

Grzegorz Bulczak*

Zastosowanie Google Trends w prognozowaniu zmian na rynku nieruchomości

Wstęp

Rządy, ekonomiści, inwestorzy i media z zainteresowaniem obserwują publikacje okresowych danych ekonomicznych. Publikacje te są dostępne z opóźnieniem, dane za dany miesiąc są publikowane w połowie następnego miesiąca i są zazwyczaj uaktualniane kilka miesięcy później. Znaczną korzyścią byłaby obserwacja tych danych wcześniej lub w czasie rzeczywistym. Przykładami firm, które udostępniają dane odzwierciedlające w przybliżeniu zmiany w aktywności gospodarczej, są: Google, MasterCard i UPS.

W artykule badana będzie przydatność danych z Google Trends (GT) w analizie zmian na rynku nieruchomości w Wielkiej Brytanii. GT jest źródłem danych na temat ilości zapytań związanych z wybranym wyszukiwanym zagadnieniem, np. ilości zapytań 'sprzedaż/kupno nieruchomości' w danym tygodniu miesiąca. Przypuszczalnie wybrane zapytanie może być skorelowane z poziomem aktywności gospodarczej w danym okresie. Prawdopodobne jest, że zapytania wpisywane w wyszukiwarki mogą być użytecznymi wskaźnikami wyprzedzającymi decyzje konsumenckie, szczególnie w sytuacjach, w których konsumenci zaczynają planowanie zakupów znacznie wcześniej przed dokonaniem zakupu.

Można sądzić, że aktywność użytkowników Internetu w danym punkcie w czasie odzwierciedla zbiorowe zachowania, ukazując zainteresowania, obawy i intencje obserwowanej populacji. Z tego punktu widzenia można wysunąć przypuszczenie, że to czego użytkownicy Internetu szukają dzisiaj, jest skorelowane z tym, co będą robić w najbliższej przyszłości. Konsumenci, rozważając zakup nowego samochodu, mogą użyć wyszukiwarek, aby dokonać porównania modeli. Potencjalni widzowie mogą sprawdzić datę premiery filmu zanim wybiorą się do kina. Osoby planujące urlop mogą szukać informacji odnośnie do interesujących miejsc, cen biletów lotniczych lub pokoi hotelowych.

* Dr, Katedra Inwestycji i Nieruchomości, Wydział Zarządzania, Uniwersytet Gdański
ul. Armii Krajowej 101, 81-824 Sopot, grzegorz.bulczak@ug.edu.pl

Celem artykułu jest przedstawienie możliwych zastosowań GT w analizie zmian aktywności gospodarczej na przykładzie rynku nieruchomości w Wielkiej Brytanii, ze szczególnym uwzględnieniem strony popytowej. Zamiarem autora nie jest stworzenie zaawansowanego modelu ekonometrycznego, a raczej wskazanie możliwości i dalszych aplikacji analizy zawartej w tym artykule. Studiowanie rynku nieruchomości jest szczególnie ważne w obliczu niedawnego kryzysu na rynku nieruchomości, spowolnienia gospodarczego USA i reszty świata. Artykuł ten będzie wkładem do badań z zakresu nanoekonomii, czyli podejmowania indywidualnych decyzji o zakupie lub sprzedaży [Arrow, 1987].

1. Przegląd literatury

Wiele dotychczasowych badań sugeruje istotność informacji pochodzących z wyszukiwarek internetowych w przewidywaniu aktywności gospodarczej i zachowań konsumentów [Cooper i inni, 2005; Ettredge i inni, 2005; Choi, Varian, 2012]. Goel i inni [2010] oferują przegląd badań w zakresie badań epidemiologicznych, makroekonomicznych szeregów czasowych oraz aktywności konsumentów związanej z filmami, muzyką i gramami wideo. W powyższym badaniu autorzy analizują korzyści i słabe strony danych z wyszukiwarek internetowych. Znaczna część badań zwraca szczególną uwagę na prognozowanie stanu obecnego danego zjawiska, np. epidemii grypy [Polgreen i inni, 2008] lub wskaźników makroekonomicznych [Castle i inni, 2009]. Przydatność danych z wyszukiwarek badali Askitas i Zimmermann [2010] w kontekście bezrobocia w USA. Natomiast Guzman [2011] sprawdzał ich użyteczność w prognozowaniu inflacji.

Cooper i inni [2005] pokazali, że wyszukiwanie informacji na temat nowotworów w latach 2001–2003 skorelowane było z ich szacunkowym występowaniem. Eysenbach [2006] wykrył wysoką korelację pomiędzy ilością kliknięć sponsorowanych wyników wyszukiwania słów kluczowych dotyczących grypy i danych epidemiologicznych w Kanadzie. Podobne wyniki uzyskali Hulth i inni [2009] w Szwecji.

Choi i Varian [2012] podkreślają, że prognozowanie stanu obecnego jest szczególnie istotne dla banków centralnych i innych agencji rządowych. W powyższym badaniu użyli oni liczby wyszukiwań do poprawy precyzji prognozowania aktywności gospodarczej, w tym sprzedaży samochodów, turystyki i zasiłków dla bezrobotnych w USA. Przydatność danych Google do analizy rynku nieruchomości w Wielkiej Brytanii sugerują również inne badania z USA [Wu i inni, 2010]. W roku 2012 w USA 90% kupujących domy korzystało z Internetu, aby sprawdzić informacje

związane z zakupem [NAR, 2012]. Podobnie raport przygotowany przez Stowarzyszenie Pośredników w Obrocie Nieruchomościami w Kalifornii informuje, że w 2008 roku 63% nabywców domów szukało agenta nieruchomości za pomocą wyszukiwarki internetowej [Appleton-Young, 2008].

Analiza z użyciem danych z wyszukiwarek nawiązuje do szeregu ciekawych problemów badawczych z zakresu ekonometrii obejmujących takie zagadnienia, jak wybór zmiennych oraz korekty danych. Ostatni kryzys w USA wykazał, że żaden z modeli nie był w stanie przewidzieć problemów na rynku nieruchomości i całej gospodarce [Krugman, 2009]. Problemy te według Simon [1984] wynikają z różnorodnych technik wydobycia informacji z danych obarczonych dużym poziomem szumu oraz błędu pomiarowego. Powyższe problemy nauka społeczna może przezwyciężyć dzięki narzędziom do obserwacji analizowanych zjawisk w wyższej rozdzielczości. Literatura zaprezentowana powyżej wskazuje na znaczącą użyteczność danych z zapytań z wyszukiwarek internetowych w prognozowaniu zjawisk ekonomicznych. Zaprezentowany przegląd badań sugeruje, że również na znacznie mniejszym rynku nieruchomości w Wielkiej Brytanii dane z GT przyczynią się do poprawy precyzji predykcji. Główne czynniki mogące wpłynąć na różnice w wynikach estymacji to: różne poziomy popularności wyszukiwarki Google oraz różnice językowe pomiędzy USA i Wielką Brytanią.

2. Dane i metody


Firma Google udostępnia publicznie od 2004 roku dane dotyczące wskaźników popularności haseł wpisywanych w narzędzie wyszukiwania. Dane te umożliwiają obserwowanie zmian popularności wybranych haseł w czasie. Indeksy zapytań przyjmujące wartości od 0 do 100 mierzą popularność danego słowa lub frazy globalnie, w państwach oraz regionach. Wybrany indeks mierzy udział zapytań, który jest liczony jako udział dla danego zapytania w danej lokalizacji geograficznej podzielony przez całkowitą liczbę zapytań w tym regionie w danym momencie. Większość zapytań powstających w Internecie w USA (67%) i w Wielkiej Brytanii (91%) odbywa się poprzez Google [comScore, 2012].

W badaniu użyte zostaną również dane z The Land Registry House Price Index (HPI). Indeks ten ukazuje zmiany w wartościach cen nieruchomości mieszkaniowych w Wielkiej Brytanii. Indeks został stworzony na podstawie transakcji przeprowadzanych na rynku nieruchomości mieszkaniowych w Anglii oraz Walii. Informuje on o zmianach na rynku w kraju, jak i w poszczególnych regionach. W skład HPI wchodzi również

liczba zawartych transakcji w danym miesiącu (*sales volume*). Dane z HPI uwzględniają sezonowe wahania cen domów.


Poniżej zaprezentowane są wykresy indeksu cen HPI (rysunek 1) oraz średnie roczne zmiany zapytań GT *'house for sale'* (dom na sprzedaż), (rysunek 2) dla lat 2004–2014. HPI osiągnął maksimum w roku 2008. Ilość zapytań *'house for sale'* wpisywanych w wyszukiwarkę Google osiągnęła lokalne maksimum w roku 2007. Rysunek 2 wskazuje, że od roku 2008 popularność tego zapytania rosła z roku na rok.

Rysunek 1. Indeks cen nieruchomości w Wielkiej Brytanii, HPI



Źródło: [The Land Registry House Price Index, 2014].

Rysunek 2. Zapytanie GT: *'house for sale'*



Źródło: [Google Trends, 2014].

Pierwszym punktem analizy będzie model podstawowy autoregresywny (AR) AR-1, w którym sprzedaż domów (sales vol) (y_t) zależna będzie od przeszłej sprzedaży (y_{t-1}) oraz wahań sezonowych S_t ,

$$y_t = b_1 y_{t-1} + \Sigma S_t + e_t \quad (1a)$$

Okres analizy obejmuje miesiące od stycznia 2004 do lutego 2014.

Analogicznie dla modelu HPI, HPI (y_t) zależny będzie od przeszłej wartości indeksu (y_{t-1}). Wahania sezonowe uwzględnione są w HPI.

$$y_t = b_1 y_{t-1} + e_t \quad (1b)$$

oraz

$$y_t = b_1 y_{t-1} + b_2 SV_{t-1} + e_t \quad (1.1b)$$

Modele 1a oraz 1b posłużą jako punkt odniesienia do modeli alternatywnych, w których wykorzystane zostaną dane z GT:

$$y_t = b_1 y_{t-1} + b_2 GT_t + b_3 GT_{t-1} + \Sigma S_t + e_t \quad (2a \text{ i } 2b)$$

Modele alternatywne zostaną również wzbogacone o zmiany indeksu cen w poprzednim okresie (HPI_{t-1}), gdzie y_t to ilość sprzedaży:

$$y_t = b_1 y_{t-1} + b_2 GT_t + b_3 GT_{t-1} + b_4 HPI_{t-1} + \Sigma S_t + e_t \quad (3a)$$

Analogicznie, zmiany ilości sprzedaży w poprzednim okresie (SV_{t-1}), gdzie y_t to HPI_t :

$$y_t = b_1 y_{t-1} + b_2 GT_t + b_3 GT_{t-1} + b_4 SV_{t-1} + e_t \quad (3b)$$

oraz dla alternatywnego zapytania GT ('house for sale'):

$$y_t = b_1 y_{t-1} + b_2 GT_t + b_3 GT_{t-1} + b_4 SV_{t-1} + e_t \quad (3.1b)$$

Opierając się na wynikach z poprzednich badań na rynku nieruchomości w USA, GT dla wybranych wyszukiwań związanych z podejmowaniem decyzji inwestycyjnych będzie w sposób istotny wpływał na poprawę precyzji predykcji modeli alternatywnych. Po wstępnej analizie korelacji oraz wyników poprzednich badań w modelach zostaną użyte następujące zapytania: 'rentals' (wynajem), 'house for sale' (dom na sprzedaż) i 'mortgage' (kredyt hipoteczny). Od wyników z poprzednich badań możliwe są jednak odchylenia ze względu na różnice językowe oraz wielkość i różną specyfikę rynków nieruchomości USA i Wielkiej Brytanii. Dodatkowo w modelach, gdzie $y_t = HPI_t$, mogą wystąpić trudności z oddzieleniem sił podaźowych i popytowych związanych z wyszukiwaniem danego zapytania, przykładem może być słowo 'rentals'.

3. Estymacja

Tablica 1 przedstawia wyniki estymacji dla modeli 1a, 2a oraz 3a. Model bazowy (1a) wyjaśnia 86% zmienności w ilości sprzedaży y_t . Model pokazuje, że liczba transakcji w danym miesiącu jest silnie zależna od transakcji wykonanych w miesiącu poprzednim ($t-1$). W modelu 2a uwzględniony został indeks wyszukiwań słowa 'rentals' w GT. Wyniki sugerują, że indeks zapytań o wynajem wpływa negatywnie na ilość sprzedaży w tym samym okresie. W analizowanym okresie jednoprocentowy wzrost zapytań o wynajem powiązany był ze spadkiem liczby transakcji o 389 (0,5% średniej liczby transakcji w analizowanym okresie). W modelu 3a do zmiennych z modelu 2a dodana została zmienna HPI_{t-1} (indeks cen z przeszłego miesiąca). Wyniki sugerują negatywną zależność pomiędzy indeksem cen w poprzednim okresie a liczbą transakcji oraz niewielką zmianę w poziomie istotności współczynnika GT.

Tablica 1. Estymacja ilości sprzedaży (sales vol)

	sales_vol ¹	p-val ²	sales_vol	p-val	sales_vol	p-val
Model	1a		2a		3a	
Sales_vol_t-1	0,94	<0,001	1,038	<0,001	1,0634	<0,001
Rentals _t			-389,088	0,0003	-449,816	0,0001
HPI t-1					-136,201	0,0223
Z. Kontrolne	sezonowe		sezonowe		sezonowe	
Skorygowany R-kwadrat	0,865		0,879		0,884	

¹ Kolumna sales vol (ilość sprzedaży) zawiera współczynniki estymacji.

² Kolumna p-val (p-values) informuje o istotności danego współczynnika, p-val wskazują poziomy istotności, p-val= 0,10, 0,05 i 0,01 odpowiadają następujące przedziały ufności: 90%, 95% i 99%.

Źródło: Opracowanie własne.

Następnym krokiem w analizie jest zbadanie użyteczności danych z GT w modelowaniu indeksu cen (HPI). Analogicznie do poprzednich badań [Wu i inni, 2010; Choi i Varian, 2012] wyniki modelu 1b wskazują silną zależność pomiędzy HPI_t i HPI_{t-1} (tablica 2). Model 1.1b jest modyfikacją modelu podstawowego. W modelu tym dodana jest zmienna SV_{t-1} (ilość sprzedanych domów w poprzednim okresie). Model alternatywny (2b) wzbogacony jest o dane z GT. Zmienną mierzącą zmiany ilości zapytań GT jest 'mortgage' (kredyt hipoteczny). Wyniki modelu wskazują na

statystycznie istotny ujemny wpływ ilości zapytań z okresu $t-2$, oraz dodatni dla $t=0$, na HPI_t . Po dodaniu SV_{t-1} do modelu zapytanie GT przestaje być istotne statystycznie (model 3b). Wynik ten sugeruje ograniczoną użyteczność zapytania 'mortgage' w modelowaniu HPI. Możliwe jest, że następstwa powyższego zapytania są zbyt rozłożone w czasie. Dodatkowo wzrost zapytań 'mortgage' może oznaczać zarówno negatywne, jak i pozytywne sygnały dla rynku nieruchomości (narastające problemy ze spłatą kredytów oraz poszukiwanie źródeł finansowania zakupu). Przymuszczalnie bardziej jednoznaczne zapytanie GT powinno pomóc w otrzymaniu lepszych wyników. W modelu 3.1b zapytanie o kredyt hipoteczny zostało zastąpione zapytaniem o sprzedaż domu. Zapytanie o sprzedaż domu związane jest ze wzrostem HPI w tym samym okresie.

Tablica 2. Estymacja HPI

	HPI ¹	p-val ²	HPI	p-val	HPI	p-val	HPI	p-val	HPI	p-val
Model	1b		1.1b		2b		3b		3.1b	
HPI t-1	0,961	<0,001	0,941	<0,001	0,959	<0,001	0,944	<0,001	0,946	<0,001
SV t-1			0,000	<0,001			0,000	<0,001	0,000	<0,001
Mortgage					0,042	0,001	0,003	0,839		
Mortgage t-2					-0,037	0,011				
House_for_sale									0,047	0,000
R ²	0,978		0,985		0,980		0,985		0,987	

¹ Kolumna sales vol (ilość sprzedaży) zawiera współczynniki estymacji.

² Kolumna p-val (p-values) informuje o istotności danego współczynnika, p-val wskazują poziomy istotności, p-val= 0,10, 0,05 i 0,01 odpowiadają następujące przedziały ufności: 90%, 95% i 99%.

Źródło: Opracowanie własne.

Kolejnym krokiem w analizie jest porównanie wyników prognozowania zmiennej y_t dla modelu bazowego (1b) i alternatywnego (3b). Dane miesięczne z lat 2004–2007 posłużą do tworzenia modeli, na podstawie których zostaną oszacowane prognozy dla miesięcy z lat 2008–2014. Opierając się na wynikach omówionych poprzednio badań, należy oczekiwać, iż modele alternatywne, dzięki danym z GT, pozwolą na prognozowanie z wyższą precyzją. Miarą, która posłuży do porównania precyzji modeli, będzie średni względny błąd prognozy (MAE). Miara ta będzie informowała o przeciętnych odchyleniach prognoz od wartości rzeczywistych.

$$\text{MAE} = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (5)$$

Tablica 3 zawiera MAE obliczone dla wybranych modeli.

Tablica 3. MAE wybranych modeli


Predykcja od	MAE	MAE	%
Modele	1.1b	3.1b	
2008	1,64	1,53	0,93
2007	1,54	1,42	0,92
Modele	1.1b	3.b	
2008	1,64	1,61	0,97
Modele	1.b	1.b+GT	
2008	1,8	1,67	0,92

Źródło: Opracowanie własne.

Zgodnie z wcześniejszymi oczekiwaniami wyniki zawarte w tablicy 3 pokazują, iż predykcje z modeli wykorzystujących dane GT są bardziej precyzyjne. Błąd prognozy w przypadku modelu bazowego 1.1b wynosił 1,65%, a dla modelu alternatywnego 1,52%. W przypadku modelu alternatywnego MAE był o 7,5% niższy. Poprawa precyzji modeli alternatywnych oscyluje w przedziale 2,5% – 8% w zależności od doboru zapytań oraz początkowej daty predykcji (2007 lub 2008). Procentowa różnica MAE między modelem 1.b a 1.1b wynosi 8%. Wynik ten pokazuje, że dane z GT poprawiają precyzję predykcji HPI w podobnym stopniu jak dane dotyczące ilości sprzedaży z okresu poprzedniego. Poprzednie badania nad użytecznością GT dla rynku nieruchomości w USA informują o wzroście precyzji estymacji od 2,3% [Wu i inni, 2008] do 12% [Choi, Varian, 2012]. Wu i inni osiągają najwyższą poprawę równą 7,1% w precyzji dla zapytania *'real estate agencies'*, natomiast Choi i Varian, 12%, dla zapytania *'Rental Listings & Referrals'*.

Rysunek 3 pokazuje różnice pomiędzy wartościami prognozowanymi a rzeczywistymi dla modelu bazowego (1.1b) oraz modelu GT (3b). Różnice między precyzją predykcji modeli 1.1b i 3b dla lat 2008–2009 są niewielkie. Rozbieżności narastają w okresach zmian trendu, przykładem jest pierwsza połowa roku 2009 oraz druga połowa roku 2010.

Rysunek 3. Predykcja HPI



Źródło: Opracowanie własne.

Zakończenie

Wyniki przeprowadzonego badania potwierdzają istotny wpływ danych z GT na poprawę precyzji w estymacji zmian HPI dla lat 2004–2014 w Wielkiej Brytanii. Precyzja prognoz modeli alternatywnych jest przeciętnie wyższa o 8%, wynik ten jest zbliżony do poprzednich badań na rynku nieruchomości w USA. Prawdopodobnie różnice między badaniami tego typu wynikają z doboru różnych zapytań GT, które według autorów mają poprzedzać decyzje inwestycyjne. Poprawa precyzji predykcji w znacznym stopniu zależy od odpowiedniego dobrania zapytań. Co więcej, możliwe jest, że dane zapytanie będzie wspomagać prognozowanie tylko w danym okresie.

Dane GT są interesującą alternatywą dla innych źródeł danych, których kolekcja jest czasochłonna i kosztowna. Zaletą wykorzystania zapytań z wyszukiwarek internetowych jest szybkość i dostępność. Dodatkowo dane GT dostarczają aktualnych informacji o zmianach w wyszukiwaniach w krajach, regionach i miastach. Szczegółowość danych GT pozwala na dobranie zapytań, które będą związane z danym zjawiskiem, np. popytem na dany produkt.

Powyższa analiza otwiera ścieżki do dalszych badań nad aplikacją danych z GT dla innych rynków i krajów. Przydatność danych GT powinna znaleźć potwierdzenie w przyszłych badaniach analizujących sku-

teczność kampanii reklamowych. Dzięki wysokiej rozdzielczości danych GT pozwala na śledzenie tygodniowych zmian popularności zapytań. Szczególne zastosowanie GT w prognozowaniu powinno dotyczyć państw, w których dane dotyczące aktualnego stanu gospodarki publikowane są ze znacznym opóźnieniem, lub też tam, gdzie ich wiarygodność jest niska.

Literatura

1. Appleton-Young L. (2008), *State of the California housing market 2008–2009*. Technical report, California Association of Realtors.
2. Arrow K. (1987), *Arrow and the foundations of the theory of economic policy, Reflections on the essays*, New York University.
3. Askitas N., Zimmermann K.F. (2010), *Google Econometrics and Unemployment Forecasting*, Technical Report, SSRN 899.
4. Castle J.L., Fawcett N.W.P., Hendry D.F. (2009), *Nowcasting is not Just Contemporaneous Forecasting*, „National Institute Economic Review”.
5. Choi H., Varian H. (2012), *Predicting the Present with Google Trends*, „Economic Record”, Vol. 88.
6. ComScore (2012), *qSearch: A comprehensive view of the search landscape*. Technical report, comScore.
7. Cooper C., Mallon K., Leadbetter S., Pollack L., Peipins L. (2005), *Cancer Internet Search Activity on a Major Search Engine, United States 2001–200*, „Journal of Medical Internet Research”.
8. Ettredge M., Gerdes J., Karuga G. (2005), *Using Web-based Search Data to Predict Macroeconomic Statistics*, „Communications of the ACM”, Vol. 48, No. 11.
9. Eysenbach G. (2006), *Infodemiology: Tracking flu-related searches on the Web for syndromic surveillance*, „American Medical Informatics Association Annual Symposium Proceedings”, Curran Associates, Red Hook, NY.
10. Goel S., Hofman J.M., Lahaie S., Pennock D.M., Watts D.J. (2010), *Predicting Consumer Behavior with Web Search*, „Proceedings of the National Academy of Sciences”, Vol. 7, No. 41.
11. Google Trends, www.google.pl/trends.
12. Guzman G. (2011), *Internet Search Behavior as an Economic Forecasting Tool: The Case of Inflation Expectations*, „The Journal of Economic and Social Measurement”, Vol. 36, No. 3.

13. Hulth A., Rydevik G., Linde A. (2009), *Web Queries as a Source for Syndromic Surveillance*, „PLoS ONE”, No. 4.
14. Krugman P. (2009), *How did economists get it so wrong?* „New York Times Magazine” z dnia 09.02.
15. NAR Research Staff (2012), *Profile of home buyers and sellers 2012*. Technical report, National Association of Realtors.
16. Polgreen P.M., Chen Y., Pennock D.M., Nelson F.D. (2008), *Using Internet Searches for Influenza Surveillance*, „Clinical Infectious Diseases”, No. 47.
17. Simon H. A. (1984), *On the behavioral and rational foundations of economic dynamics*, „Journal of Economic Behavior and Organization”, Vol. 5, No. 1.
18. The Land Registry, www.landregistry.data.gov.uk.
19. Wu L., Waber B., Aral S., Brynjolfsson E., Pentland A. S. (2008), *Mining face-to-face interaction networks using sociometric badges: Predicting productivity in an IT configuration task*. „ICIS 2008 Proceedings”.

Użyte skróty

- AR – Autoregresja
- GT – Google Trends
- HPI – House Prices Index
- MAE – średni względny błąd prognozy
- Sales vol – ilość sprzedaży

Streszczenie

Decyzje inwestycyjne poprzedzone są szeregiem działań związanych z uzyskiwaniem i weryfikacją informacji. Poniższe badanie ma na celu zbadanie użyteczności danych pochodzących z wyszukiwarek internetowych pod względem ich przydatności w prognozowaniu zmian na rynku nieruchomości. Dane te mogą być dodatkowym źródłem informacji dla inwestorów, jeśli okaże się, że zawierają ślady poszukiwania informacji w okresie przed podjęciem danej decyzji inwestycyjnej. Przeprowadzona analiza jest istotnym dodatkiem do już istniejącej literatury badającej rolę czynników behawioralnych w procesie podejmowania decyzji. Wyniki tego badania mogą wnieść nowe spojrzenie na zachowanie rynków oraz inwestorów.

Słowa kluczowe

rynek nieruchomości, Google Trends, prognozowanie

Predicting changes in the real estate market with the use of Google Trends (Summary)

Investment decisions are preceded by a range of activities related to obtaining and verification of information. The following study aims to explore the usefulness of the Google search engine data in predicting real estate markets. These data may prove to be an additional source of information for investors if they contain traces of search information in the period before making an investment decision. The analysis is an important addition to the existing literature exploring the role of behavioral factors in the decision making process. The results of this study may shed new light on the behavior of markets and investors.

Keywords

real estate, Google Trends, forecasting