Bank i Kredyt 57(4), 2026, 421-436
DOI: 10.5604/01.3001.0055.8608

BANK I KREDYT
BANK & CREDIT

Wpływ mediów na rynki o wysokiej zmienności: ryzyko dla inwestorów na przykładzie bitcoina

Dmitry Parfenovich*

Nadesłany: 7 kwietnia 2026 r. Zaakceptowany: 10 czerwca 2026 r.

Jak cytować: Parfenovich D. (2026), Wpływ mediów na rynki o wysokiej zmienności: ryzyko dla inwestorów na przykładzie bitcoina, *Bank i Kredyt,* 57(4), 421–436, DOI: 10.5604/01.3001.0055.8608.

Streszczenie

W artykule przeanalizowano rolę presji medialnej jako źródła ryzyka na rynku bitcoina z wykorzystaniem autorskiego Indeksu Medialnej Presji Bitcoina (BMPI) skonstruowanego na podstawie danych GDELT GKG 2.0. Badanie obejmuje 3800 obserwacji dziennych z lat 2015–2026. Wyniki wskazują, że aktywność medialna poprzedza wzrost skali anomalii cenowych oraz epizody podwyższonej zmienności. Testy przyczynowości Grangera potwierdzają istnienie kanału ryzyka informacyjnego, natomiast analiza reżimowa wskazuje na zróżnicowanie efektów pomiędzy fazami rynku. Uzyskane rezultaty sugerują, że BMPI może stanowić użyteczne narzędzie wspomagające ocenę ryzyka inwestycyjnego na rynkach kryptowalut.

Słowa kluczowe: bitcoin, BMPI, presja medialna, ryzyko spekulacyjne, ochrona inwestorów

JEL: G14, G15, C58, D82, G28

* Polsko-Japońska Akademia Technik Komputerowych (PJATK); e-mail: parfendima84@gmail.com.

1. Wprowadzenie

Rynki kryptowalut są przykładem aktywów o bardzo wysokiej zmienności i spekulacyjnym charakterze. W przeciwieństwie do tradycyjnych rynków w znacznie mniejszym stopniu opierają się na klasycznych fundamentach ekonomicznych, takich jak zyski, dywidendy czy przepływy pieniężne. Rynek bitcoina, jako najważniejszy z nich, silnie reaguje na informacje medialne i uwagę inwestorów. W praktyce oznacza to, że intensywność przekazów medialnych może powodować zwiększanie zmienności rynku i sprzyjać epizodom spekulacyjnym – często ze stratą dla inwestorów indywidualnych, którzy reagują z opóźnieniem.

W artykule odpowiadamy na pytanie, czy presja medialna może być traktowana jako mierzalne źródło ryzyka na rynku bitcoina. Ma to znaczenie zarówno dla teorii efektywności rynku, jak i dla ochrony inwestorów oraz dla działań regulacyjnych. Rynek kryptowalut stanowi tu skrajny przypadek, który pozwala lepiej zrozumieć podobne mechanizmy obecne także na innych rynkach.

W badaniu wykorzystano autorski Indeks Medialnej Presji Bitcoina (BMPI), opracowany na podstawie danych GDELT GKG 2.0 dla 3800 dni z lat 2015–2026. Indeks ten opiera się wyłącznie na danych medialnych, co pozwala wyodrębnić wpływ informacji jako czynnika ryzyka. Sprawdzono, czy wzrost aktywności medialnej poprzedza anomalne ruchy cen, oraz zidentyfikowano okresy podwyższonego ryzyka dla inwestorów. Sprawdzono również, czy znaczenie tego zjawiska zależy od fazy rynku.

W artykule poruszono cztery główne zagadnienia. Po pierwsze, pokazano, że presja medialna może być mierzalnym źródłem ryzyka. Po drugie, wskazano, że jej wpływ zależy od fazy rynku i jest silniejszy w okresach wzrostów. Po trzecie, zidentyfikowano konkretne epizody wysokiego ryzyka związane z nasileniem informacji medialnych. Po czwarte, omówiono znaczenie tych wyników dla ochrony inwestorów oraz możliwych działań regulacyjnych.

2. Przegląd literatury

2.1. Media, informacja i spekulacja na rynkach finansowych

Związek między aktywnością medialną a dynamiką cen ma bogatą tradycję badawczą w finansach empirycznych. Negatywny wydźwięk przekazów medialnych może poprzedzać spadki cen aktywów, co wykazał Tetlock (2007). Z kolei Fang i Peress (2009) stwierdzili, że spółki rzadko opisywane w mediach osiągają premie związane z niższą płynnością i ograniczonym zainteresowaniem inwestorów. Badania Da, Engelberga i Gao (2015) wskazują natomiast, że efekty uwagi inwestorów, mierzone wyszukiwaniem informacji, są istotnie powiązane z przyszłymi stopami zwrotu akcji. Wyniki te sugerują, że kanał informacyjny może oddziaływać szybciej niż tradycyjne mechanizmy przetwarzania informacji przez rynek.

Na rynkach kryptowalut efekty te są wzmocnione ze względu na brak fundamentalnych punktów odniesienia. Bollen, Mao i Zeng (2011) wykazali, że nastroje wyrażane w mediach społecznościowych mogą mieć wartość predykcyjną względem przyszłych zmian na rynkach finansowych, z wyprzedzeniem 2–6 dni. Kristoufek (2013) zidentyfikował dwukierunkowy związek między aktywnością w wyszukiwarkach a cenami bitcoina. Ciaian, Rajcaniova i Kancs (2016) udokumentowali z kolei, że ceny bitcoina wykazują własności bliskie efektywności słabej, ale z licznymi anomaliami wynikającymi z napływu informacji.

2.2. Media a epizody spekulacyjne na rynku kryptowalut

Szczególnie istotnym zjawiskiem na rynku kryptowalut są epizody o charakterze spekulacyjnym, w tym zdarzenia przypominające schematy *pump-and-dump*. W takich sytuacjach gwałtowny wzrost zainteresowania medialnego może prowadzić do napływu inwestorów indywidualnych oraz krótkookresowych odchyleń cen od wartości ekonomicznej. Hamrick i in. (2021) wskazują, że epizody tego typu często są poprzedzane przez nietypowe wzrosty aktywności informacyjnej, natomiast inwestorzy wchodzący na rynek w końcowej fazie takich zjawisk ponoszą relatywnie wysokie straty. Podobne wzorce na rynku kryptowalut zidentyfikowali Li, Shin i Wang (2021), dokumentując sekwencję obejmującą gwałtowny wzrost zainteresowania, szczyt cenowy oraz następującą po nim korektę.

Zastosowania GDELT w badaniach finansowych pozostają ograniczone, szczególnie w odniesieniu do rynku kryptowalut. Elshendy i in. (2018) pokazali, że dane GDELT mogą być wykorzystywane do ilościowego pomiaru globalnego środowiska informacyjnego i wspierać analizę rynków surowcowych. W odniesieniu do kryptowalut nadal istnieje jednak luka badawcza dotycząca możliwości wykorzystania globalnych danych medialnych do oceny ryzyka informacyjnego i identyfikacji okresów podwyższonej niestabilności rynku. Phillips i Gorse (2018) wykazali ponadto, że różne reżimy nastrojów medialnych wiążą się z odmienną dynamiką cen bitcoina, co stanowi dodatkowe uzasadnienie podejścia zastosowanego w niniejszym badaniu.

2.3. Efektywność informacyjna a ryzyko inwestora

Z perspektywy hipotezy efektywności rynku (Fama 1970) ceny aktywów powinny szybko odzwierciedlać publicznie dostępne informacje. Jeżeli jednak aktywność medialna wykazuje statystycznie istotny związek z późniejszym występowaniem anomalii cenowych, może to wskazywać na ograniczenia procesu przetwarzania informacji przez uczestników rynku. W takich warunkach inwestorzy dysponujący lepszym dostępem do informacji lub większą zdolnością jej interpretacji mogą uzyskiwać przewagę nad inwestorami reagującymi z opóźnieniem.

Garcia i in. (2014) wykazali, że nastroje wyrażane w mediach społecznościowych są powiązane z dynamiką rynku bitcoina, co sugeruje istotną rolę kanałów informacyjnych w kształtowaniu zachowań inwestorów. W literaturze z dziedziny finansów behawioralnych podkreśla się również, że inwestorzy indywidualni często reagują na informacje medialne w sposób emocjonalny, co może zwiększać zmienność rynku i prowadzić do okresowych odchyleń cen od wartości ekonomicznej.

Niniejszy artykuł wpisuje się w nurt badań nad efektywnością informacyjną rynków spekulacyjnych. Rynek bitcoina został potraktowany jako szczególny przypadek rynku, na którym można obserwować presję medialną kwantyfikowaną jako potencjalne źródło ryzyka inwestycyjnego.

3. Hipotezy badawcze

Na podstawie przeglądu literatury sformułowano następujące hipotezy badawcze:

H1**.** Presja medialna (BMPI) poprzedza okresy podwyższonej anomalii i ryzyka na rynku bitcoina, w szczególności wzrost skali (wartości bezwzględnej) nienormalnych stóp zwrotu, a nie kierunek przyszłych zmian ceny.

H2**.** Związek pomiędzy presją medialną a skalą anomalii cenowych zależy od fazy rynku i jest słabszy w okresach konsolidacji.

H3. W epizodach spekulacyjnych identyfikowanych przez przekroczenie progu wysokiej presji medialnej (BMPI ≥ BMPI_thr, tj. 70. percentyl próby uczącej ≈ 0,53) presja medialna stanowi istotny komponent obserwowanych anomalii cenowych na rynku bitcoina.

H4. BMPI dostarcza informację unikatową względem benchmarku CFGI (Crypto Fear and Greed Index).

4. Dane i metodyka

4.1. Źródła danych

Dane rynkowe bitcoina (cena, kapitalizacja rynkowa oraz wolumen obrotu z częstotliwością dzienną, 2013–2026) pozyskano z serwisu CoinGecko. Zmienne makroekonomiczne kontrolne obejmują indeks NASDAQ Composite, indeks szerokiego dolara amerykańskiego (DTWEXBGS, FRED) oraz ceny złota.

Dane GDELT GKG 2.0 pozyskano z globalnej bazy Global Knowledge Graph projektu GDELT. Główna specyfikacja wykorzystuje preset zrównoważony (słowa kluczowe: „bitcoin", „btc") i obejmuje 3800 obserwacji dziennych w okresie od 1 października 2015 r. do 1 maja 2026 r.

GDELT GKG 2.0 zapewnia ustrukturyzowane, wielojęzyczne dane opisujące globalny krajobraz medialny (Leetaru, Schrodt 2013). Dane pozyskano z publicznych plików GDELT GKG 2.0 dostępnych w repozytorium Google BigQuery oraz z plików dziennych w formacie TSV kompresowanym ZIP (aktualizowane co 15 minut). Do analizy wykorzystano następujące pola rekordu GKG: V2GCAM (Global Content Analysis Measures) – w szczególności wymiary tonu (*tone*) i intensywności przekazu – oraz V2COUNTS (liczba wzmianek powiązanych ze słowami kluczowymi). Selekcja artykułów opierała się na filtrze słów kluczowych („bitcoin", „btc") stosowanym do pola V2THEMES i V2PERSONS. Dzięki niezależności od danych cenowych baza ta umożliwia ilościową ocenę aktywności medialnej oraz identyfikację kanału informacyjnego jako potencjalnego źródła ryzyka inwestycyjnego.

4.2. Konstrukcja BMPI

BMPI jest dziennym wskaźnikiem złożonym opartym na liczbie wzmianek (M_t) oraz przeciętnym tonie publikacji (T_t) pochodzących z bazy GDELT GKG 2.0. Oba sygnały są normalizowane metodą z-score z wykorzystaniem rozszerzającego się okna (*expanding window*) opartego wyłącznie na danych historycznych poprzedzających dany dzień, co eliminuje ryzyko *look-ahead bias*.

$$BMPI_t = \sigma\left(0{,}60z_{M,t} + 0{,}40z_{T,t}\right) \tag{1}$$

gdzie:

$\sigma(x) = \dfrac{1}{1+\exp(-x)}$ – funkcja logistyczna (sigmoid),

M – dzienna liczba wzmianek medialnych z bazy GDELT GKG 2.0,

T_t – przeciętny ton dobowy publikacji,

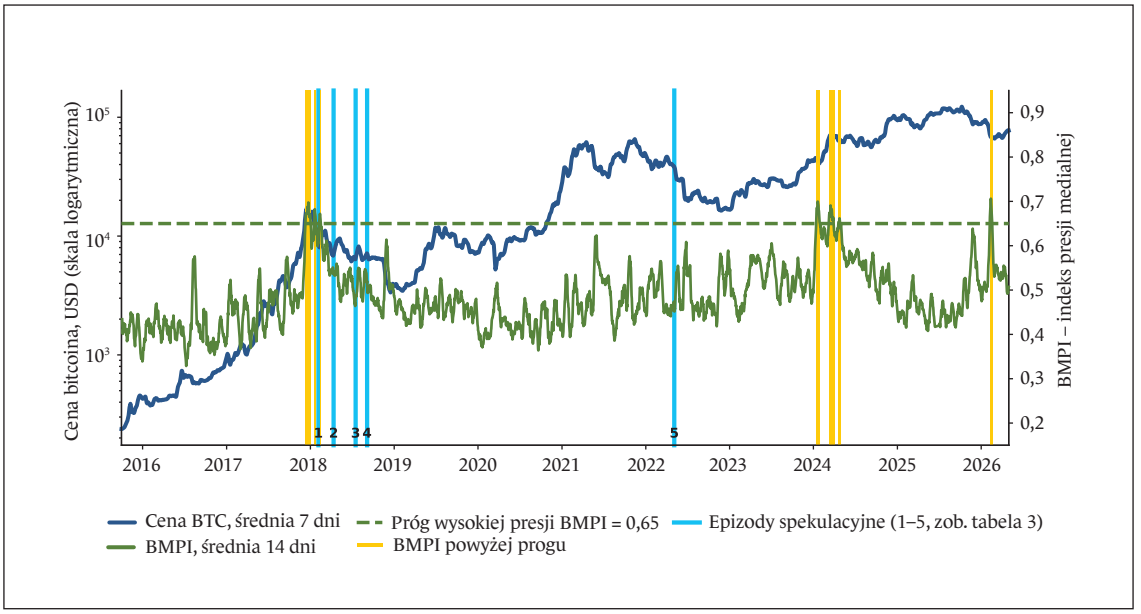
$z(M, t)$, $z(T, t)$ – wartości znormalizowane metodą z-score w rozszerzającym się oknie historycznym, estymowanym wyłącznie na danych dostępnych przed dniem t.

Wagi 0,60 dla liczby wzmianek oraz 0,40 dla tonu zostały wyznaczone na próbie uczącej obejmującej okres do 31 grudnia 2021 r. Kalibracja polegała na wyborze kombinacji wag minimalizującej błąd predykcji skumulowanej nienormalnej stopy zwrotu w oknie zdarzenia, przy ograniczeniu $w_M + w_T = 1$. Wyższa waga liczby wzmianek odzwierciedla większą stabilność tego sygnału względem tonu publikacji.

Parametry normalizacji, kalibracji wag oraz próg wysokiego ryzyka medialnego zostały wyznaczone wyłącznie na próbie uczącej. Ocena skuteczności BMPI została przeprowadzona na niezależnej próbie testowej poza próbą (OOS) obejmującej lata 2022–2026. Próg wysokiego ryzyka medialnego zdefiniowano jako 70. percentyl rozkładu BMPI w próbie uczącej (BMPI_thr ≈ 0,53).

Wykres 1

Dynamika BMPI oraz ceny bitcoina w latach 2015–2026



Uwaga: epizody oznaczone numerami odpowiadają zdarzeniom z tabeli 3: 1 – 05.02.2018; 2 – 12.04.2018; 3 – 17.07.2018; 4 – 05.09.2018; 5 – 05.05.2022.

Źródło: obliczenia własne na podstawie danych GDELT GKG 2.0 oraz danych dla rynku bitcoina.

4.3. Model bazowy i efekt medialny

Izolowanie nadmiarowego efektu medialnego przebiega dwuetapowo. Na pierwszym etapie logarytmiczne stopy zwrotu bitcoina są poddawane analizie regresji na zmiennych kontrolnych modelu bazowego obejmujących indeks NASDAQ Composite, indeks dolara amerykańskiego (DXY) oraz ceny złota, a także na komponentach sezonowych. Model bazowy osiąga współczynnik dopasowania $R^2 = 0{,}428$. Reszty modelu reprezentują część zmian cen niewyjaśnioną przez uwzględnione czynniki rynkowe.

Na drugim etapie zastosowano regresję grzbietową (*ridge regression*) z parametrem regularyzacji λ = 10,0 oraz pięciokrotną walidacją TimeSeriesSplit w celu ograniczenia problemu współliniowości między zmiennymi medialnymi. Model odwzorowuje sygnały GDELT na reszty modelu bazowego i dostarcza dzienną estymację nadmiarowego efektu medialnego (excess_media_effect_usd).

Szczyty cenowe są identyfikowane metodą kroczącego z-score (okno 30 dni, próg 1,5σ, minimalna przerwa pomiędzy zdarzeniami 14 dni), co prowadzi do identyfikacji 29 epizodów spekulacyjnych poddanych dalszej analizie.

4.4. Analiza bootstrap i walidacja OOS

Dla wszystkich kluczowych statystyk konstruowane są 95-procentowe bootstrapowe przedziały ufności (2000 replikacji), co pozwala ocenić stabilność i odporność uzyskanych wyników. Walidacja poza próbą (*out-of-sample*, OOS) obejmuje: (1) podział próby na część uczącą i testową według granicy 01.01.2022, (2) analizę kroczących okien o długości 365 + 30 dni (114 okien) oraz (3) odrębną analizę reżimową dla faz hossy, bessy i konsolidacji.

5. Wyniki

5.1. Medialny kanał ryzyka spekulacyjnego – analiza główna

Tabela 1 przedstawia bootstrapowe przedziały ufności dla skumulowanych nienormalnych stóp zwrotu (CAR [0; +7]) w zidentyfikowanych zdarzeniach medialnych. Wyniki wskazują, że zarówno dodatnie, jak i ujemne epizody medialne są związane z istotnymi statystycznie odchyleniami cen od wartości oczekiwanych. Wąskie przedziały ufności oraz zgodność wyników pomiędzy testem t-Studenta, testem Wilcoxona i testem znaków wskazują na wysoką stabilność uzyskanych rezultatów.

Tabela 1

Bootstrapowe przedziały ufności dla skumulowanych nienormalnych stóp zwrotu CAR [0; +7] (5000 replikacji bootstrapowych, CI = 95%)

Typ zdarzenia	N	Średni CAR [0; +7]	Przedział 95% CI
Pozytywne zdarzenia medialne	182	4,86%	[3,32%; 6,46%]
Negatywne zdarzenia medialne	262	-4,87%	[-5,88%; -3,91%]

Uwagi: wszystkie wyniki pozostają istotne statystycznie według testu t-Studenta, testu Wilcoxona oraz testu znaków ($p < 0,001$).

Źródło: obliczenia własne.

5.2. Przyczynowość Grangera – test H1

Wyniki testów Grangera dostarczają częściowego wsparcia hipotezy H1. Najsilniejsze zależności zaobserwowano nie w przypadku kierunku przyszłych zmian cen, lecz skali przyszłych odchyleń cen od wartości oczekiwanych (abs_abnormal_logret).

W szczególności wskaźnik presji medialnej (media_pressure_score) poprzedza przyszłe anomalie cenowe mierzone wartością bezwzględną abnormalnych stóp zwrotu ($F = 15{,}60$; $p < 0{,}001$ dla opóźnienia 1). Podobny efekt zaobserwowano dla wolumenu medialnego (*mentions*), który również istotnie poprzedza wzrost przyszłej anomalii cenowej ($F = 12{,}25$; $p < 0{,}001$ dla opóźnienia 1).

Jednocześnie zależności dotyczące kierunku przyszłych zmian cen (abnormal_logret) okazały się znacznie słabsze i mniej stabilne. Oznacza to, że aktywność medialna dostarcza więcej informacji o przyszłym poziomie ryzyka i niestabilności rynku niż o kierunku przyszłych ruchów cenowych.

Uzyskane wyniki sugerują, że kanał medialny pełni przede wszystkim funkcję wskaźnika ryzyka spekulacyjnego. Wzrost intensywności przekazów medialnych poprzedza okresy podwyższonej zmienności i większych odchyleń cen od wartości oczekiwanych, co ma duże znaczenie z punktu widzenia ochrony inwestorów indywidualnych.

5.3. Analiza reżimowa – test H2

Tabela 2 dokumentuje korelację BMPI z efektem spekulacyjnym w rozbiciu na reżimy rynkowe i okresy. Wyniki potwierdzają hipotezę H2 z wyraźną asymetrią reżimową.

Tabela 2

Korelacja presji medialnej z bezwzględną skalą anomalii cenowych według reżimu rynkowego

Reżim	N (ucz.)	r (ucz.)	sig	N (OOS)	r (OOS)	sig
Hossa (bull)	859	0,339	***	470	0,151	**
Bessa (bear)	498	0,314	***	410	0,175	***
Flat (konsol.)	184	0,177	*	195	0,121	n.s.

Uwagi:
*** $p < 0{,}001$; ** $p < 0{,}01$; * $p < 0{,}05$; n.s. – nieistotne.
Zmienna zależna: bezwzględna wartość nienormalnej stopy zwrotu (abs_abnormal_logret).
Podział TRAIN/OOS: 01.01.2022.
Reżimy: krocząca 30-dniowa średnia logarytmiczna stopy zwrotu.

Źródło: obliczenia własne.

Szczególnie interesujące jest utrzymanie dodatniej zależności pomiędzy presją medialną a skalą anomalii cenowych zarówno w próbie uczącej, jak i w walidacji *out-of-sample*. W okresach bessy korelacja pozostaje istotna statystycznie w obu podpróbach (TRAIN: $r = 0{,}314$; $p < 0{,}001$; OOS: $r = 0{,}175$; $p < 0{,}001$), co świadczy o względnej stabilności badanego zjawiska w czasie.

Dodatkowo test Kołmogorowa-Smirnowa wskazuje na istotną zmianę rozkładu BMPI pomiędzy okresem TRAIN i OOS ($p < 0{,}001$). Średnia wartość BMPI wzrosła z 0,462 do 0,518 ($\Delta = 0{,}056$), co sugeruje zwiększenie intensywności presji informacyjnej na rynku bitcoina w analizowanym okresie. Wynik ten jest zgodny z interpretacją BMPI jako wskaźnika ryzyka informacyjnego i spekulacyjnego.

5.4. Zdarzenia szczytowej presji medialnej – test H3

Tabela 3 przedstawia pięć zdarzeń o najwyższym poziomie ryzyka medialnego zidentyfikowanych w aktualnym *pipeline* badawczym. Zdarzenia te charakteryzują się wysokimi wartościami BMPI oraz znacznymi skumulowanymi nienormalnymi stopami zwrotu, co wskazuje na współwystępowanie intensywnej aktywności medialnej i ponadprzeciętnej niestabilności rynku.

Tabela 3
Pięć zdarzeń o najwyższym ryzyku medialnym jako epizody podwyższonego ryzyka spekulacyjnego (2015–2026)

Zdarzenie	Data	BMPI	CAR [0; +7] (%)	Kontekst
BTC_SENSITIVE_NEGATIVE_EVT_0090	05.05.2022	0,470	-19,2	Początek krachu Terra/LUNA
BTC_SENSITIVE_POSITIVE_EVT_0036	17.07.2018	0,596	16,9	BlackRock + Mastercard + short squeeze
BTC_SENSITIVE_NEGATIVE_EVT_0032	05.02.2018	0,788	25,8	Historyczne dno kryptozimy
BTC_SENSITIVE_POSITIVE_EVT_0033	12.04.2018	0,635	11,6	Przełamanie konsolidacji
BTC_SENSITIVE_NEGATIVE_EVT_0039	05.09.2018	0,592	-12,3	Goldman Sachs – fałszywa informacja

Uwagi:
CAR [0; +7] oznacza skumulowaną nienormalną stopę zwrotu od dnia zdarzenia do siedmiu dni po zdarzeniu. BMPI oznacza poziom presji medialnej oszacowany na podstawie danych GDELT GKG 2.0.

Źródło: obliczenia własne.

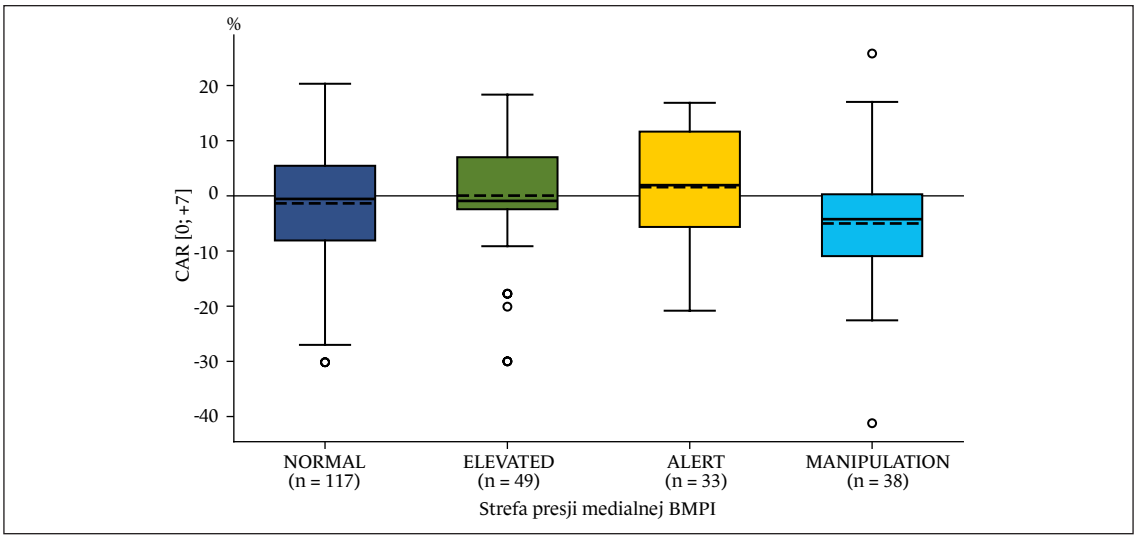
Wykres 2 wskazuje, że rozkład CAR różni się pomiędzy strefami presji medialnej BMPI. Szczególnie interesujące jest przejście od strefy ALERT do strefy MANIPULATION, gdy mediana CAR zmienia znak z dodatniego na ujemny. Wynik ten sugeruje występowanie efektu przegrzania informacyjnego rynku.

Wykres 3 przedstawia średnią ścieżkę skumulowanych nienormalnych stóp zwrotu wokół zdarzeń medialnych. W dniu zdarzenia ($t = 0$) obserwowany jest wyraźny spadek średniego CAR, który utrzymuje się również w kolejnych dniach. Wynik ten wskazuje na podwyższone ryzyko korekty po epizodach wzmożonej presji medialnej i potwierdza interpretację BMPI jako wskaźnika ryzyka spekulacyjnego.

Łącznie wyniki przedstawione w tabeli 3 oraz na wykresach 2 i 3 potwierdzają hipotezę H3. Epizody wysokiej presji medialnej wiążą się ze zmianą rozkładu anomalii cenowych oraz zwiększonym ryzykiem występowania korekt po zdarzeniu. Uzyskane rezultaty wspierają interpretację BMPI jako wskaźnika ryzyka spekulacyjnego oraz przegrzania informacyjnego rynku.

Wykres 2

Rozkład skumulowanych nienormalnych stóp zwrotu CAR [0; +7] według stref presji medialnej BMPI

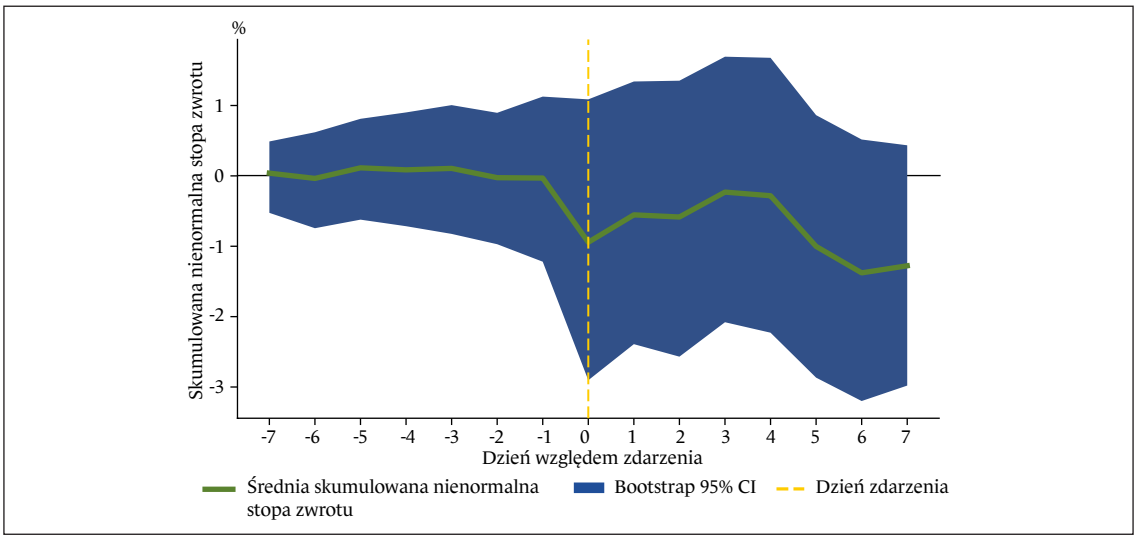


Uwagi:
Linia ciągła oznacza medianę, linia przerywana – średnią.
Strefy BMPI odpowiadają kolejnym poziomom presji medialnej: NORMAL, ELEVATED, ALERT oraz MANIPULATION.

Źródło: obliczenia własne.

Wykres 3

Średnia ścieżka skumulowanych nienormalnych stóp zwrotu (CAR) w oknie zdarzenia [-7; +7]



Źródło: obliczenia własne.

5.5. Porównanie z CFGI – test H4

Korelacja pomiędzy BMPI a Crypto Fear & Greed Index (CFGI) jest bardzo niska ($r = -0{,}092$; $p < 0{,}001$), co wskazuje, że oba wskaźniki opisują odmienne aspekty środowiska informacyjnego rynku bitcoina.

W próbie uczącej model wykorzystujący wyłącznie CFGI osiąga $R^2 = 0{,}0008$ dla skali anomalii cenowych, podczas gdy model oparty wyłącznie na BMPI osiąga $R^2 = 0{,}0801$. Połączenie CFGI i BMPI zwiększa R^2 do 0,0820.

Wyniki wskazują, że BMPI dostarcza informację istotnie różniącą się od zawartej w CFGI i ma znacznie większą zdolność wyjaśniania obserwowanych anomalii cenowych. Otrzymane rezultaty wspierają hipotezę H4.

6. Dyskusja i implikacje

6.1. Mechanizm ryzyka medialnego

Wyniki badania wskazują na istnienie spójnego kanału ryzyka informacyjnego na rynku bitcoina. Intensywność przekazów medialnych systematycznie poprzedza wzrost skali anomalii cenowych oraz epizody podwyższonej aktywności spekulacyjnej. Jednocześnie uzyskane rezultaty sugerują, że wpływ mediów realizuje się przede wszystkim przez zwiększenie zmienności i odchyleń cen od wartości oczekiwanych, a nie przez bezpośrednie oddziaływanie na długookresowy poziom ceny aktywów.

Zaobserwowana asymetria reżimowa wskazuje, że znaczenie presji medialnej zależy od warunków rynkowych. W próbie uczącej najsilniejsze zależności występowały w okresach hossy, natomiast w analizie *out-of-sample* (2022–2026) istotne zależności pojawiły się również w fazach bessy. Może to świadczyć o zmianach strukturalnych zachodzących na rynku bitcoina wraz ze wzrostem jego dojrzałości, rozwojem infrastruktury inwestycyjnej oraz zwiększaniem udziału inwestorów instytucjonalnych.

Uzyskane wyniki sugerują, że presja medialna może być traktowana jako odrębne źródło ryzyka informacyjnego, które powinno być uwzględniane w procesie oceny ryzyka inwestycyjnego oraz ochrony inwestorów indywidualnych.

6.2. Implikacje dla ochrony inwestorów

Wyniki mają też duże znaczenie dla ochrony inwestorów indywidualnych na rynkach o wysokiej zmienności. Analiza wykazała, że okresy podwyższonej presji medialnej współwystępują ze wzrostem skali anomalii cenowych oraz podwyższonym ryzykiem występowania gwałtownych zmian cen. Oznacza to, że decyzje inwestycyjne podejmowane wyłącznie na podstawie intensywnych przekazów medialnych mogą się wiązać z podwyższonym poziomem ryzyka.

Mediana bezwzględnego udziału komponentu medialnego w analizowanych epizodach BTC wynosi 43%, co wskazuje, że środowisko informacyjne istotnie wpływa na obserwowane anomalie cenowe. Dodatkowe analizy bootstrapowe potwierdzają stabilność tego efektu.

Z perspektywy instytucji finansowych oraz organów nadzoru uzyskane rezultaty wskazują na potencjalną użyteczność wskaźników opartych na danych medialnych, takich jak BMPI, jako narzędzi

wspomagających ocenę ryzyka informacyjnego. Rozwiązania tego typu mogą stanowić uzupełnienie tradycyjnych miar ryzyka rynkowego, szczególnie na rynkach podatnych na silne reakcje informacyjne i zachowania spekulacyjne.

6.3. Implikacje dla efektywności informacyjnej

Uzyskane wyniki są zgodne z hipotezą ograniczonej efektywności informacyjnej rynku bitcoina. Testy przyczynowości Grangera wskazują, że intensywne przekazy medialne poprzedzają wzrost skali anomalii cenowych, podczas gdy zależność odwrotna nie została potwierdzona. Oznacza to, że kanał informacyjny może dostarczać informacji o przyszłych odchyleniach cen od wartości oczekiwanych, co trudno pogodzić z silną formą efektywności rynku.

Szczególnie ważny jest fakt utrzymywania się istotności statystycznej dla kilku opóźnień czasowych, co sugeruje występowanie opóźnień w procesie absorpcji informacji przez uczestników rynku. Wyniki te są zgodne z wcześniejszą literaturą dotyczącą rynków kryptowalut, wskazującą na większą podatność tych rynków na wpływ narracji medialnych oraz zachowań inwestorów.

Otrzymane rezultaty nie oznaczają możliwości systematycznego prognozowania poziomu ceny bitcoina, lecz wskazują, że środowisko informacyjne może wpływać na skalę przyszłych anomalii cenowych i poziom ryzyka rynkowego.

6.4. Ograniczenia

Przy interpretacji wyników należy uwzględnić kilka ograniczeń badania. Po pierwsze, dane GDELT charakteryzują się nierównomiernym pokryciem geograficznym i językowym, co może prowadzić do większej reprezentacji źródeł anglojęzycznych względem innych regionów świata. Po drugie, zastosowana metodyka pozwala identyfikować związki między presją medialną a anomaliami cenowymi, jednak nie umożliwia bezpośredniego rozróżnienia pomiędzy naturalnym procesem rozpowszechniania informacji a celowymi manipulacjami uczestników rynku. Po trzecie, model bazowy wykorzystany do wyznaczania anomalii cenowych opiera się na ograniczonym zestawie zmiennych makroekonomicznych i nie uwzględnia wszystkich potencjalnych czynników wpływających na rynek kryptowalut.

Dodatkowo badanie koncentruje się wyłącznie na rynku bitcoina, który stanowi szczególny przypadek aktywów o wysokiej zmienności i silnej ekspozycji na oddziaływanie mediów. W związku z tym możliwość uogólnienia wyników na inne klasy aktywów wymaga dalszej weryfikacji empirycznej.

6.5. Ryzyko kwantowe jako przyszły szok informacyjny

Odrębną kategorię ryzyka przyszłościowego, istotną z punktu widzenia logiki niniejszego badania, może stanowić przełom w dziedzinie obliczeń kwantowych. Bitcoin opiera swoje bezpieczeństwo na kryptografii krzywych eliptycznych (ECDSA) stosowanej do podpisów transakcji, a w mniejszym stopniu na funkcjach haszujących SHA-256, zabezpieczających mechanizm *proof-of-work*. Algorytm Shora, działający na wystarczająco dużym komputerze kwantowym, mógłby teoretycznie zagrozić prywatnym

kluczom portfeli opartych na ECDSA. Choć pełnoskalowy komputer kwantowy zdolny do złamania kryptografii stosowanej przez bitcoina pozostaje dziś poza zasięgiem technologicznym, sam medialny przekaz o wiarygodnym przełomie kwantowym mógłby uruchomić mechanizm ryzyka informacyjnego analogiczny do opisanego w niniejszym artykule.

Scenariusz ten wpisuje się bezpośrednio w logikę BMPI: gwałtowny wzrost liczby wzmianek medialnych o zagrożeniu kwantowym, nawet gdyby nie był jeszcze technicznie uzasadniony, mógłby doprowadzić do podwyższenia wartości BMPI powyżej progu wysokiej presji medialnej, a także do odpływu kapitału z giełd i portfeli, wzrostu zmienności oraz erozji zaufania inwestorów indywidualnych do długookresowego bezpieczeństwa aktywów kryptograficznych. Jednocześnie ekosystem kryptowalut aktywnie pracuje nad rozwiązaniami post-quantum, co stanowi potencjalny czynnik łagodzący. Wątek ten należy traktować jako scenariusz ryzyka przyszłościowego, a nie jako bieżącą podstawę do prognozowania ceny bitcoina.

7. Wnioski

Badanie wskazuje, że aktywność medialna stanowi istotny element środowiska informacyjnego rynku bitcoina. Testy przyczynowości Grangera sugerują, że wzrost presji medialnej statystycznie wyprzedza pojawianie się anomalii cenowych, podczas gdy zależność odwrotna nie została potwierdzona. Wynik ten jest zgodny z hipotezą istnienia kanału ryzyka informacyjnego na rynku kryptowalut.

Wpływ mediów nie jest jednak stały. Analiza reżimowa wykazała, że zależności pomiędzy BMPI a anomaliami cenowymi zmieniają się wraz ze zmianą fazy rynku. Najsilniejsze efekty obserwowano w okresach hossy, natomiast analiza *out-of-sample* wskazuje, że w części okresów bessy presja medialna również pozostaje istotnym elementem otoczenia rynkowego.

Wyniki pokazują również, że BMPI dostarcza informacji odmiennych niż Crypto Fear & Greed Index. Niska korelacja pomiędzy tymi wskaźnikami oraz wyższa zdolność BMPI do wyjaśniania anomalii cenowych sugerują, że oba mierniki opisują różne aspekty zachowania rynku.

Z perspektywy praktycznej dane medialne mogą stanowić wartościowe uzupełnienie tradycyjnych miar ryzyka finansowego. Wskaźniki oparte na analizie środowiska informacyjnego mogą wspierać identyfikację okresów podwyższonego ryzyka na rynkach o wysokiej zmienności i silnej podatności na narracje medialne. Uzyskane wyniki nie oznaczają możliwości systematycznego prognozowania poziomu ceny bitcoina, wskazują jednak, że kanał informacyjny odgrywa istotną rolę w kształtowaniu skali anomalii cenowych oraz ryzyka inwestycyjnego.

Bibliografia

Bollen J., Mao H., Zeng X. (2011), Twitter mood predicts the stock market, *Journal of Computational Science*, 2(1), 1–8, DOI: 10.1016/j.jocs.2010.12.007.

Ciaian P., Rajcaniova M., Kancs d'A. (2016), The economics of Bitcoin price formation, *Applied Economics*, 48(19), 1799–1815, DOI: 10.1080/00036846.2015.1109038.

Da Z., Engelberg J., Gao P. (2015), The sum of all FEARS: investor sentiment and asset prices, *Review of Financial Studies*, 28(1), 1–32, DOI: 10.1093/rfs/hhu072.

Elshendy M., Colladon A.F., Battistoni E., Gloor P.A. (2018), Using four different online media sources to forecast the crude oil price, *Journal of Information Science*, 44(3), 408–421, DOI: 10.1177/0165551517698298.

Fama E.F. (1970), Efficient capital markets: a review of theory and empirical work, *Journal of Finance*, 25(2), 383–417, DOI: 10.2307/1912108.

Fang J., Peress J. (2009), Media coverage and the cross-section of stock returns, *Journal of Finance*, 64(5), 2023–2052, DOI: 10.1111/j.1540-6261.2009.01493.x.

Garcia D., Tessone C.J., Mavrodiev P., Perony N. (2014), The digital traces of bubbles: feedback cycles between socio-economic signals in the bitcoin economy, *Journal of the Royal Society Interface*, 11(99), 20140623, DOI: 10.1098/rsif.2014.0623.

Hamrick J.T., Rouhi F., Mukherjee A., Feder A., Gandal N., Moore T., Vasek M. (2021), An empirical analysis of cryptocurrency pump-and-dump schemes, *Information Economics and Policy*, 54, 100880, DOI: 10.1016/j.infoecopol.2020.100880.

Kristoufek L. (2013), BitCoin meets Google Trends and Wikipedia: quantifying the relationship between phenomena of the Internet era, *Scientific Reports*, 3(1), 3415, DOI: 10.1038/srep03415.

Leetaru K., Schrodt P.A. (2013), GDELT: global data on events, location and tone, 1979–2012, *ISA Annual Convention*, 2(4), 1–49.

Li T., Shin D., Wang B. (2021), *Cryptocurrency pump-and-dump schemes*, SSRN Working Paper, 3267041, DOI: 10.2139/ssrn.3267041.

Phillips R., Gorse D. (2018), Cryptocurrency price drivers: wavelet coherence analysis revisited, *PLoS ONE*, 13(4), e0195200, DOI: 10.1371/journal.pone.0195200.

Tetlock P.C. (2007), Giving content to investor sentiment: the role of media in the stock market, *The Journal of Finance*, 62(3), 1139–1168, DOI: 10.1111/j.1540-6261.2007.01232.x.

Podziękowania

Autor dziękuje projektowi GDELT za otwarty dostęp do danych GKG 2.0. Badanie nie otrzymało zewnętrznego finansowania.

Konflikt interesów

Autor deklaruje brak konfliktu interesów.

Wykorzystanie narzędzi AI

Podczas przygotowywania niniejszego artykułu autor korzystał z narzędzi AI (modele językowe Claude firmy Anthropic oraz ChatGPT firmy OpenAI) w zakresie: (1) wspomagania redakcji i korekty językowej tekstu, (2) generowania fragmentów kodu Python służącego do przetwarzania i analizy danych, (3) wspomagania przeglądu literatury. Wszystkie wyniki analityczne, interpretacje oraz wnioski zostały samodzielnie zweryfikowane przez autora. Autor ponosi pełną odpowiedzialność za treść artykułu, w tym za fragmenty przygotowane przy wsparciu narzędziami AI.

The impact of media on high-volatility markets: risks for investors based on the example of Bitcoin

Abstract

Cryptocurrency markets, and Bitcoin in particular, are characterised by extreme price volatility, speculative dynamics, and a structural absence of traditional fundamental anchors such as earnings or dividends. A growing body of empirical literature documents that media activity and investor attention – measured through newspaper sentiment, social media tone, or search engine queries – have a significant influence on short-term price dynamics in financial markets (Tetlock 2007; Da, Engelberg, Gao 2015). On cryptocurrency markets, where informational feedback loops are amplified and institutional stabilisers are weaker, media-driven risk may constitute a distinct and measurable source of investment risk (Kristoufek 2013; Phillips, Gorse 2018). Despite this, the existing literature lacks a systematic, daily-frequency index of media pressure for Bitcoin that is constructed exclusively from global news data and validated out-of-sample as a risk indicator. The present article addresses this gap.

The central research question is: can media pressure be treated as a measurable source of risk on the Bitcoin market? In particular, the article investigates whether an increase in media intensity Granger-causes a subsequent increase in the scale (absolute value) of abnormal returns, whether this relationship is regime-dependent, and whether a media-based index provides information content beyond the widely used Crypto Fear and Greed Index (CFGI).

Four hypotheses are tested. H1: media pressure (BMPI) Granger-causes periods of elevated price anomaly and risk on the Bitcoin market – specifically the scale, not the direction, of future abnormal returns. H2: the relationship between media pressure and the magnitude of price anomalies is regime--dependent and weaker during market consolidation. H3: in speculative episodes identified by BMPI exceeding the high-pressure threshold (70^{th} percentile of the training sample, ≈ 0.53), media pressure constitutes a significant component of observed price anomalies. H4: BMPI contributes unique information relative to the CFGI benchmark.

The Bitcoin Media Pressure Index (BMPI) is constructed as a daily composite indicator based on two signals extracted from GDELT Global Knowledge Graph 2.0: the standardised daily mention count (z_{M, t}) and the standardised average tone (z_{T, t}), both normalised via expanding-window z-score to eliminate look-ahead bias. The index is defined as $BMPI_t = \sigma\left(0.60 z_{M,t} + 0.40 z_{T,t}\right)$, where σ denotes the logistic function; weights were calibrated on the training sample (2015–2021). Abnormal returns are estimated via a two-stage procedure: a market model baseline ($R^2 = 0.428$; controls: NASDAQ, DXY, gold) isolates the residual, and a ridge regression (λ = 10.0, TimeSeriesSplit CV) maps GDELT signals onto the residual. The sample covers 3,800 daily observations from October 2015 to May 2026. Out-of-sample validation uses a hard split at 01-01-2022; 95% confidence intervals are obtained via block bootstrap (2,000 replications). Granger causality tests, regime analysis (bull/bear/flat), placebo comparisons, and multiple-testing corrections (Bonferroni, Benjamini-Hochberg) are applied throughout.

Granger causality tests confirm H1: the media pressure score significantly Granger-causes the absolute abnormal return ($F = 15.60$; $p < 0.001$, lag 1), while the reverse relationship is not significant. Regime analysis (H2) shows that the correlation between BMPI and absolute abnormal returns is

strongest in the bull market (training: $r = 0.339$, $p < 0.001$; OOS: $r = 0.151$, $p < 0.01$) and significant in bear markets (training: $r = 0.314$; OOS: $r = 0.175$, both $p < 0.001$), but not significant in consolidation periods. Event-study results (H3) demonstrate statistically significant cumulative abnormal returns: positive media events yield mean CAR [0; +7] = +4.86% (95% CI: [3.32%; 6.46%]), negative events yield -4.87% ([-5.88%; -3.91%]). The median absolute media effect share in identified episodes is 43%. H4 is supported: correlation between BMPI and CFGI equals -0.092 ($p < 0.001$); BMPI alone explains $R^2 = 0.0801$ of abnormal return variance versus $R^2 = 0.0008$ for CFGI alone.

The findings support the interpretation of BMPI as a measurable information risk indicator on the Bitcoin market. Media pressure is associated with elevated price anomalies and speculative episode risk, while its predictive value for price direction is limited. BMPI should be understood as a risk and volatility indicator rather than a directional price forecast tool. Media-based indices of this type may complement traditional risk measures, particularly on markets characterised by high sensitivity to informational narratives. The article also identifies an emerging scenario risk: a credible quantum computing breakthrough could trigger a media-driven shock consistent with the BMPI mechanism, independently of the technical maturity of the threat.

The study has several limitations. First, GDELT coverage is uneven across languages and regions, with a potential over-representation of English-language sources. Second, the methodology identifies statistical associations between media pressure and price anomalies but cannot directly distinguish organic information diffusion from coordinated manipulation. Third, the baseline model relies on a limited set of macro controls and may not capture all drivers of Bitcoin price dynamics. Finally, the results are specific to Bitcoin and their generalisability to other asset classes requires further empirical verification.

Keywords: Bitcoin, BMPI, media pressure, speculative risk, investor protection, background