عصبی پرسپترون چندلایه استفاده کرده‌ایم. منظور از آموزش شبکه عصبی تنظیم بهینه پارامترهای شبکه عصبی یعنی وزن‌ها و بایاس می‌باشند. الگوریتم‌های فراابتکاری که در این پژوهش به کاررفته‌اند الگوریتم سیاه‌چاله، الگوریتم سنجاقک، الگوریتم ژنتیک، الگوریتم بهینه‌سازی ملخ‌ها، الگوریتم گرگ خاکستری، الگوریتم بهینه‌سازی انبوه ذرات، الگوریتم سینوس-کسینوس و الگوریتم بهینه‌سازی نهنگ می‌باشند. پارامترهای الگوریتم‌های فراابتکاری که در این پژوهش استفاده شده‌اند در جدول ۲ آورده شده است.

جدول ۲- پارامترهای الگوریتم‌های فرا ابتکاری

مقدار	پارامتر	الگوریتم‌های فرا ابتکاری
۴۰	تعداد جمعیت	پارامترهای مشترک
۱۰۰	تعداد تکرار	
۰,۷	احتمال ترکیب	الگوریتم ژنتیک
۰,۱۵	احتمال جهش	
۰,۹	w	الگوریتم بهینه‌سازی انبوه ذرات
۲	c_1, c_2	

۳. شیوه پژوهش

شکل ۲ به صورت مفهومی نحوه آموزش شبکه عصبی را نشان می‌دهد. پارامترهای شبکه عصبی یعنی وزن‌ها و مقادیر بایاس‌ها به‌عنوان متغیرهای بهینه‌سازی به الگوریتم‌های فرا ابتکاری داده می‌شود و الگوریتم‌های فرا ابتکاری مقادیر بهینه این متغیرها را جستجو می‌کند به طوری که میزان MSE کمترین مقدار باشد. به عبارت دیگر تابع برازندگی الگوریتم‌های فرا ابتکاری تابع MSE می‌باشد که



شکل ۲- ترکیب شبکه عصبی پرسپترون چند لایه با الگوریتم‌های فرا ابتکاری

^۱fitness function

به صورت رابطه (۲) تعریف می گردد.

تابع MSE به صورت رابطه (۲) محاسبه می شود.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad \text{رابطه (۲)}$$

که y مقدار واقعی متغیر و \hat{y} مقدار پیش بینی شده متغیر می باشد. n نیز نشان دهنده تعداد نمونه ها می باشد.

تنظیمات شبکه عصبی پرسپترون چندلایه که در این پژوهش استفاده شده است در جدول ۳ آورده شده است.

جدول ۳- تنظیمات شبکه عصبی پرسپترون چندلایه

مقادیر	پارامترهای شبکه عصبی
۴	تعداد لایه ها
۲	تعداد لایه های پنهان
۵	تعداد نرون
tansig	تابع فعال سازی برای نرون های لایه پنهان
purelin	تابع فعال ساز برای لایه خروجی
نرمال سازی داده ها به بازه [-1,+1]	پیش پردازش داده ها
۷۰٪ داده ها آموزش و ۳۰٪ داده ها آزمون	درصد داده های آموزش و داده های آزمون
۴	تعداد ورودی ها

۱-۳ داده‌ها

داده‌های موردنیاز جهت ارزیابی آموزش MLP از سامانه شرکت مدیریت فناوری بورس تهران به آدرس www.tsetmc.com از تاریخ فروردین ۱۳۹۵ لغایت اسفند ۱۳۹۹ در بازه ۵ ساله جمع‌آوری شده است. شاخص کل نشان‌دهنده سطح عمومی قیمت کلیه سهام موجود در بازار بورس است. از آنجایی که شاخص یک عدد است و واحد اندازه‌گیری خاصی برای آن تعریف نشده است به منظور این که قابلیت تفسیر و تحلیل پیدا کند به اینصورت عمل می‌گردد. یک سال مشخص را به عنوان سال پایه تعریف می‌کنند و تمامی ارقام شرکت‌ها در آن سال را به عنوان ارقام مبنا در سال پایه تعریف می‌کنند. پس از آن تغییرات قیمتی سهام در سال‌های بعد را نسبت به آن سال می‌سنجند و از این طریق رشد یا نزول شاخص اتفاق می‌افتد. در جدول ۴ مار توصیفی داده‌های این پژوهش آورده شده است.

جدول ۴ - آمار توصیفی

تعداد مشاهدات	کمترین	بیشترین	میانگین	انحراف معیار
۱۲۰۸	۷۲۶۱۵	۲۰۷۸۵۱۱٫۸	۳۹۱۳۸۱٫۲۶	۵۰۸۷۵۲٫۸۳

به‌منظور پیش‌بینی شاخص کل در این پژوهش از سری زمانی کوتاه‌مدت ۴ روزه به‌عنوان ورودی شبکه عصبی استفاده شده است. سری زمانی شاخص کل توسط رابطه (۳) ساخته می‌شود.

$$y(k) = f(y(k-1), y(k-2), y(k-3), y(k-4)) \quad \text{رابطه (۳)}$$

که $y(k)$ مقدار شاخص کل در روز k می‌باشد. یکی از مهم‌ترین جنبه‌های طراحی یک ساختار شبکه عصبی، مجموعه داده و آماده‌سازی آن است. نرمال‌سازی داده‌ها کمک می‌کند که اهمیت آن‌ها به واحد اندازه‌گیری‌شان بستگی نداشته باشد. روش‌های مختلفی جهت نرمال‌سازی داده‌ها وجود دارند که در این پژوهش از نرمال‌سازی خطی استفاده کرده‌ایم. نرمال‌سازی خطی در بازه $[a, b]$ که توسط رابطه (۴) محاسبه می‌شود.

$$x_{norm} = (b - a) \left(\frac{(x - x_{min})}{(x_{max} - x_{min})} \right) + a \quad \text{رابطه (۴)}$$

در این کار داده‌ها در $[-1,1]$ با توجه به کمترین و بیشترین مقادیر تمام داده‌ها مقایسه‌بندی شده‌اند. تمام مقادیر ورودی و خروجی در بازه $[-1,1]$ با استفاده از رابطه (۵) نرمال‌سازی شده‌اند؛ که x_{max} بیشترین و x_{min} کمترین مقدار می‌باشد.

$$x_{norm} = 2 \left(\frac{(x - x_{min})}{(x_{max} - x_{min})} \right) - 1 \quad \text{رابطه (۵)}$$

۲-۳ معیارهای ارزیابی

به‌منظور ارزیابی عملکرد روش پیشنهادی از معیارهای جدول ۵ استفاده شده است.

جدول ۵ - معیارهای ارزیابی

فرمول	نام معیار
$MAE = \frac{1}{N} \sum_{i=1}^N fo_i - fe_i $	میانگین مطلق خطا ^۱
$MSE = \frac{1}{N} \sum_{i=1}^N (fo_i - fe_i)^2$	میانگین مربعات خطا ^۲
$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (fo_i - fe_i)^2}$	مجذور میانگین مربعات خطا ^۳
$R = \frac{\sum_{i=1}^N (fo_i - \bar{fo}_1)(fe_i - \bar{fe}_1)}{\sqrt{\sum_{i=1}^N (fo_i - \bar{fo}_1)^2 (fe_i - \bar{fe}_1)^2}}$	ضریب رگرسیون ^۴

^۱mean absolute error

^۲mean squared error

^۳root mean squared error

^۴regression coefficient

در معیارهای ارزیابی جدول ۵ fe مقادیر واقعی و fo مقادیر پیش‌بینی شده می‌باشد. عبارات \overline{fe} و \overline{fo} به ترتیب میانگین مقادیر واقعی و میانگین مقادیر پیش‌بینی می‌باشد و N نیز تعداد کل داده‌ها می‌باشد.

۴. نتایج تجربی

نتایج معیارهای ارزیابی، برای داده‌های آموزشی، آزمون و کل داده‌ها، به صورت خلاصه در جدول ۶ آورده شده است. برای به دست آوردن رتبه هر معیار ارزیابی، میانگین درجه بندی بر اساس معیارهای اعتبارسنجی ($R, MAE, RMSE, MSE$) در جدول ۶ محاسبه شده‌اند.

جدول ۶ - خلاصه معیارهای ارزیابی برای الگوریتم‌های فرا ابتکاری

R		MAE		RMSE		MSE		نوع داده	الگوریتم فراابتکاری
رتبه	مقدار	رتبه	مقدار	رتبه	مقدار	رتبه	مقدار		
10	0.9967	13	0.0430	13	0.0538	13	0.00290	آموزش	الگوریتم سیاه‌چاله
10	0.9967	17	0.0446	18	0.0577	18	0.00333	آزمون	
10	0.9967	14	0.0435	14	0.0550	14	0.00303	کل	
13	0.9960	9	0.0197	10	0.0446	10	0.00199	آموزش	الگوریتم سنجاک
15	0.9951	12	0.0225	12	0.0531	12	0.0028	آزمون	
14	0.9956	10	0.0205	11	0.0473	11	0.00224	کل	
16	0.9940	15	0.0437	17	0.0568	17	0.00323	آموزش	الگوریتم ژنتیک
18	0.9936	18	0.0450	15	0.05637	15	0.00317	آزمون	
17	0.9939	16	0.0441	16	0.05672	16	0.00321	کل	
7	0.9976	7	0.0191	7	0.03414	7	0.0011	آموزش	الگوریتم بهینه‌سازی ملخ
9	0.9975	11	0.0210	9	0.03677	9	0.00135	آزمون	
8	0.9976	8	0.0197	8	0.03495	8	0.0012	کل	
4	0.9990	3	0.0147	4	0.02276	4	0.00051	آموزش	الگوریتم بهینه‌سازی گرگ خاکستری
3	0.9990	1	0.0139	1	0.02180	1	0.00047	آزمون	
4	0.9990	2	0.0145	2	0.02248	2	0.00050	کل	
1	0.9990	6	0.0184	6	0.02358	6	0.00055	آموزش	الگوریتم بهینه‌سازی

R		MAE		RMSE		MSE		نوع داده	الگوریتم فراابتکاری
رتبه	مقدار	رتبه	مقدار	رتبه	مقدار	رتبه	مقدار		
6	0.9989	4	0.0178	3	0.02251	3	0.00050	آزمون	انبوه ذرات
2	0.9990	5	0.0182	5	0.02326	5	0.00054	کل	
22	0.9887	22	0.0657	22	0.07966	22	0.00634	آموزش	الگوریتم سینوس-کسینوس
24	0.9871	24	0.0700	24	0.08717	24	0.00759	آزمون	
23	0.9882	23	0.0670	23	0.0819	23	0.00672	کل	
21	0.9903	19	0.0538	19	0.06913	19	0.00477	آموزش	الگوریتم بهینه‌سازی نهنگ
19	0.9906	21	0.0563	21	0.07253	21	0.00526	آزمون	
20	0.9904	20	0.0546	20	0.07017	20	0.00492	کل	


در جدول ۷ میانگین رتبه داده‌های آموزش، آزمون و کل داده‌ها بر اساس اطلاعات جدول ۶ محاسبه شده است. به‌عنوان مثال در الگوریتم سیاه‌چاله رتبه داده‌های آموزش برای ۴ معیار ارزیابی (۱۳ و ۱۳ و ۱۳ و ۱۰) به‌دست آمده است و میانگین این امتیازات ۱۲٫۲۵ به‌عنوان میانگین رتبه داده‌های آموزش برای الگوریتم سیاه‌چاله در جدول ۷ آورده شده است. امتیاز نهایی در جدول ۷ بر اساس میانگین رتبه داده‌های آموزش، آزمون و کل داده‌ها محاسبه می‌شود و نهایتاً رتبه نهایی بر اساس امتیاز نهایی محاسبه می‌شود.

جدول ۷. رتبه‌بندی الگوریتم‌های فرا ابتکاری بر اساس نتایج


رتبه نهایی	امتیاز نهایی	میانگین رتبه کل داده‌ها	میانگین رتبه داده‌های آزمون	میانگین رتبه داده‌های آموزش	الگوریتم فراابتکاری
5	13.6666	13	15.75	12.25	الگوریتم سیاه‌چاله
4	11.5833	11.5	12.75	10.5	الگوریتم سنجاقک
6	16.3333	16.25	16.5	16.25	الگوریتم ژنتیک
3	8.16666	8	9.5	7	الگوریتم بهینه‌سازی ملخ
1	2.58333	2.5	1.5	3.75	الگوریتم بهینه‌سازی گرگ خاکستری
2	4.33333	4.25	4	4.75	الگوریتم بهینه‌سازی انبوه ذرات
8	23	23	24	22	الگوریتم سینوس-کسینوس

رتبه نهایی	امتیاز نهایی	میانگین رتبه کل داده‌ها	میانگین رتبه داده‌های آزمون	میانگین رتبه داده‌های آموزش	الگوریتم فراابتکاری
7	20	20	20.5	19.5	الگوریتم بهینه‌سازی نهنگ


با توجه به نتایج به دست آمده مشاهده می‌شود الگوریتم بهینه‌سازی گرگ خاکستری دارای بهترین عملکرد در آموزش شبکه عصبی داشته است و در جایگاه اول قرار می‌گیرد. الگوریتم بهینه‌سازی انبوه ذرات در جایگاه دوم قرار می‌گیرد. الگوریتم بهینه‌سازی ملخ و الگوریتم سنجاچک به ترتیب در جایگاه‌های سوم و چهارم قرار می‌گیرند. پنجمین رتبه نیز به الگوریتم سیاه‌چاله تعلق می‌گیرد. رتبه ششم و هفتم نیز به ترتیب به الگوریتم ژنتیک و الگوریتم بهینه‌سازی نهنگ می‌رسد. نهایتاً بدترین عملکرد در آموزش شبکه عصبی نیز به الگوریتم سینوس-کسینوس می‌رسد که در جایگاه هشتم قرار دارد. در شکل ۳ نمودار ضریب رگرسیون برای داده‌های آموزشی و برای هشت الگوریتم فراابتکاری ترسیم شده است. با توجه به شکل ۳ و مقادیر R الگوریتم بهینه‌سازی انبوه ذرات و الگوریتم بهینه‌سازی گرگ خاکستری به ترتیب در جایگاه‌های اول و دوم قرار دارند. در شکل ۴ نیز نمودار ضریب رگرسیون برای داده‌های آزمون ترسیم شده است. در شکل ۵ نمودار ضریب رگرسیون برای کل داده‌ها ترسیم شده است. در شکل ۶ و شکل ۷ میزان خطا به ترتیب برای داده‌های آموزشی و آزمون آورده شده است. برای هر الگوریتم فراابتکاری نیز مقادیر میانگین و انحراف معیار خطا نیز در بالای هر تصویر آورده شده است.




الگوریتم سیاه چاله




الگوریتم سنجاقک




الگوریتم ژنتیک




الگوریتم بهینه سازی ملخ




الگوریتم بهینه سازی گرگ خاکستری



الگوریتم بهینه سازی انبوه ذرات




الگوریتم سینوس-کسینوس




الگوریتم بهینه سازی نهنگ


شکل ۳- نمودار ضریب رگرسیون برای داده‌های آموزش




الگوریتم سیاه چاله




الگوریتم سنجاک




الگوریتم ژنتیک




الگوریتم بهینه سازی ملخ




الگوریتم بهینه سازی گرگ خاکستری



الگوریتم بهینه سازی انبوه ذرات




الگوریتم سینوس-کسینوس




الگوریتم بهینه سازی نهنگ


شکل ۴- نمودار ضریب رگرسیون برای داده های آزمون




الگوریتم سیاه چاله




الگوریتم سنجا فک




الگوریتم ژنتیک




الگوریتم بهینه سازی ملخ




الگوریتم بهینه سازی گرگ خاکستری



الگوریتم بهینه سازی انبوه ذرات




الگوریتم سینوس-کسینوس




الگوریتم بهینه سازی نهنگ


شکل ۵- نمودار ضری برگسیون برای کل داده ها




الگوریتم سیاه چاله




الگوریتم سنجاقک




الگوریتم ژنتیک




الگوریتم بهینه سازی ملخ




الگوریتم بهینه سازی گرگ خاکستری



الگوریتم بهینه سازی انبوه ذرات




الگوریتم سینوس-کسینوس




الگوریتم بهینه سازی نهنگ


شکل ۶- نمودار میزان خطا برای داده های آموزش




الگوریتم سیاه چاله




الگوریتم سنجاقک




الگوریتم ژنتیک




الگوریتم بهینه سازی ملخ




الگوریتم بهینه سازی گرگ خاکستری



الگوریتم بهینه سازی انبوه ذرات



الگوریتم سینوس-کسینوس



الگوریتم بهینه سازی نهنگ

شکل ۷- نمودار میزان خطا برای داده های آزمون

۵. نتیجه گیری

در این پژوهش ما با استفاده از هشت الگوریتم فراابتکاری به آموزش شبکه عصبی پرسپترون چندلایه پرداختیم. داده‌های موردنیاز جهت ارزیابی آموزش شبکه عصبی شاخص کل بورس تهران از تاریخ فروردین ۱۳۹۵ لغایت اسفند ۱۳۹۹ در بازه ۵ ساله بررسی شد. یکی از روش‌های آموزش شبکه عصبی استفاده از الگوریتم‌های فراابتکاری می‌باشد. در این مقاله از هشت الگوریتم فراابتکاری به منظور آموزش شبکه عصبی استفاده کردیم و به مقایسه نتایج پرداختیم.

نتایج تجربی نشان داد که الگوریتم بهینه‌سازی گرگ خاکستری در رتبه اول قرار گرفت. در رتبه دوم الگوریتم بهینه‌سازی انبوه ذرات قرار گرفت و بدترین عملکرد مربوط به الگوریتم سینوس-کسینوس بود و در جایگاه هشتم قرار گرفت. برای کارهای پیش رو، استفاده از سایر الگوریتم‌های بهینه‌سازی که اخیراً معرفی شده‌اند می‌تواند موضوع جذابی برای محققان باشد. همچنین استفاده از سایر شبکه‌های عصبی مانند شبکه عصبی المان و یا شبکه عصبی LSTM و همچنین مقایسه این شبکه‌های عصبی با یکدیگر پیشنهاد می‌گردد.

منابع

بهرامی، آسو و همه خانی، صادق. (۱۳۹۵). استفاده از شبکه عصبی برای پیش‌بینی روند قیمت سهام. <https://civilica.com/doc/705448>

رحیمی گرکانی، عهدیه. (۱۳۹۶). شناسایی اثربخش‌ترین مدل پیشگویی قیمت سهام شرکت‌های فعال در بازار بورس اوراق بهادار ساختاریافته با شبکه عصبی مصنوعی، دومین کنفرانس بین‌المللی پژوهش‌های دانش بنیان در مهندسی کامپیوتر و فناوری اطلاعات، تهران، دانشگاه مجلسی.

میرزائی، سیداحمد و دعائی، میثم. (۱۳۹۸). ارائه مدلی جدید با رویکرد هوش مصنوعی به منظور پیش‌بینی قیمت سهام، ششمین کنفرانس ملی پژوهش‌های کاربردی در مهندسی کامپیوتر و فناوری اطلاعات، تهران، <https://civilica.com/doc/1011734>.

Atashpaz-Gargari, E., & Lucas, C. (2007, September). Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. In 2007 IEEE congress on evolutionary computation (pp. 4661-4667). Ieee.

Chandar, S. K. (2021). Grey Wolf Optimization-Elman neural network model for stock price prediction. *Soft Computing*, 25(1), 649-658.

Chen, J. F., Do, Q. H., & Hsieh, H. N. (2015). Training artificial neural networks by a hybrid PSO-CS algorithm. *Algorithms*, 8(2), 292-308.

Chopra, S., Yadav, D., & Chopra, A. N. (2019). Artificial neural networks based Indian stock market price prediction: before and after demonetization. *J Swarm Intel EvolComput*, 8(174), 2.

Chopra, S., Yadav, D., & Chopra, A. N. (2019). Artificial Neural Networks Based Indian Stock Market Price Prediction: Before and After Demonetization. *J Swarm Intel EvolComput*, 8(174), 2.

Eberhart, R., & Kennedy, J. (1995, October). A new optimizer using particle swarm theory. In MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science (pp. 39-43). Ieee.

Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38(8), 10389-10397.

Heidari, A. A., Faris, H., Aljarah, I., & Mirjalili, S. (2019). An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Computing*, 23(17), 7941-7958.

Holland, J. H. (1975). *Adaptation in natural and artificial systems*, University of Michigan press. Ann arbor, MI, 1(97), 5.

Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.

Mirjalili, S. (2016). Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. *Neural Computing and Applications*, 27(4), 1053-1073.

Mirjalili, S. (2016). SCA: a sine cosine algorithm for solving optimization problems. *Knowledge-based systems*, 96, 120-133.

Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.

Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.

Moghaddam, A. H., Moghaddam, M. H., & Esfandyari, M. (2016). Stock market index prediction using artificial neural network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93.

Ojha, V. K., Abraham, A., & Snášel, V. (2017). Metaheuristic design of feedforward neural networks: A review of two decades of research. *Engineering Applications of Artificial Intelligence*, 60, 97-116.

Saremi, S., Mirjalili, S., & Lewis, A. (2017). Grasshopper optimisation algorithm: theory and application. *Advances in Engineering Software*, 105, 30-47.

Yong, B. X., Rahim, M. R. A., & Abdullah, A. S. (2017, August). A stock market trading system using deep neural network. In *Asian Simulation Conference* (pp. 356-364). Springer, Singapore.