Financial Research Journal

Print ISSN: 1024-8153

Online ISSN: 2423-5377

# Using a Graph-based Method for Detecting the Optimal Turning Points of Financial Time Series

**Fateme Yazdani** *

*Corresponding Author, MSc., Department of Industrial, Faculty of Industrial and Systems Engineering, Isfahan University of Technology, Isfahan, Iran. E-mail: yazdanifateme@in.iut.ac.ir

**Mehdi Khashei**

Assistant Prof., Department of Industrial, Faculty of Industrial and Systems Engineering, Isfahan University of Technology, Isfahan, Iran. E-mail: khashei@cc.iut.ac.ir

**Seyed Reza Hejazi**

Prof., Department of Industrial, Faculty of Industrial and Systems Engineering, Isfahan University of Technology, Isfahan, Iran. E-mail: rehejazi@iut.ac.ir

## Abstract

**Objective:** One of the concerns of financial market investors is adopting a profitable trading strategy, which is based on profitable turning points (TPs). To achieve this target, it is necessary to predict TPs. The first step for predicting TPs is to detect TPs from the history of the corresponding time series. The profitability of the predicted TPs depends on the profitability of the detected TPs. Hence, the academic literature has always tried to enhance the performance of TPs detection methods or improve the profitability of the detected TPs. Yet, to the best of our knowledge, none of the existing methods can detect the most profitable and optimal TPs. The current paper aims to fill this research gap.

**Methods:** Our proposed method seeks the optimal TPs from the history of time series, by implementing the detection problem in the context of the graph and solving it by searching the longest path.

**Results:** The proposed graph-based TPs detection method, in contrast to the existing detection methods, is able to detect the optimal TPs from the history of the corresponding financial time series. The optimality of this method is based on its graph-based specific structure. In this method, the only potentially valuable trading points (breakpoints, i.e., BPs) are considered as the corresponding graph's vertices and connections between the entire pair of BPs form the corresponding graph's edge set. Considering the vertex and

edge set, the proposed graph-based TPs detection method optimizes the detection process, by finding the longest path existing in the corresponding graph and extracting the vertices existing in the longest path (as the optimal TPs). It is worth noticing that due to the structure of the corresponding graph, the longest path is equal to the most profitable set of BPs and the most profitable trading strategy available in the history of time series. Hence, the vertices existing in the longest path are the most profitable and the optimal TPs.

**Conclusion:** To evaluate the performance of the proposed graph-based TPs detection method, it was applied to real-world data set, and thereafter its detection results were benchmarked against other detection models. Constraints considered for modeling the proposed graph-based TPs detection method were applied to the comparative detection models, as well. These constraints included the possibility of short-selling the financial asset, the impossibility of detecting consecutive buying or selling TPs, and considering no time value for the investment money. Results from applying the proposed method to NASDAQ and New York Stock Exchange indicated the efficiency of the proposed method in the problem of detecting the optimal TPs. Besides, comparison results revealed the superiority of the proposed graph-based TPs detection method, in comparison with other detection models available in the existing literature.

**Keywords:** Financial time series, Graph, Optimal, Trading strategy, Turning points (TPs) detection.

**Citation:** Yazdani, Fateme; Khashei, Mehdi & Hejazi, Seyed Reza (2022). Using a Graph-based Method for Detecting the Optimal Turning Points of Financial Time Series. *Financial Research Journal*, 24(1), 18-36. https://doi.org/10.22059/FRJ.2021.327413.1007219 (*in Persian*)

Financial Research Journal, 2022, Vol. 24, No.1, pp. 18-36
Published by University of Tehran, Faculty of Management
doi: https://doi.org/10.22059/FRJ.2021.327413.1007219
Article Type: Research Paper
© Authors
Received: August 05, 2021
Received in revised form: November 04, 2021
Accepted: February 14, 2022
Published online: June 20, 2022

شاپا چاپی: ۸۱۵۳-۱۰۲۴
شاپا الکترونیکی: ۵۳۷۷-۲۴۲۳
تحقیقات مالی

# به‌کارگیری روشی مبتنی بر گراف برای شناسایی نقاط عطف بهینه سری زمانی مالی

**فاطمه یزدانی***
* نویسنده مسئول، کارشناس ارشد، گروه مهندسی صنایع، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان، ایران.
رایانامه: yazdanifateme@in.iut.ac.ir

**مهدی خاشعی**
استادیار، گروه مهندسی صنایع، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان، ایران. رایانامه: khashei@cc.iut.ac.ir

**سیدرضا حجازی**
استاد، گروه مهندسی صنایع، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان، ایران. رایانامه: rehejazi@iut.ac.ir

## چکیده

**هدف:** اتخاذ استراتژی معاملاتی سودده، یکی از دغدغه‌های سرمایه‌گذاران بازار مالی است. این استراتژی، بر پایه نقاط معاملاتی یا نقاط عطفِ سودده شکل می‌گیرد و لازمه دستیابیِ به آن، پیش‌بینی نقاط عطف است. گام نخست در راستای پیش‌بینی نقاط عطف، شناسایی نقاط عطف موجود در گذشته سری زمانی است. میزان سوددهی نقاط عطف پیش‌بینی‌شده، به میزان سوددهی نقاط عطف شناسایی شده بستگی دارد. به همین دلیل، ادبیات موضوع همواره در راستای ارتقای عملکرد روش‌های شناسایی نقاط عطف یا افزایش میزان سوددهی نقاط عطف شناسایی شده، تلاش کرده است. با این حال تا جایی که می‌دانیم، هیچ‌یک از روش‌های موجود، قابلیت شناسایی سوددهترین نقاط عطف یا نقاط عطف بهینه را ندارد. مقاله حاضر، با هدف برطرف‌سازی این شکاف تحقیقاتی تدوین شده است.

**روش:** مدل پیشنهادی در این مقاله، با پیاده‌سازی مسئله شناسایی نقاط عطف در بستر گراف و حل آن با جست‌وجوی طولانی‌ترین مسیر، نقاط عطف بهینه را شناسایی می‌کند.

**یافته‌ها:** مدل پیشنهادی، بر خلاف روش‌های شناسایی موجود در ادبیات، قابلیت شناسایی نقاط عطف بهینه موجود در گذشته سری زمانی مالی را دارد.

**نتیجه‌گیری:** به‌منظور نشان‌دادن عملکرد مدل پیشنهادی، ابتدا مدل روی بازارهای بورس نزدک و نیویورک پیاده‌سازی و نتایج آن با بهترین مدل‌های شناسایی موجود در ادبیات موضوع مقایسه شد. نتایج به‌دست‌آمده، برتری عملکرد مدل پیشنهادی را نسبت به سایر مدل‌ها نشان می‌دهد.

**کلیدواژه‌ها:** استراتژی معاملاتی، بهینه، سری زمانی مالی، شناسایی نقاط عطف، گراف.

**استناد:** یزدانی، فاطمه؛ خاشعی، مهدی و حجازی، سیدرضا (۱۴۰۱). به‌کارگیری روشی مبتنی بر گراف برای شناسایی نقاط عطف بهینه سری زمانی مالی. *تحقیقات مالی*، ۲۴(۱)، ۱۸ – ۳۶.

تحقیقات مالی، ۱۴۰۱، دوره ۲۴، شماره ۱، صص. ۱۸ – ۳۶
ناشر: دانشکدهٔ مدیریت دانشگاه تهران
نوع مقاله: علمی پژوهشی
© نویسندگان
تاریخ دریافت: ۱۴۰۰/۰۵/۱۴
تاریخ ویرایش: ۱۴۰۰/۰۸/۱۳
تاریخ پذیرش: ۱۴۰۰/۱۱/۲۵
تاریخ انتشار: ۱۴۰۱/۰۳/۳۰
doi: https://doi.org/10.22059/FRJ.2021.327413.1007219

## مقدمه

در بازارهای مالی، یکی از مهم‌ترین اهداف سرمایه‌گذاران و معامله‌گران، کسب درآمد و افزایش ثروت است (راعی، باجلان و عجم، ۱۳۹۹). تحقق این امر به یکی از مسائل مهم حوزه سرمایه‌گذاری گره خورده است و آن این است که سرمایه‌گذاران از زمان خرید و فروش دارایی مالی اطلاع داشته باشند (سیف، جمشیدی نوید، قنبری و اسماعیل پور، ۱۳۹۹). با توجه به ادبیات موضوع مورد نظر، می‌توان به بیان این نکته پرداخت که نقاط خرید و فروش دارایی مالی، نقاط عطف[1] نام دارند. با استناد بر پژوهش چی و مادالا[2] (۱۹۹۹) می‌توان ادعا کرد که اتخاذ استراتژی معاملاتی بر پایه عطف سودده، به کسب سود بالا و پایدار منجر می‌شود. بنابراین استفاده از ابزار یا ابزارهایی که بتوان به وسیله آن از زمان وقوع نقاط عطف سودده پیش رو مطلع شد، از اهمیت بالایی برخوردار است.

مدل‌سازی مالی، با به‌کارگیری روش‌های گوناگون، همواره به دنبال مدل‌سازی و پیش‌بینی رفتار بازارهای مالی بوده است (طباطبائی و پاک گوهر، ۱۳۹۹). در این راستا، پیش‌بینی نقاط عطف سری زمانی مالی، اطلاع از زمان وقوع نقاط عطف مالی پیش رو را ممکن می‌سازد. با این حال، مسئله پیش‌بینی نقاط عطف مالی، یکی از چالش برانگیزترین مسائل حوزه مالی است (چن، مابو، شیمادا و هیراساوا[3]، ۲۰۰۹؛ اولادیمجی[4]، ۲۰۱۶). زیرا مدل‌های پیش‌بینی نقاط عطف مالی، برخلاف مدل‌های پیش‌بینی قیمت و مدل‌های پیش‌بینی روند، به جای کمینه کردن خطای پیش‌بینی، به بیشینه‌سازی سود نقاط پیش‌بینی شده می‌پردازند (چن و همکاران، ۲۰۰۹؛ تانگ، دونگ و شی[5]، ۲۰۱۹). به علاوه، ویژگی‌های مختص سری زمانی مالی از جمله ناپایداری[6]، وجود داده‌های پَرت[7]، ماهیت بدون ساختار، درجه بالای عدم قطعیت و وجود روابط پنهان، دشواری مسئله پیش‌بینی نقاط عطف مالی را دوچندان می‌کند (اولادیمجی، ۲۰۱۶).

علی‌رغم دشواری و چالش‌برانگیز بودن مسئله پیش‌بینی نقاط عطف مالی، اهمیت بسیار بالای این مسئله از دیدگاه سرمایه‌گذاران و معامله‌گران، سبب تشویق محققان به انجام پژوهش‌های متعدد در این راستا شده است. دلیل اهمیت مسئله پیش‌بینی نقاط عطف سری زمانی مالی، در مطالعه لی و دنگ[8] (۲۰۰۷) به تصریح بیان شده است. به عقیده نویسندگان، ازدیدگاه فعالان بازار مالی، مسئله پیش‌بینی فرصت‌های معاملاتی سودده و یا نقاط عطف سودده، بسیار مهم‌تر از مسئله پیش‌بینی قیمت دارایی در روزهای معاملاتی آتی است. نتایج حاصل از بررسی ادبیات موضوع نشان می‌دهد که میزان سوددهی نقاط عطف پیش‌بینی شده، به سه عامل بستگی دارد: ۱. دقت مدل پیش‌بینی به‌کار رفته؛ ۲. سوددهی نقاط عطف شناسایی شده (عملکرد مدل شناسایی به‌کار رفته) و ۳. میزان هزینه‌های معاملاتی خرید و فروش دارایی مالی (چی و مادالا، ۱۹۹۹). بنابراین می‌توان نتیجه گرفت که افزایش میزان سوددهی نقاط عطف شناسایی شده،

1. Turning Points
2. Qi & Maddala
3. Chen, Mabu, Shimada & Hirasawa
4. Oladimeji
5. Tang, Dong & Shi
6. Non-Stationarity
7. Noise
8. Li & Deng

باعث می‌شود نقاط عطف پیش‌بینی شده از سوددهی بالاتری برخوردار باشند. به همین دلیل و بنابر ارتباط مستقیم میزان سوددهی نقاط عطف شناسایی‌شده و میزان سوددهی نقاط عطف پیش‌بینی‌شده، تمامی حجم ادبیات شناسایی نقاط عطف مالی بر افزایش میزان سوددهی روش‌های شناسایی نقاط عطف مالی متمرکز شده است.

پیرو رابطه مستقیم میزان سوددهی نقاط عطف شناسایی‌شده و میزان سوددهی نقاط عطف پیش‌بینی‌شده، روش‌های شناسایی موجود در ادبیات موضوع، همواره به دنبال بهبود عملکرد روش‌های پیشین بوده‌اند. با این حال، تا جایی‌که نتایج بررسی ادبیات موضوع توسط محققان این پژوهش نشان می‌دهد که هیچ یک از روش‌های موجود قابلیت شناسایی سودده‌ترین نقاط عطف یا نقاط عطف بهینه موجود در گذشته سری زمانی مالی را ندارند. به بیان دیگر، نقاط عطف شناسایی‌شده توسط روش‌های موجود در ادبیات، نقاط عطف بهینه موجود در گذشته سری زمانی نخواهند بود. این کمبود، ریشه در ساختار و ماهیت روش‌های شناسایی موجود دارد.

هدف از این مقاله، بر طرف سازی شکاف تحقیقاتی موجود در ادبیات شناسایی نقاط عطف مالی است. مدل پیشنهادی در این مقاله، ابتدا مسئله شناسایی نقاط عطف مالی را در بستر گراف معاملاتی پیاده‌سازی می‌کند. پس از آن با جست‌وجوی طولانی‌ترین مسیر گراف معاملاتی، مسئله مورد نظر را به صورت بهینه حل می‌کند. نتیجه به دست آمده از جست‌وجوی طولانی‌ترین مسیر در گراف معاملاتی، مجموعه نقاط عطف بهینه خواهد بود. این نقاط، نقاط سازنده طولانی‌ترین مسیر موجود در گراف معاملاتی هستند. شایان ذکر است که مسئله شناسایی نقاط عطف مالی با مسئله پیش‌بینی نقاط عطف مالی تفاوت دارد. نقاط شناسایی‌شده توسط مدل‌های شناسایی نقاط عطف، به عنوان ورودی مدل پیش‌بینی استفاده شده و مدل پیش‌بینی بر اساس این نقاط آموزش می‌بینند. در همین راستا، باید به این نکته اشاره کرد که این مقاله به مسئله شناسایی می‌پردازد، نه مسئله پیش‌بینی. مقاله حاضر، در بخش دوم، به بیان پژوهش‌های انجام‌شده در راستای افزایش سوددهی روش‌های شناسایی نقاط عطف مالی می‌پردازد. سپس، در بخش سوم، مدل پیشنهادشده برای شناسایی نقاط عطف بهینه مالی بیان می‌شود. پس از آن، بخش چهارم، با معرفی مجموعه داده‌های واقعی و پیاده‌سازی مدل پیشنهادی بر آنها، کارایی مدل در مسئله شناسایی را نشان می‌دهد و پس از آن به مقایسه مدل پیشنهادی با حالات مختلف روش نمایش خطی قطعه‌ای می‌پردازد. در پایان، نتایج و پیشنهادهای پژوهش ارائه می‌شوند.

## پیشینه پژوهش

دسته اولِ روش‌های شناسایی نقاط عطف موجود در گذشته سری زمانی مالی، روش‌های شناسایی مبتنی بر شاخص‌های فنی[1] هستند. شاخص‌های فنی که از جمله آنها می‌توان به میانگین متحرک ساده[2] و میانگین متحرک نمایی[3] اشاره کرد، با استفاده معیارهایی مانند حجم معاملات روزانه و قیمت روزانه دارایی مالی، به شناسایی نقاط عطف موجود در گذشته سری زمانی مالی می‌پردازند. منطق روش‌های شناسایی مبتنی بر شاخص‌های فنی، بر این حقیقت استوار است که

1. Technical Indicators
2. Simple Moving Average
3. Exponential Moving Average

قیمت دارایی مالی بر اساس روندهای تکرارشونده حرکت می‌کند و تا زمانی که عوامل خارجی بر این روندها تأثیر نگذارند، روندهای صعودی و نزولی قیمت دارایی حفظ می‌شوند (پیمانی فروشانی، ارضا، صالحی و صالحی، ۱۳۹۹). میانگین متحرک ساده که یکی از شاخص‌های فنی موجود در بازار مالی است، به عنوان یکی از متداول‌ترین و ساده‌ترین روش‌های شناسایی نقاط عطف و استخراج استراتژی معاملاتی شناخته می‌شود (هوانگ، پاسکوئر و کوک[1]، ۲۰۰۹، دش و دش[2]، ۲۰۱۶). استفاده از میانگین متحرک برای شناسایی نقاط عطف، از محبوبیتی خاص در میان فعالان بازار مالی برخوردار است. با این حال، سوددهی نقاط عطف شناسایی‌شده با استفاده از میانگین متحرک نمایی، بیشتر از میانگین متحرک ساده است. زیرا میانگین متحرک نمایی، وزن بیشتری را به قیمت دارایی در روزهای اخیر و وزن کمتری را به روزهای ماقبل اختصاص می‌دهد (کایال[3]، ۲۰۱۰؛ ژو و وانگ[4]، ۲۰۱۰). در همین راستا، گریلنزونی[5] (۲۰۱۲)، مطالعه خود را به بررسی عملکرد میانگین متحرک نمایی، در فرایند شناسایی نقاط عطف سری زمانی مالی اختصاص داد. وی، در پژوهش بعدی خود، ارزیابی تأثیر ضرایب هموارساز نمایی بر سوددهی نقاط عطف شناسایی‌شده را محور اصلی کار خود قرار داد (گریلنزونی، ۲۰۱۴).

بررسی مقالات موجود در ادبیات موضوع مورد نظر، نشان می‌دهد که به‌کار بردن ترکیبی از شاخص‌های فنی در فرایند شناسایی نقاط عطف، نتایج رضایت بخش‌تری را نسبت به استفاده تکی از شاخص‌های فنی، به دنبال خواهد داشت (چانگ، فان و لین[6]، ۲۰۱۱). هم‌چنین، بر اساس نتایج حاصل از بررسی ادبیات موضوع (غزالی، حسین و لیاتسیس[7]، ۲۰۱۱؛ کردوس و کویوک[8]، ۲۰۱۱؛ پوترا و کوسالا[9]، ۲۰۱۱؛ کو، کو و چو[10]، ۲۰۱۳؛ چو، کو و کو[11]، ۲۰۱۴؛ چیانگ، لین، چن و لین[12]، ۲۰۱۶) می‌توان نتیجه گرفت که نقاط عطف شناسایی‌شده بر اساس ترکیبی از شاخص‌های فنی، سوددهی بالاتری نسبت به نقاط عطف شناسایی‌شده از طریق یک شاخص دارند. در همین راستا، مسئله چگونگی ترکیب کردن شاخص‌های فنی، مورد توجه ادبیات موضوع قرار می‌گیرد. از زمان پیشنهاد الگوریتم ژنتیک[13] برای یافتن ترکیب بهینه شاخص‌های فنی توسط وانگ و لو[14] (۱۹۹۶) و وانگ، چن و لو[15] (۱۹۹۷)، مطالعات و پژوهش‌های فراوانی در راستای بهینه سازی این ترکیب صورت گرفته است. برای مثال، فرم توسعه یافته الگوریتم ژنتیک تحت عنوان برنامه

1. Huang, Pasquier & Quek
2. Dash & Dash
3. Kayal
4. Zhu & Wang
5. Grillenzoni
6. Chang, Fan & Lin
7. Ghazali, Hussain & Liatsis
8. Kordos & Cwiok
9. Putra & Kosala
10. Kuo, Kuo & Chou
11. Chou, Kuo & Kuo
12. Chiang, Lin, Chen & Lin
13. Genetic Algorithm
14. Wang & Leu
15. Wang, Chen & Leu

ریزی ژنتیک استاندارد[1] (پوتوین، سوریانو و والی[2]، ۲۰۰۴؛ لوپچ و کورن[3]، ۲۰۰۹) در فرایند انتخاب ترکیب شاخص‌های فنی، توسط ادبیات موضوع مورد بررسی قرار گرفته است. به عنوان نمونه‌ای دیگر، می‌توان به پژوهش کو و همکاران (۲۰۱۳) و چو و همکاران (۲۰۱۴) اشاره کرد که در آن نویسندگان برای یافتن ترکیب مناسب شاخص‌های فنی، از الگوریتم جست‌وجوی ممنوعه[4] استفاده کردند. با وجود روش‌های مختلفی که ادبیات موضوع برای یافتن ترکیب بهینه شاخص‌های فنی، استفاده کرده است، یافتن ترکیب بهینه شاخص‌های فنی مورد استفاده برای شناسایی نقاط عطف مالی، هم‌چنان به صورت مسئله‌ای حل نشده باقی مانده است (ورا[5]، ۲۰۱۱).

به دلیل پیچیدگی موضوع «انتخاب ترکیب مناسبی از شاخص‌های فنی»، محققان به استفاده از مفهوم برنامه ریزی شبکه ژنتیک[6] روی آوردند. ساختار برنامه ریزی شبکه ژنتیک، بر مبنای استفاده از شاخص‌های فنی شکل گرفته است. در راستای استفاده از مفهوم برنامه ریزی شبکه ژنتیک برای شناسایی نقاط عطف، می‌توان به پژوهش ایزومی، یاماگوچی، مابو، هیراساوا و هو[7] (۲۰۰۶) اشاره کرد که در آن نویسندگان با استفاده از برنامه ریزی شبکه ژنتیک و نمودارهای شمعی[8]، به شناسایی استراتژی معاملاتیِ بر پایه نقاط عطف، پرداختند. پس از آن، مابو و هیراساوا[9] (۲۰۱۱) با اضافه کردن الگوریتم یادگیری سارسا[10] به ساختار شبکه ژنتیک، عملکرد شبکه و در نتیجه سوددهی استراتژی معاملاتی شناسایی‌شده را نسبت به شبکه بدون الگوریتم سارسا، ارتقاء دادند. مفهوم شبکه ژنتیک فازی برای اولین بار توسط بهار، زرندی و اصفهانی پور[11] (۲۰۱۶) ارائه شد. آنها در پژوهش خود، با فازی سازی ساختار شبکه ژنتیک ـ الگوریتم سارسا، میزان سوددهی نقاط عطف شناسایی‌شده را نسبت به حالت غیر فازیِ شبکه ژنتیک ـ الگوریتم سارسا افزایش دادند. استفاده از شاخص‌های فنی، به صورت مستقل و یا در بستر برنامه ریزی شبکه ژنتیک، با هدف شناسایی نقاط عطف مالی، معایبی مانند احتمال شناسایی استراتژی معاملاتی زیان ده (دش و دش، ۲۰۱۶) را دارد. بنابراین، تضمینی بر سوددهی نقاط عطف شناسایی‌شده با استفاده از شاخص‌های فنی وجود ندارد.

در ادامه مطالعات انجام‌شده در راستای افزایش میزان سوددهی روش‌های شناسایی نقاط عطف مالی، به بهترین روش شناسایی موجود در ادبیات موضوع، یعنی روش نمایش خطی قطعه‌ای[12] می‌رسیم (چن و هه[13]، ۲۰۱۵). شایان ذکر است که منظور از بهترین روش شناسایی، روشی است که سوددهی نقاط عطف شناسایی‌شده توسط آن، بیشتر از سایر روش‌های شناسایی است. روش نمایش خطی قطعه‌ای با استفاده از قطعات تقریب زننده سری زمانی، به استخراج

1. Standard Genetic Programming
2. Potvin, Soriano & Vallée
3. Lohpetch & Corne
4. Tabu Search Algorithm
5. Vora
6. Genetic Network Programming
7. Izumi, Yamaguchi, Mabu, Hirasawa & Hu
8. Candlestick Charts
9. Mabu & Hirasawa
10. Sarsa Learning Algorithm
11. Bahar, Zarandi & Esfahanipour
12. Piecewise Linear Representation
13. Chen & He

روندهای موجود و شناسایی نقاط عطف موجود می‌پردازد. این تقریب بر اساس پارامتر ورودی اندازه پنجره صورت می‌گیرد. قطعات تقریب‌زننده سری زمانی در روش نمایش خطی قطعه‌ای، همان خطوط رگرسیونی برازش یافته بر سری زمانی هستند. روش نمایش خطی قطعه‌ای، با نظارت بر تغییر در پارامترهای خطوط رگرسیونی برازش یافته، به شناسایی نقاط عطف می‌پردازد. استدلال نهفته در این روش، آن است که تغییرات پارامترهای خطوط رگرسیونی برازش یافته بر سری زمانی ابزارهای مالی، نشان‌دهنده تغییر شیب محلی سری زمانی بوده و از آن می‌توان به عنوان شاخصی برای شناسایی نقاط عطف استفاده کرد.

با توجه به منطق و ساختار روش نمایش خطی قطعه‌ای، می‌توان دریافت که میزان سوددهی نقاط عطف شناسایی‌شده توسط این روش، به پارامتر ورودی روش بستگی دارد (چانگ، لیائو، لین و فان[1]، ۲۰۱۱). همین موضوع سبب جهت گیری ادبیات شناسایی نقاط عطف، به سمت انتخاب پارامتر ورودی مناسب برای روش نمایش خطی قطعه‌ای و در افزایش نتیجه میزان سوددهی نقاط عطف شناسایی‌شده شد. پژوهش چانگ، لیو، فان، لین و لای[2] (۲۰۰۹) به عنوان نقطه شروع این مطالعات شناخته می‌شود. نویسندگان این پژوهش با استفاده از روش نمایش خطی قطعه‌ای با پارامتر تصادفی به شناسایی نقاط عطف پرداختند. نتایج حاصل از این مطالعه توسط لین، ژو، ژانگ و ال وی[3] (۲۰۱۴) و با انتخاب پارامتر از طریق الگوریتم ژنتیک، بهبود داده شد. پس از آن، لو، یو، ژو و پنگ[4] (۲۰۱۷) رابطه بین میزان سوددهی نقاط عطف و اندازه پنجره را بررسی و از «درصد نقاط عطف موجود در مجموعه داده» به عنوان اندازه پنجره استفاده کردند. نتایج عددی به دست آمده، نشان دهنده بالاتر بودن سوددهی روش پیشنهادی در مقایسه با استفاده از اندازه پنجره تصادفی برای روش نمایش خطی قطعه‌ای است. تانگ، ژنگ، یو، چن و ژو[5] (۲۰۱۸) در مطالعه خود، با استفاده از الگوریتمی پویا بر پایه احتساب جداگانه درصد نقاط خرید متوالی و نقاط فروش، به تنظیم اندازه پنجره روش نمایش خطی قطعه‌ای پرداختند. پس از آن، تانگ و همکاران (۲۰۱۹) در راستای رفع مشکل انتخاب پارامتر یکسان برای نوسانات قیمتی متفاوت، تابع برازش پیشنهادی خود را ارائه دادند. تابع برازشِ پیشنهادی آنها، با بیشینه سازی سود حاصل از انجام معامله در نقاط عطف شناسایی‌شده توسط روش نمایش خطی قطعه‌ای، قابلیت تنظیم خودکار اندازه پنجره برای نوسانات قیمتی متفاوت را دارد.

همان‌طور که گفته شد در حال حاضر روش نمایش خطی قطعه‌ای، بهترین روش شناسایی موجود در ادبیات نقاط عطف مالی است. با این حال، این روش دارای معایبی است که آن را از شناسایی نقاط عطف بهینه مالی موجود در گذشته سری زمانی، باز می‌دارد. سوددهی نقاط عطف شناسایی‌شده توسط این روش، کاملا به اندازه پنجره انتخاب‌شده بستگی دارد؛ با این حال روش نمایش خطی قطعه‌ای توانایی انتخاب خودکار این پارامتر را ندارد (تانگ و همکاران، ۲۰۱۹) و انتخاب نادرست پارامتر ورودی این روش، ممکن است منجر به اتخاذ تصمیمات معاملاتی زیان آور شود (دش و

1. Chang, Liao, Lin & Fan
2. Chang, Liu, Fan, Lin & Lai
3. Lin, Xu, Zhang & Lv
4. Luo, You, Xu & Peng
5. Tang, Zheng, Yu, Chen & Zhu

دش، ۲۰۱۶). به علاوه، مسئله انتخاب اندازه پنجره بر اساس نوسانات قیمتی متفاوت، هم‌چنان حل نشده است (تانگ و همکاران، ۲۰۱۹). بنابراین، عملکرد روش نمایش خطی قطعه‌ای در فرایند شناسایی نقاط عطف مالی، سؤال برانگیز خواهد بود. همان‌طور که گفته شد، منظور از عملکرد، در روش‌های شناسایی نقاط عطف مالی، میزان سوددهی نقاط عطف شناسایی‌شده توسط روش شناسایی می‌باشد.

تمامی پژوهش‌های موجود در ادبیات موضوع، با محوریت افزایش میزان سوددهی روش‌های شناسایی نقاط عطف مالی انجام شده‌اند. تا آنجا که نتایج بررسی ادبیات موضوع توسط محققان این پژوهش نشان می دهد، علی رغم تمامی مطالعات انجام‌شده، هیچ یک از روش‌های موجود در ادبیات، قابلیت شناسایی نقاط عطف بهینه موجود در گذشته سری زمانی مالی را ندارند. این مقاله، ابتدا مسئله شناسایی نقاط عطف مالی را در بستر گراف معاملاتی پیاده‌سازی می‌کند. پس از آن با جست‌وجوی طولانی‌ترین مسیر موجود در گراف معاملاتی، به حل بهینه مسئله شناسایی نقاط عطف مالی می‌پردازد. نتایج حاصل از پیاده‌سازی مدل پیشنهادی، نشان می‌دهد که این مدل بر خلاف روش‌های موجود، قابلیت شناسایی نقاط عطف بهینه مالی را دارد.

## روش شناسی پژوهش

همان‌طور که گفته شد، این مقاله با هدف برطرف سازی شکاف تحقیقاتی موجود در ادبیات موضوع نقاط عطف مالی تدوین گردیده است. بر اساس این شکاف تحقیقاتی، تا آنجا که نتایج بررسی ادبیات موضوع توسط محققان این پژوهش نشان می دهد، هیچ یک از روش‌های موجود در ادبیات، قابلیت شناسایی نقاط عطف بهینه موجود در گذشته سری زمانی مالی را ندارند. مدل پیشنهادی در این مقاله، ابتدا مسئله شناسایی نقاط عطف بهینه مالی را در بستر گراف معاملاتی پیاده‌سازی می‌کند. پس از آن با جست‌وجوی طولانی‌ترین مسیر، استراتژی معاملاتی بهینه را شناسایی می‌کند. در مدل پیشنهادی، استراتژی معاملاتی بهینه، همان طولانی‌ترین مسیر موجود در گراف معاملاتی است. گره‌های موجود در طولانی‌ترین مسیر شناسایی‌شده، مجموعه نقاط عطف بهینه را تشکیل خواهند داد. شایان ذکر است که مسئله، با رعایت سه فرض مدل‌سازی و حل می‌شود: ۱. امکان فروش استقراضی[1] دارایی مالی؛ ۲. در نظر نگرفتن ارزش زمانی پول؛ ۳. ممنوعیت شناسایی نقاط عطفِ خرید متوالی و فروش متوالی. قبل از معرفی مدل پیشنهادی، لازم است به تعریف مفاهیم نقطه شکست[2] و نقطه عادی[3] بپردازیم.

همان‌طور که در شکل ۱ مشاهده می‌شود، نقاط شکست، به یکی از چهار شکل زیر، در روند موجود در سری زمانی مالی اخلال ایجاد می‌کنند: تغییر روند از صعودی به نزولی، صعودی به ایستا، نزولی به صعودی و نزولی به ایستا. این نقاط، که به عنوان نقاط عطف بالقوه نیز شناخته می‌شوند، توسط مجموعه $F = \{p_{f_1}, p_{f_2}, \ldots, p_{f_m}\}$ نشان داده می‌شوند. پارامتر $m$ نشان دهنده تعداد نقاط شکست موجود در گذشته سری زمانی مورد بررسی است و منظور از $p_{f_i}$

1. Short-selling
2. Breakpoints
3. Ordinary Points

قیمت دارایی در نقطه شکست $f_i$ است. اگر نقطه شکست، نقطه عطف بهینه نیز باشد، توسط مدل پیشنهادی شناسایی‌شده و به مجموعه نقاط عطف بهینه تعلق خواهد گرفت. در غیر این صورت، عضوی از مجموعه نقاط نگهداری[1] خواهد بود.

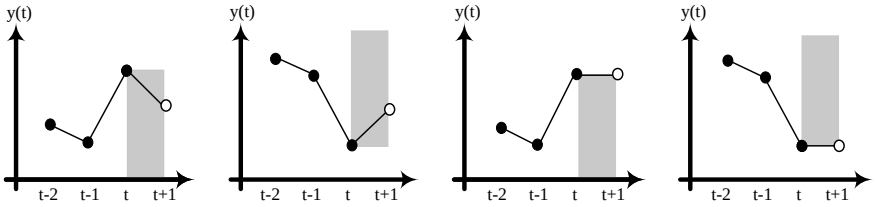


**شکل ۱. انواع نقاط شکست موجود در گذشته سری زمانی مالی**

شکل ۲ نشان دهنده نقاط عادی موجود در سری زمانی مالی است. تمامی نقاط موجود در سری زمانی مالی، به جز نقاط شکست، تحت عنوان نقاط عادی شناخته می‌شوند. نقاط عادی، فاقد ارزش معاملاتی بوده و به مجموعه نقاط نگهداری تعلق می‌گیرند. بنابراین مجموعه نقاط نگهداری از اجتماع دو مجموعه زیر به دست می‌آید: «مجموعه نقاط شکستی که عطف بهینه نیستند» و «مجموعه نقاط عادی».

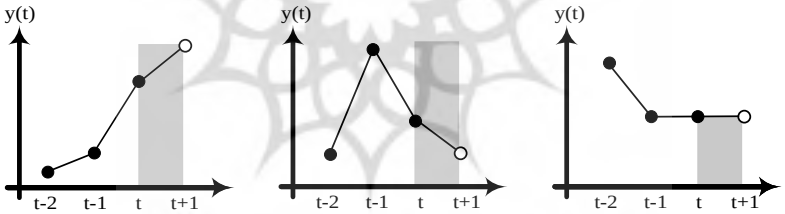


**شکل ۲. انواع نقاط عادی موجود در گذشته سری زمانی مالی**

مجموعه گره[2]، مجموعه کمان[3] و ماتریس وزن[4] گراف معاملاتی $G$ به ترتیب توسط روابط ۱، ۲ و ۳ نشان داده می‌شوند. مجموعه گره‌های گراف معاملاتی $V(G)$ متشکل از اندیس‌های زمانی نقاط شکست، به ترتیب صعودی می‌باشد. مجموعه کمان‌های گراف معاملاتی که با $E(G)$ نشان داده می‌شود، از کمان‌های جهت دارِ متصل کننده تمامی زوج نقاط شکست، از اندیس زمانی کوچک‌تر به اندیس زمانی بزرگتر، تشکیل می‌شود. ماتریس وزن $W(G)$ شامل مقادیر عددی مورد نیاز برای برچسب گذاری گره‌های موجود در گراف معاملاتی می‌باشد. برچسب گذاری گره‌های گراف، بخشی از فرایند جست‌وجوی طولانی‌ترین مسیر است.

1. Holding Points
2. Vertex Set
3. Edge Set
4. Weight Matrix

رابطه ۱)
$$V(G)=\{v_1,v_2,\ldots,v_m\}=\{f_1,f_2,\ldots,f_m\}$$

رابطه ۲)
$$E(G)=\{v_iv_j\}=\{f_if_j\};\quad i=1,2,\ldots,m-1,\ \ j=i+1,i+2,\ldots,m$$

رابطه ۳)
$$W(G)=\begin{pmatrix} - & w_{v_1v_2} & w_{v_1v_3} & \cdots & w_{v_1v_{m-1}} & w_{v_1v_m} \\ - & - & w_{v_2v_3} & \cdots & w_{v_2v_{m-1}} & w_{v_2v_m} \\ - & - & - & \cdots & \vdots & \vdots \\ - & - & - & - & w_{v_{m-2}v_{m-1}} & w_{v_{m-2}v_m} \\ - & - & - & - & - & w_{v_{m-1}v_m} \\ - & - & - & - & - & - \end{pmatrix}$$

که در آن:

رابطه ۴)
$$w_{v_iv_j}=\max\begin{Bmatrix}(1-TC_s)p_{f_j}-(1+TC_b)p_{f_i},\\ (1-TC_s)p_{f_i}-(1+TC_b)p_{f_j}\end{Bmatrix};$$
$$i=1,2,\ldots,m-1,\ \ j=i+1,i+2,\ldots,m$$

در ماتریس وزن، پارامترهای $TC_b$ و $TC_s$ نشان دهنده هزینه‌های معاملاتی[1] ناشی از خرید و فروش دارایی مالی هستند. مقادیر عددی موجود در ماتریس وزن، سود حاصل از انجام معامله در تمامی زوج نقاط شکست موجود است و از بیشینه سود موقعیت‌های فروش استقراضی و خرید به دست می‌آید. بر اساس فرض در نظر نگرفتن ارزش زمانی پول، وجه تضمین[2] موقعیت فروش استقراضی در محاسبات ماتریس وزن وارد نمی‌شود. اکنون با در دست داشتن مجموعه‌های فوق می‌توان گراف معاملاتی مسئله شناسایی نقاط عطف بهینه مالی را به صورت شکل ۳ رسم کرد.

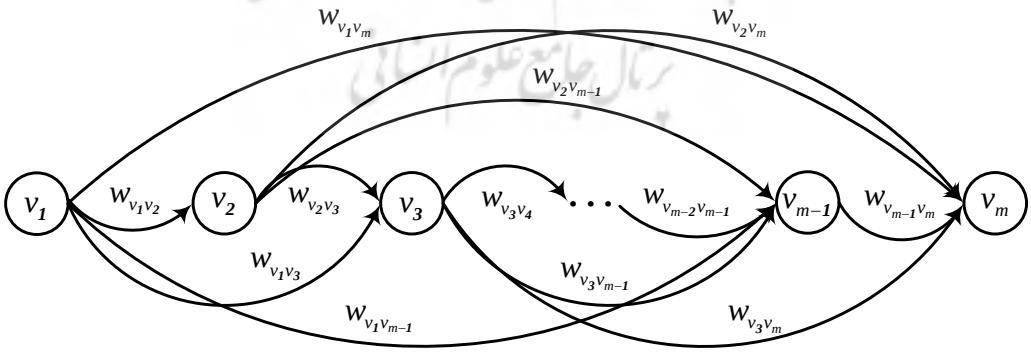


**شکل ۳. نمایش مسئله شناسایی نقاط عطف، در قالب گراف معاملاتی**

1. Transaction Costs
2. Collateral

برای شناسایی مجموعه نقاط عطف بهینه موجود در گذشته سری زمانی مالی، کافی است فرایند جست‌وجوی طولانی‌ترین مسیر موجود در گراف معاملاتی را، که در شش مرحله انجام می‌شود، طی کنیم. در این فرایند، که در قسمت زیر بیان خواهد شد، منظور از $Label(v_i)$ برچسب گره $i$ ام موجود در گراف معاملاتی است. در طول این فرایند که بر پایه برچسب گذاری گره‌های گراف انجام می‌شود، میزان سوددهی و یا همان طول تمامی مسیرهای موجود در گراف معاملاتی، از تمامی گره‌های مبدأ به تمامی گره‌های مقصد، با یکدیگر مقایسه می‌شوند. پس از آن، مسیر دارای بیشترین میزان سوددهی، که طولانی‌ترین مسیر موجود در گراف است، شناسایی می‌شود. گره‌های سازنده مسیر شناسایی‌شده، نقاط عطف بهینه مالی هستند.

**مرحله ۱.** قرار دهید $v_i = v_1$

**مرحله ۲.** فرایند زیر را طی کنید.

1. $Label(v_i) \leftarrow 0$
2. $for \;\; v_j \neq v_i \;\; (j = i+1, i+2, \ldots, m) \;\; do$
3. $Label(v_j) \leftarrow -\infty$
4. $for \;\; j \leftarrow i \;\; to \;\; m$
5. $for \;\; k \leftarrow j+1 \;\; to \;\; m$
6. $if \;\; Label(v_j) + w_{v_j v_k} > Label(v_k) \;\; then$
7. $Label(v_k) \leftarrow Label(v_j) + w_{v_j v_k}$

**مرحله ۳.** خروجی مرحله ۲ را در فهرستی ذخیره کنید. خروجی مرحله ۲، برچسب طولانی‌ترین مسیر بین $v_i$ فرض‌شده در مرحله ۱ و سایر گره‌های گراف است.

**مرحله ٤.** اگر $v_i < v_m$ است، قرار دهید $v_i = v_{i+1}$ و به مرحله ۲ بازگردید. در غیر این صورت به مرحله ۵ بروید.

**مرحله ۵.** عناصر موجود در لیست به دست آمده را با یکدیگر مقایسه کنید و عنصر دارای بیشترین مقدار را بیابید. این عنصر، بر چسب طولانی‌ترین مسیر موجود در گراف معاملاتی است. منظور از برچسب، میزان سوددهی است.

**مرحله ٦.** گره‌های سازنده طولانی‌ترین مسیر موجود در گراف را به عنوان مجموعه نقاط عطف بهینه گزارش کنید.

## یافته‌های پژوهش

در این قسمت، با استفاده از چهار مجموعه داده متشکل از قیمت‌های روزانه بسته شدن پنج شرکت فعال در بازار اوراق بهادار نزدک و نیویورک (اپل[1]، تسلا[2]، توییتر[3]، فیسبوک[4] و نتفلیکس[5]) به شناسایی نقاط عطف بهینه با استفاده از مدل پیشنهادی می‌پردازیم. مجموعه داده‌های انتخابی، مشابه با داده‌های مورد بررسی توسط بیربک و کلیف[6] (۲۰۱۸) است.

1. Apple Incorporation (AAPL)
2. Tesla Incorporation (TSLA)
3. Twitter Incorporation (TWTR)
4. Facebook Incorporation (FB)
5. Netflix Incorporation (NFLX)
6. Birbeck & Cliff

افق زمانی در نظر گرفته‌شده برای تحقق هدف شناسایی نقاط عطف بهینه مالی، از ششم ژوئن ۲۰۱۹ تا ششم ژوئن ۲۰۲۱ است. در این مدت زمان، هر سهم ۵۰۴ روز معاملاتی را تجربه می‌کند. با استفاده از مدل پیشنهادی، می‌توان مجموعه نقاط عطف بهینه موجود در گذشته سری زمانی مالی دارایی مورد بررسی را شناسایی و استخراج کرد. نتایج حاصل از پیاده‌سازی مدل پیشنهادی بر روی مجموعه داده‌های معرفی شده، در شکل‌های ۴ تا ۸ به تصویر کشیده شده است. در این شکل‌ها، نقاط قرمز و سبز به ترتیب نشان دهنده نقاط عطف بهینه خرید و نقاط عطف بهینه فروش هستند.

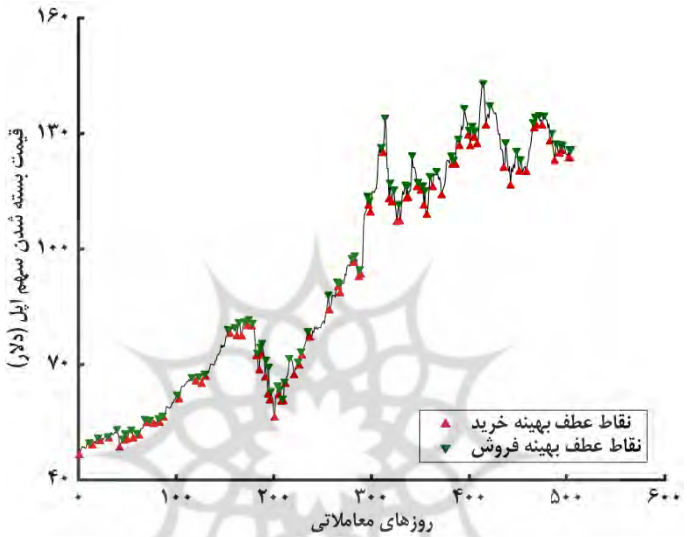


**شکل ٤. نقاط عطف بهینه سهم اپل**

**شکل ۵. نقاط عطف بهینه سهم تسلا**

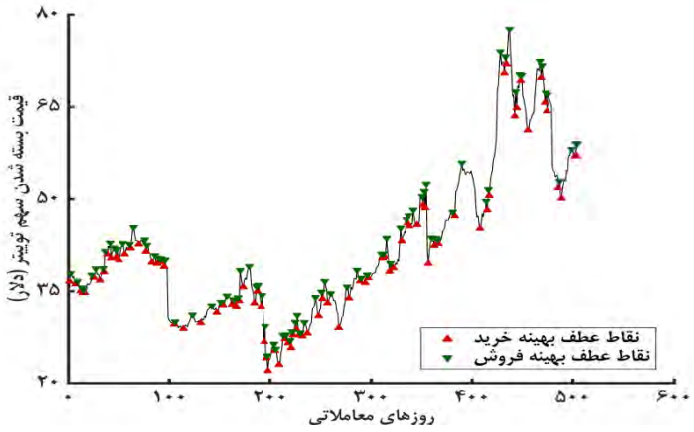


**شکل ٦. نقاط عطف بهینه سهم توییتر**

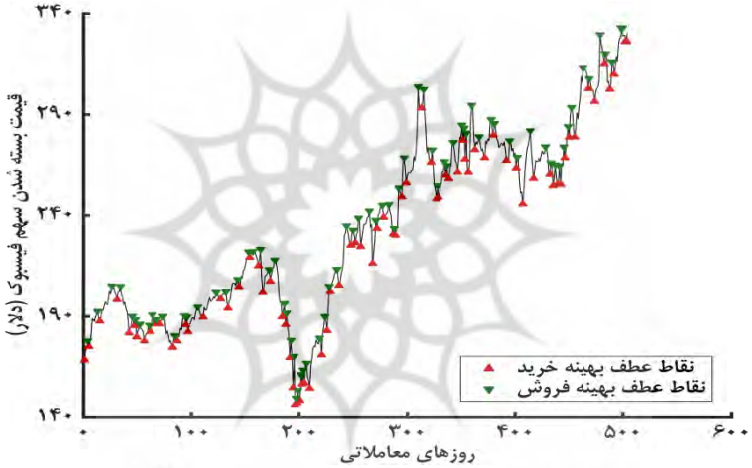


**شکل ۷. نقاط عطف بهینه سهم فیسبوک**

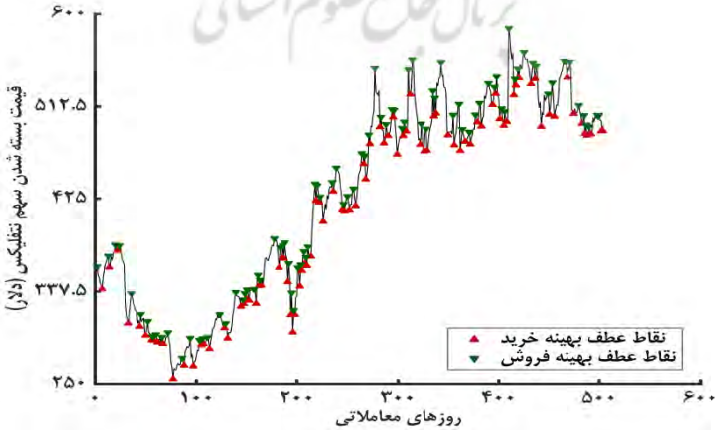


**شکل ۸. نقاط عطف بهینه سهم نتفلیکس**

## مقایسه مدل پیشنهادی با سایر روش‌های شناسایی

در این قسمت به منظور نشان دادن کارایی مدل پیشنهادی در مسئله شناسایی نقاط عطف بهینه مالی، مدل پیشنهادی با حالات مختلف روش نمایش خطی قطعه‌ای مقایسه می‌شود. همان‌طور که پیش‌تر نیز گفته شد روش نمایش خطی قطعه‌ای، به عنوان بهترین منطق شناسایی موجود در ادبیات شناخته می‌شود. روش‌های انتخاب‌شده برای مقایسه با مدل پیشنهادی عبارتند از روش‌های شناسایی ارائه‌شده توسط تانگ و همکاران (۲۰۱۹)، لو و همکاران (۲۰۱۷) و چن و هه (۲۰۱۵). این روش‌ها، درصددند تا با تنظیم پارامتر اندازه پنجره، عملکرد روش نمایش خطی قطعه‌ای قبل از خود را بهبود بخشند.

شایان ذکر است که تمامی روش‌ها، تحت فرضیات در نظر گرفته‌شده برای مدل پیشنهادی، پیاده‌سازی شده‌اند. تانگ و همکاران (۲۰۱۹)، لو و همکاران (۲۰۱۷) و چن و هه (۲۰۱۵) در مقالات خود، به هر دو مسئله شناسایی نقاط عطف مالی و پیش‌بینی نقاط عطف مالی می‌پردازند. اما از آنجایی که در این مقاله فقط مسئله شناسایی مورد بررسی قرار می‌گیرد، از روش‌های شناسایی ارائه‌شده در این مقالات استفاده می‌شود تا با مدل پیشنهادی مقایسه شوند. به عبارت دیگر، این مقاله، مدل‌های پیش‌بینی مورد استفاده در مقالات تانگ و همکاران (۲۰۱۹)، لو و همکاران (۲۰۱۷) و چن و هه (۲۰۱۵) را مورد بررسی قرار نمی‌دهد. معیار ارزیابی و مقایسه روش‌های شناسایی، میزان سوددهی نقاط عطف شناسایی‌شده توسط روش است.

نتایج عددی حاصل از مقایسه میزان سوددهی نقاط عطف شناسایی‌شده از طریق مدل پیشنهادی و روش‌های تانگ و همکاران (۲۰۱۹)، لو و همکاران (۲۰۱۷) و چن و هه (۲۰۱۵)، در جدول ۱ گزارش شده است. بر اساس این نتایج، می‌توان دریافت که مدل پیشنهادی، بالاترین سطح عملکرد را نسبت به سایر روش‌های شناسایی داراست. سایر روش‌های شناسایی، به دلیل ماهیت‌شان قابلیت شناسایی نقاط عطف بهینه مالی را ندارند. هم‌چنین می‌توان نتیجه گرفت که روش‌های تانگ و همکاران (۲۰۱۹) و لو و همکاران (۲۰۱۷) نسبت به یکدیگر برتری نسبی دارند. به طوری‌که در مورد تمامی سهم‌ها، به جز سهم توییتر، روش تانگ و همکاران (۲۰۱۹) بهتر از روش لو و همکاران (۲۰۱۷) عمل می‌کند و در مورد سهم توییتر برتری عملکرد از آنِ روش لو و همکاران (۲۰۱۷) است. این در حالی است که برتری مدل پیشنهادی نسبت به سایر روش‌های شناسایی مطلق است. این موضوع، از بهینگی مدل پیشنهادی نیز استنباط می‌شود. به عبارت دیگر، بهینگی ساختار مدل پیشنهادی، که منجر به شناسایی نقاط عطف بهینه مالی می‌شود، باعث می‌شود مدل، بالاترین سطح عملکرد ممکن را در مسئله شناسایی نقاط عطف مالی را از خود نشان دهد. در مقابل، روش‌های شناسایی موجود در ادبیات، که بر اساس ماهیت و ساختارشان، توانایی شناسایی نقاط عطف بهینه را ندارند، امکان دستیابی به بهترین سطح عملکرد ممکن را نخواهند داشت و همین امر موجب می‌شود عملکرد مدل پیشنهادی نسبت به روش‌های موجود، برتری مطلق داشته باشد.

جدول ۱. مقایسه میزان سوددهی نقاط عطف شناسایی‌شده، توسط روش‌های شناسایی

| سهم / مدل شناسایی | | مدل پیشنهادی | تانگ و همکاران (۲۰۱۹) | لو و همکاران (۲۰۱۷) | چن و هه (۲۰۱۵) |
|---|---|---|---|---|---|
| اپل | میزان سوددهی (درصد) | ۲۹۲/۶۹۷۴ | ۲۵۴/۴۴۶۸ | ۲۳۰/۵۷۳۵ | ۱۷۶/۹۴۵۱ |
| | رتبه عملکرد | ۱ | ۲ | ۳ | ۴ |
| تسلا | میزان سوددهی (درصد) | ۶۳۴/۵۹۶۷ | ۵۳۶/۶۳۹۴ | ۵۳۳/۴۷۵۶ | ۳۸۱/۳۰۵۸ |
| | رتبه عملکرد | ۱ | ۲ | ۳ | ۴ |
| توییتر | میزان سوددهی (درصد) | ۴۳۴/۷۶۹۵ | ۳۷۲/۳۴۹۲ | ۳۷۹/۰۱۹۹ | ۲۹۸/۸۳۳۸ |
| | رتبه عملکرد | ۱ | ۳ | ۲ | ۴ |
| فیسبوک | میزان سوددهی (درصد) | ۳۰۵/۵۹۲۶ | ۲۷۰/۴۴۱۵ | ۲۵۹/۰۴۳۷ | ۱۷۳/۰۰۴۸ |
| | رتبه عملکرد | ۱ | ۲ | ۳ | ۴ |
| نتفلیکس | میزان سوددهی (درصد) | ۳۳۰/۳۱۴۱ | ۲۹۴/۵۰۴۶ | ۲۸۲/۹۱۰۹ | ۱۸۶/۷۷۴۷ |
| | رتبه عملکرد | ۱ | ۲ | ۳ | ۴ |
| میانگین | میزان سوددهی (درصد) | ۳۹۹/۵۹۴۱ | ۳۴۵/۶۷۶۳ | ۳۳۷/۰۰۴۷ | ۲۴۳/۳۷۲۸ |
| | رتبه عملکرد | ۱ | ۲ | ۳ | ۴ |

جدول ۲. نتایج حاصل از مقایسات زوجی روش‌های شناسایی

| مدل شناسایی / مدل شناسایی | | مدل پیشنهادی | لو و همکاران (۲۰۱۷) | تانگ و همکاران (۲۰۱۹) | چن و هه (۲۰۱۵) |
|---|---|---|---|---|---|
| مدل پیشنهادی | تعداد بهبود | | ۵ | ۵ | ۵ |
| | حداقل بهبود (درصد) | – | ۳۵/۱۵۱۱ | ۴۶/۵۴۸۹ | ۱۱۵/۷۵۲۳ |
| | متوسط بهبود (درصد) | | ۵۳/۹۱۷۸ | ۶۲/۵۸۹۴ | ۱۵۶/۲۲۱۳ |
| تانگ و همکاران (۲۰۱۹) | تعداد بهبود | | | ۴ | ۵ |
| | حداقل بهبود (درصد) | ۰ | – | ۳/۱۶۳۷ | ۷۳/۵۱۵۳ |
| | متوسط بهبود (درصد) | | | ۱۲/۵۰۷۱ | ۱۰۲/۳۰۳۴ |
| لو و همکاران (۲۰۱۷) | تعداد بهبود | | ۱ | | ۵ |
| | حداقل بهبود (درصد) | ۰ | ۶/۶۷۰۷ | – | ۵۳/۶۲۸۴ |
| | متوسط بهبود (درصد) | | ۶/۶۷۰۷ | | ۹۳/۶۳۱۹ |
| چن و هه (۲۰۱۵) | تعداد بهبود | | | | |
| | حداقل بهبود (درصد) | ۰ | ۰ | ۰ | – |
| | متوسط بهبود (درصد) | | | | |

نتایج عددی حاصل از مقایسات زوجی روش‌های شناسایی، در جدول ۲ آورده شده است. مقادیر عددی حداقل بهبود و میانگین بهبود، بر اساس درصد گزارش شده‌اند. بر اساس نتایج عددی گزارش‌شده در جدول ۲، می‌توان برتری مطلق مدل پیشنهادی نسبت به سایر روش‌ها و برتری نسبی سایر روش‌ها (به جز مدل پیشنهادی) در مقایسه با یکدیگر را نتیجه گرفت. برتری مطلق عملکرد مدل پیشنهادی، نسبت به سایر روش‌های شناسایی امری بدیهی بوده و ریشه در بهینگی ساختار آن دارد. همان‌طور که پیش‌تر نیز گفته شد مدل پیشنهادی، ابتدا به جست‌وجوی طولانی‌ترین (سودده‌ترین) مسیر موجود در گراف معاملاتی می‌پردازد. مسیرهای موجود در گراف معاملاتی، از توالی‌های متمایز نقاط شکست شکل می‌گیرند. انتخاب نقاط شکست به عنوان عناصر سازنده مسیرهای گراف معاملاتی، به این دلیل است که نقاط عادی (تمامی نقاط سری زمانی به جز نقاط شکست) فاقد ارزش معاملاتی بوده و استفاده از آنها در گراف معاملاتی، ضرورتی ندارد. زمانی‌که طولانی‌ترین مسیر موجود در گراف معاملاتی یافت شد، نقاط شکست سازنده آن مسیر، نقاط عطف بهینه موجود در گذشته سری زمانی دارایی مالی مورد بررسی خواهند بود.

## نتیجه‌گیری و پیشنهادها

سرمایه‌گذاران و فعالان بازارهای مالی همواره به دنبال کسب سود بالا و پایدار بوده‌اند. این هدف از طریق انجام معاملات در نقاط عطف سودده پیش رو محقق می‌شود. پیش‌بینی نقاط عطف مالی یکی از مهم‌ترین و در عین حال چالش برانگیزترین مسائل حوزه مالی است. اولین گام در راستای پیش‌بینی نقاط عطف، شناسایی نقاط عطف موجود در گذشته سری زمانی دارایی مالی است. هرچه میزان سوددهی نقاط عطف شناسایی‌شده بیشتر باشد، میزان سوددهی نقاط عطف پیش‌بینی‌شده نیز بیشتر خواهد شد. از این رو، ادبیات نقاط عطف مالی همواره به دنبال افزایش میزان سوددهی نقاط عطف شناسایی شده بوده است. تا آنجا که نتایج بررسی ادبیات موضوع توسط محققان این پژوهش نشان می دهد، علی رغم تمامی تلاش‌های صورت گرفته، هیچ یک از روش‌های موجود در ادبیات، قابلیت شناسایی نقاط عطف بهینه مالی را ندارند. به عبارت دیگر، تمامی این روش‌ها، فرایند شناسایی را به صورت غیر بهینه پیاده‌سازی می‌کنند.

این مقاله، با هدف بهینه سازی فرایند شناسایی نقاط عطف مالی تدوین و ارائه شده است. در این مقاله، مسئله شناسایی نقاط عطف بهینه مالی در ساختار گراف معاملاتی پیاده‌سازی‌شده و پس از آن با جست‌وجوی طولانی‌ترین مسیر گراف، حل می‌شود. مدل پیشنهادی، ابتدا به جست‌وجوی طولانی‌ترین (سودده‌ترین) مسیر موجود در گراف معاملاتی می‌پردازد. مسیرهای موجود در گراف معاملاتی، از توالی‌های متمایز نقاط شکست شکل می‌گیرد. انتخاب نقاط شکست به عنوان عناصر سازنده مسیرهای گراف معاملاتی، به این دلیل است که نقاط عادی (تمامی نقاط سری زمانی به جز نقاط شکست) فاقد ارزش معاملاتی بوده و استفاده از آنها در گراف معاملاتی، ضرورتی ندارد. زمانی‌که طولانی‌ترین مسیر موجود در گراف معاملاتی یافت شد، نقاط شکست سازنده طولانی‌ترین مسیر، به عنوان نقاط عطف بهینه موجود در گذشته سری زمانی دارایی مالی مورد بررسی گزارش می‌شوند. بهینگی ساختار مدل شناسایی پیشنهادی، باعث می‌شود عملکرد مدل در عمل، بالاتر از عملکرد روش‌های شناسایی موجود در ادبیات باشد. نتایج حاصل از پیاده‌سازی مدل

پیشنهادی، بیانگر کارایی مدل پیشنهادی در مسئله شناسایی نقاط عطف بهینه مالی است. مقایسه عملکرد مدل پیشنهادی با حالات متفاوت روش نمایش خطی قطعه‌ای، نشان می‌دهد که میزان سوددهی نقاط عطف شناسایی‌شده توسط مدل پیشنهادی، بیشتر از میزان سوددهی نقاط شناسایی‌شده توسط روش‌های شناسایی موجود در ادبیات موضوع است. برای پژوهش‌های بعدی، می‌توان مدل پیشنهادی را در حالت در نظر گرفتن ارزش زمانی پول و دخالت دادن وجه تضمین موقعیت فروش استقراضی، و یا امکان پذیر نبودن فروش استقراضی برای دارایی، مورد بررسی و مطالعه قرار داد.

## منابع


پیمانی فروشانی، مسلم؛ ارضا، امیرحسین؛ صالحی، مهدی و صالحی، احمد (۱۳۹۹). بازدهی معامله‌ها بر اساس نمودارهای شمعی در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۲(۱)، ۶۹-۸۹.

راعی، رضا؛ باجلان، سعید و عجم، علیرضا (۱۳۹۹). بررسی کارایی مدل 1/N در انتخاب پورتفوی. *تحقیقات مالی*، ۲۳(۱)، ۱-۱۶.

سیف، سمیرا؛ جمشیدی نوید، بابک؛ قنبری، مهرداد؛ اسماعیلی پور، منصور (۱۳۹۹). پیش‌بینی روند بورس سهام ایران با استفاده از نوسان نمای موج الیوت و شاخص قدرت نسبی. *تحقیقات مالی*، ۲۳(۱)، ۱۳۴-۱۵۷.

طباطبائی، سید جلال و پاک گوهر، علیرضا (۱۳۹۹). مدل‌سازی سری زمانی مقادیر فرین بر اساس رویکرد تحلیل طیفی. *تحقیقات مالی*، ۲۲(۴)، ۵۹۴-۶۱۱.


## References


Bahar, H. H., Zarandi, M. H. F. & Esfahanipour, A. (2016). Generating ternary stock trading signals using fuzzy genetic network programming. *Annual Conference of the North American Fuzzy Information Processing Society (NAFIPS)*, El Paso, Institute of Electrical and Electronics Engineers.

Birbeck, E. & Cliff, D. (2018). Using Stock Prices as Ground Truth in Sentiment Analysis to Generate Profitable Trading Signals. *Symposium Series on Computational Intelligence (SSCI)*, Bengaluru, Institute of Electrical and Electronics Engineers.

Chang, P.-C., Fan, C.-Y. & Lin, J. L. (2011). Trend discovery in financial time series data using a case based fuzzy decision tree. *Expert Systems with Applications*, 38 (5), 6070-6080.

Chang, P.C., Liao, T. W., Lin, J.J. & Fan, C.-Y. (2011). A dynamic threshold decision system for stock trading signal detection. *Applied Soft Computing*, 11 (5), 3998-4010.

Chang, P.C., Liu, C.H., Fan, C.Y., Lin, J. L. & Lai, C.M. (2009). An ensemble of neural networks for stock trading decision making. *International Conference on Intelligent Computing*, Heidelberg, Springer.

Chen, X. & He, Z.-J. (2015). Prediction of stock trading signal based on support vector machine. *8th International Conference on Intelligent Computation Technology and Automation (ICICTA)*, Nanchang, Institute of Electrical and Electronics Engineers.

Chen, Y., Mabu, S., Shimada, K. & Hirasawa, K. (2009). A genetic network programming with learning approach for enhanced stock trading model. *Expert Systems with Applications*, 36 (10): 12537-12546.

Chiang, C.-W., Lin, J.-B., Chen, C.-m. & Lin, Y.-T. (2016). Backpropagation neural network model for stock trading points prediction. *International Research Journal of Applied Finance*, 7 (10): 254-266.

Chou, Y.-H., Kuo, S.-Y. & Kuo, C. (2014). A dynamic stock trading system based on a multi-objective quantum-inspired tabu search algorithm. *International Conference on Systems, Man, and Cybernetics (SMC)*, San Diego, Institute of Electrical and Electronics Engineers.

Dash, R. & Dash. P. K. (2016). A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science*, 2 (1), 42-57.

Ghazali, R., Hussain, A. J. & Liatsis, P. (2011). Dynamic Ridge Polynomial Neural Network: Forecasting the univariate non-stationary and stationary trading signals. *Expert Systems with Applications*, 38 (4), 3765-3776.

Grillenzoni, C. (2012). Evaluation of recursive detection methods for turning points in financial time series. *Australian & New Zealand Journal of Statistics*, 54 (3), 325-342.

Grillenzoni, C. (2014). Sequential smoothing for turning point detection with application to financial decisions. *Applied Stochastic Models in Business and Industry*, 30 (2), 132-140.

Huang, H., Pasquier, M. & Quek, C. (2009). Financial market trading system with a hierarchical coevolutionary fuzzy predictive model. *IEEE transactions on Evolutionary Computation*, 13 (1), 56-70.

Izumi, Y., Yamaguchi, T., Mabu, S., Hirasawa, K. & Hu, J. (2006). Trading rules on the stock markets using genetic network programming with candlestick chart. *International Conference on Evolutionary Computation*, Vancouver, Institute of Electrical and Electronics Engineers.

Kayal, A. (2010). A neural networks filtering mechanism for foreign exchange trading signals. *International Conference on Intelligent Computing and Intelligent Systems*, Xiamen, Institute of Electrical and Electronics Engineers.

Kordos, M. & Cwiok, A. (2011). A new approach to neural network based stock trading strategy. *International Conference on Intelligent Data Engineering and Automated Learning*, Heidelberg, Springer.

Kuo, S.-Y., Kuo, C. & Chou, Y.-H. (2013). Dynamic stock trading system based on quantum-inspired tabu search algorithm. *Congress on Evolutionary Computation*, Cancun, Institute of Electrical and Electronics Engineers.

Li, X. & Deng, Z. (2007). A machine learning approach to predict turning points for chaotic financial time series. *19th International Conference on Tools with Artificial Intelligence (ICTAI 2007)*, Patras, Institute of Electrical and Electronics Engineers.

Lin, N., Xu, W., Zhang, X. & Lv, S. (2014). Can Web News Media Sentiments Improve Stock Trading signal Prediction?. *The 18th Pacific Asia Conference on Information Systems (PACIS 2014)*, Chengdu, Association for Information Systems (AIS).

Lohpetch, D. & Corne, D. (2009). Discovering effective technical trading rules with genetic programming: Towards robustly outperforming buy-and-hold. *World Congress on Nature & Biologically Inspired Computing (NaBIC)*, Coimbatore, Institute of Electrical and Electronics Engineers.

Luo, L., You, S., Xu, Y. & Peng, H. (2017). Improving the integration of piece wise linear representation and weighted support vector machine for stock trading signal prediction. *Applied Soft Computing*, 56 (3), 199-216.

Mabu, S. & Hirasawa, K. (2011). Enhanced rule extraction and classification mechanism of genetic network programming for stock trading signal generation. *Proceedings of the 13th annual conference on Genetic and evolutionary computation*, Dublin, Association for Computing Machinery.

Oladimeji, I. W. (2016). Forecasting Shares Trading Signals With Finite State Machine Variant. *Multidisciplinary Engineering Science and Technology*, 3 (4), 4488-4493.

Peymany Foroushany, M., Erzae, A. H., Salehi, M., & Salehi, A. (2020). Trades Return Based on Candlestick Charts in Tehran Stock Exchange. Financial Research Journal, 22 (1), 69-89. (*in Persian*)

Potvin, J.-Y., Soriano, P. & Vallée, M. (2004). Generating trading rules on the stock markets with genetic programming. *Computers & Operations Research*, 31 (7), 1033-1047.

Putra, E. F. & Kosala, R. (2011). Application of artificial neural networks to predict intraday trading signals. *Proceedings of the 10th WSEAS international conference on E-Activities*, Jakarta, World Scientific and Engineering Academy and Society (WSEAS).

Qi, M. & Maddala, G. (1999). Economic factors and the stock market: a new perspective. *Journal of Forecasting*, 18 (3), 151-166.

Raei, R., Bajalan, S., & Ajam, A. (2021). Investigating the Efficiency of the 1/N Model in Portfolio Selection. Financial Research Journal, 23 (1), 1-16. (*in Persian*)

Seif, S., Jamshidinavid, B., Ghanbari, M., & Esmaeilpour, M. (2021). Predicting Stock Market Trends of Iran Using Elliott Wave Oscillation and Relative Strength Index. Financial Research Journal, 23 (1), 134-157. (*in Persian*)

Tabatabaei, S. J., & Pakgohar, A. (2021). Time Series Modeling of Extreme Losses Values Based on a Spectral Analysis Approach. Financial Research Journal, 22 (4), 594-611. (*in Persian*)

Tang, C., X. Zheng, Yu, X., Chen, C. & Zhu, W. (2018). Design and Research of Intelligent Quantitative Investment Model Based on PLR-IRF and DRNN Algorithm. *4th Information Technology and Mechatronics Engineering Conference (ITOEC)*, Chongqing, Institute of Electrical and Electronics Engineers.

Tang, H., Dong, P. & Shi, Y. (2019). A new approach of integrating piecewise linear representation and weighted support vector machine for forecasting stock turning points. *Applied Soft Computing*, 78, 685-696.

Vora, M. N. (2011). Genetic algorithm for trading signal generation. *International Conference on Business and Economics Research*, Kuala Lumpur, International Association of Computer Science and Information Technology (IACSIT).

Wang, J.-H., Chen, S.-M. & Leu, J.-Y. (1997). Stock trading decision support system using a rule selector based on sliding window. *International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation*, Orlando, Institute of Electrical and Electronics Engineers.

Wang, J.-H. & Leu, J.-Y. (1996). Dynamic trading decision support system using rule selector based on genetic algorithms. *Neural Networks for Signal Processing VI. Proceedings of Signal Processing Society Workshop*, Kyoto, Institute of Electrical and Electronics Engineers.

Zhu, M. & Wang, L. (2010). Intelligent trading using support vector regression and multilayer perceptrons optimized with genetic algorithms. *International Joint Conference on Neural Networks (IJCNN)*, Barcelona, Institute of Electrical and Electronics Engineers.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی