

شناسایی نقطه تغییر در داده‌های پانلی به روش هم‌زمان میانگین متحرک

موزون‌نمایی و جمع تجمعی

کریم آتشگر^{۱*}، ناصر رفیعی^۲

۱. دانشیار مهندسی صنایع دانشگاه صنعتی مالک‌اشتر، تهران

۲. دانشجوی کارشناسی ارشد مهندسی صنایع، دانشگاه صنعتی مالک‌اشتر، تهران

(تاریخ دریافت: ۹۷/۱۰/۰۹، تاریخ دریافت روایت اصلاح‌شده: ۹۸/۰۱/۲۴، تاریخ تصویب: ۹۸/۰۱/۳۱)

چکیده

شناسایی نقطه تغییر در داده‌های پانلی به کارشناسان کمک می‌کند تا دریابند مقاطع داده‌ها در چه زمانی تغییر کرده است. شناسایی این زمان به تحلیل واقعی‌تری از تغییرات در فرایند می‌انجامد. روش‌های مختلفی برای شناسایی نقطه تغییر در داده‌های پانلی معرفی شده است، اما افزایش حساسیت روش‌ها در شناسایی نقطه تغییر داده‌های پانلی، اهمیت بسیاری دارد. در این مقاله، به کمک رویکرد ترکیبی روشی با حساسیت بالا برای شناسایی نقطه تغییر در داده‌های پانلی (با ابعاد بزرگ) معرفی شده است. در این مقاله، روشی جدید با رویکرد ترکیبی با نام جمع تجمعی دوپل-میانگین متحرک موزون (double CUSUM-EWMA) که حساسیت بسیاری دارد، برای شناسایی نقطه تغییر داده‌های پانلی پیشنهاد می‌شود. همچنین با استفاده از داده‌های شبیه‌سازی‌شده، فرایندی در ابعاد بزرگ بررسی می‌شود که داده‌های پانلی آن از تغییر پله‌ای تأثیر پذیرفته است. نتایج مقایسه عملکرد روش پیشنهادی با یکی از بهترین روش‌ها در ادبیات نشان‌دهنده بهبود عملکرد روش پیشنهادی این مقاله از روش بررسی‌شده است.

واژه‌های کلیدی: جمع تجمعی دوپل، داده‌های پانلی، میانگین متحرک موزون‌نمایی، نقطه تغییر.

مقدمه

مشخص (T) به دست آمده باشند. در این صورت ماتریسی

را که $n \times T$ داده آماری دارد، داده‌های پانلی می‌نامند.

تغییرات تصادفی در داده‌های پانلی، بیانگر شرایط طبیعی در سیستم یا فرایند مورد مطالعه است، اما هنگامی که یک سیستم یا فرایند از عوامل غیرطبیعی (غیر تصادفی) تأثیر می‌گیرد، بخشی از داده‌ها، تحت شرایط غیرطبیعی ایجاد می‌شوند. زمانی که سیستم یا فرایندی از عوامل غیرطبیعی تأثیر می‌گیرد و از آن زمان به بعد داده‌هایی با تغییرات غیرتصادفی تولید می‌شود نقطه تغییر نام دارد؛ از این رو داده‌هایی که پس از نقطه تغییر ایجاد شده‌اند، با تغییر در حداقل یکی از پارامترهای میانگین، واریانس یا ساختار وابستگی مواجه خواهند شد.

مدل داده‌های پانلی در این پژوهش به صورت رابطه ۱ تعریف می‌شود:

$$x_{j,t} = \mu_j + \delta_j | \{t > t_0\} + \varepsilon_{j,t}, \quad (1)$$

$$t = 1, \dots, T; \quad j = 1, \dots, n$$

که در آن، $\varepsilon_{j,t}$ خطای فرایند در مقطع j ام و زمان t ام است و فرض می‌شود در بعد زمانی ایستا است و $E(\varepsilon_{j,t}) = 0$ است.

مشاهدات آماری به سه دسته داده‌های سری زمانی، داده‌های مقطعی و داده‌های پانلی تقسیم می‌شوند. داده‌های سری زمانی داده‌هایی هستند که طی یک دوره زمانی از مقادیر مربوط به یک یا چند متغیر جمع‌آوری شده‌اند و به صورت $y_t = y_{1,t}, y_{2,t}, \dots, y_{n,t}$ یا $\{y_t; t \in T\}$ نشان داده می‌شوند؛ به طوری که در آن $t = 1, 2, \dots, T$ بیانگر زمانی است که متغیر تصادفی y در آن اندازه‌گیری شده است. T نیز نشان‌دهنده طول سری زمانی یا تعداد کل مشاهدات است. داده‌های مقطعی داده‌هایی هستند که براساس مقادیر یک یا چند متغیر در یک زمان مشخص جمع‌آوری می‌شوند. به عبارت دیگر داده‌های مقطعی به مقادیر مربوط به یک یا چند متغیر در زمان معین برای واحدهای متعدد گفته می‌شود. داده‌های پانلی داده‌هایی هستند که هم‌زمان شامل ویژگی‌های داده‌های مقطعی و سری زمانی هستند. همچنین به مجموعه‌ای از داده‌ها گفته می‌شود که براساس آن‌ها، داده‌های مشاهده‌شده از یک یا چند متغیر برای بسیاری از واحدهای مقطعی (n) که به صورت تصادفی انتخاب می‌شوند، در طول یک دوره زمانی

مشترک تمرکز می کند؛ به طوری که در پژوهش او تمام سری ها، نقطه تغییر مشابهی دارند. وی از روش برآورد کمترین مربعات خطا (LSE) برای برآورد نقطه تغییر در میانگین و از روش حداکثر درست‌نمایی گوسی (QML) برای برآورد نقطه تغییر در میانگین، واریانس یا هر دو به صورت هم‌زمان استفاده کرده است. هوروات و هوسکووا [۴] آماره مربوط به برآوردگر نقطه تغییر در میانگین های داده های پانلی را که بای [۳] با استفاده از روش حداکثر درست‌نمایی گوسی ایجاد کرده است بررسی کردند و توزیع تقریبی آماره را ارائه دادند. تمرکز آن‌ها در این پژوهش بر آزمونی برای تغییرات احتمالی در موقعیت پارامتر میانگین در داده‌های پانلی است و در آن آزمون طراحی شده است که به تغییرات نسبتاً بزرگ میانگین در تعداد کمی از واحدهای مقطعی و هم‌زمان به تغییرات نسبتاً کوچک میانگین در تعداد زیادی از واحدهای مقطعی حساس است. این آزمون از استدلال درست‌نمایی ناشی شده و مبتنی بر تطبیق روش جمع تجمعی (CUSUM) بر داده‌های پانلی است. لی و همکاران [۵] آماره هوروات و هوسکووا [۴] را توسعه دادند و آماره مبتنی بر روش جمع تجمعی برای شناسایی نقطه تغییر مشترک در واریانس را پیشنهاد کردند. دی واچتر و تزاوالیس روش آزمون تشخیص شکست ساختاری برای مدل داده‌های پانلی خطی پویا با رگرسورهای برون‌زا را توسعه دادند [۶] (منظور از شکست ساختاری تغییر در ساختار یک مدل است). روش ارائه شده می‌تواند تغییر در پارامترهای شیب و تأثیرات ثابت را در خود جای دهد. این کار براساس چارچوب روش تعمیم‌یافته گشتاورهای (GMM) استفاده شده آرلانو و باند [۷] انجام شده است. در این روش، تفاوت در مقدار توابع هدف GMM با فرض صفر (هیچ تغییری رخ نداده است) و هریک از جایگزین‌ها (تغییر در یکی از زمان‌ها رخ داده است) اساسی برای آماره آزمون خواهد بود. زو و همکاران رویکرد تشخیص نقطه تغییر مبنی بر تابع کاپیولا^۸ را در داده‌های پانلی نامتعادل ارائه کردند [۸]. در این رویکرد، کاپیولا برای توصیف ساختار وابستگی داده‌ها استفاده می‌شود و پارامتر کاپیولا نشان‌دهنده درجه وابستگی است. رویکرد این روش در تشخیص نقطه تغییر را می‌توان به عنوان فرایند سه‌مرحله‌ای خلاصه کرد. در ابتدا، کاپیولا یا عضو رابط مناسب که می‌تواند ساختار وابستگی

همچنین $\delta_j \neq 0$ مقدار تغییر در میانگین μ_j از بعد از نقطه تغییر نامعلوم $t_0 \in [1, T]$ است. در مدل فوق μ_j نشان‌دهنده میانگین مقطع z ام در شرایط تحت کنترل است. بدیهی است باید انتظار داشت که در شرایط تحت کنترل، هر مشاهده در هر مقطع به صورت تصادفی حول میانگین قرار بگیرد. در مدل داده‌های پانلی ۱، میانگین مقطع z ام از زمان بعد از t_0 ، از μ_j به $\mu_j + \delta_j$ تغییر می‌کند.

هرچند روش‌های مختلفی برای شناسایی نقطه تغییر در داده‌های پانلی معرفی شده است، اما حساسیت بالا برای روش‌ها در شناسایی نقطه تغییر داده‌های پانلی، اهمیت بسیاری دارد. با توجه به حساسیت روش‌های جمع تجمعی و میانگین متحرک موزون، که برخلاف رویکرد شوهارت اثر داده‌های گذشته را در پایش داده‌های فعلی مدنظر قرار می‌دهد، در این مقاله با رویکردی ترکیبی، نقطه تغییر در داده‌های پانلی (با ابعاد بزرگ) شناسایی شده است.

در بخش بعدی این مقاله، ادبیات مربوط به مسئله نقطه تغییر در داده‌های پانلی بررسی می‌شود. بخش سوم این مقاله به معرفی روش‌های مختلف شناسایی نقطه تغییر در داده‌های پانلی با رویکرد جمع تجمعی اختصاص یافته است. در بخش چهارم، آماره پیشنهادی این مقاله برای شناسایی نقطه تغییر در داده‌های پانلی تشریح شده است. در بخش پنجم، ضمن تجزیه و تحلیل کمی قابلیت روش پیشنهادی، به مقایسه عملکرد روش پیشنهاد این مقاله با دیگر روش‌های موجود در ادبیات پرداخته شده است. در بخش ششم، روش پیشنهادی در یک نمونه واقعی استفاده شده و در نهایت بخش آخر این مقاله به نتیجه‌گیری اختصاص یافته است.

پیشینه پژوهش

جوزف و ولفسون [۱، ۲] پیشگام پژوهش در مورد مسئله نقطه تغییر در داده‌های پانلی هستند. آن‌ها با فرض اینکه در n سری داده، نقاط تغییر به طور مستقل و با توزیع یکسان (iid) هستند، مدلی را برای شناسایی نقطه تغییر تصادفی پیشنهاد کردند؛ به طوری که هر سری نقطه تغییر خاص خود را دارد. آن‌ها نشان دادند توزیع مشترک نقاط تغییر می‌تواند به طور سازگار برآورد شود. بای [۳] بر وضعیت نقطه تغییر

برای تمام مقاطع در نظر گرفته می‌شود. براساس مطالعات تجربی چو و فریزلیچ [۱۶] چنین رویکردهایی ممکن است منجر به عملکرد پایین‌تر در تشخیص و تعیین نقاط تغییر در تنظیمات با ابعاد بزرگ شوند؛ از این رو این دو پژوهشگر روشی را ارائه کردند که در آن جمع‌های تجمعی در نقاط تغییر به مقطعی محدود می‌شود که در آن‌ها تغییر رخ داده است. چو [۱۷] با ارائه آماره جمع تجمعی دوپل (DC)^۱ رویکرد چو و فریزلیچ را به‌طور قابل‌ملاحظه‌ای ارتقا داد.

آماره جمع تجمعی دوپل با استفاده از ساختار نقطه تغییر مقطعی با بررسی جمع تجمعی از جمع‌های تجمعی مرتب در هر نقطه تغییر حاصل می‌شود؛ یعنی ساختار برآورد نقطه تغییر در هر مقطع، در میان مقاطع نیز برای هر نقطه تغییر احتمالی به‌کار گرفته می‌شود و در این صورت تنها مقطعی که دچار تغییر شده اند در تشخیص نقطه تغییر مشترک شرکت می‌کنند؛ بنابراین نه تنها این اطلاعات در تفسیر نقاط تغییر شناسایی شده مفید است، بلکه می‌تواند نقش مهمی در کارآمدی جمع‌های تجمعی سری‌های با ابعاد بزرگ داشته باشد. چو [۱۷] روش خود را هم در توان آزمون و هم در دقت برآورد با روش‌های ارائه شده ژانگ و همکاران [۱۳]، انیکویا و هارچوی [۱۴]، جیراک [۱۵] و چو و فریزلیچ [۱۶] مقایسه کرد. در جدول ۱، قابلیت‌های کاربردی روش‌های مختلف شناسایی نقطه تغییر در داده‌های پانلی به تفصیل آمده است.

آماره جمع تجمعی و آماره جمع تجمعی دوپل

فرض کنید C_{t_0} عامل جمع تجمعی را نشان می‌دهد؛ به‌طوری‌که $X_{j,t}$ را براساس مدل ۱ در فاصله زمانی $t \in [1, T]$ به‌عنوان ورودی دریافت می‌کند و $\mathbb{Y}_{1,t_0,T}^j$ را برای $t_0 = 1 \dots T-1$ به‌صورت زیر باز می‌گرداند. رابطه ۲

$$\mathbb{Y}_{1,t_0,T}^j = C_{t_0} \left(\left\{ X_{j,t} \right\}_{t=1}^T \right) = \left(\frac{t_0(T-t_0)}{T} \right)^j \left(\frac{1}{t_0} \sum_{t=1}^{t_0} X_{j,t} - \frac{1}{(T-t_0)} \sum_{t=t_0+1}^T X_{j,t} \right) \quad (2)$$

که در آن اندیس j نشان‌دهنده مقطع j ام است و $j \in \{1, \dots, n\}$ همچنین $\gamma \in (0, 1)$.

مجموع داده‌ها را توصیف کند، انتخاب می‌شود. سپس این کاپولا متناسب با زیرمجموعه داده‌ها به‌صورت پویا با اضافه‌کردن داده‌های جدید به داده‌های قبلی در هر زمان به‌روزرسانی می‌شود. در نهایت تغییرات می‌تواند با تجزیه و تحلیل روند پارامترهای متناسب‌شده در هر نقطه زمانی شناسایی شود. چن و هو [۹] برآوردگر نقطه تغییر مشترک را برای میانگین، با پیچیدگی کمتر و دقت بیشتر از روش برآورد کمترین مربعات خطای بای [۳] پیشنهاد کردند که در آن از روش جمع تجمعی برای برآورد نقطه تغییر مشترک استفاده می‌شود. پستوا و پستا [۱۰] آزمون را با استفاده از بوت استرپ برای تغییر مشترک در میانگین واحدهای مقطعی پانل در دوره زمانی ثابت، بررسی کردند که می‌تواند نسبتاً کوچک یا متوسط باشد. همچنین پستوا و پستا [۱۱] برآوردگر نقطه تغییر مشترک را برای میانگین واحدهای مقطعی پانل پیشنهاد کردند. به‌طوری‌که روش آن‌ها برگرفته از روش کمترین مربعات خطا بود. روش پستوا و پستا [۱۱] این ویژگی را دارد که وضعیتی که در آن نقطه تغییر آخرین مشاهده را نشان می‌دهد به این معنی است که هیچ تغییری در میانگین‌های مقاطع رخ نداده است. انوموتو و ناگاتا [۱۲] روش ماهالانوبیس-تاگوچی (YMT) را به کمک استنتاج بی‌ز، برای تشخیص نقطه تغییر در داده‌های پانلی گسترش دادند که BMT^A نام دارد. در این روش، برای تشخیص نقطه تغییر، مقاطع در زمانی معین به‌صورت یک بردار از مشاهدات در نظر گرفته می‌شود. فاصله این بردار با بردار میانگین چند مشاهده زمانی اخیر، با استفاده از فاصله ماهالانوبیس محاسبه می‌شود. افزایش ناگهانی فاصله در زمانی خاص نشان می‌دهد ستون مشاهده‌شده از مقاطع در آن زمان در مقایسه با ستون‌های مشاهده‌شده در چند مشاهده زمانی اخیر، تغییر ناگهانی داشته است، اگر این افزایش ناگهانی از مقدار آستانه فرض شده بیشتر باشد، سیگنال خارج از کنترل نقطه تغییر در داده‌های پانلی را نشان می‌دهد.

برخی آزمون‌های تشخیص نقطه تغییر در داده‌های پانلی، براساس روش جمع تجمعی و برای داده‌هایی با ابعاد بزرگ ارائه شده‌اند که توانایی تشخیص چند نقطه تغییر را دارند. در این مورد می‌توان به ژانگ و همکاران [۱۳]، انیکویا و هارچوی [۱۴] و جیراک [۱۵] اشاره کرد. در روش‌های فوق، مجموع جمع‌های تجمعی در نقطه تغییر

جدول ۱. مقایسه روش‌های شناسایی نقطه تغییر در داده‌های پانلی

توضیحات	روش استفاده‌شده در تشخیص نقطه تغییر	بررسی کارایی در آزمون تشخیص تغییر	بررسی کارایی در دقت برآورد	کارایی روش با وجود هم‌بستگی در مقاطع در مقایسه با یکدیگر	کارایی روش با وجود هم‌بستگی در مشاهدات در طول زمان	تشخیص چند نقطه تغییر	تشخیص نقطه تغییر در ساختار وابستگی	تشخیص نقطه تغییر در واریانس	تشخیص نقطه تغییر در میانگین	قابلیت مرجع
	LSE, QML	*	*				*	*		بای [۳]
برای داده‌هایی با ابعاد کوچک کارایی دارد (برای مثال $n = 20, T = 10$)	CUSUM	*		*				*		هوروات و هوسکوا [۴]
برای داده‌هایی با ابعاد بزرگ کارایی دارد (برای مثال $n = 200, T = 100$)	CUSUM	*		*			*			لی و همکاران [۵]
برای داده‌هایی با ابعاد متوسط کارایی دارد (برای مثال $n = 50, T = 50$)	GMM	*	*	*		*				دی واچتر و تراوالیس [۶]
برای داده‌هایی با ابعاد متوسط کارایی دارد (برای مثال $n = 100, T = 6$)	Copula			*	*	*	*			زو و همکاران [۸]
اگر تعدادی از داده‌های پانلی در مقاطع و زمان‌های معین نباشند، کارایی خود را از دست نمی‌دهند.	CUSUM	*		*				*		چن و هو [۹]
برای داده‌هایی با ابعاد متوسط کارایی دارد (برای مثال $n = 100, T = 10$)	LSE	*		*				*		پستوها و پستا [۱۱]
برای داده‌هایی با ابعاد کوچک کارایی دارد (به‌طور مثال $n = 20, T = 10$)	BMT	*	*	*		*	*	*	*	انوموتو و ناگاتا [۱۲]
یک نمودار کنترل را طراحی می‌کند که کارایی آن در ابعاد کوچک نشان داده شده است. (برای مثال $T = 30, n = 4$)	Double CUSUM	*	*	*	*	*		*		چو [۱۷]
برای داده‌هایی با ابعاد بزرگ کارایی دارد (برای مثال $n = 200, T = 100$)	double CUSUM	*	*	*	*			*		پژوهش حاضر
برای داده‌هایی با ابعاد بزرگ، توان تشخیص بیشتری دارد.	EWMA									

$$\mathbb{X}_{1,t_0,T}^j = C_{t_0} \left(\left\{ \sigma_j^{-1} x_{j,t} \right\}_{t=1}^T \right) = \frac{1}{\sigma_j} \sqrt{\frac{t_0(T-t_0)}{T}} \left(\frac{1}{t_0} \sum_{t=1}^{t_0} x_{j,t} - \frac{1}{(T-t_0)} \sum_{t=t_0+1}^T x_{j,t} \right) \quad (3)$$

که در آن σ_j ، انحراف معیار مشاهدات در طول مقطع زام است که باید برآورد شود (در این مقاله برآورد σ_j با استفاده از روش ارائه‌شده در ملاحظه (۲، ۳) چو [۱۷]

چن و هو [۹] برآوردگر جمع تجمعی را براساس رابطه ۲ و با استفاده از جمع‌آوری جمع‌های تجمعی همه مقاطع، به منظور برآورد نقطه تغییر در داده‌های پانلی تعریف کردند و نشان دادند که مقادیر مختلف γ تا حد معینی بر میزان دقت برآورد تأثیرگذار است. می‌توان رابطه ۲ را به کمک انحراف معیار مشاهدات در طول هر مقطع، به صورت رابطه ۳ تعریف کرد:

$\varphi \in [0, 1]$ است. سپس برای تشخیص نقطه تغییر در فاصله زمانی $[1, T]$ آماره جمع تجمعی دابل به صورت زیر تعریف می‌شود:

$$\mathbb{T}_{1,T}^{\varphi} = \max_{t_0 \in [1, T]} \max_{1 \leq m \leq n} D_m^{\varphi} \left(\left\{ \left| \sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(j)} \right| \right\} \right) \quad (5)$$

بنابراین، برآوردگر نقطه تغییر روی بازه زمانی $[1, T]$ به صورت زیر است:

$$\hat{\eta} = \arg \max_{t_0 \in [1, T]} \max_{1 \leq m \leq n} D_m^{\varphi} \left(\left\{ \left| \sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(j)} \right| \right\} \right) \quad (6)$$

با توجه به خواص ارائه شده از مدل فاکتور پویای عمومی (برای مطالعه مدل فاکتور پویای عمومی (GDFM)^۱) به فورنی و همکاران [۱۹] رجوع کنید.) چو [۱۷] روش بوت استرپ را برای انتخاب معیار آزمون پیشنهاد می‌کند که هم‌بستگی مقطع‌ها و درون‌سری‌ها را در داده‌های با ابعاد بزرگ به‌شمار می‌آورد. این معیار آزمون، زمینه تشخیص چند نقطه تغییر در داده‌هایی با ابعاد بزرگ را با استفاده از الگوریتم دودویی فراهم می‌کند. همچنین الگوریتم تقسیم‌بندی دودویی جمع تجمعی دابل (DCBS)^۱ را برای تقسیم‌بندی داده‌های پانل تشکیل می‌دهد که با معیار آزمون $\pi_{n,T}^{\varphi}$ مجهز شده‌اند؛ بنابراین اگر در هر فاصله زمانی مانند $\{(s, e); 1 \leq s < e < T\}$ ، مقادیر $\pi_{s,e}^{\varphi} > \pi_{n,T}^{\varphi}$ باشد، آنگاه $\hat{\eta}$ برآورد نقطه تغییر است. مقادیر s و e با استفاده از الگوریتم تقسیم‌بندی دودویی (BS)^۲ به شیوه بازگشتی حاصل می‌شود (برای مطالعه الگوریتم تقسیم‌بندی دودویی برای تشخیص چند نقطه تغییر به بخش ۳-۲ چو [۱۷] رجوع کنید).

آماره پیشنهادی جمع تجمعی دابل-میانگین متحرک موزون

اگر $X_{j,t}$ مقدار مشاهده شده براساس مدل ۱ در زمان t و در مقطع j باشد، میانگین متحرک موزون‌نمایی (EWMA)^۳ برای مشاهده زمانی $t \in [1, T]$ ، در مقطع $\{1, \dots, n\}$ ، به صورت رابطه ۷ تعریف می‌شود:

$$Z_{j,t} = \lambda X_{j,t} + (1 - \lambda) Z_{j,t-1} \quad (7)$$

به‌دست آمده است). رابطه ۳ از پژوهش سن و سربوآستاوا [۱۸] ناشی شده است که این رابطه را با روش حداکثر درست‌نمایی به‌دست آورده‌اند. اگر در رابطه ۳، $\sigma_j = 1$ در نظر گرفته شود، رابطه ۲ به‌دست می‌آید. مطالعات عددی نشان می‌دهد این ساده‌سازی منطقی است [۱۳، ۱۸]. هوروات و هوسکووا [۴] و ژانگ و همکاران [۱۳]، آماره‌هایی را براساس رابطه ۳ و با استفاده از جمع‌آوری مجذور جمع‌های تجمعی همه مقاطع، برای تشخیص نقطه تغییر داده‌های پانلی تعریف کردند. جیراک [۱۵] آماره آزمون خود را براساس رابطه ۳ و با استفاده از به‌دست‌آوردن حداکثر نقطه به نقطه روی جمع‌های تجمعی در هر مقطع و هر زمان معرفی کرده است.

روش‌های فوق در استفاده از روش جمع تجمعی، حداکثر نقطه به نقطه یا مجموع (مجذور) جمع‌های تجمعی را در نظر می‌گیرند. مطالعات تجربی چو و فریزلیچ [۱۶] نشان می‌دهد چنین رویکردهایی ممکن است به عملکرد پایین‌تر در تشخیص و تعیین نقاط تغییر با ابعاد بزرگ منجر شوند؛ از این‌رو آن‌ها روشی را ارائه دادند که در آن جمع‌آوری جمع‌های تجمعی در نقاط تغییر به مقاطعی محدود می‌شود که در آن‌ها تغییر رخ داده است.

چو [۱۷] با ارائه آماره جمع تجمعی دابل، رویکرد چو و فریزلیچ [۱۶] را به شکل قابل‌ملاحظه‌ای ارتقا داد. برای به‌دست‌آوردن آماره جمع تجمعی دابل، ابتدا با استفاده از رابطه ۳، مقدار $\sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(j)}$ برای $t_0 = 1 \dots T-1$ و $j = 1 \dots n$ به‌دست می‌آید. درواقع $\sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(j)}$ در رابطه ۳، مقدار جمع تجمعی محاسبه‌شده بر $X_{j,t}$ با $t \in [1, T]$ را برای $t_0 = 1 \dots T-1$ نشان می‌دهد. D_m^{φ} نیز عامل آماره جمع تجمعی دابل است و به صورت زیر تعریف می‌شود:

$$D_m^{\varphi} \left(\left\{ \left| \sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(j)} \right| \right\} \right) = \quad (4)$$

$$\left\{ \frac{m(2n-m)}{2n} \right\}^{\varphi} \left(\frac{1}{m} \sum_{j=1}^m \left| \mathbb{X}_{1,t_0,T}^{(j)} \right| - \frac{1}{2n-m} \sum_{j=m+1}^n \left| \mathbb{X}_{1,t_0,T}^{(j)} \right| \right)$$

که در آن برای $m \in \{1, \dots, n\}$ و $t_0 \in [1, T]$ ، آماره جمع تجمعی دابل، اپراتور D_m^{φ} را به ترتیب برای مقادیر جمع تجمعی، $\left| \sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(1)} \right| \geq \left| \sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(2)} \right| \geq \dots \geq \left| \sum_{j=1}^n \mathbb{X}_{1,t_0,T}^{(n)} \right|$ در هر $t_0 \in [1, T]$ ، به‌عنوان ورودی دریافت می‌کند. همچنین

به طوری که $Z_{j,t}$ بر یک فاصله زمانی $t \in [1, T]$ به عنوان یک ورودی دریافت می شود و $Z_{1,t_0,T}^j$ برای $t_0 = 1 \dots T-1$ به صورت زیر بازمی گردد:

$$Z_{1,t_0,T}^j = CE_{t_0} \left(\left\{ \sigma_j^{-1} Z_{j,t} \right\}_{t=1}^T \right) = \frac{1}{\sigma_j} \sqrt{\frac{t_0(T-t_0)}{T}} \left(\frac{1}{t_0} \sum_{t=1}^{t_0} Z_{j,t} - \frac{1}{(T-t_0)} \sum_{t=t_0+1}^T Z_{j,t} \right) \quad (9)$$

سپس برای تعریف آماره ترکیبی جمع تجمعی دوپل- میانگین متحرک موزون (DCE^{۱۴})، عامل D_m^Φ به صورت رابطه ۱۰ تعریف می شود:

$$D_m^\Phi \left(\left\{ \left| Z_{1,t_0,T}^{(j)} \right| \right\}_{j=1}^n \right) = \left\{ \frac{m(2n-m)}{2n} \right\}^\Phi \left(\frac{1}{m} \sum_{j=1}^m \left| Z_{1,t_0,T}^{(j)} \right| - \frac{1}{2n-m} \sum_{j=m+1}^n \left| Z_{1,t_0,T}^{(j)} \right| \right) \quad (10)$$

که در آن برای $m \in \{1, \dots, n\}$ و $t_0 \in [1, T]$ آماره جمع تجمعی دوپل- میانگین متحرک موزون، اپراتور D_m^Φ را به ترتیب برای مقادیر $\left| Z_{1,t_0,T}^{(1)} \right| \geq \left| Z_{1,t_0,T}^{(2)} \right| \geq \dots \geq \left| Z_{1,t_0,T}^{(n)} \right|$ در هر $t_0 \in [1, T]$ ، به عنوان ورودی دریافت می کند. سپس برای تشخیص نقطه تغییر در فاصله زمانی $[1, T]$ ، آماره جمع تجمعی دوپل- میانگین متحرک موزون به صورت زیر تعریف می شود:

$$\mathbb{T}_{1,T}^\Phi = \max_{t_0 \in [1, T]} \max_{1 \leq m \leq n} D_m^\Phi \left(\left\{ \left| Z_{1,t_0,T}^{(j)} \right| \right\}_{j=1}^n \right) \quad (11)$$

الگوریتم روش پیشنهادی جمع تجمعی دوپل- میانگین

متحرک موزون

به طور کلی روش پیشنهادی این مقاله از الگوریتم زیر پیروی می کند.

گام اول: اگر $X_{j,t}$ مقدار مشاهده شده بر اساس مدل ۱ در زمان t و در مقطع j باشد، مقادیر میانگین متحرک موزون نمایی $Z_{j,t}$ ، بر اساس رابطه ۸ حاصل می شود. گام دوم: عامل جمع تجمعی را بر مقادیر حاصل از گام اول به ازای هر $t_0 = 1 \dots T-1$ و $j = 1 \dots n$ اعمال می کنیم؛ بنابراین بر اساس رابطه ۹ مقادیر $Z_{1,t_0,T}^j$ حاصل می شود.

در رابطه ۷، λ ضریب هموارسازی و دارای مقدار ثابتی بین صفر و ۱ است. $Z_{j,0}$ نیز مقدار میانگین اطلاعات اولیه $\left(\sum_{t=1}^d X_{j,t} / d \right)$ است. در داده هایی با ابعاد بزرگ هنگامی که به دنبال نقطه تغییر در بازه زمانی معین $\{1, T\}$ هستیم، فاصله کوتاه در نزدیک نقطه ابتدایی و انتهایی $\{1, T\}$ نقطه تغییر را شامل نمی شوند؛ زیرا این نقاط به شدت از نقاط قبل خود تأثیر می پذیرند؛ بنابراین تجزیه و تحلیل نقاط تغییر در آن ها باید شامل نقاط زمانی قبل یا بعد از بازه زمانی تعیین شده باشد. چو اندازه این فاصله را با $d = \lceil c \log^2 T \rceil$ تعیین کرده است که در آن $c > 0$ است؛ از این رو جست و جوی نقاط تغییر تنها در $\mathcal{L}_{1,T} \setminus [1, T]$ صورت می گیرد که $\mathcal{L}_{1,T} = [1, 1+d] \cup [T-d, T]$ است؛ بنابراین اگر به جای $Z_{j,t-1}$ معادل آن جایگزین شود، رابطه ۸ به دست می آید:

$$Z_{j,t} = \lambda \sum_{l=0}^{t-1} (1-\lambda)^l X_{j,(t-l)} + \frac{1}{d} (1-\lambda)^t \sum_{t=1}^d X_{j,t} \quad (8)$$

اگر در هر مقطع مشاهدات $X_{j,t}$ روی فاصله زمانی $t \in [1, T]$ توزیعی نرمال با میانگین μ و واریانس σ_j^2 داشته باشند، برای سری های زمانی بزرگ، $Z_{j,t}$ توزیعی نرمال با میانگین μ و واریانس حدی $\left(\frac{\lambda}{2-\lambda} \right) \sigma_j^2$ دارد (برای اثبات به مرجع مونگومری [۲۰] رجوع کنید). اکنون فرض کنید در مدل داده های پانلی ۱، میانگین مقطع j ام از زمان t_0 به بعد، از μ_j به $\mu_j + \delta_j$ تغییر می کند؛ بنابراین اندازه تغییر در میانگین بر حسب انحراف معیار، $\frac{\delta_j}{\sigma_j}$

است. از آنجا که $\frac{\delta_j}{\sigma_j} \leq \frac{\delta_j}{\sigma_j} \sqrt{\frac{2-\lambda}{\lambda}}$ است، در حالی که مقدار آستانه آزمون بر حسب فرض صفر عدم تغییر در مدل داده های پانلی ۱ به دست آمده است، کم شدن پراکندگی $Z_{j,t}$ نسبت به $X_{j,t}$ بر فاصله زمانی $t \in [1, T]$ این انتظار را به وجود می آورد که توان آزمون برای تشخیص نقطه تغییر در میانگین با استفاده از مقادیر $Z_{j,t}$ از $X_{j,t}$ بیشتر خواهد شد.

اگر مقادیر متغیر $Z_{j,t}$ در رابطه ۸ جایگزین متغیر $X_{j,t}$ در رابطه ۳ شوند، CE_{t_0} ، عامل ترکیب جمع تجمعی و میانگین متحرک موزون نمایی به صورت رابطه ۹ است؛

پانلی با ۲۵۰ مقطع و ۱۰۰ مشاهده زمانی در هر مقطع را در نظر بگیرید که در آن m مقطع که به صورت تصادفی انتخاب شده‌اند، دارای یک نقطه تغییر در زمان η_1 در میانگین خود هستند. اندازه تغییر برای هر مقطع از تابع یکنواخت $U(0.75, 1.25)$ با ضریب δ_1 پیروی می‌کند که در آن $\delta_1 \in \{0.05, 0.075, 0.1\}$ است. در همه آماره‌ها $\varphi=0.5$ است. توجه داشته باشید در مشاهداتی با ابعاد بالا که در آن میان داده‌ها هم‌بستگی وجود دارد، برآورد انحراف معیار در هر بار تولید داده با اریبی‌های مختلف همراه خواهد بود؛ بنابراین اگر اندازه تغییر نسبتی از انحراف معیار برآورد شده باشد، نتایج حاصل از هر بار شبیه‌سازی متفاوت خواهد بود. برای کاهش این تفاوت چو [۱۷] به پیروی از جیراک [۱۵] اندازه تغییر را بدون برآورد انحراف معیار تولید می‌کند. درواقع اندازه‌های $\{0.1, 0.075, 0.05\}$ تقریباً با $\{0.75\sigma, 0.75\sigma, 0.5\sigma\}$ معادل هستند. تعداد تکرار شبیه‌سازی و تعداد تکرار بازنمونه‌گیری بوت استرپ ۱۰۰۰ است. همچنین شاخص اندازه‌گیری دقت برآورد با تعداد تکرارهای شبیه‌سازی برابر است که در شرایط $|\hat{\eta}_1 - \eta_1| < \log T$ صدق می‌کند که در آن η_1 نقطه تغییر صحیح مشترک و $\hat{\eta}_1$ برآورد آن است.

جدول ۲ و ۳ توان آزمون با $\alpha=0.05$ و شاخص دقت شناسایی مکان نقطه تغییر، برای آماره جمع تجمعی دوبل و آماره پیشنهادی جمع تجمعی دوبل-میانگین متحرک موزون با $0.1, 0.075, 0.07, 0.065, 0.06$ به ترتیب برای $\varrho=0.1$ و $\varrho=0.5$ را نشان می‌دهد. در آماره جمع تجمعی دوبل-میانگین متحرک موزون، تعداد مشاهدات اولیه $d=5$ در نظر گرفته شده است. همچنین، معیار آزمون در هر دو روش یکسان است و براساس روش بوت استرپ چو [۱۷] بر داده‌های پانلی مدل ۱ به دست آمده است. باید توجه داشت که مقادیر کوچک λ به کاهش دقت برآورد منجر خواهد شد. شاید این کاهش دقت به این دلیل باشد که مقدار مشاهده زمانی پس از نقطه تغییر وابستگی بسیاری به مشاهده زمانی قبل از نقطه تغییر دارد.

گام سوم: برای هر نقطه تغییر احتمالی $t_0=1 \dots T-1$ ، مقادیر قدر مطلق از $Z_{1,t_0,T}^j$ به ازای $n=1 \dots j$ به صورت نزولی مرتب می‌شود؛ بنابراین مقادیر $|Z_{1,t_0,T}^{(1)}| \geq |Z_{1,t_0,T}^{(2)}| \geq \dots \geq |Z_{1,t_0,T}^{(n)}|$ در هر $t_0 \in [1, T)$ حاصل خواهد شد.

گام چهارم: عامل جمع تجمعی بر مقادیر حاصل از گام سوم، به ازای هر $m \in \{1, \dots, n\}$ و $t_0 \in [1, T)$ اعمال می‌شود؛ بنابراین براساس رابطه ۱۰ مقادیر D_m^φ حاصل می‌شود.

گام پنجم: برای تشخیص نقطه تغییر در فاصله زمانی $[1, T]$ ، آماره جمع تجمعی دوبل-میانگین متحرک موزون، به صورت رابطه ۱۱ تعریف می‌شود.

گام ششم: معیار آزمون براساس روش بوت استرپ چو [۱۷] به نام روش GDFM_Boot به دست می‌آید. این معیار در کتابخانه نرم افزار R، با عنوان پکیج Hdbinseg قابل دسترسی است.

گام هفتم: اگر معیار آزمون حاصل از گام ششم را با $\pi_{n,T}^\varphi$ نشان دهیم و در فاصله زمانی $[1, T]$ ، $\pi_{n,T}^\varphi > \pi_{n,T}^\varphi$ باشد، آنگاه $\hat{\eta}$ برآورد نقطه تغییر است و به صورت زیر تعریف می‌شود:

$$\hat{\eta} = \arg \max_{t_0 \in [1, T)} \max_{1 \leq m \leq n} D_m^\varphi \left(\left\{ |Z_{1,t_0,T}^{(j)}| \right\}_{j=1}^n \right) \quad (12)$$

مطالعات شبیه‌سازی برای تشخیص نقطه تغییر

داده‌های استفاده شده در این مطالعه، براساس داده‌های شبیه‌سازی شده چو [۱۷] است که در آن داده‌ها از مدل خودهم‌بسته میانگین متحرک $(ARMA(2, 2))$ پیروی می‌کنند؛ به طوری که:

$$\varepsilon_{j,t} = 0.2\varepsilon_{j,t-1} - 0.3\varepsilon_{j,t-2} + u_{j,t} + 0.2u_{j,t-1} \quad (13)$$

که در آن:

$$u_{j,t} = \sum_{i=0}^{99} \varrho_i v_{j-i,t} \quad (14)$$

همچنین $\varrho_i = \varrho(i+1)^{-1}$ ، $\sigma_v = 0.1\varrho^{-1}$ ، $v_{j,t} \sim_{iid} N(0, \sigma_v^2)$ و $\varrho \in \{0.1, 0.5\}$ است. در اینجا، ϱ ضریب تعدیل پراکندگی داده‌هاست.

جدول ۲. توان آزمون و اندازه شاخص دقت برای روش های DC و DCE با λ های مختلف ($q=0.2$)

δ_i	m	η_1	Location accuracy (1/1000)					Power Test					DC	
			DCE	DCE	DCE	DCE	DCE	DC	DCE	DCE	DCE	DCE		DCE
			$\lambda=0.6$	$\lambda=0.65$	$\lambda=0.7$	$\lambda=0.75$	$\lambda=0.8$	$\lambda=0.6$	$\lambda=0.65$	$\lambda=0.7$	$\lambda=0.75$	$\lambda=0.8$		
0.05	\sqrt{n}	0.1T	0	0	0	0	0	0	0.001	0.001	0	0.001	0.001	0
		0.5T	2	0	0	0	0	0	0.006	0.002	0.003	0.003	0.001	0.001
		0.1T	6	4	5	2	2	0	0.014	0.011	0.014	0.005	0.007	0.003
	0.4n	0.5T	359	327	298	282	286	217	0.660	0.600	0.548	0.488	0.484	0.396
		0.1T	0	0	0	0	0	0	0	0.001	0.001	0.004	0.001	0
		0.5T	5	8	6	2	3	1	0.033	0.030	0.015	0.013	0.009	0.005
0.075	\sqrt{n}	0.1T	0	0	0	0	0	0	0	0.001	0.001	0.004	0.001	0
		0.5T	5	8	6	2	3	1	0.033	0.030	0.015	0.013	0.009	0.005
		0.1T	56	52	43	29	33	25	0.80	0.70	0.67	0.40	0.44	0.37
	0.4n	0.5T	814	804	796	810	816	790	1	1	0.999	1	0.999	0.999
		0.1T	0	0	0	1	0	0	0.002	0.007	0.002	0.003	0.002	0.005
		0.5T	22	10	9	7	4	5	0.50	0.29	0.20	0.15	0.07	0.10
0.1	\sqrt{n}	0.1T	516	495	438	417	396	345	0.629	0.566	0.520	0.495	0.460	0.390
		0.5T	902	911	910	942	931	929	1	1	1	1	1	1
		0.1T	0	0	0	0	0	0	0.002	0.007	0.002	0.003	0.002	0.005
	0.4n	0.5T	22	10	9	7	4	5	0.50	0.29	0.20	0.15	0.07	0.10
		0.1T	516	495	438	417	396	345	0.629	0.566	0.520	0.495	0.460	0.390
		0.5T	902	911	910	942	931	929	1	1	1	1	1	1

جدول ۳. توان آزمون و اندازه شاخص دقت برای روش های DC و DCE با λ های مختلف ($q=0.5$)

δ_i	m	η_1	Location Accuracy (1/1000)					Power Test					DC	
			DCE	DCE	DCE	DCE	DCE	DC	DCE	DCE	DCE	DCE		DCE
			$\lambda=0.6$	$\lambda=0.65$	$\lambda=0.7$	$\lambda=0.75$	$\lambda=0.8$	$\lambda=0.6$	$\lambda=0.65$	$\lambda=0.7$	$\lambda=0.75$	$\lambda=0.8$		
0.05	\sqrt{n}	0.1T	0	0	0	0	0	0	0.002	0	0	0	0	0
		0.5T	0	0	1	0	0	0	0.005	0.002	0.003	0.002	0.001	0
		0.1T	19	17	9	8	14	13	0.065	0.053	0.035	0.034	0.036	0.035
	0.4n	0.5T	406	385	327	322	333	271	0.798	0.722	0.626	0.604	0.607	0.496
		0.1T	0	0	0	0	0	0	0.001	0.001	0	0	0.001	0.001
		0.5T	3	3	0	1	2	2	0.012	0.008	0.003	0.006	0.009	0.004
0.075	\sqrt{n}	0.1T	69	55	52	33	43	36	0.094	0.073	0.068	0.053	0.060	0.042
		0.5T	794	801	819	817	823	817	1	1	1	1	1	1
		0.1T	0	0	0	0	0	0	0.003	0.001	0	0	0	0
	0.4n	0.5T	31	19	14	4	9	1	0.059	0.045	0.030	0.015	0.018	0.010
		0.1T	753	771	789	762	764	649	0.926	0.920	0.915	0.892	0.895	0.829
		0.5T	903	909	906	926	922	932	1	1	1	1	1	1

حالت ۱: هنگامی که به طور متوسط ۴۰ درصد از مقاطع $(n/4)$ از تغییر پله‌ای به اندازه ۰/۱ یا ۰/۰۷۵ در زمان $0.5T$ تأثیر می‌گیرند، در حالتی که ضریب تعدیل انحراف معیار داده‌ها $q=0.2$ است، همچنین زمانی که ضریب تعدیل انحراف معیار داده‌ها $q=0.5$ است، توان آزمون برای آماره‌های مختلف تقریباً صد درصد است. در این موارد توان تشخیص تغییر وجود دارد و شاخص دقت برآورد نقطه تغییر نیز مقادیر نزدیک به هم و استواری را نشان می‌دهد.

حالت ۲: هنگامی که به طور متوسط ۴۰ درصد از مقاطع $(n/4)$ تحت تأثیر یک تغییر پله‌ای به اندازه ۰/۱ یا ۰/۰۷۵ در زمان $0.1T$ قرار می‌گیرد، در حالتی که $q=0.2$ و $q=0.5$ است، بهبود توان تشخیص نقطه تغییر با استفاده از آماره پیشنهادی جمع تجمعی دوپل-میانگین متحرک موزون در مقایسه با آماره جمع تجمعی دوپل مشهود است؛ به طوری که در $\lambda=0.6$ بهترین نتیجه حاصل می‌شود.

در جدول ۲ و ۳، DC مخفف Double CUSUM و نشان دهنده آماره جمع تجمعی دوپل است. همچنین مخفف Double CUSUM_EWMA و نشان دهنده آماره جمع تجمعی دوپل-میانگین متحرک موزون و λ ضریب هموارسازی به کار گرفته شده در آماره است. در جدول ۲ و ۳، Power Test نشان دهنده توان آزمون در تشخیص وجود نقطه تغییر با حساسیت یک‌هزارم است و Location Accuracy مقدار شاخص دقت برآورد را نسبت به هزار بار تکرار شبیه‌سازی نشان می‌دهد. در این مقاله از نرم‌افزار R ورژن ۳/۵/۱ و پکیج Hdbinseg برای محاسبات استفاده شد. با توجه به اینکه چو [۱۷] عملکرد DC را با دیگر روش‌های ادبیات مقایسه کرده و برتری مدل DC را از دیگر مدل‌ها نشان داده است، این مقاله، مدل پیشنهادی خود را تنها با DC مقایسه می‌کند. نتایج جدول ۲ و ۳ در پنج حالت زیر آمده است:

شناسایی کرده که به ۶ ژانویه ۲۰۱۶ مربوط است. در جدول ۴، شرکت‌هایی که بیشترین پرش را در نقطه تغییر دارند، به ترتیب آمده‌اند.

	[,1]	[,2]	[,3]
level_index	1.000	2.00000	3.00000
child_index	1.000	2.00000	4.00000
s	1.000	18.00000	127.00000
b	17.000	126.00000	221.00000
e	252.000	252.00000	252.00000
test_stat	262.593	34.29913	24.19499

```
$secp
[1] 17 126 221
```

```
$thr
99%
17.55767
```

شکل ۱. نتایج اجرای روش پیشنهادی با استفاده از الگوریتم تقسیم‌بندی دودویی در داده‌های مالی

جدول ۴. شرکت‌های دارای نقطه تغییر مشترک در ۷ ژانویه ۲۰۱۶

شماره	نماد شرکت	شماره	نماد شرکت	شماره	نماد شرکت
۱	MS	۱۳	FDX	۲۵	WFC
۲	C	۱۴	PFE	۲۶	BRK.B
۳	AXP	۱۵	WBA	۲۷	VZ
۴	HAL	۱۶	GD	۲۸	CSCO
۵	GS	۱۷	T	۲۹	JPM
۶	GILD	۱۸	CAT	۳۰	AIG
۷	COF	۱۹	BAC	۳۱	BIIB
۸	MET	۲۰	IBM	۳۲	USB
۹	F	۲۱	BK	۳۳	BA
۱۰	NKE	۲۲	MDLZ	۳۴	MA
۱۱	AAPL	۲۳	ABT		
۱۲	COP	۲۴	SO		

نتیجه‌گیری

در این مطالعه، مسئله تشخیص نقطه تغییر در میانگین داده‌های پانل با استفاده از ترکیب روش میانگین متحرک موزون‌نمایی با روش جمع تجمعی دوپل، پیشنهاد و تجزیه و تحلیل شد. روش جمع تجمعی دوپل با توجه به دقت بسیاری که در برآورد نقطه تغییر دارد، در تشخیص این نقطه به کمک آزمون بوت استرپ توان کمی در تغییرات کوچک دارد؛ بنابراین با هدف بالابردن توان تشخیص تغییر در میانگین داده‌های پانلی با استفاده از این آزمون، پژوهش حاضر آماره ترکیبی جمع تجمعی دوپل-میانگین متحرک موزون را پیشنهاد می‌دهد. براساس مطالعات شبیه‌سازی، این رویکرد موجب می‌شود دقت برآورد نقطه تغییر کیفیت خود را حفظ کند و توان تشخیص تغییر از دیگر روش‌ها بهبود یابد.

حالت ۳: هنگامی که به طور متوسط ۴۰ درصد از مقاطع ($n/4$) از تغییر پله‌ای به اندازه 0.05 در زمان $0.5T$ تأثیر می‌گیرند، بهبود در توان تشخیص نقطه تغییر در هر دو حالت $\rho=0.2$ و $\rho=0.5$ با استفاده از آماره پیشنهادی مشاهده می‌شود. در صورتی که نقطه تغییر در زمان $0.1T$ باشد، نتایج با استفاده از آماره پیشنهادی در λ های کوچک بهبود می‌یابد.

حالت ۴: هنگامی که در تعداد کمی از مقاطع (\sqrt{n}) تغییر پله‌ای به اندازه 0.1 یا 0.075 در زمان $0.5T$ رخ می‌دهد، توان تشخیص نقطه تغییر با استفاده از آماره پیشنهادی در λ های کوچک بهبود می‌یابد.

حالت ۵: هنگامی که در تعداد کمی از مقاطع (\sqrt{n}) تغییر پله‌ای به اندازه 0.1 ، 0.075 یا 0.05 در زمان $0.1T$ ، یا تغییر پله‌ای 0.05 در زمان $0.5T$ رخ می‌دهد، احتمال تشخیص یک تغییر غیر تصادفی در آماره های مختلف تقریباً صفر است.

موردکاوی

برای ارزیابی روش پیشنهادی این پژوهش، گزارش های پایان هر روز قیمت‌های سهام مدنظر قرار می‌گیرد که چو [۱۷] در فاصله زمانی ۲۴ فوریه ۲۰۱۵ تا ۲۳ فوریه ۲۰۱۶ برای ارزیابی مدل پیشنهادی خود استفاده کرده است. باید توجه داشت داده‌های فوق به قیمت‌های سهام ۱۰۰ شرکت برتر در بازار بورس ایالات‌متحده آمریکا مربوط است که با شاخص S&P۱۰۰ ارزیابی می‌شوند. فهرست مؤلفه‌های شاخص S&P۱۰۰ برای دوره زمانی مورد نظر از آدرس اینترنتی <https://nemozny.github.io/dataset> قابل دسترسی است. چو [۱۷] در بررسی خود، به آخرین نقطه تغییر توجه کرد. در این پژوهش، با استفاده از آماره پیشنهادی جمع تجمعی دوپل-میانگین متحرک موزون و با $\lambda=0.6$ (به دلیل داشتن توان بالاتر در ارزیابی شبیه‌سازی) آخرین نقطه تغییر در قیمت سهام شرکت‌های برتر ایالات‌متحده در بازه تعریف‌شده بالا شناسایی شد. شکل ۱ نتایج روش پیشنهادی را که در نرم‌افزار R گزارش شده است نشان می‌دهد. همان‌طور که مشاهده می‌شود، آخرین نقطه تغییر، زمان ۲۲۱ و مربوط به ۷ ژانویه ۲۰۱۶ است. چو در گزارش خود، نقطه تغییر را در زمان ۲۲۰

منابع

1. Joseph, L., and Wolfson, D. B., (1992). "Estimation in Multi-Path Change-Point Problems", *Communications in Statistics Theory and Methods*, Vol. 21, No. 4, PP. 897-913.
2. Joseph, L., and Wolfson, D. B., (1993). "Maximum Likelihood Estimation in the Multi-Path Change Point Problem", *Annals of the Institute of Statistical Mathematics*, Vol. 45, No. 3, PP. 511-530.
3. Bai, J., (2010). "Common Breaks in Means and Variances for Panel Data", *Journal of Econometrics*, Vol. 157, No. 1, PP. 78-92.
4. Horváth, L., and Hušková, M., (2012). "Change-Point Detection in Panel Data", *Time Series Analysis*, Vol. 33, No. 4, PP. 631-648.
5. Li, F., Tian, Z., Xiao, Y., and Chen, Z., (2015). "Variance Change-Point Detection in Panel Data Models", *Review of Economics Letters*, Vol. 126, No. 1, PP. 140-143.
6. De Wachter, S., and Tzavalis, E., (2012). "Detection of Structural Breaks in Linear Dynamic Panel Data Models", *Computational Statistics and Data Analysis*, Vol. 56, No. 11, PP. 3020-3034.
7. Arellano, M., and Bond, S., (1991). "Some Tests of Specification for Panel Data: Monte Carlo Evidence and An Application to Employment Equations", *Economic Studies*, Vol. 58, No. 2, PP. 277-297.
8. Zhu, X., Li, Y., Liang, C., Chen, J., and Wu, D., (2013). "Copula Based Change Point Detection for Financial Contagion in Chinese Banking", *Information Technology and Quantitative Management (ITQM)*, Vol. 17, No. 1, PP. 619-626.
9. Chen, Z., and Hu, Y., (2015). "Cumulative Sum Estimator for Change-Point in Panel Data", *Statistical Papers*, Vol. 58, No. 3, PP. 707-728.
10. Peštová, B., and Pešta, M., (2015). "Testing Structural Changes in Panel Data with Small Fixed Panel Size and Bootstrap", *Metrika*, Vol. 78, No. 6, PP. 665-689.
11. Peštová, B., and Pešta, M., (2017). "Change Point Estimation in Panel Data Without Boundary Issue", *Risks*, Vol. 5, No. 1, PP. 7.
12. Enomoto, T., and Nagata, Y., (2016). "Detection of Change Points in Panel Data Based on Bayesian MT Method", *Total Quality Science*, Vol. 2, No. 1, PP. 36-47.
13. Zhang, N. R., Siegmund, D. O., Ji, H., and Li, J. Z., (2010). "Detecting Simultaneous Change Points in Multiple Sequences", *Biometrika*, Vol. 97, No. 3, PP. 631-645.
14. Enikeeva, F., and Harchaoui, Z., (2014). *High-Dimensional Change-Point Detection with Sparse Alternatives*, Arxiv Preprint, Arxiv: 1312, 1900.
15. Jirak, M., (2015). "Uniform Change Point Tests in High Dimension", *Annals of Statistics*, Vol. 43, No. 6, PP. 2451-2483.
16. Cho, H., and Fryzlewicz, P., (2015). "Multiple-Change-Point Detection for High Dimensional Time Series Via Sparsified Binary Segmentation", *Journal of the Royal Statistical Society: Series B*, Vol. 77, No. 2, PP. 475-507.
17. Cho, H., (2016). "Change-Point Detection in Panel Data Via Double CUSUM Statistic", *Electronic Journal of Statistics*, Vol. 10, No. 2, PP. 2000-2038.
18. Sen, A., and Srivastava, M. S., (1975). "On Tests for Detecting a Change in Mean", *Annals of Statistics*, Vol. 3, No. 1, PP. 98-108.
19. Forni, M., Hallin, M., Lippi, M., and Reichlin, L., (2000). "The Generalized Dynamic Factor Model: Identification and Estimation", *The Review of Economics and Statistics*, Vol. 82, No. 4, 540-554.
20. Montgomery, D. C., (2007). *Introduction to Statistical Quality Control: John Wiley and Sons*.

واژه‌های انگلیسی به ترتیب استفاده در متن

1. Independent and Identically Distributed
2. Least Squares Estimation
3. Quasi-Maximum Likelihood
4. Cumulative Sum
5. Generalized Method of Moments
6. Copula
7. Mahalanobis-Taguchi
8. Bayesian Mahalanobis-Taguchi
9. Double CUSUM
10. Generalized Dynamic-Factor Model

11. Double CUSUM and Binary Segmentation
 12. Binary Segmentation
 13. Exponentially Weighted Moving Average
 14. Double CUSUM_EWMA
-

